Block E/A

Reinhard Bündgen
buendgen@de.ibm.com

Blockgeräte

- z.B. Platten, CDs/DVD Laufwerke, USB-Sticks, ...
- Kleinste Zugriffseinheit: HW: Sektor (SW: Block)
- Feste Anzahl von Sektoren
- Random Access Zugriff („DASD“)
  - Beliebige Reihenfolge
  - Beliebig oft
  - Lesen und Schreiben beliebig abwechseln
- I.A. langsam
  - Caching von Sektoren im Hauptspeicher: page cache

E/A Konzepte

- Buffer
  - Kopie, von Daten die auf Blockgerät liegen (sollen): „Cache“
- Block E/A Operation
  - Beschreibung einer Datenbewegung zwischen Hauptspeicher (Buffern) und Gerät (Sektoren)
- E/A Anfrage (Request)
  - eine Menge von E/A Operationen deren zusammenhängender Ablauf geplant ist/wird

Block E/A: Begriffe

Platten: Sektoren, Hauptspeicher: Seiten, Dateien: Blöcke

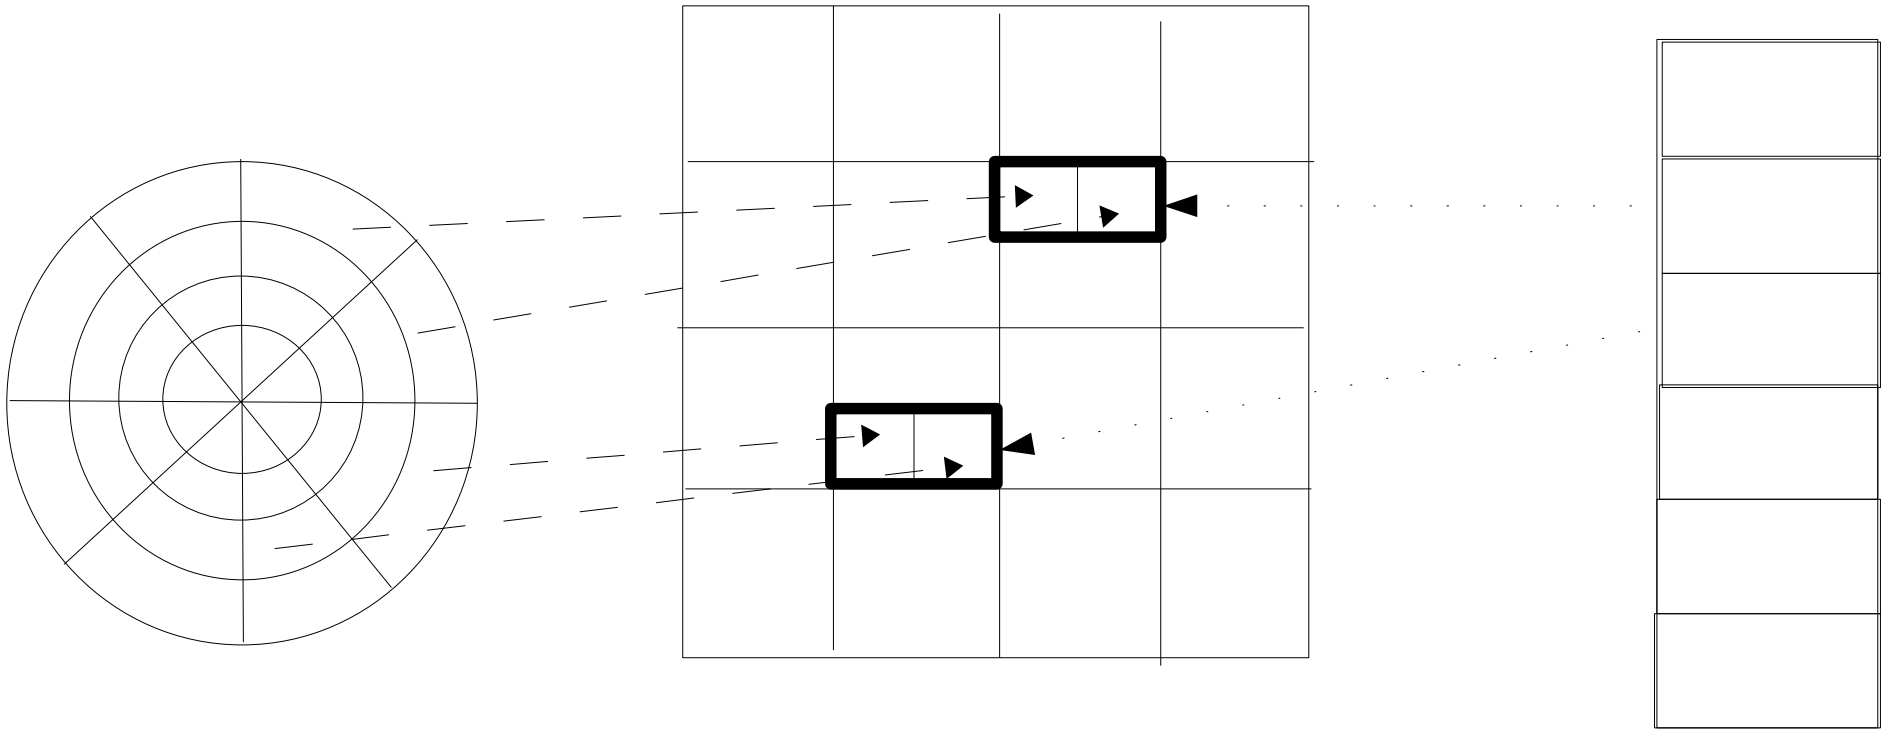

$|Block| = n * |Sektor| = 2^k \ \wedge \ |Block| <= |Seite|$

Puffer (buffers)

- Jeder Sektor wird durch einen buffer repräsentiert
- Buffer head
  - Daten die Buffer beschreiben
  - Typ: `struct buffer_head` in `<linux/buffer_head.h>`
  - Assozeiert Gerät/Sektor mit Seite/Position/Puffergröße
  - Zustand (`b_state` Komponente):
    - `BH_Uptodate` – enthält gültige Daten
    - `BH_Dirty` – Block aktueller als Gerät
    - `BH_Lock` – während E/A
    - `BH_Req` – gehört zu E/A Request
    - `BH_Mapped` – entspricht Daten auf Gerät
    - `BH_New` – neu, noch kein Zugriff
    - `BH_Async_Read` – an asynch read beteiligt
    - `BH_Async_Write` – an asynch write beteiligt
    - `BH_Delay` – hat noch keine entsprechende Sektoren
    - ...

Block E/A Operationen

- Lesen oder Schreiben zusammenhängender Sektoren
- wird durch `bio` Struktur repräsentiert
  - <linux/bio.h>: `struct bio`
    - Position auf Gerät
    - Operation: Lesen oder Schreiben
    - Liste von Segmenten
      - Segment (`struct bio_vec`)
        - Kontinuierlicher Datenbereich (in einer Seite)
    - Zeiger in aktuelles Segment
- Scatter/Gather Liste

Requests

- <linux/blkdev.h>
- Request
  - Beschreibt Zugriff auf zusammenhängende Menge von Sektoren
  - `struct request`
  - Enthält ein oder mehrere bio Strukturen
- Request Queue
  - Beschreibt eine Liste von Requests für ein Gerät
  - `struct request_queue`

E/A Planer (I/O Scheduler)

- E/A ist langsam
  - Insbesondere seek-Operationen
  - Positionierung des Plattenkopfs
  - Dauert mehrere Millisekunden
- Aufgabe:
  - Minimierung von seek-Operationen
- Mittel
  - merging & sorting
- Resultat
  - E/A Planer virtualisiert Platte für mehrere E/A Requests
  - (Leicht) unfair
  - Größerer globaler(!) Durchsatz

Aufzugs Problem

- Betrachte Aufzug im Empire State Buildung
- Ziel
  - fahre eine möglichst geringe Stecke
- Mittel
  - Sortiere die Anfragen
    - Mache in einer Richtung möglichst viele Stops
  - Merge
    - Nehme möglichst viele Personen pro Station mit
- „Lösung“
  - Fahre immer zu nächsten anfragenden Station
- Problem
  - Stockwerke können „verhungern“

Linus Elevator

- Veraltet, aber prototypisch
  - War Standard I/O Scheduler in Linux 2.4
- Sorting:
  - Request queue nach Sektornummer sortiert
- Merging
  - Direkt aneinander anschliessende Requests werden zu einem request vereinigt
  - Front merging & back merging
- Fairness:
  - Falls es zu alte Requests gibt werden neue (nicht merge-bare) requests ans Ende der request queue gehängt

Lese vs Schreibzugriffe

- Lesezugriffe
  - Applikation muss auf Abschluss der Leseoperation warten
  - Oft hängt eine Leseoperation von einer anderen ab
  - Latenz von Leseoperationen beeinflusst Applikations Performanz
- Schreibzugriffe
  - Können asynchron von Applikation abgearbeitet werden
    - Ausnahme sync Funktionen
  - Schreiblatenz beeinflußt Applikationsperformanz nur wenig
  - Regelmäßiges Abspeichern verringert das Risiko von Datenverlusten

Deadline I/O Scheduler (1)

- drivers/block/deadline-iosched.c
- 3 queues:
  - Sorted queue
  - Read FIFO
  - Write FIFO
- Jeder neue Request wird
  - Bzgl der Platten Position ge-merge-t & sortiert in die sorted queue eingefügt und
  - Je nach Zugriffstyp an die Read- oder Write FIFO gehängt
- Jeder Request wir mit einer Expirationszeit markiert
  - Read request default: 500 ms
  - Write request default 5 sec

Deadline I/O Scheduler (2)

- Abarbeiten des nächsten Requests:
  - Bearbeite den nächsten abgelaufenen Request aus den FIFO Queues
  - Wenn keine abgelaufenen Requests vorhanden, bearbeite den nächsten request aus der Sorted Queue
- Front Merging optional
- Achtung
  - Der Deadline Scheduler gibt keine Garantien darüber, dass ein Request vor Expirationszeit durchgeführt wird

Anticipatory I/O Scheduler

- `drivers/block/as-iosched.c`
- DL I/O Scheduler + antizipatorische Heuristik:
  - Nachdem ein Request bearbeitet wird
    - Wird *nicht* der Nächste gesucht,
    - *Sondern* es wird einige ms gewartet, ob nicht ein Request für einen Nachbarsektor abgesetzt wird.
  - Versucht via Statistiken Applikationsverhalten zu erahnen.

Weitere I/O Scheduler

- Complete-Fair-Queuing-I/O Scheduler (CFQ)
  - `drivers/block/cfq-iosched.c`
  - eine queue pro Task
  - Round-Robin: konfigurierbare Anzahl von Requests pro Queue
  - Anwendung: Multimedia – Fairness unter Anwendungen
- Noop-I/O Scheduler
  - `drivers/block/noop-iosched.c`
  - keine Requestsortierung, nur Merging
  - Anwendung: Geräte ohne Suchaufwand (z.B. Flash-Memory Karten)