Betriebssysteme

Kapitel 6: I/O und Storage

6.1: I/O, Disks, SCSI

Stand: WS 10/11

Prof. Dr. Wolfgang Küchlin

Dipl.-Inform., Dr. sc. techn. (ETH)

Arbeitsbereich Symbolisches Rechnen
Wilhelm-Schickard-Institut für Informatik
Fakultät für Informations- und Kognitionswissenschaften

Universität Tübingen

Steinbeis Transferzentrum
Objekt- und Internet-Technologien (OIT)

Wolfgang.Kuechlin@uni-tuebingen.de
http://www-sr.informatik.uni-tuebingen.de

SR 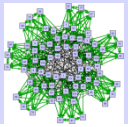

Überblick

Teil 1: I/O und Disks

Teil 2: SCSI

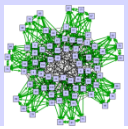

UNIX System V Kern

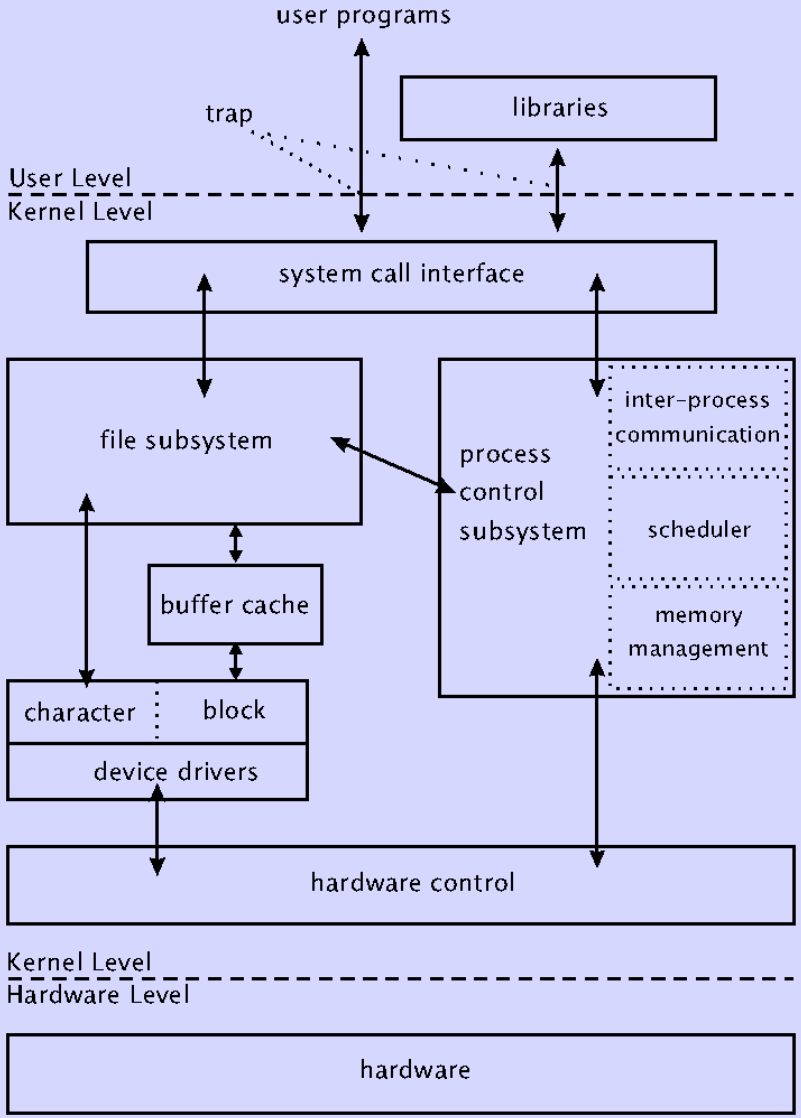

Erinnerung: System-Architektur der Hardware

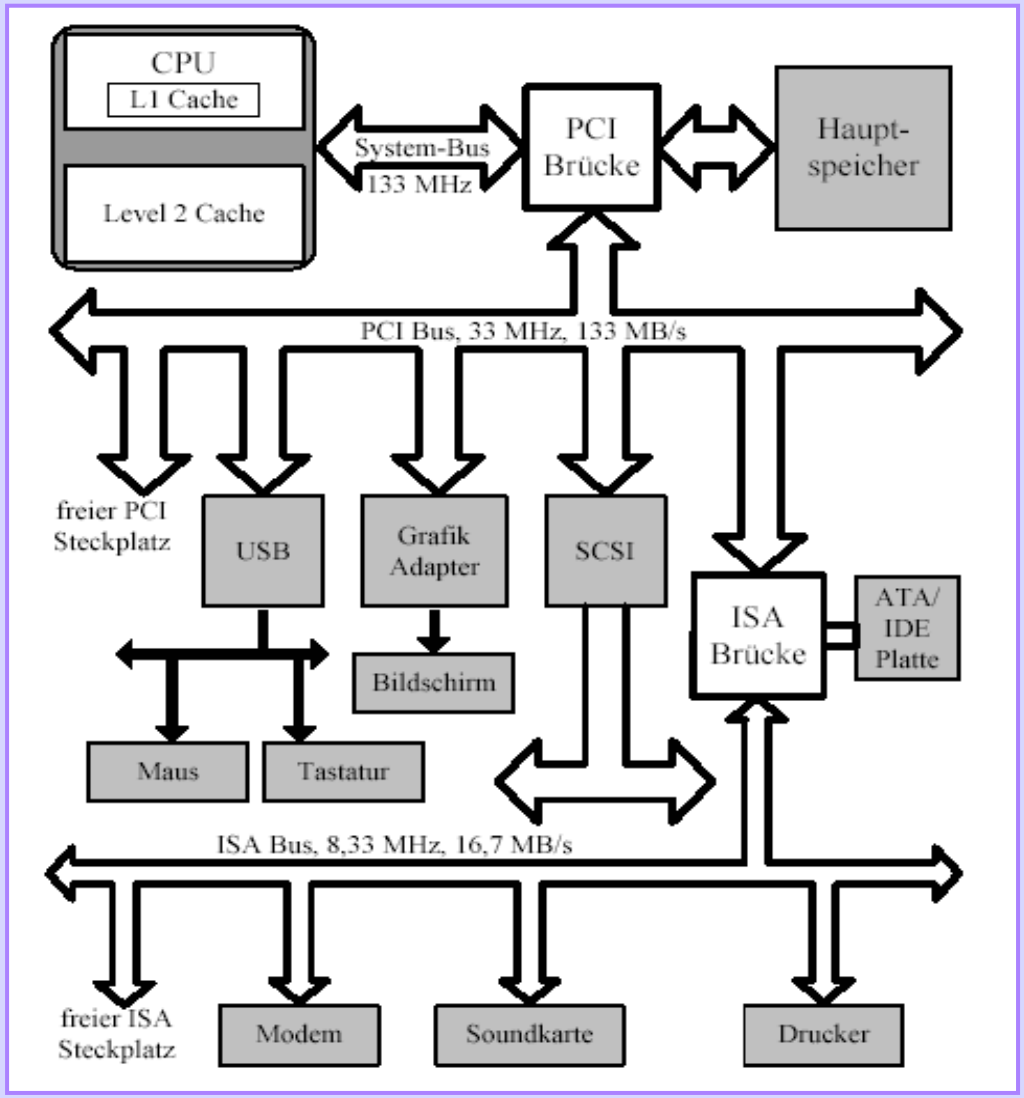

Küchlin, Weber, Abb. 2.3:
„Architektur eines Intel P2 PC Systems mit mehreren Bussen an Brücken“

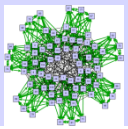

Komponenten eines Plattenlaufwerks

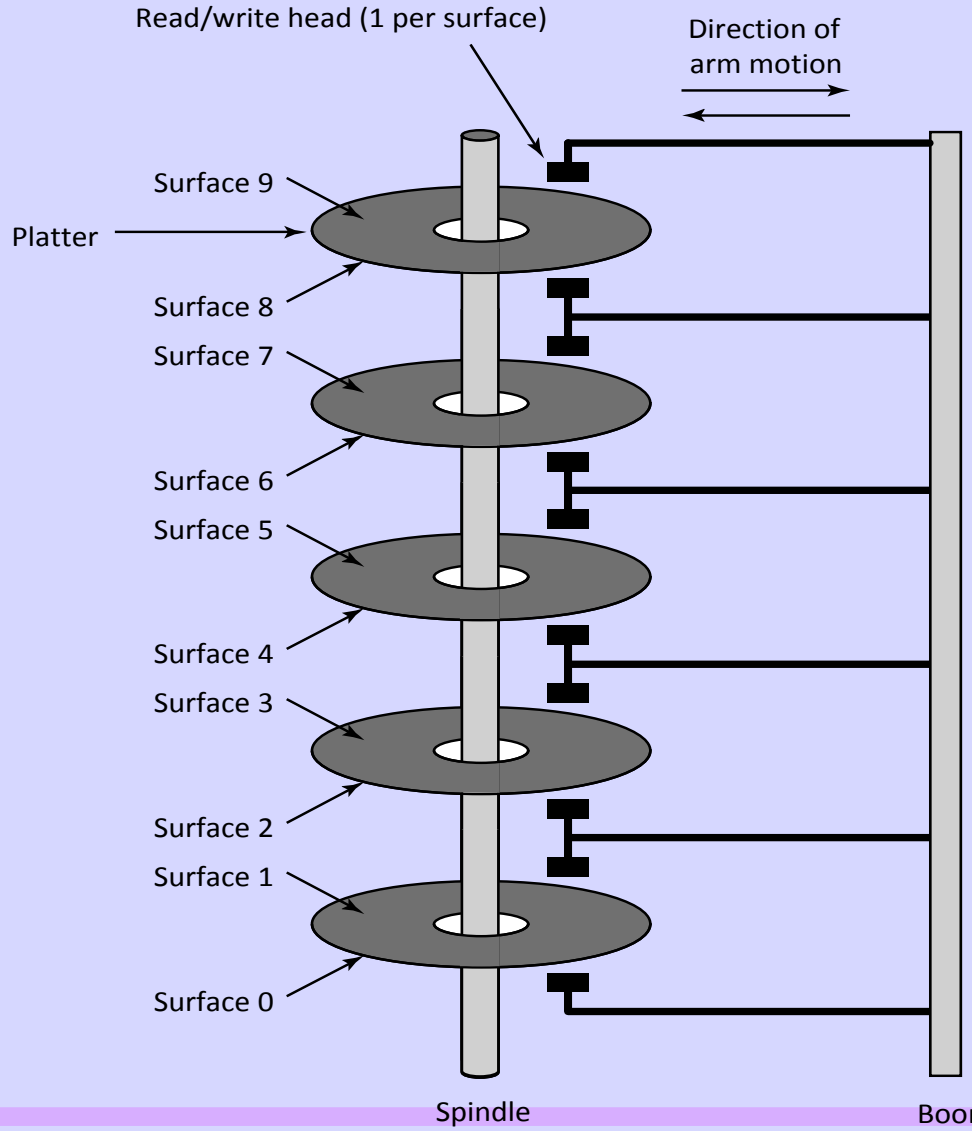

Stallings, Abb.11.18

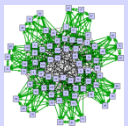

Disk Data Layout

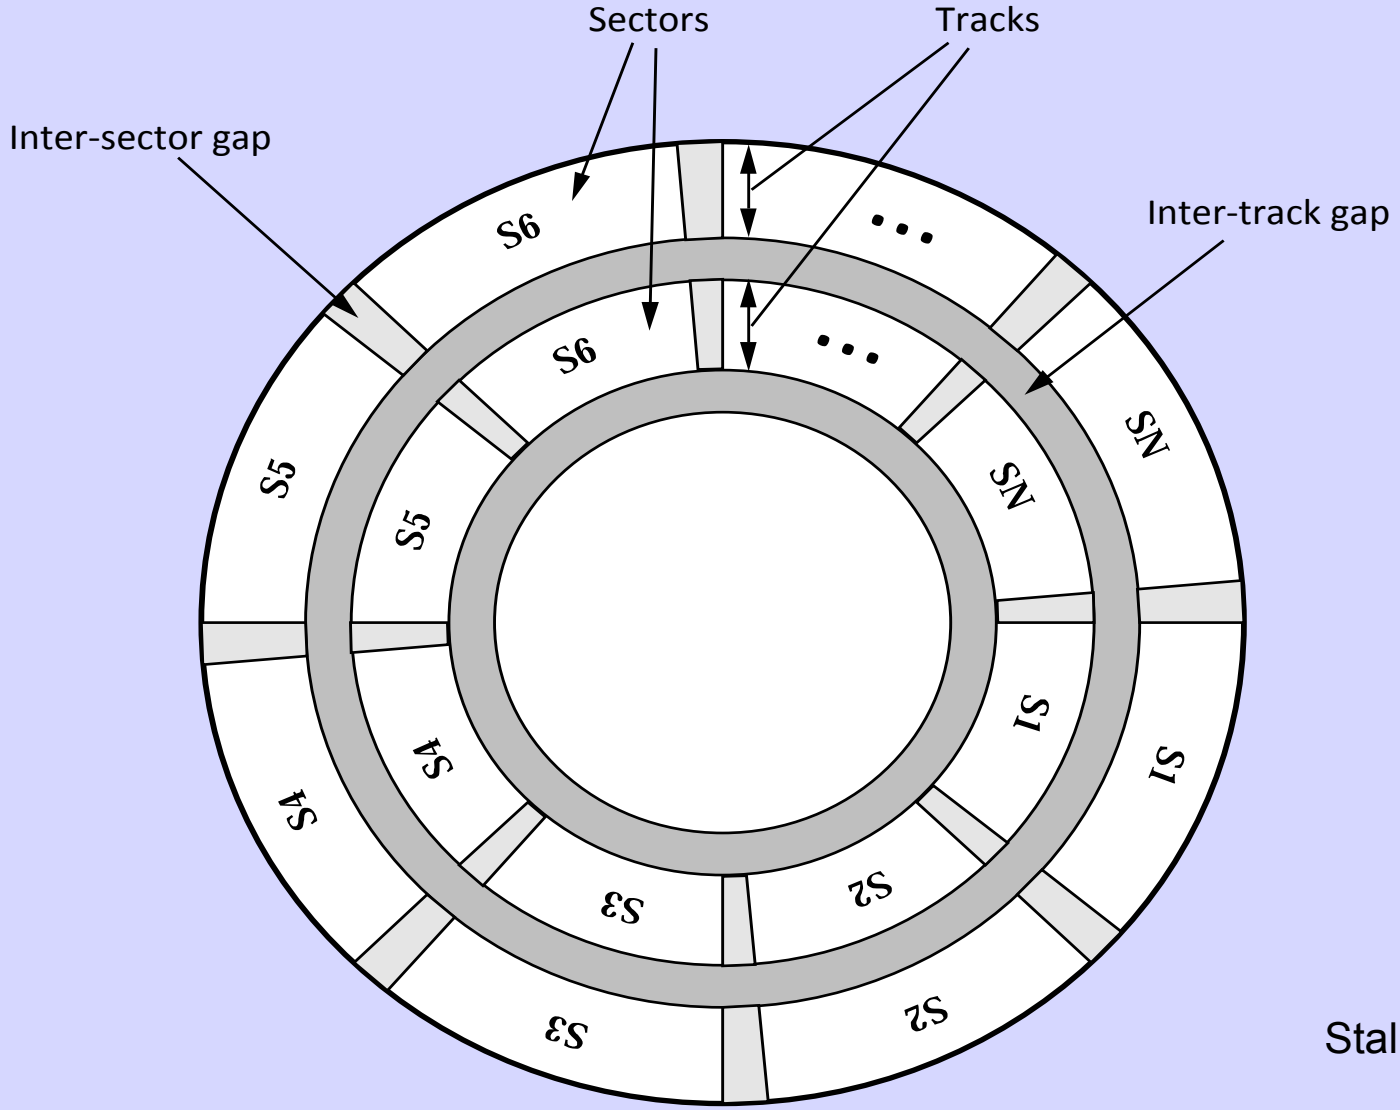

Stallings, Abb.11.16

Disk Data Layout

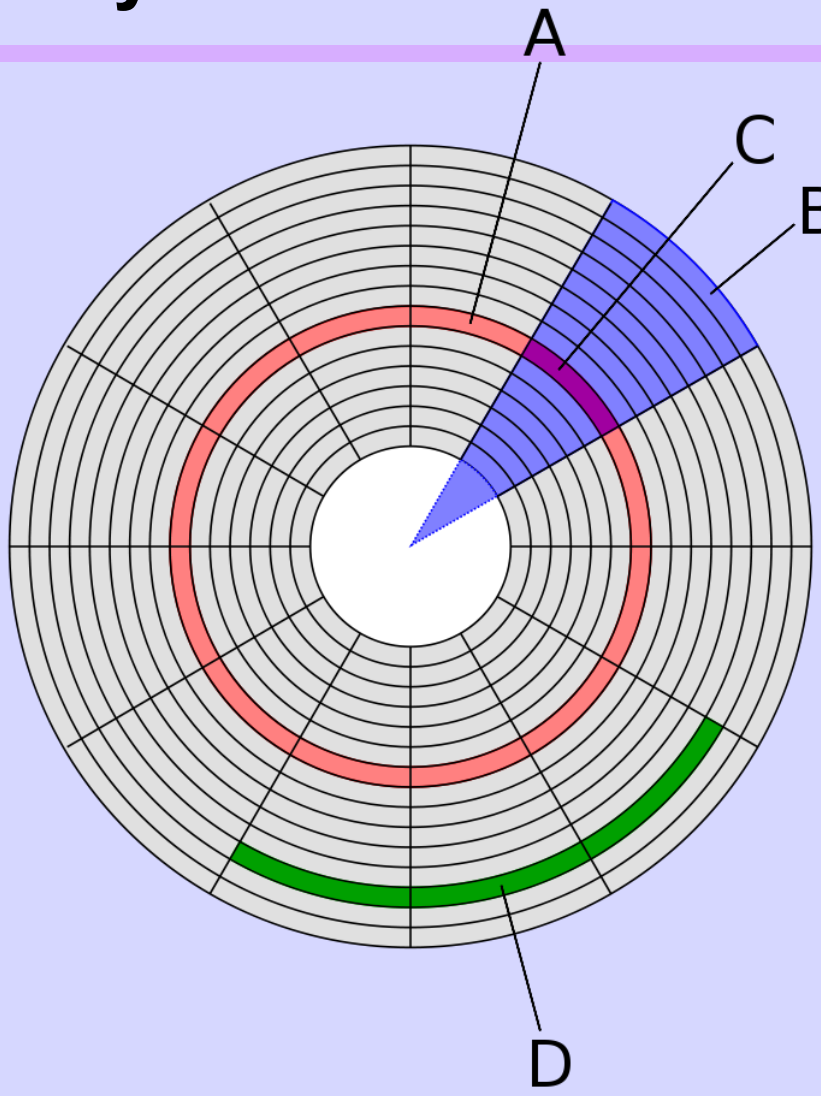

A: Track (Spur)
B: Geometrical Sector
C: Track Sector
D: Cluster (of sectors)

Quelle: Wikipedia

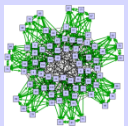

Disk Layout: Classical and Advanced Format Sectors

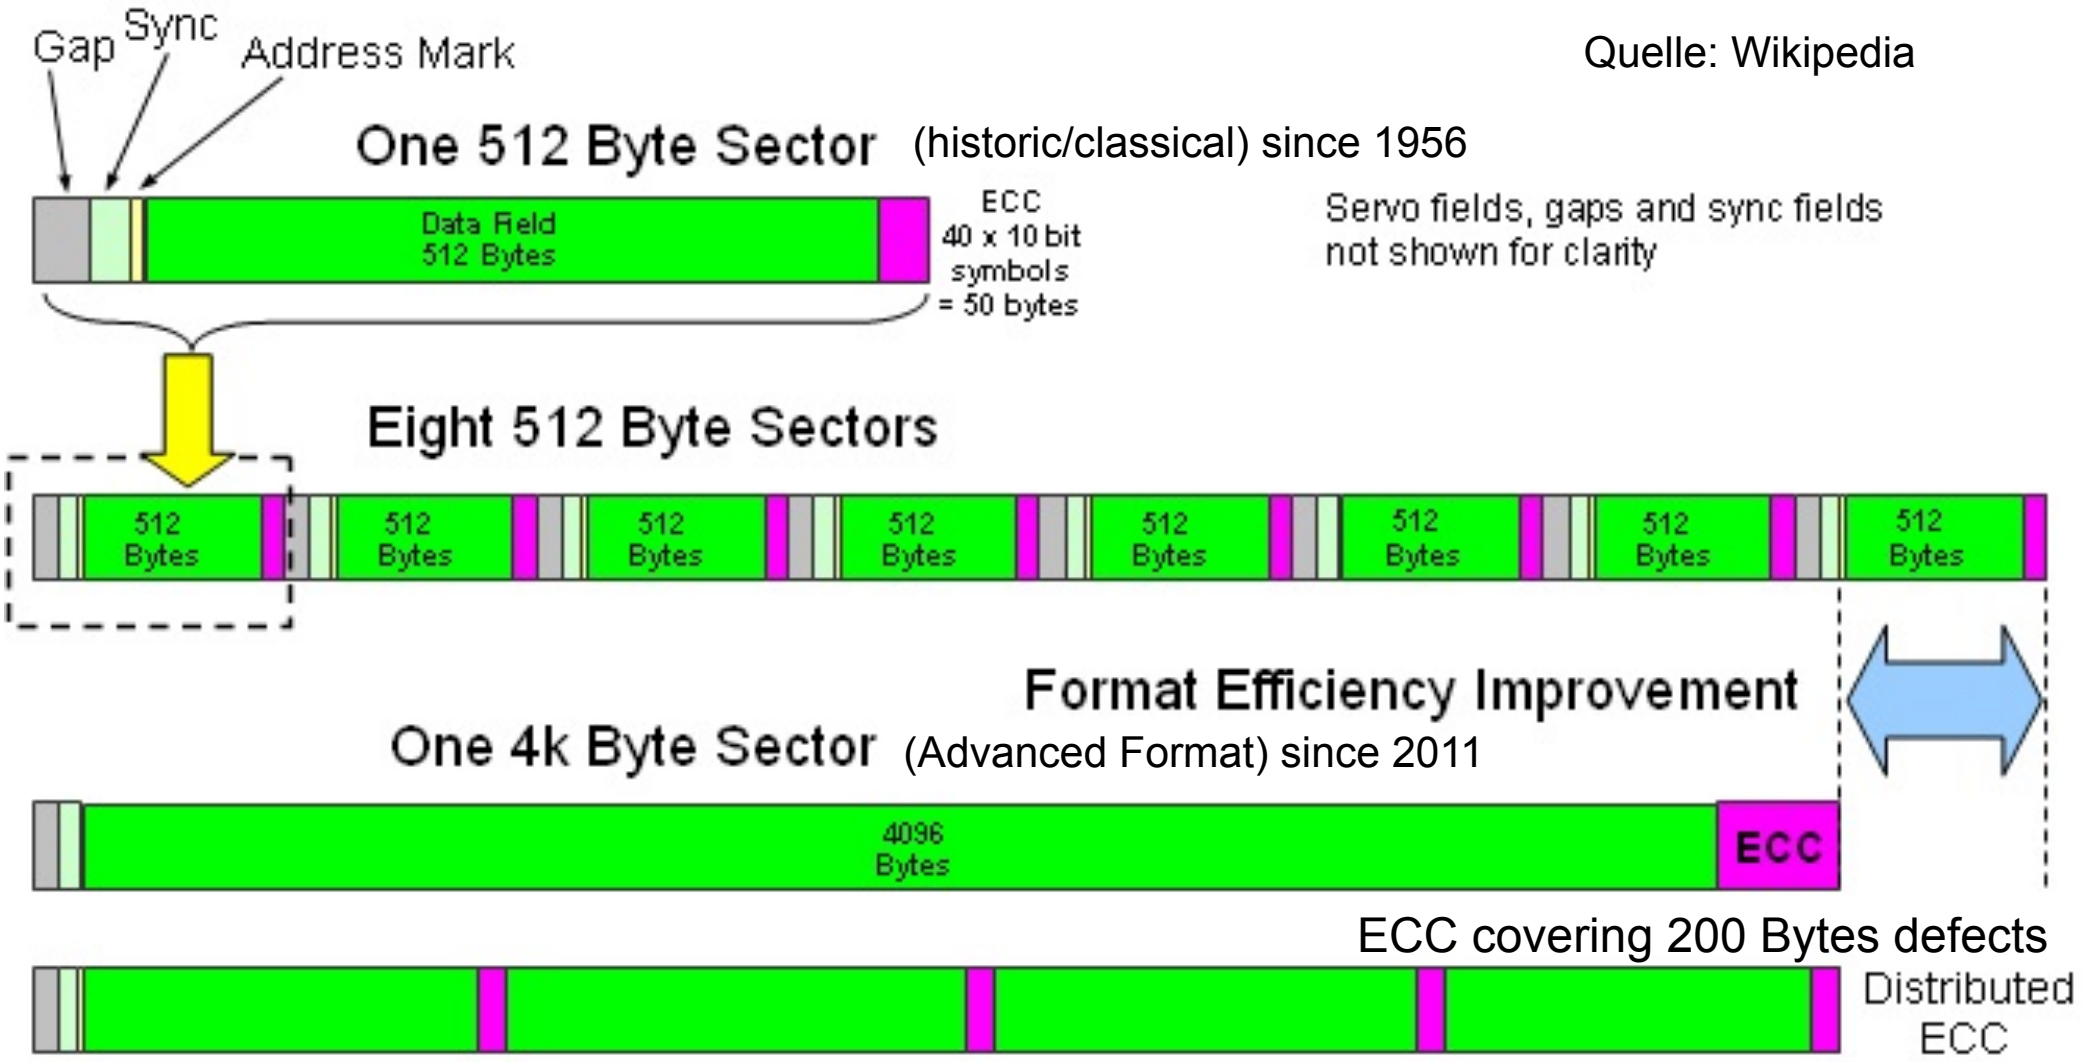

Disk Data Layout: Sectors

- Sektor: kleinste Speicher-Einheit auf der Festplatte
  - klassisch: 512 Bytes Nutzdaten (seit 1956)
- Block: kleinste Datenmenge, die das Filesystem überträgt
  - kann ein Vielfaches der Sektorgröße sein
- Advanced Format: 4096 Bytes
  - Neudefinition seit 2011
  - Durch IDEMA: International Disk Drive Equipment and Materials Association (Hersteller-Vereinigung)
  - 512e Format: Platte bildet externe 512byte Block-Requests ab auf 4KB Sektoren (write führt zu read-replace-write Sequenz)
- Nutzdaten sind gesichert durch Prüfsumme (ECC Block)
  - klassisch: 40x10bits sichern (korrigieren) bis zu 50 Bytes Nutzdaten
  - Advanced Format: neuer ECC Block sichert 200 Bytes Nutzdaten

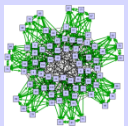

Disk Data Layout: Tracks and Zones

- Defining a sector as the intersection between a radius and a track creates larger sectors towards the outside of the disk.
- The same number of bytes can be accomplished by reducing the bit density of the outer sectors relative to the inner ones.
- Modern hard discs use zoned bit recording, where the disk is divided into zones encompassing a small number of contiguous tracks. Each zone contains sectors of a similar physical size. Outer zones have more sectors per zone. This is known as zoned bit rate.

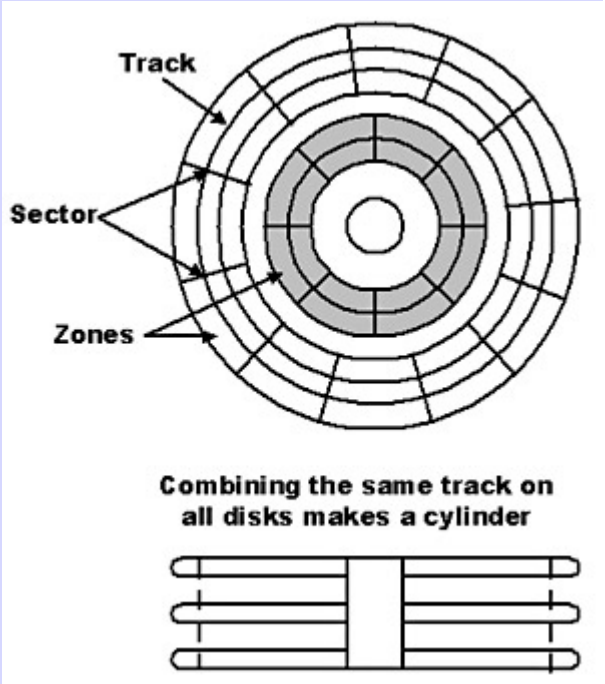

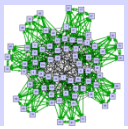

RAID

- RAID = Redundant Array of Inexpensive/Independent Disks
- Problemstellung:
  - Platten werden immer größer und immer billiger
  - Bei Ausfällen gehen große Datenmengen verloren
  - Die Wahrscheinlichkeit von Ausfällen steigt mit der Anzahl benutzter Platten
  - Platten werden relativ zu Prozessoren immer langsamer
- Durch Parallelschaltung werden Plattenzugriffe schneller
- gleichzeitig steigt das Ausfall-Risiko durch mehr Platten
  - 1 Platte: Ausfallrisiko *p*, kein Ausfall: (1-*p*).
  - n Platten: Ausfallrisiko: $1 - (1-p)^n$
  - Bei Risiko 1/1000 und 1.000 Platten ist das Risiko = 1 !!
- Durch extra Platten bekommt man die nötige Redundanz
- Verschiedene RAID-Varianten im Einsatz
  - gebräuchlichste: RAID-0, RAID-1, RAID-5 und Kombinationen davon

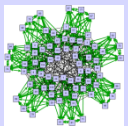

RAID-0 (Striping)

- Jeder Datenblock wird in Streifen (*strip*) über parallele Disks verteilt
- Hier mit 2 Disks →
- Eigenschaften:
  - Beschleunigung durch Parallelzugriff
  - keine Redundanz

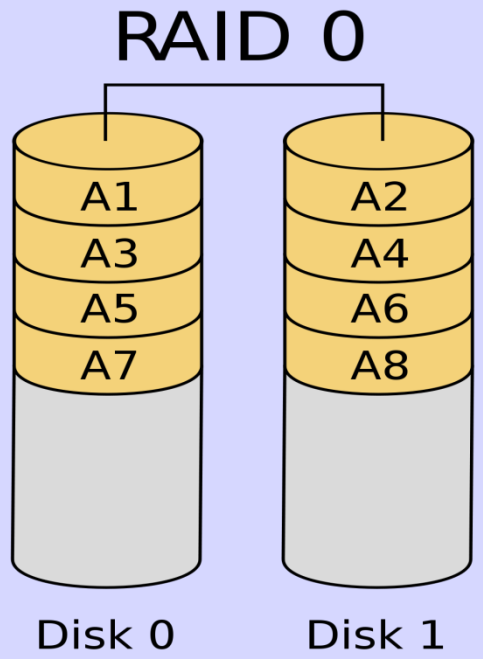

Grafik: Wikipedia

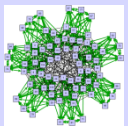

RAID-1 (Mirroring)

- Platten werden gespiegelt
- Hier mit 2 Disks →
  - jede Platte separat funktionsfähig
    (alle I-nodes und Datenblöcke vollständig)
- Eigenschaften:
  - Redundanz: 1 Platte darf ausfallen
  - 2x-schnelles Lesen durch Parallelzugriff
  - Schreiben nur 1x-schnell

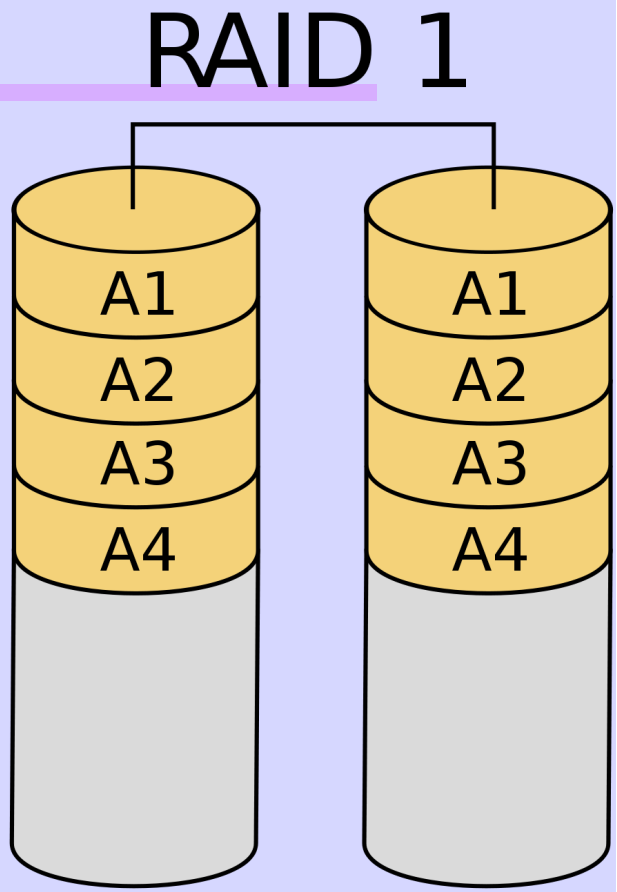

Grafik: Wikipedia

RAID-5 (Block-level striping with parity)

- Striping mit Paritätsbit
  - z.B. 1 Wort = 4 Bytes + 1 Byte für die Paritätsbits
  - Raid-5: Platte mit Paritätsbyte wechselt
  - Raid-4: dedizierte Parity-Platte
    (Flaschenhals beim Schreiben)
- Hier mit 3+1 Disks →
  - oft auch 4+1 Disks

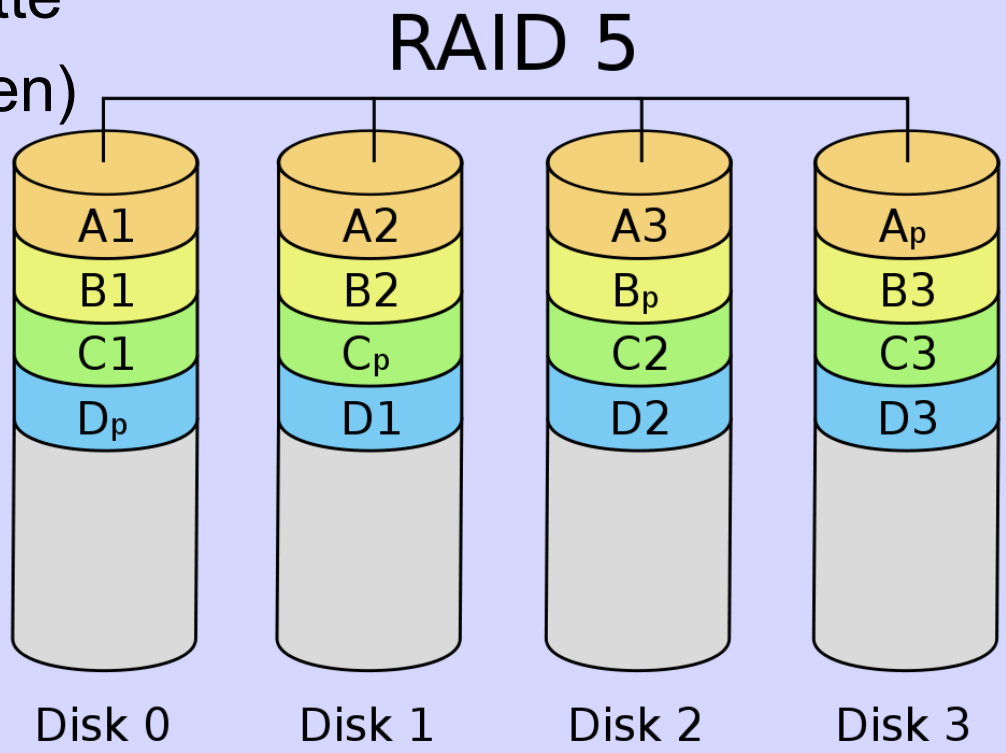

Grafik: Wikipedia

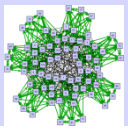

RAID-5 (Block-level striping with parity)

- Schreiben verlangt Parity-Berechnung
  - Entweder alle restlichen strips lesen und dann parity rechnen
  - Oder neuen strip mit altem vergleichen und parity rechnen
- Danach Daten strip und parity strip schreiben
  - Mehrere dieser Schreibvorgänge können bei Raid-5 parallel erfolgen, bei Raid-4 bildet Parity-Platte ein bottleneck.
- Lesen durch Parallelzugriff
  - z.B. wenn ein 2KB File-Block aus 4 Strips zu je 512KB besteht
  - z.B. wenn 4 Prozesse je 1 strip von versch. Platten lesen

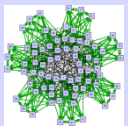

RAID-Kombinationen

- Ein RAID bildet nach außen wieder eine logische Platte (die schneller und sicherer ist).
- Aus solchen „RAID“-Platten können wiederum RAIDs gebildet werden
  - Beispielsweise können mehrere Platten zu einem parallelen *RAID 0* zusammengefasst werden und aus mehreren dieser *RAID-0*-Arrays kann ein *RAID-5*-Array gebildet werden. Man bezeichnet diese Kombinationen dann etwa als *RAID 05* (0+5).
  - Umgekehrt würde ein Zusammenschluss von mehreren *RAID-5*-Arrays zu einem *RAID-0*-Array als *RAID 50* (oder *RAID 5+0*) bezeichnet werden.
  - Die beliebtesten Kombinationen sind *RAID 01* und *RAID 10*

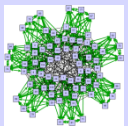

RAID-01

- Bei *RAID 01* („0+1“, bzw. „1 über 0“) arbeiten je zwei Platten parallel und werden dabei von zwei anderen Platten gespiegelt (insgesamt vier Platten).
- „sicheres Raid aus schnellen Platten“
- Eigenschaft
  - Schnelligkeit durch RAID-0
  - Sicherheit durch RAID-1
  - Weniger Kapazität als RAID 5 mit 3+1 Platten (50% Nutzdaten i. Vgl. zu 75% Nutzdaten)
  - Bei Ausfall einer RAID-1 „Platte“ muss ein ganzes RAID-0 erneuert werden

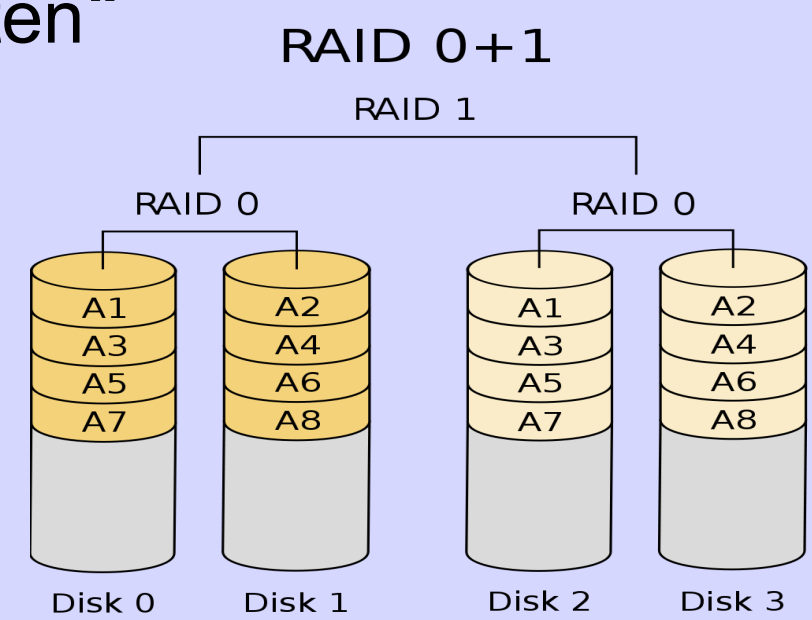

Grafik: Wikipedia

RAID-10

- Bei *RAID 10* („1+0“, „1 über 0“) werden (mindestens) zwei mal zwei Platten gespiegelt und zu einem RAID 0 verbunden
- „schnelles Raid aus sicheren Platten“
- Eigenschaft
  - Sicherheit durch RAID-1 Platten
  - Schnelligkeit durch Parallelität
  - Weniger Kapazität als RAID 5 mit 3+1 Platten (50% Nutzdaten i. Vgl. zu 75% Nutzdaten)
  - Ausfall eines Laufwerks kann genau lokalisiert und lokal (schnell) behoben werden

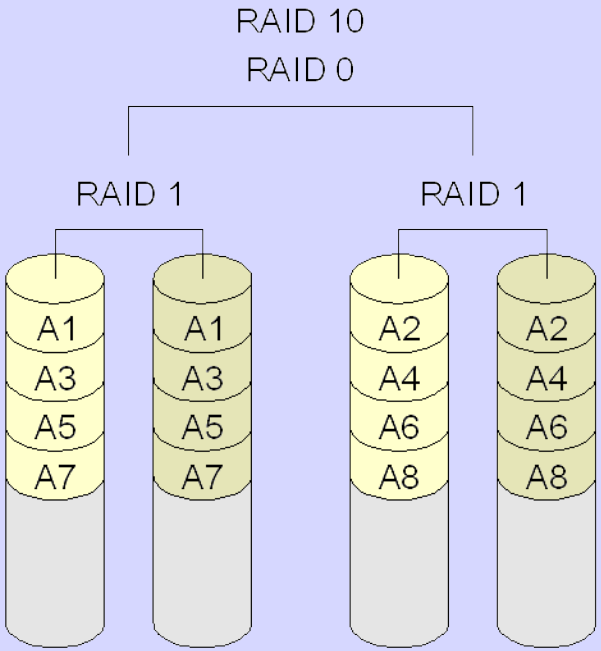

Grafik: Wikipedia

Überblick

Teil 1: I/O und Disks

Teil 2: SCSI – Small Computer Systems Interface

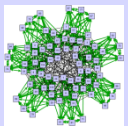

SCSI – Funktionsprinzip

- SCSI definiert einen **Bus und** ein **Protokoll** zum Datenaustausch
- SCSI betrachtet gesamte Speicherkapazität einer Festplatte als zusammenhängende **Liste von Datenblöcken** fester Größe.
  - im Gegensatz zu anderen Festplattenschnittstellen (z.B. IDE) mit Spuren und Sektoren
- Verwaltung der Blöcke Aufgabe des intelligenten Controllers
- SCSI Festplatte setzt logische Blocknummer in Spuren und Sektoren um
  - autonomes bad block replacement möglich
- SCSI Bandlaufwerk übernimmt Blocknummern fast unverändert

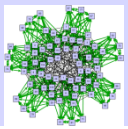

SCSI – Funktionsprinzip

- SCSI-Protokoll besteht aus physikalischen Steuersignalen und logischen Messages.
- SCSI Bus:
  - max. 8 Teilnehmer
  - Beispiele:
    - Festplatten
    - Bandlaufwerke
    - optische Laufwerke
- Nur zwei Teilnehmer können gleichzeitig aktiv sein
- Datenaustausch ohne Eingreifen der CPU möglich

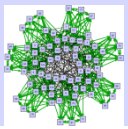

SCSI – Überblick

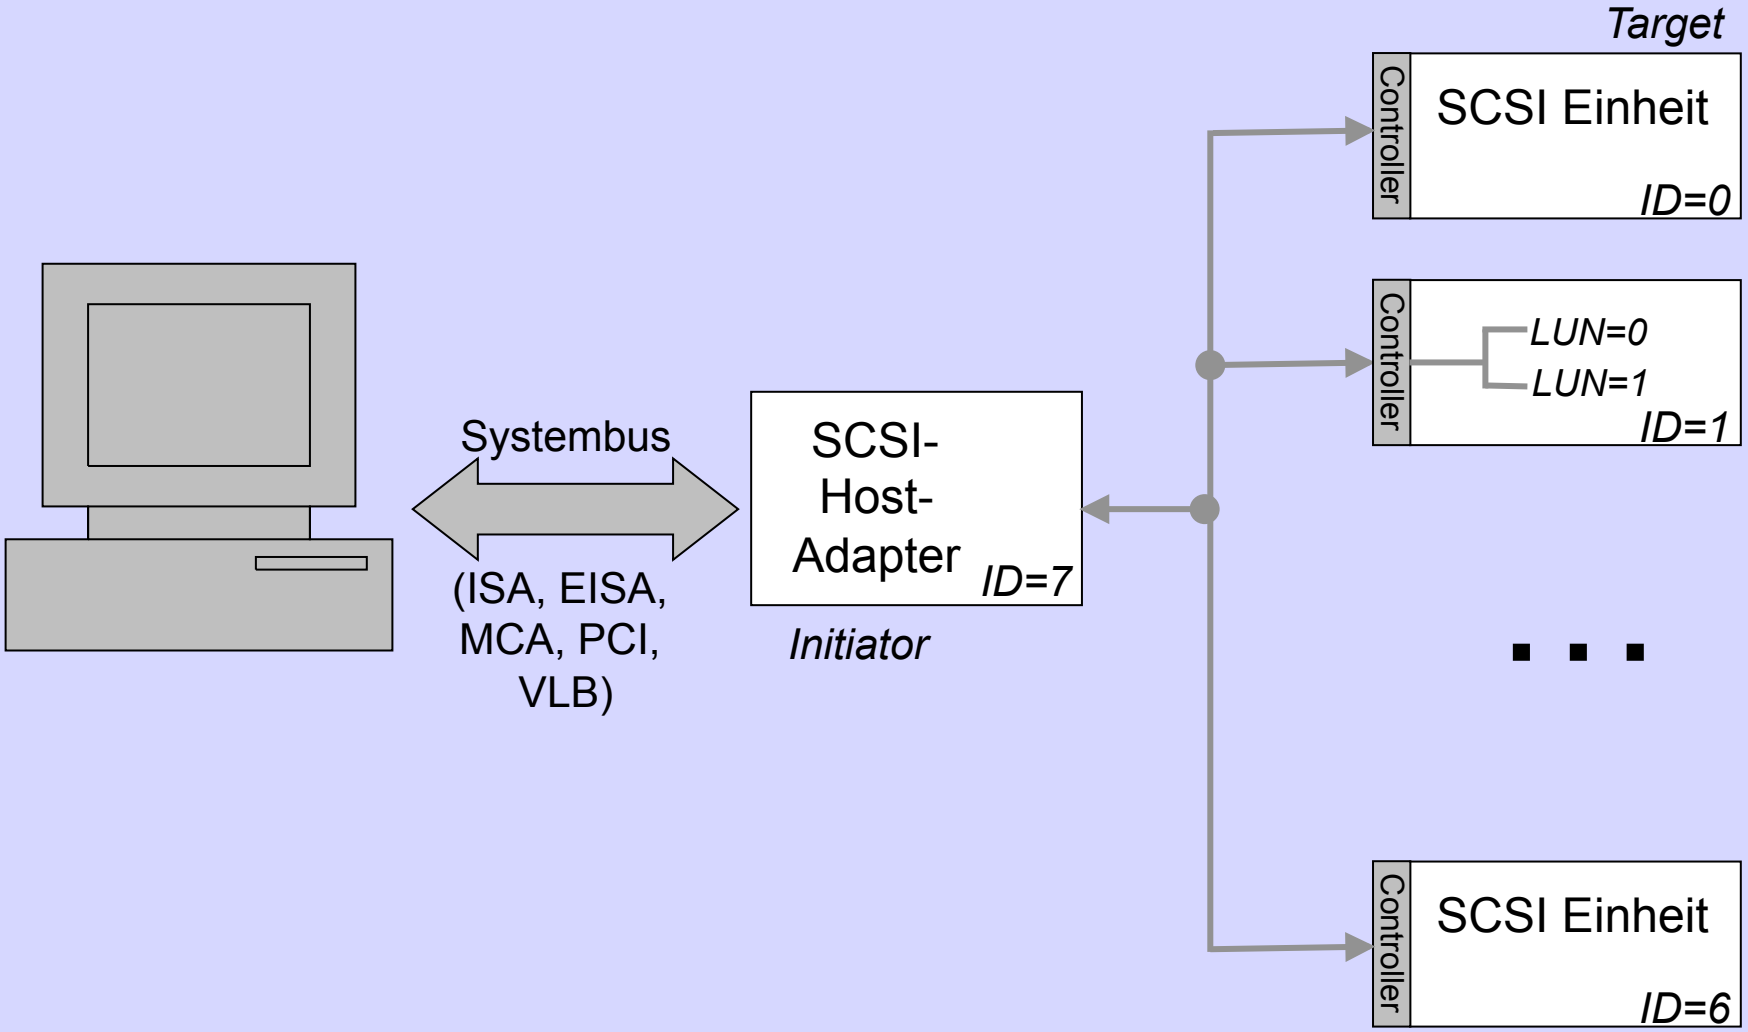

SCSI vs LUN

- SCSI-ID: SCSI-Adresse für jede SCSI-Einheit
  - Adressen 0 bis 7
  - Hostadapter verwendet meist Adresse Nr.7
  - Hostadapter spricht als Initiator die anderen SCSI-Einheiten (*Targets*) an
    - Genauer: Controller als Verbindung zum SCSI-Bus wird angesprochen
- LUN (= *Logical Unit Number)*
  - Jedes Target kann bis zu acht logische Einheiten enthalten
    - Identifizierung der logischen Einheiten innerhalb eines SCSI-Befehls über LUN.
    - Bsp.: SCSI-Controller, der mehrere Laufwerke steuert (→ RAID)

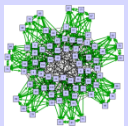

SCSI – Signale und Datenübertragung

- Datenübertragung
  - acht Datenbits DB(0) bis DB(7)
  - ein Paritätsbit DB(P)
  - neun Steuersignale
- Datenübertragungsrate bei verschiedenen Modi
  - asynchroner Modus: 3MB/s
  - synchroner Modus: 5MB/s
  - Fast-Modus: 10MB/s
  - Ultra-Fast-Modus: 20MB/s

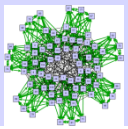

SCSI – Datenübertragung

- Jede SCSI-Einheit kann als Initiator die Steuerung des SCSI-Bus übernehmen.
- Initiator aktiviert über SCSI-Adresse ein Target, das eine bestimmte Funktion ausführen soll.
  - Initiator belegt Bus nur zur Befehls- und Datenübertragung
  - Beispiel für auszuführende Funktion: Lesen eines Blocks
- Target stellt nach Befehlsausführung für Datenübertragung Verbindung zum Initiator wieder her.
- Ansonsten ist der Bus frei für andere SCSI-Einheiten.

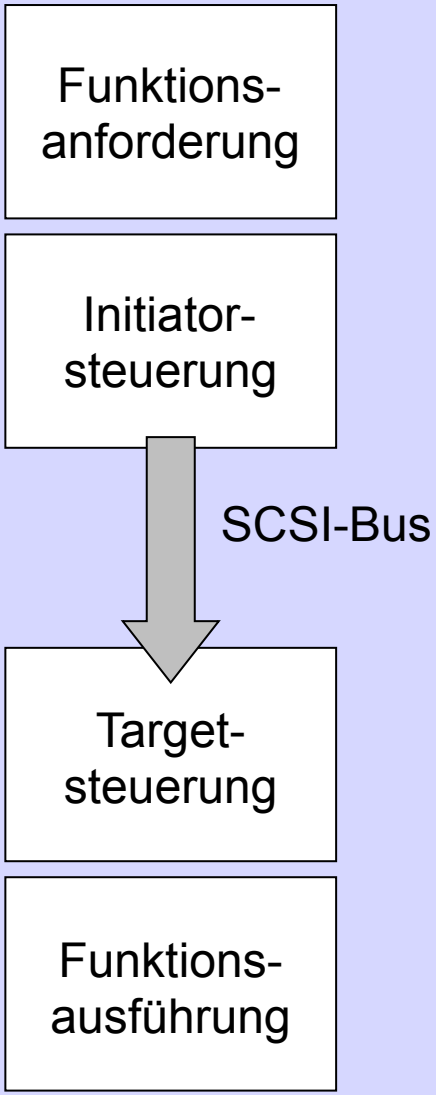

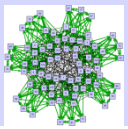

SCSI – Busphasen und Messages

- Acht Busphasen bei SCSI
  - Bus frei
  - Arbitration
  - Selection
  - Reselection
  - Command
  - Daten
  - Message
  - Status

  } Informationstransferphase

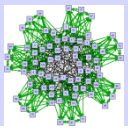

SCSI – Busphasen und Messages

- Bus-frei-Phase
  - keine SCSI-Einheit nutzt oder steuert den Bus im Moment
- Arbitration-Phase
  - SCSI-Einheit kann als Initiator oder Target die Steuerung des Buses übernehmen
- Selection-Phase
  - Initiator kann eine Target-Einheit für eine auszuführende Funktion auswählen
- Reselection-Phase
  - Target kann Verbindung mit dem Initiator *wieder* aufnehmen
  - Bsp: Ausführung eines Lesebefehls
    - während interner Ausführung beim Target: Bus-frei-Phase

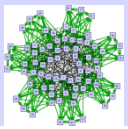

SCSI – Busphasen und Messages

- Command-Phase
  - adressiertes Target kann Befehlsdaten vom Initiator anfordern
- Daten-Phase
  - Target verlangt Daten vom Initiator (*Data-out*)
  - Target liefert Daten an den Initiator (*Data-In*)
- Message-Phase
  - Control Messages werden vom oder zum Target geschickt
  - Beispiele für Messages
    - Befehl abgeschlossen
    - Trennen (z.B. während der internen Verarbeitung)
    - Abbruch
    - …
- Status-Phase
  - Target übergibt Statusinformationen an den Initiator

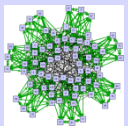

SCSI – Busphasen und Messages

- Jeder Initiator besitzt zwei Sätze à drei Zeiger
  - aktive Zeiger
    - betreffen gegenwärtig aktive Verbindung
    - zeigen auf nächstes zu übertragendes Befehls-, Daten- bzw. Statusbyte
  - gesicherte Zeiger
    - gibt es für jeden aktiven Befehl, auch wenn Verbindung zwischen Initiator und Target temporär nicht besteht
    - Befehlszeiger weist auf Beginn des Befehlsblocks
    - Statuszeiger weist auf Beginn des Statusbereichs

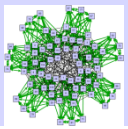

SCSI – Befehle und Programmierung

- Schema für SCSI-Befehle:

Befehlscode (1 Byte)
LUN (3 Bits) Blockadresse /-Länge/ Parameter (variable Länge)
Steuerbyte (1 Byte)

- Aufbau eines Befehlsbytes
  - Befehl (5 Bits)
    - Wert 0 bis 31: Befehlscode
  - Gruppe (3 Bits)

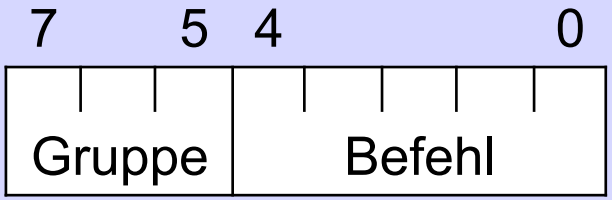

0	6-Byte-Befehl
1,2	10-Byte-Befehl
3,4	Reserviert
5	12-Byte-Befehl
6,7	Hersteller

Aus dem Aufbau folgt:
- Acht mögliche Befehlsgruppen
- pro Gruppe 32 Befehle
- insgesamt: 256 verschiedene Befehle

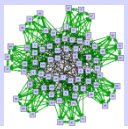

SCSI – Aufbau eines 6-Byte-Befehls

Bit Byte	7	6	5	4	3	2	1	0
0	Befehlscode							
1	LUN			LBA (MSB)				
2	Logische Blockadresse							
3	Logische Blockadresse (LSB)							
4	Transfer-/Zuweisungslänge/ Parameter							
5	Steuerbyte							

Logische Blockadresse: umfasst 21Bits vom most significant bit (MSB) bis zum least significant bit (LSB).

Transferlänge : Anzahl der zu übertragenen Daten in Blöcken
Bei 1Byte für Transferlänge können daher 256 Blöcke auf einmal übertragen werden.

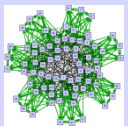

SCSI – Aufbau eines 10-Byte-Befehls

Bit Byte	7	6	5	4	3	2	1	0
0	Befehlscode							
1	LUN			reserviert				REL
2	Logische Blockadresse (MSB)							
3	Logische Blockadresse							
4	Logische Blockadresse							
5	Logische Blockadresse (LSB)							
6	reserviert							
7	Transfer-/Zuweisungslänge/ Parameter							
8	Transfer-/Zuweisungslänge/ Parameter							
9	Steuerbyte							

REL : Bit für relative Adressierung

2 Bytes für Transferlänge = max. 65K Blöcke Übertragung

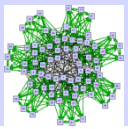

SCSI – Aufbau eines 12-Byte-Befehls

Bit Byte	7	6	5	4	3	2	1	0
0	Befehlscode							
1	LUN			reserviert				REL
2	Logische Blockadresse (MSB)							
3	Logische Blockadresse							
4	Logische Blockadresse							
5	Logische Blockadresse (LSB)							
6	Transfer-/Zuweisungslänge/ Parameter							
7	Transfer-/Zuweisungslänge/ Parameter							
8	Transfer-/Zuweisungslänge/ Parameter							
9	Transfer-/Zuweisungslänge/ Parameter							
10	reserviert							
11	Steuerbyte							

4 Bytes für Transferlänge = max. 4G Blöcke Übertragung

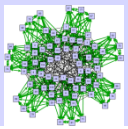

SCSI – Befehle und Programmierung

- Aufbau eines Steuerbytes
  - F (Flag) (1 Bit)
    - 0 : Message verketteter Befehl abgeschlossen übergeben
    - 1 : Message verketteter Befehl mit Flag abgeschlossen übergeben
  - L (Link) (1 Bit)
    - 0 : keine Befehlsverkettung
    - 1 : Befehlsverkettung
  - reserviert (4 Bit)
  - H (Hersteller) (1 Bit)

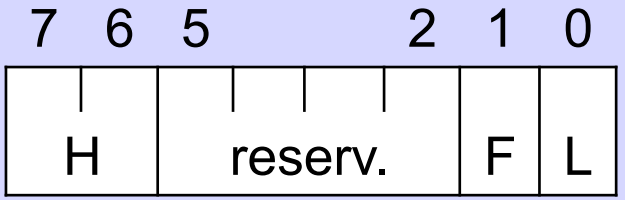

- Ist L=1, verlangt Initiator Befehlsverkettung
  - Target übergibt nach Abschluss eines Befehls nur Zwischenstatus und fordert nächsten Befehl
  - Verbindung wird nicht unterbrochen und Initiator übergibt sofort nächsten Befehl

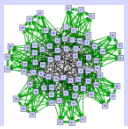

SCSI – beispielhafte Befehlsausführung (I)

- SCSI-Bus aktivieren
- Ende der **Arbitration-Phase** bestimmen und sicherstellen, dass Host-Adapter Kontrolle über Bus erlangt hat
- **Selection-Phase** zum Anwählen eines Targets
- Ermitteln ob Target auf Selection-Phase reagiert und Bussteuerung übernommen hat
- Beginn der **Command-Phase** ermitteln
- Befehlsausführung starten durch Übermittlung des Befehlsblocks an das Target über den SCSI-Datenport

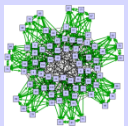

SCSI – beispielhafte Befehlsausführung (II)

- Beginn der **Data-Out-Phase** ermitteln und wenn nötig
  - Parameterliste über den SCSI-Datenport ausgeben
  - Datenblock über den SCSI-Datenport ausgeben
- Wenn ein Datenblock an Initiator übergeben werden soll, Beginn der **Data-In-Phase** erkennen und Datenblock über den SCSI-Datenport einlesen.
- Beginn der **Status-Phase** ermitteln und über den SCSI-Datenport das Statusbyte empfangen.
- Beginn der **Message-In-Phase** bestimmen und die Message über den SCSI-Datenport einlesen.

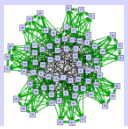

SCSI – Die verschiedenen Standards

- Vorteile von SCSI gegenüber IDE
  - bei Einsatz von diverser Peripherie
    - mehrere Festplatten
    - CD-Writer
    - Scanner
    - Tape-Streamer
  - einfacher Datenaustausch bspw. mittels SCSI-Wechselplatten
- SCSI-II
  - geräteunabhängige und daher sehr flexible Busschnittstelle