Rechnernetze II

SoSe 2024

Roland Wismüller
Betriebssysteme / verteilte Systeme
roland.wismueller@uni-siegen.de
Tel.: 0271/740-4050, Büro: H-B 8404

Stand: 18. März 2024

Rechnernetze II

SoSe 2024

9 Leistungssteigerung von Netzen

Inhalt

- Motivation: Hochleistungsrechner
- Maßnahmen zur Leistungssteigerung
- Beispiel: Infiniband

- Harald Richter: Verbindungsnetzwerke für parallele und verteilte Systeme. Spektrum Akademischer Verlag, 1997
- Weitere Angaben auf der WWW-Seite

Hochleistungsrechner

- Für rechenintensive Anwendungen
  - Klimasimulation, Genomanalyse, Arzneimittel-Design, ...
- Als Server
  - WWW (Suchmaschinen), Datenbanken, ...
- Multiprozessorsysteme: mehrere gekoppelte Prozessoren
  - mit gemeinsamem Speicher (SMP, ccNUMA)
  - mit verteiltem Speicher (MPP)
- Beispiel: Frontier (ORNL, USA, schnellster Rechner der Welt!)
  - 8,7 Millionen CPU-Kerne
  - $1{,}1 \cdot 10^{18}$ Flop/s (=1,1 EFlop/s) Rechenleistung

Multiprozessorsysteme mit verteiltem Speicher (MPPs)

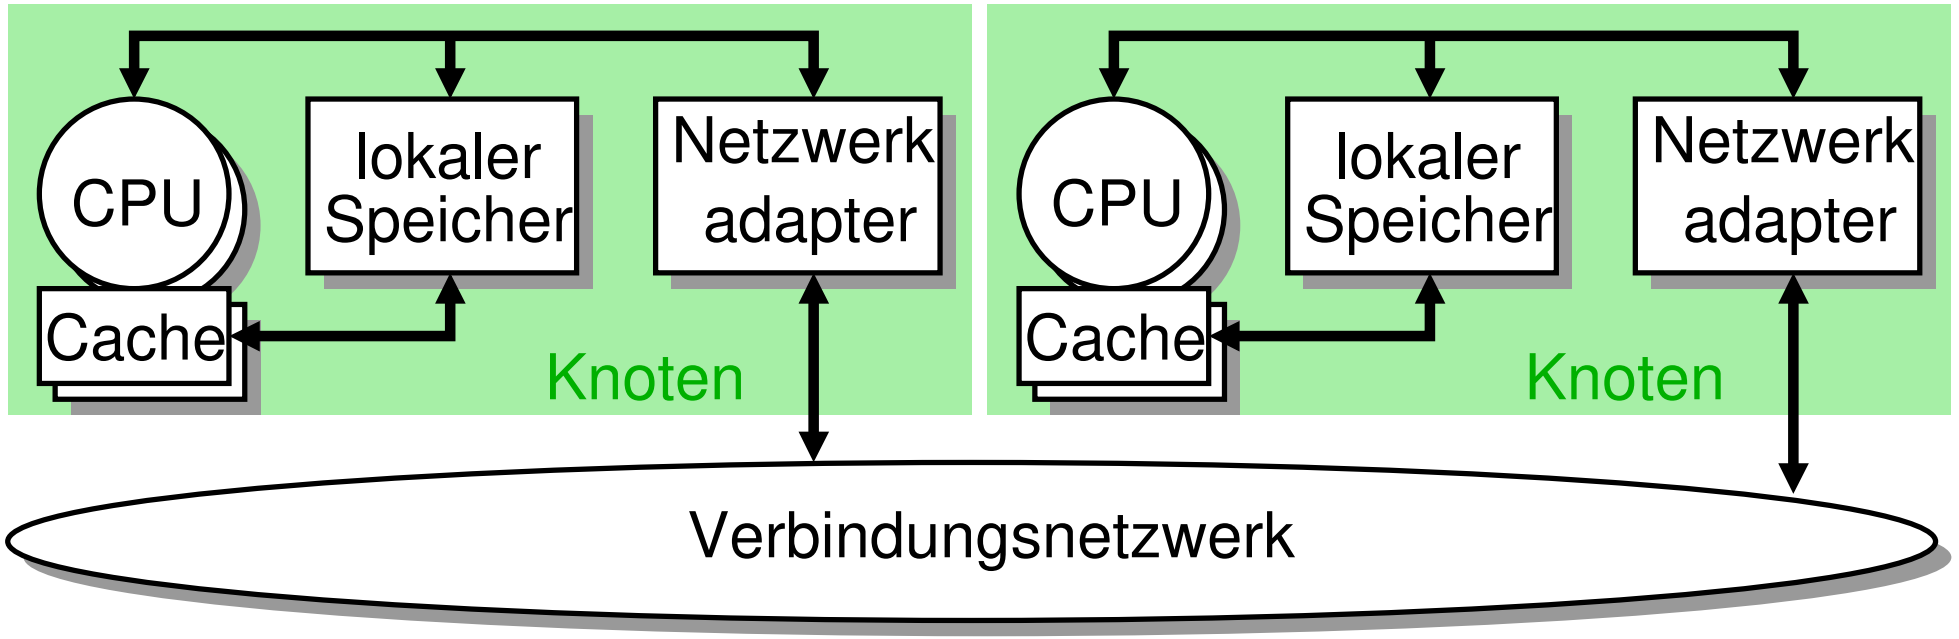

- Sehr gut skalierbar (bis mehrere 100000 Knoten)
- Kommunikation/Synchronisation durch Nachrichtenaustausch
- Architektur entspricht Cluster von Rechnern

Programmierung von MPPs

- Parallele Prozesse (meist ein Prozeß pro Knoten)
  - jeder Prozeß bearbeitet ein Teilproblem
- Kooperation durch Nachrichtenaustausch
  - Punkt-zu-Punkt: *send*, *receive*
  - global: *broadcast* (1-zu-N), *reduce* (N-zu-1), ...
  - oft sehr große Nachrichten
- Wichtig für hohe Rechenleistung:
  - Kommunikationszeit $\ll$ Rechenzeit
  - Überlappung von Kommunikation und Berechnung
  - gleichzeitige Kommunikation vieler Knoten

Maßgebliche Eigenschaften der Verbindungsnetze

- Routing: i.a. mehrere mögliche Pfade
  - **Blockierungsfreiheit**: Kommunikation zweier Knoten blockiert andere Kommunikationen nicht
  - Ausfallsicherheit
- **Bisektionsbandbreite**: Gesamtbandbreite, wenn eine Hälfte der Knoten an die anderen sendet (*worst case*)
- **Durchmesser** des Netzes: Pfadlänge zwischen zwei maximal entfernten Knoten
- **Verbindungsgrad** eines Knotens: Anzahl der Links
- **Skalierbarkeit**: „Eigenschaften des Netzes bleiben bei Erweiterung erhalten“

Beispiel

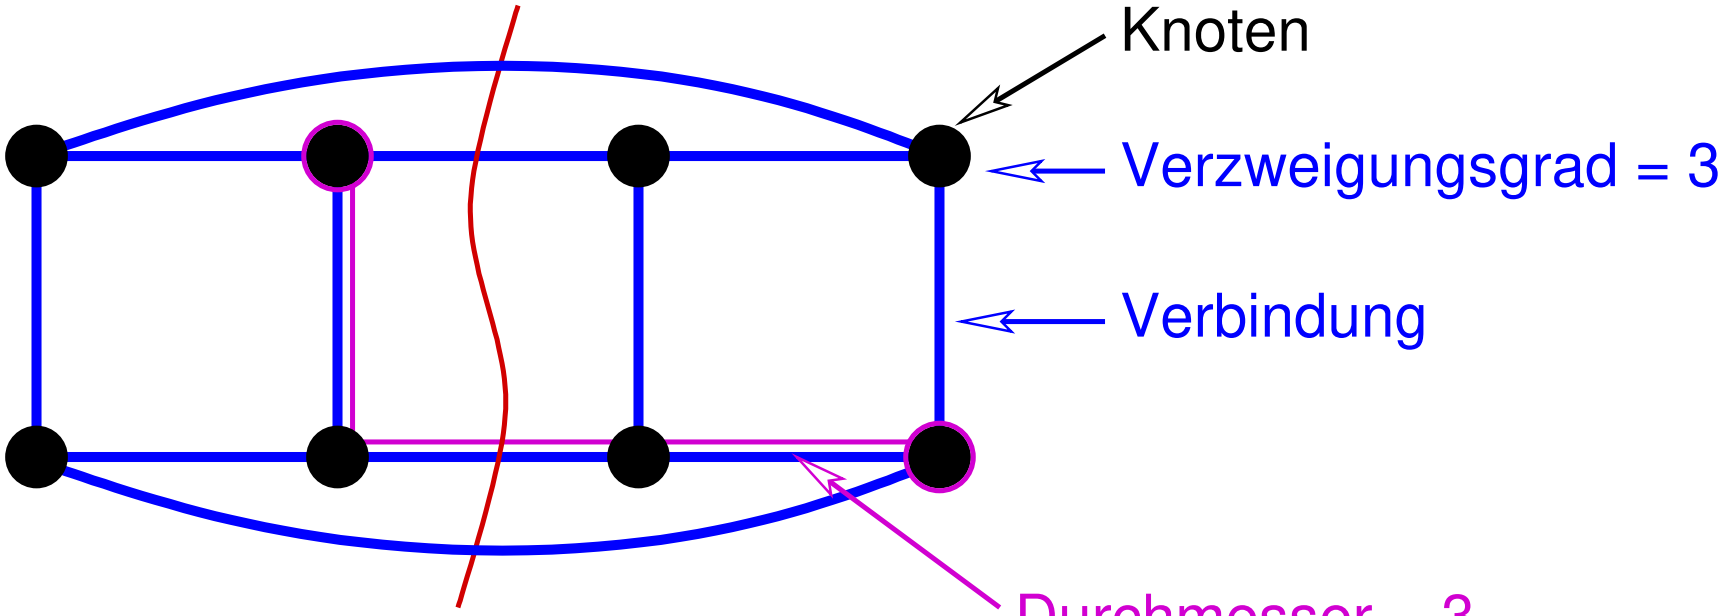

Bisektionsbandbreite =
4 * Bandbreite der Einzelverbindungen

9.2 Maßnahmen zur Leistungssteigerung

- Ziele:
  - hohe Bisektionsbandbreite
  - niedrige Latenz
    - schnelle Weiterleitung in den Zwischenknoten
    - geringe Latenz durch Softwareschichten
- Mechanismen:
  - Netztopologien
  - Weiterleitungstechniken
  - Protokolle der Anwendungsschicht
    - Vermeidung von Kopiervorgängen
  - *Remote DMA* und *OS bypass*
    - Vermeidung von Betriebssystem-Einsprüngen

9.2.1 Netztopologien

- „Statische“ Verbindungsnetze
  - direkte Verbindungen zwischen Paaren von Knoten
  - Forwarding erfolgt durch in die Knoten eingebaute Switches
  - z.B. Ring, Gitter, Hyperwürfel
- Dynamische Verbindungsnetze
  - Knoten sind indirekt über einen oder mehrere Switches verbunden
  - z.B. Kreuzschienenverteiler, Clos-Netz

Statische Verbindungsnetze: Beispiele

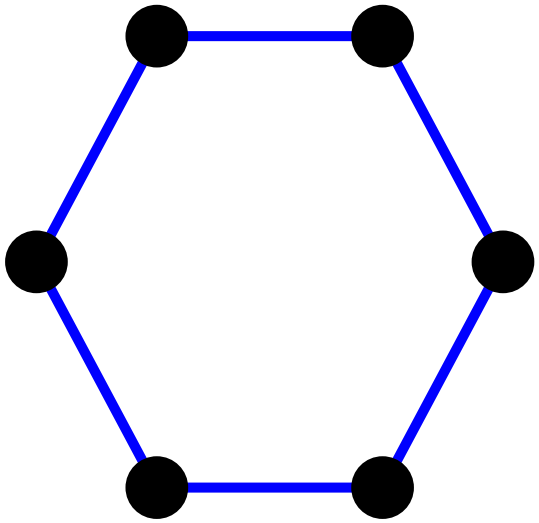

Ring

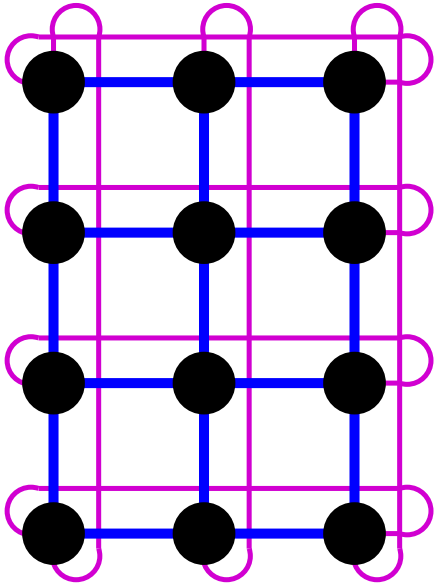

Gitter / Torus

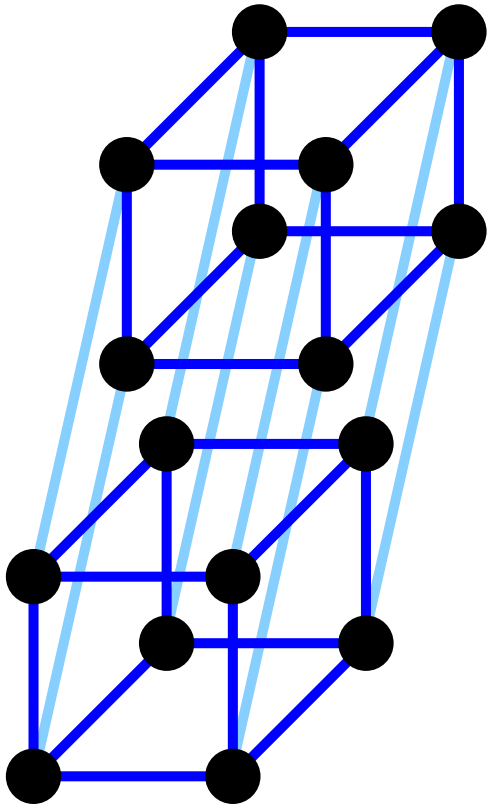

4D Hyperwürfel

	Ring	Gitter / Torus	4D Hyperwürfel
Durchmesser	O(N)	$O(\sqrt{N})$	O(log(N))
Verzweigungsgrad	2	4	O(log(N))
Bisektionsbandbr.	2 * Link	$O(\sqrt{N})$ * Link	O(N) * Link

Dynamische Verbindungsnetze: Kreuzschienenverteiler (*Crossbar Switch*)

- Knoten hat getrennte Links pro Richtung
- Alle möglichen, disjunkten Knotenpaare können gleichzeitig verbunden werden
  - blockierungsfreies Netz
- Hoher Hardwareaufwand: n^2 Schaltelemente bei n Knoten
- I.a. nicht erweiterbar

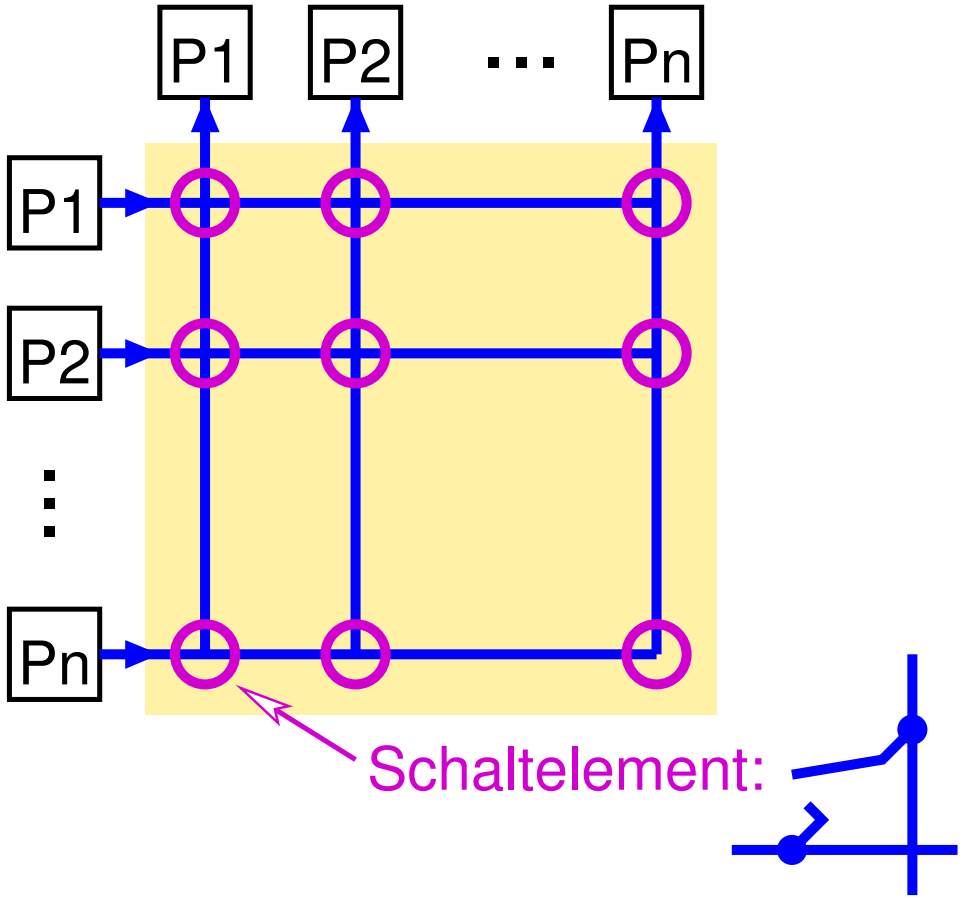

Dynamische Verbindungsnetze: Clos-Netz

- Erweiterbares Netz auf Basis (kleiner) Kreuzschienenverteiler
  - maximal mögliche Bisektionsbandbreite
  - blockierungsfrei, wenn ex. Routen geändert werden dürfen
- Beispiel: Vernetzung 32 Knoten mit 8x8 Crossbars

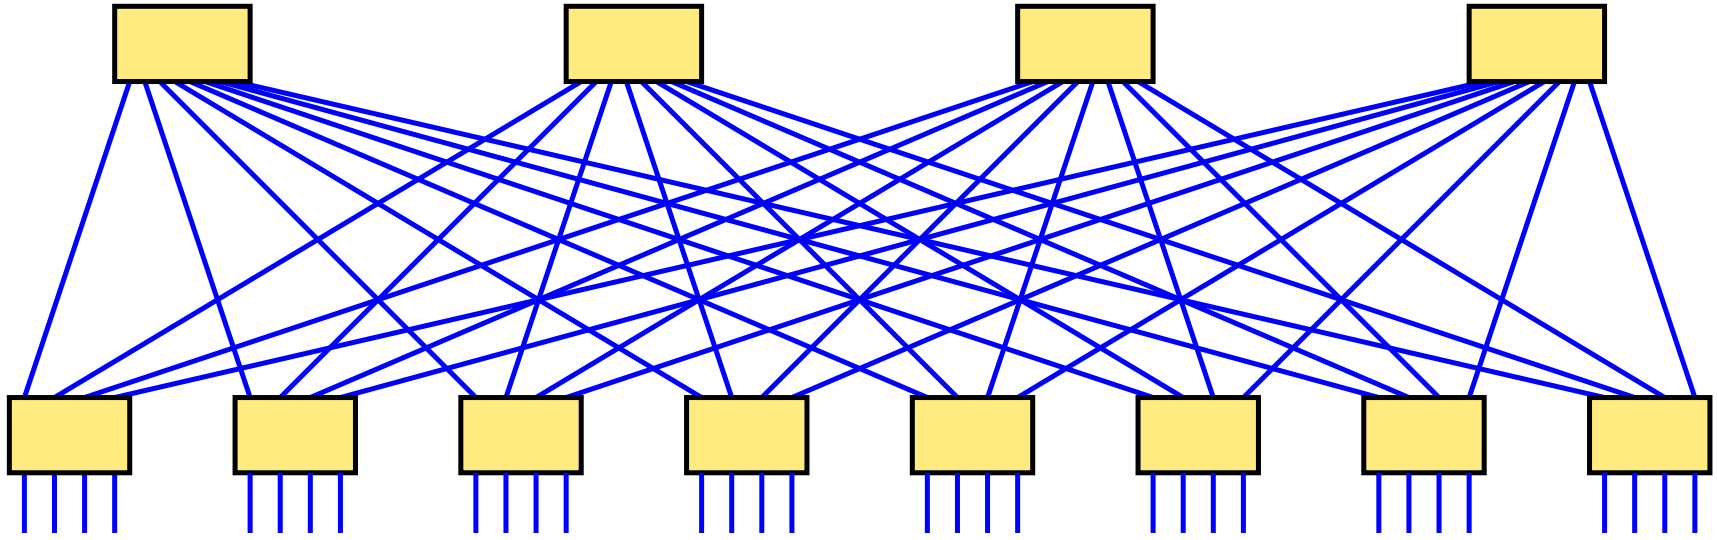

32 Knoten

Dynamische Verbindungsnetze: Clos-Netz

- Erweiterbares Netz auf Basis (kleiner) Kreuzschienenverteiler
  - maximal mögliche Bisektionsbandbreite
  - blockierungsfrei, wenn ex. Routen geändert werden dürfen
- Beispiel: Vernetzung 32 Knoten mit 8x8 Crossbars

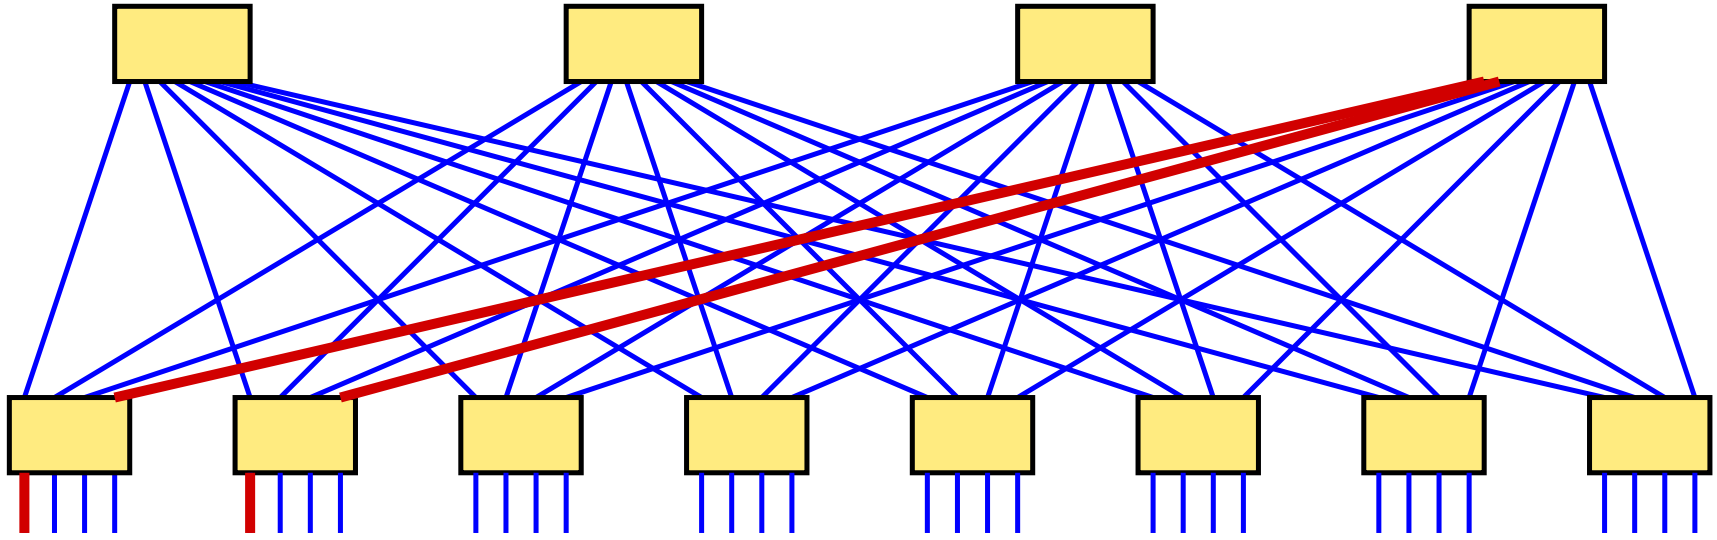

32 Knoten

Dynamische Verbindungsnetze: Clos-Netz

- Erweiterbares Netz auf Basis (kleiner) Kreuzschienenverteiler
  - maximal mögliche Bisektionsbandbreite
  - blockierungsfrei, wenn ex. Routen geändert werden dürfen
- Beispiel: Vernetzung 32 Knoten mit 8x8 Crossbars

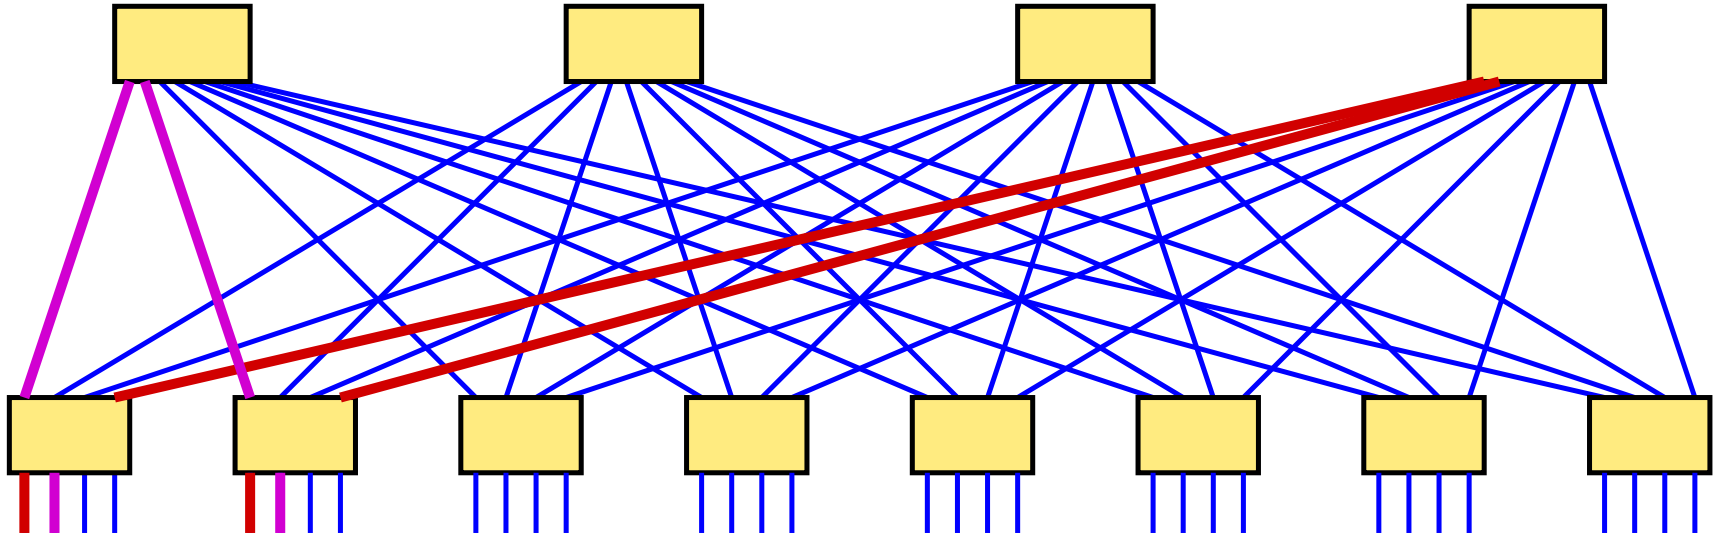

32 Knoten

Dynamische Verbindungsnetze: Clos-Netz

- Erweiterbares Netz auf Basis (kleiner) Kreuzschienenverteiler
  - maximal mögliche Bisektionsbandbreite
  - blockierungsfrei, wenn ex. Routen geändert werden dürfen
- Beispiel: Vernetzung 32 Knoten mit 8x8 Crossbars

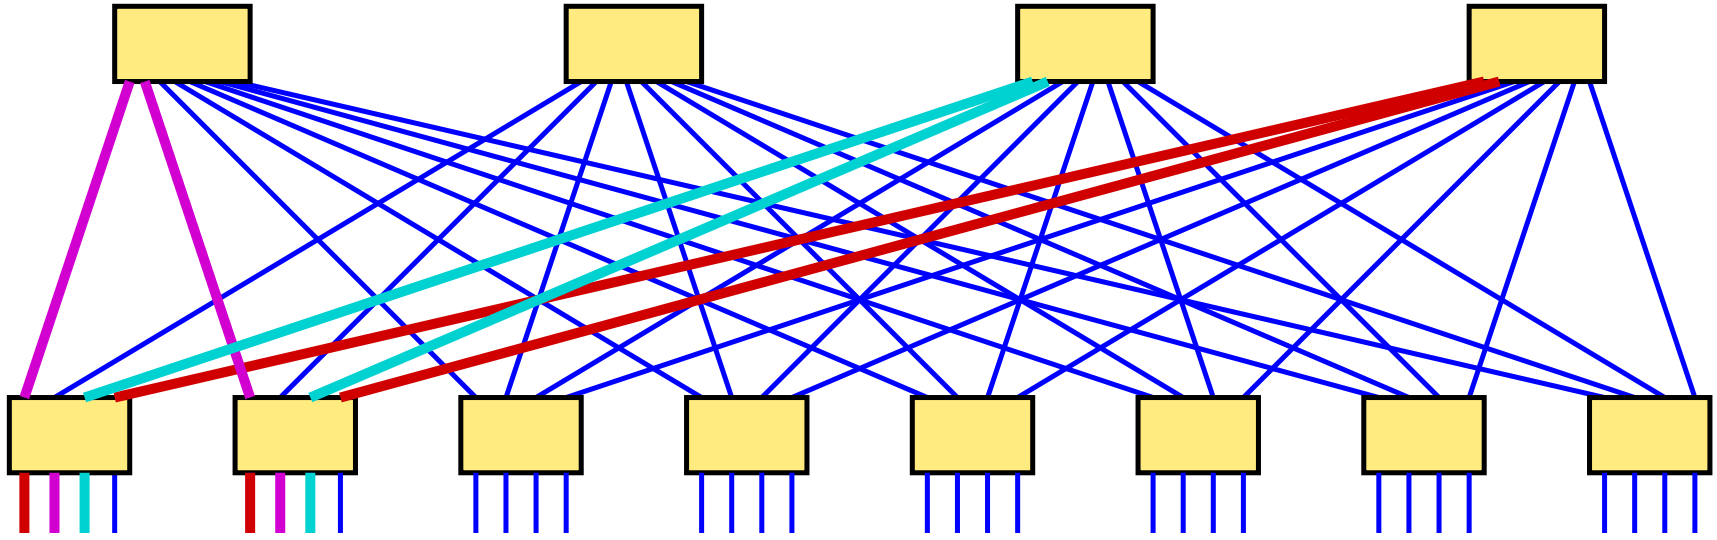

32 Knoten

Dynamische Verbindungsnetze: Clos-Netz

- Erweiterbares Netz auf Basis (kleiner) Kreuzschienenverteiler
  - maximal mögliche Bisektionsbandbreite
  - blockierungsfrei, wenn ex. Routen geändert werden dürfen
- Beispiel: Vernetzung 32 Knoten mit 8x8 Crossbars

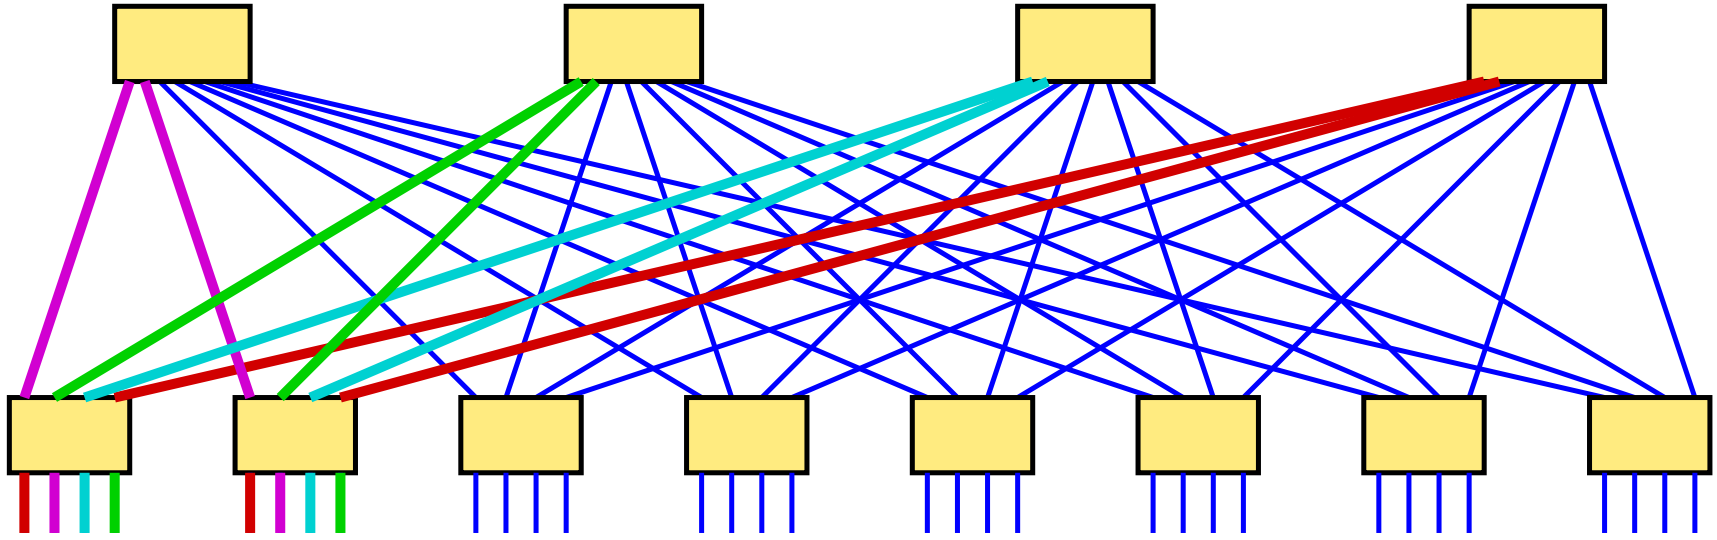

32 Knoten

9.2.2 Weiterleitungstechniken

- Ziel: Schnelle Weiterleitung in den Zwischenknoten
- Randbedingung: Netze mit hoher Bandbreite und großen Paketen
  - hoher Bedarf an Pufferplatz in den Switches
  - daher ggf. Flusskontrolle zwischen Switches
- Randbedingung: mehrere mögliche Wege im Netz
  - schnelle (einfache) Routing-Verfahren erforderlich
- Trend: Zentralisierung der Steuerung des Netzverkehrs
  - *Software Defined Networking*

9.2.2 Weiterleitungstechniken ...

- ***Store-and-Forward Routing***
  - Switch empfängt Paket vollständig, analysiert Header, gibt Paket an entsprechenden Ausgangsport weiter
  - Puffer für mindestens ein Paket notwendig
  - paketorientierte Flußkontrolle
  - Problem: hohe Latenz
- ***Virtual-Cut-Through Routing***
  - Switch schaltet Weg zum passenden Ausgangsport bereits nach Empfang des Headers durch
    - benötigt schnelle Forwarding-Logik
  - falls Ausgangsport belegt: Puffern des gesamten Pakets
  - paketorientierte Flußkontrolle

Vergleich von *Store-and-Forward* und *Virtual-Cut-Through*

Store–and–Forward–Routing

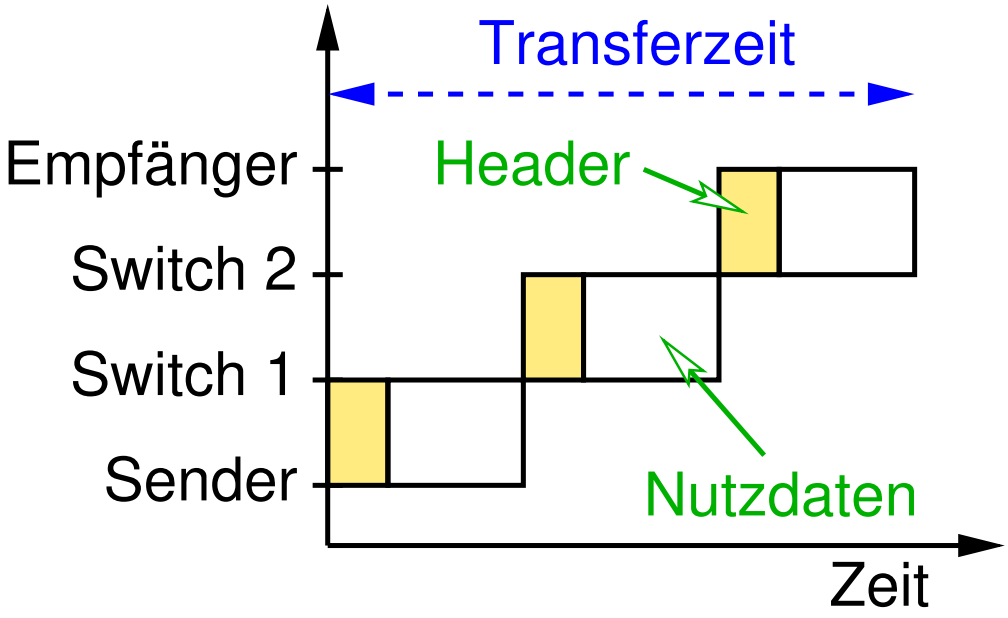

Virtual–Cut–Through–Routing

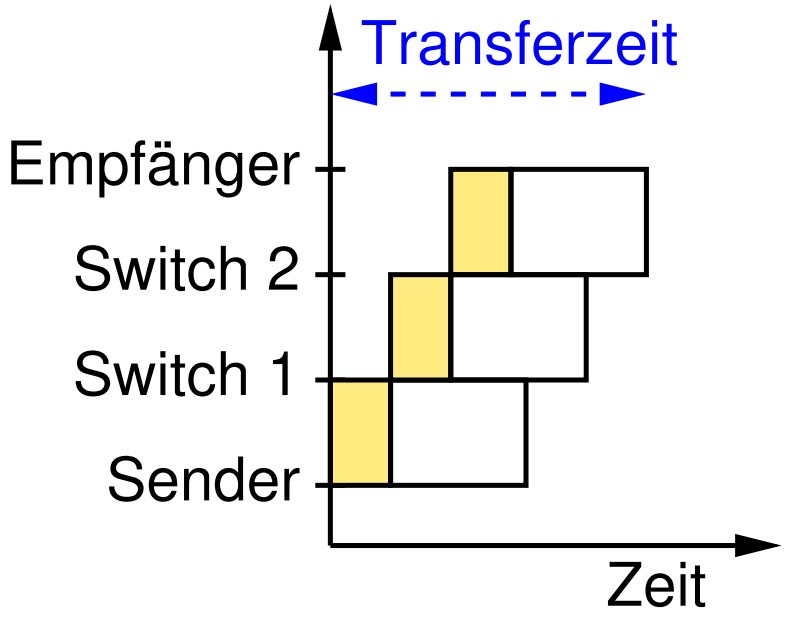

- Anmerkung: auch schnelle Ethernet-Switches verwenden heute *Virtual-Cut-Through*

9.2.2 Weiterleitungstechniken ...

- ***Wormhole-Routing***
  - Weiterleitung wie bei *Virtual-Cut-Through*
  - feingranulare Flußkontrolle auf Bitübertragungsebene
    - Flits (*flow control digits*), typ. 1-2 Bytes
  - in Switches nur Puffer für wenige Flits (abhängig von RTT)
  - bei belegtem Ausgangsport: Rückstau des Pakets
    - Flits enthalten keine Zieladresse $\Rightarrow$ Links bleiben blockiert
  - Vorteil: geringe Latenz, wenig Pufferbedarf
  - Nachteil: (größere) Gefahr von Deadlocks
    - Vermeidung durch entsprechende Routing-Algorithmen

Software Defined Networking (SDN)

- Schichtenaufbau eines Weiterleitungsknotens:
  - *Data Plane*: regelbasierte, tabellengesteuerte Weiterleitung von Frames/Paketen
  - *Control Plane*: Erstellung der Regeln bzw. Weiterleitungstabellen (z.B. durch Routing-Protokolle)
- Grundideen von SDN:
  - Trennung von *Data Plane* und *Control Plane*
  - Zentralisierung der *Control Plane*
    - Kommunikation zwischen zentralem Controller und Weiterleitungsknoten über das Netzwerk
    - Protokoll z.B. OpenFlow (über TLS / TCP)

Software Defined Networking (SDN) ...

- Vergleich der Architekturen:

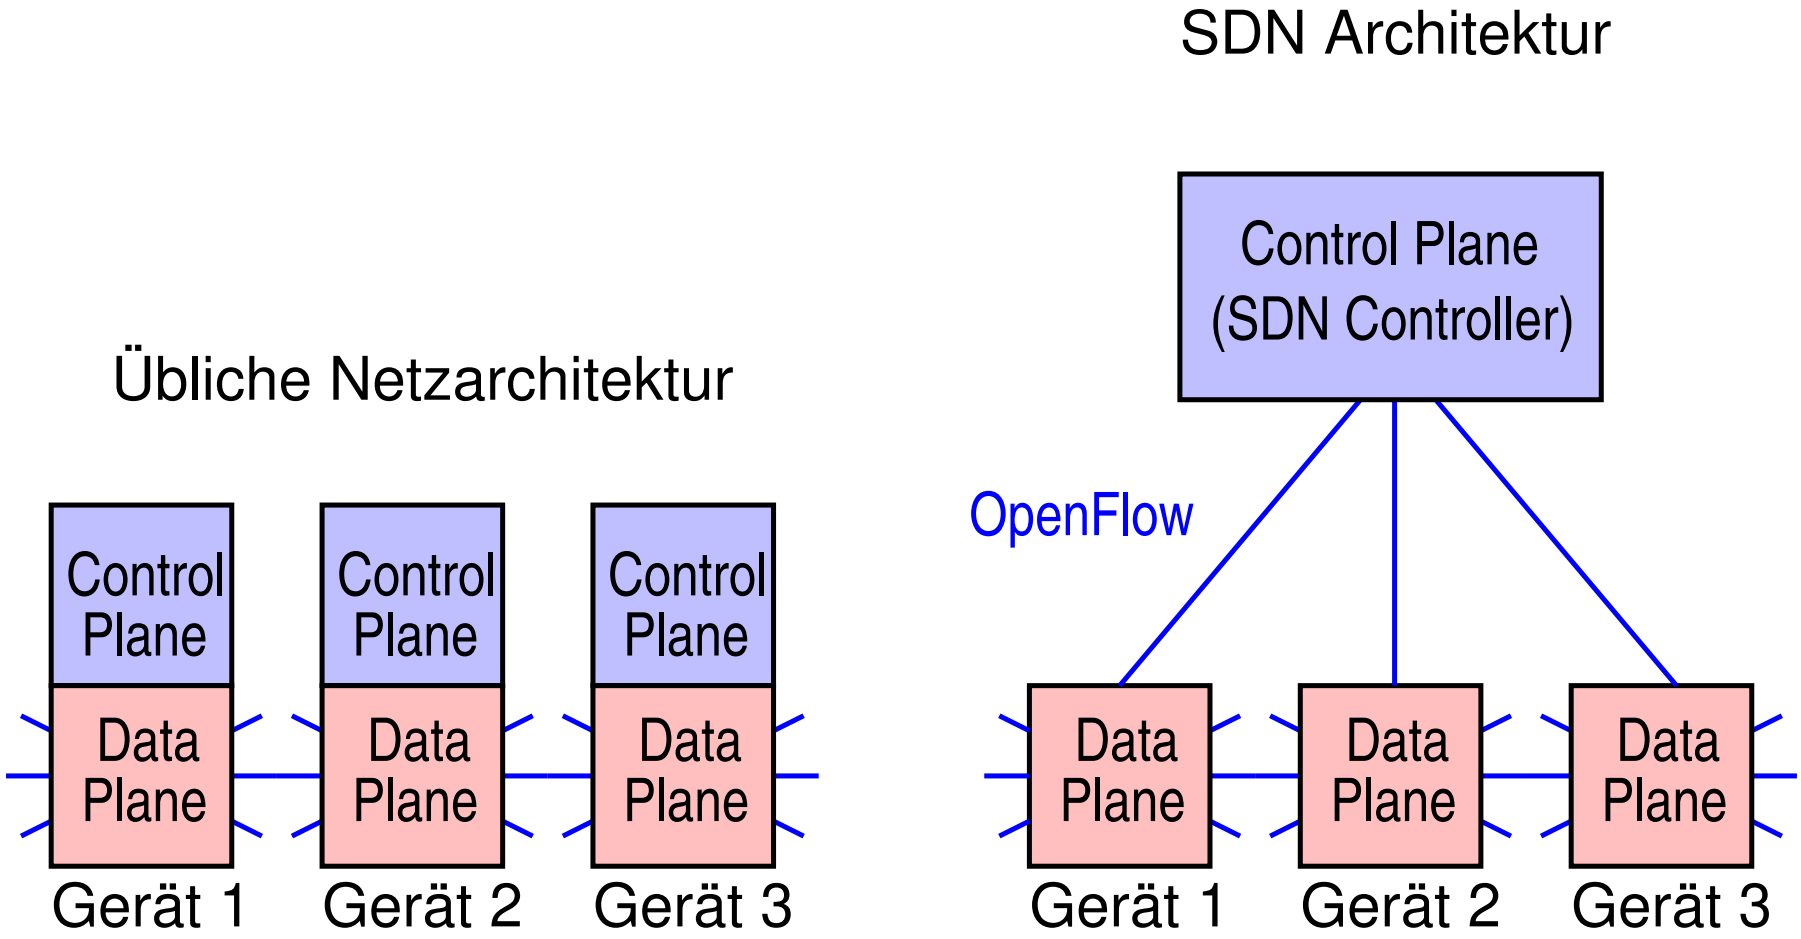

9.2.2 Weiterleitungstechniken ...

Vorteile von SDN:

- Flexiblere Weiterleitungsregeln
  - bei OpenFlow u.a. basierend auf:
    - Quell-/Ziel-MAC, VLAN-ID, VLAN Priorität
    - MPLS Label
    - Quell-/Ziel-IP-Adresse, Flow-Label, Protokoll
    - Quell-/Ziel-Port
  - Weiterleitung kann flussbasiert erfolgen
  - damit insbes. bessere QoS Unterstützung
- Intelligentere Controller möglich
  - z.B. können Weiterleitungsregeln automatisch aufgrund vorgegebener Policies erstellt werden

9.2.3 Protokolle der Anwendungsschicht

- Nachrichtenaustausch auf Anwendungsebene:
  - Kopieren von Daten aus dem Adreßraum des Senders in den Adreßraum des Empfängers

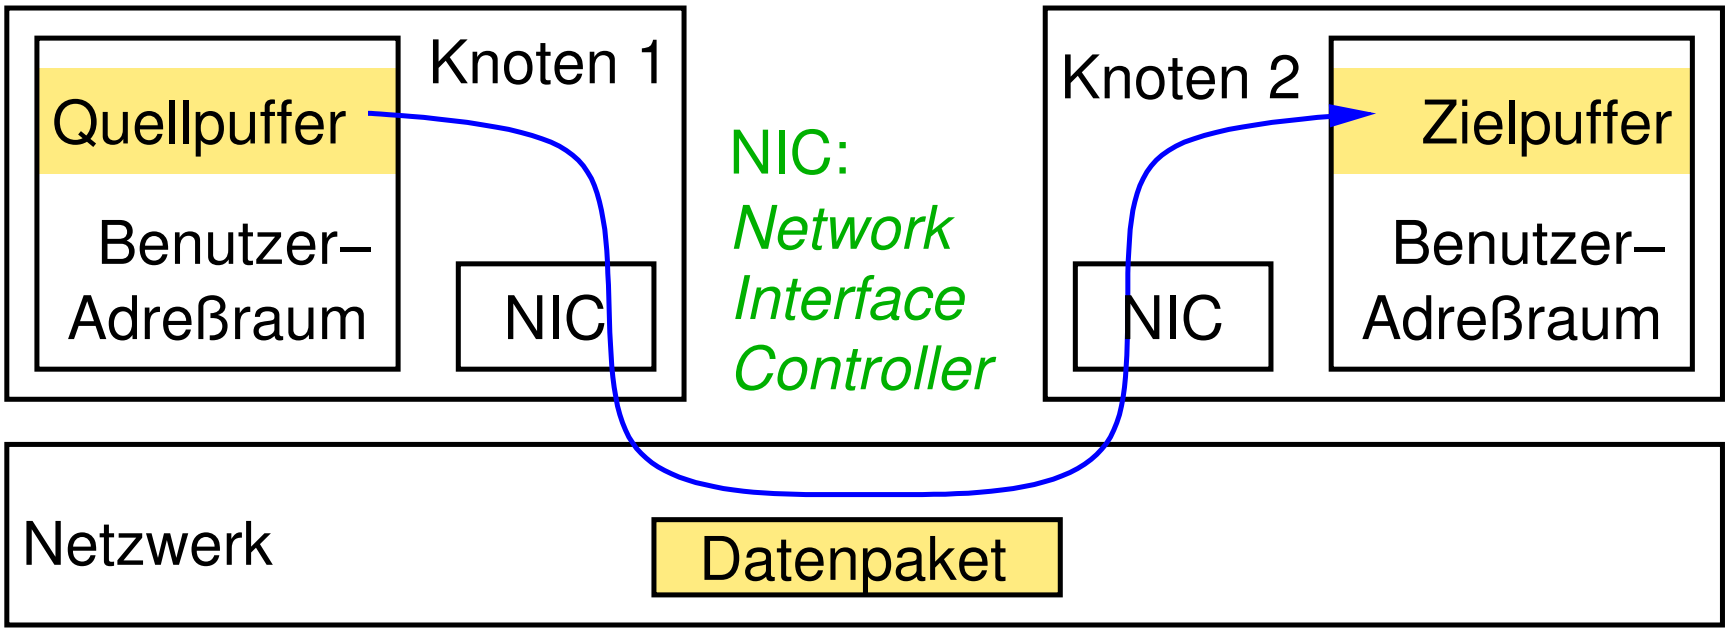

  - Problem: Adresse des Zielpuffers erst bekannt, wenn Empfänger bereits auf Nachricht wartet

Asynchrones, optimistisches Protokoll

- Senderprozeß verschickt Nachricht ohne Wissen über den Zustand des Empfängerprozesses
- Falls Empfangsoperation noch nicht gestartet: Kommunikations-bibliothek muß Nachricht zwischenspeichern
  - Probleme:
    - Speicherplatzbedarf
    - Zusätzliche Kopie bei Empfangsoperation
- Daher nur für kurze Nachrichten eingesetzt
  - lange Nachrichten mit synchronem Protokoll (∼ RTS/CTS) (oder Zusicherung des Senders, daß Empfänger bereit ist)

Synchrones Protokoll

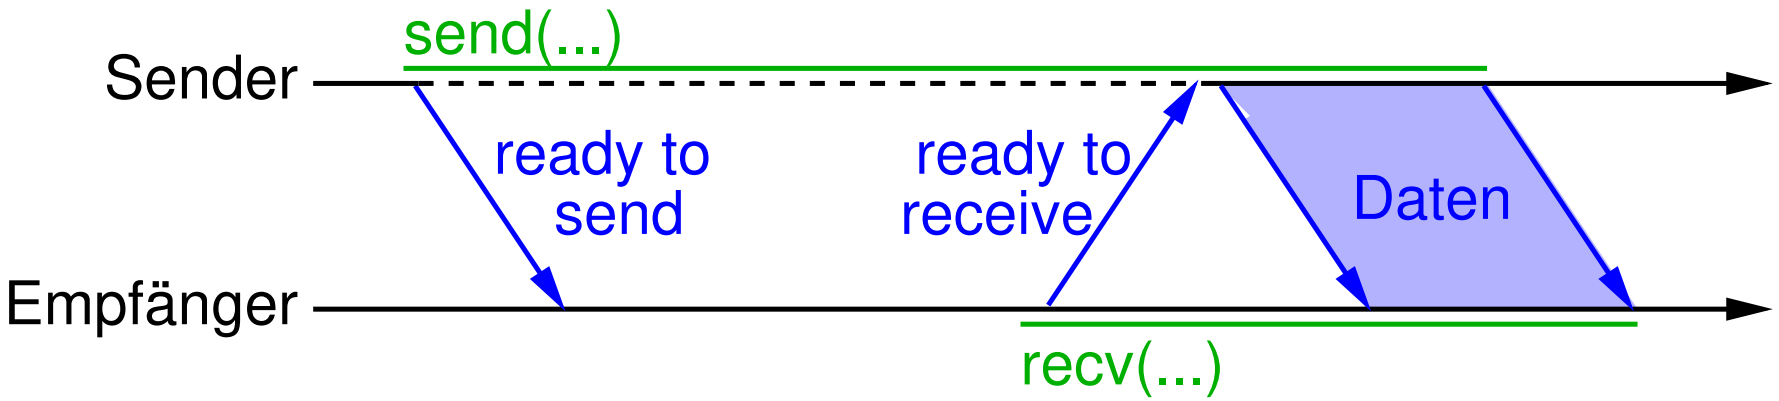

- Sender wird blockiert, bis Empfang gestartet wurde
- *ready-to-send*-Nachricht enthält Länge der Daten
- Vorteil:
  - kein zusätzlicher Pufferspeicher notwendig
  - Vermeidung einer Kopieroperation beim Empfänger
- Nachteil: evtl. höhere Latenz und Blockierung des Senders

9.2.4 *Remote DMA* und *OS Bypass*

- Kommunikation in geschichteten Systemen (hier IP):

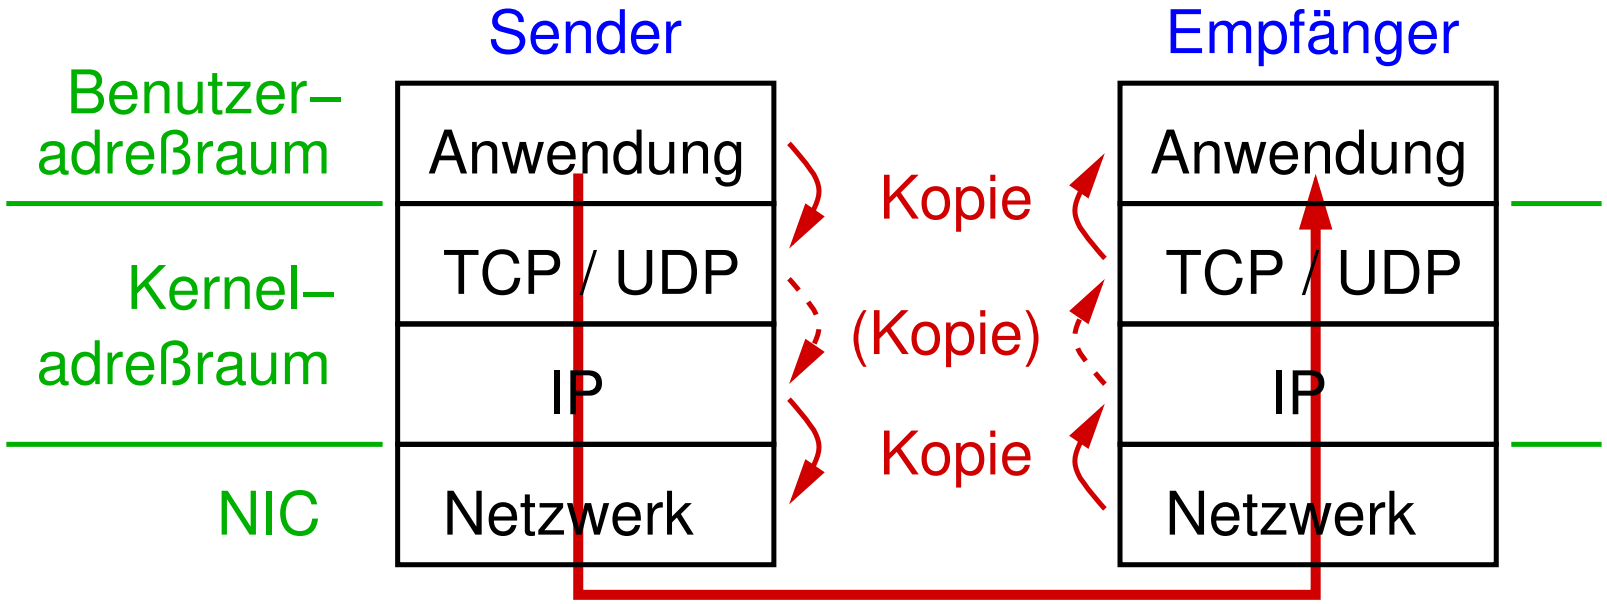

- Kopieroperationen limitieren Bandbreite, erhöhen Latenz, belasten CPU
- Ziel: Kopieren möglichst vermeiden („*zero copy*“)

Remote DMA

- DMA (*Direct Memory Access*)
  - DMA-Controller führt selbständig Datentransfers zwischen zwei Speicherbereichen durch (parallel zu CPU-Aktivität)
  - Auftrag durch die CPU: Quell- und Zieladresse, Länge
- *Remote DMA*
  - DMA-Transfer zwischen (Benutzer-)Speicherbereichen auf **verschiedenen** Rechnern über ein Netz
  - Operationen: RDMA Read, RDMA Write
    - Protokolle werden vollständig durch NIC realisiert
  - Betriebssystem muß Transfer nur noch anstoßen

Nachrichtenübertragung mit RDMA Read

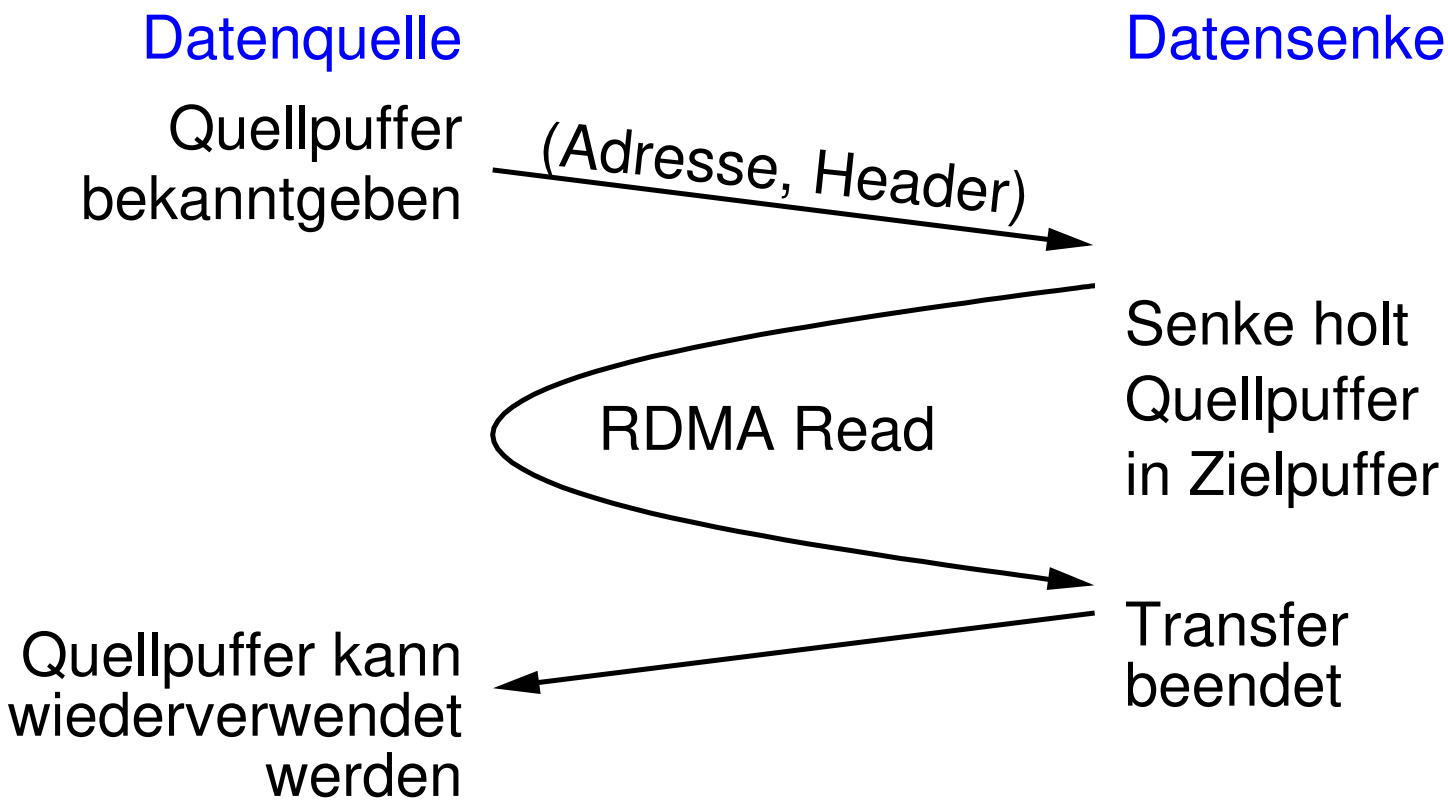

Nachrichtenübertragung mit RDMA Write

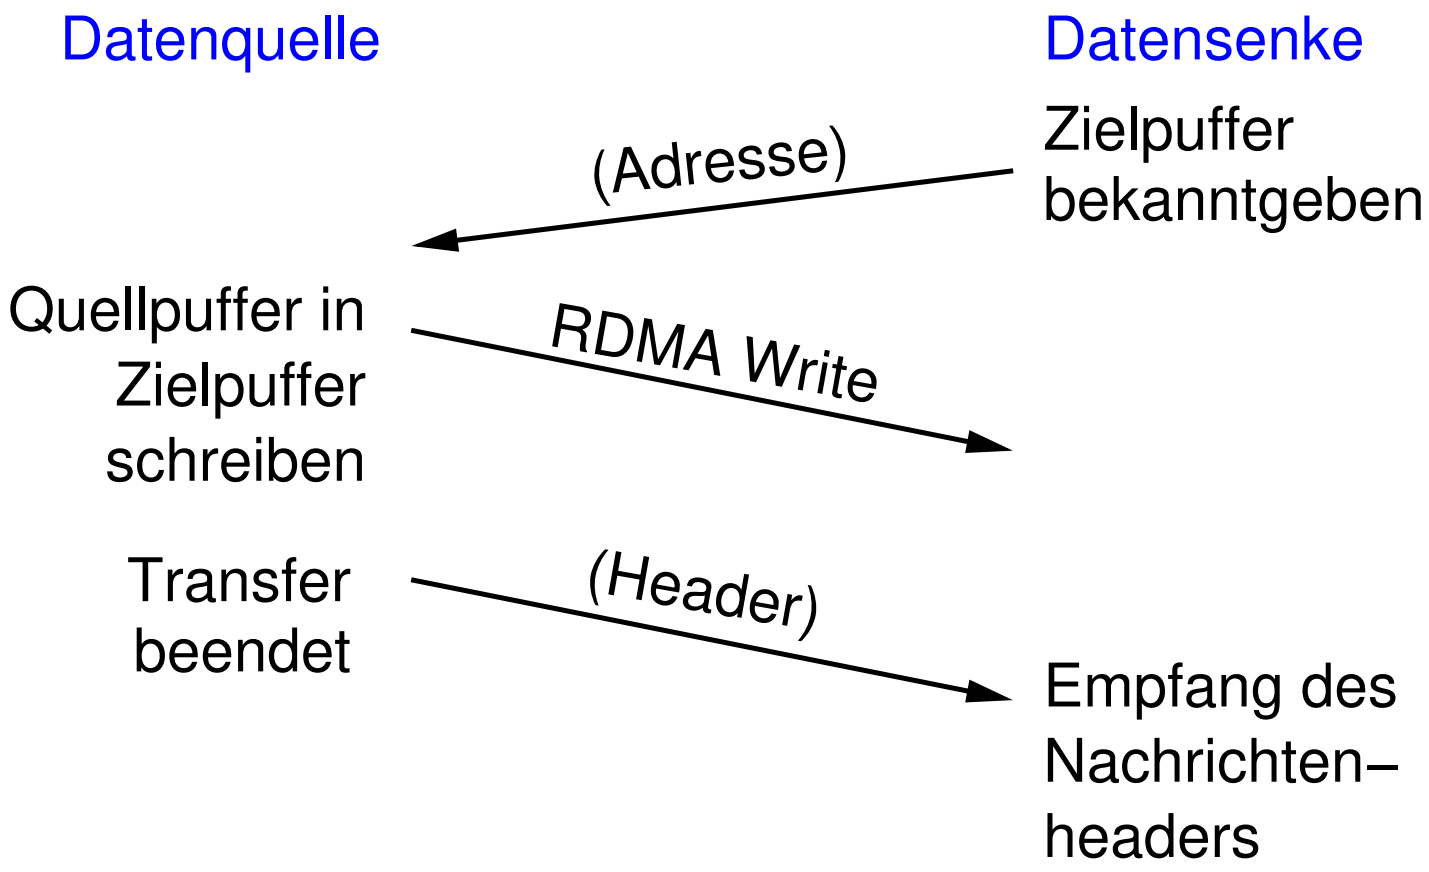

VIA: *Virtual Interface Architecture*

- Spezifikation von Intel, Compaq und Microsoft (1997)
- Ziel: Betriebssystem (BS) vollständig aus kritischem Pfad der Kommunikation entfernen
- Trennung von Steuerung und Daten
  - BS nur noch zum Aufsetzen von Verbindungen nötig (verbindungsorientiertes Protokoll)
  - Kommunikation ohne Einbeziehung des BS möglich
- Datenaustausch wird vollständig durch NIC realisiert, insbesondere Multiplexing und Demultiplexing
  - jeder Prozeß bekommt eigene virtuelle Schnittstelle zum NIC

VIA Operationen

- Initialisierung und Terminierung (über BS)
  - erzeugen der virtuellen Schnittstelle
- Registrierung und Deregistrierung von Puffern (über BS)
  - Puffer werden im physischen Adreßraum fixiert
- Verbindungsauf- und -abbau (über BS)
  - BS programmiert NIC und erzeugt Zugriffsschlüssel
- Datentransfer (direkt über virtuelle Schnittstelle)
  - Senden, Empfangen, RDMA Write, RDMA Read (optional)

VIA: Aufbau der virtuellen Schnittstelle

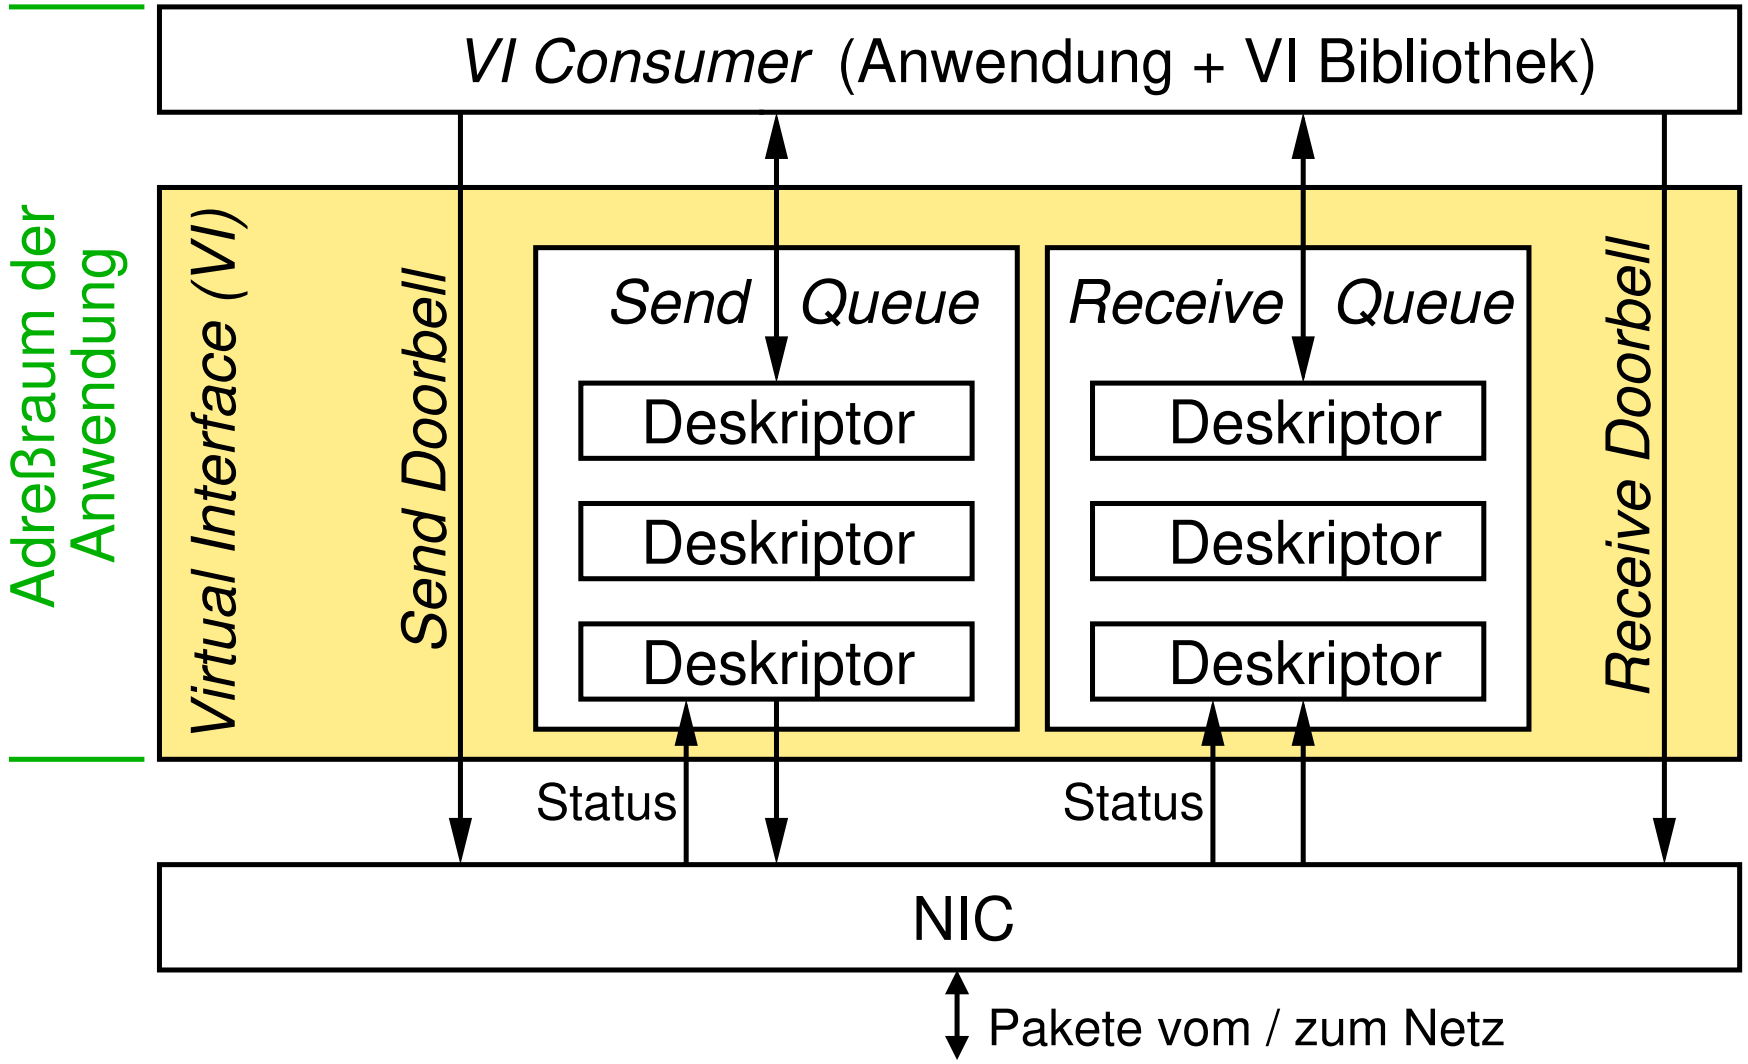

VIA: Ablauf eines Datentransfers

- Senden:
  - Deskriptor erzeugen (Adresse und Länge des Sendepuffers) und in *Send Queue* einreihen
  - *Send Doorbell* läuten
  - Statusbit im Deskriptor zeigt Ende der Operation an, Polling durch Anwendung (oder: blockierender BS-Aufruf)
- Empfangen: analog
  - eingehende Pakete ohne passenden Deskriptor werden verworfen
- RDMA Write / Read:
  - Initiator gibt auch Pufferadresse im anderen Knoten an

9.3 Beispiel: Infiniband

- Ziel: Hochgeschwindigkeitsnetz für Cluster
  - Kommunikation zwischen den Knoten
  - Anbindung von E/A-Geräten (Alternative zu E/A Bussen)
- Leistungsdaten:
  - Bandbreite bis zu 300 Gb/s
  - Hardware-Latenz pro Switch: ca. 100ns
  - zwischen Anwendungen: Latenz 1,32 μs, Durchsatz 952 MB/s (mit 8 Gb/s Link)
- Infiniband umfasst die OSI-Schichten 1-4
  - Subnetze beliebiger Topologie, ggf. über Router verbunden
    - häufig: *Fat Tree*, Clos-Netzwerke, 3D-Torus, ...
- Unter den 500 schnellsten Rechnern der Welt: 40% mit Infiniband (45% mit 10G Ethernet)

Komponenten eines Infiniband-Subnetzes

- *Host Channel Adapter*: Netzwerkkarte
- *Target Channel Adapter*: Brücke zu E/A-Geräten
  - Schnittstelle zu SCSI, *Fibre Channel*, Ethernet, ...
- Switches (*Virtual-Cut-Through*)
- Subnetz Manager
  - zentrale (ggf. redundante) Komponente
  - Konfiguration der Switches (Weiterleitungstabellen!)
  - Netzwerkmonitoring

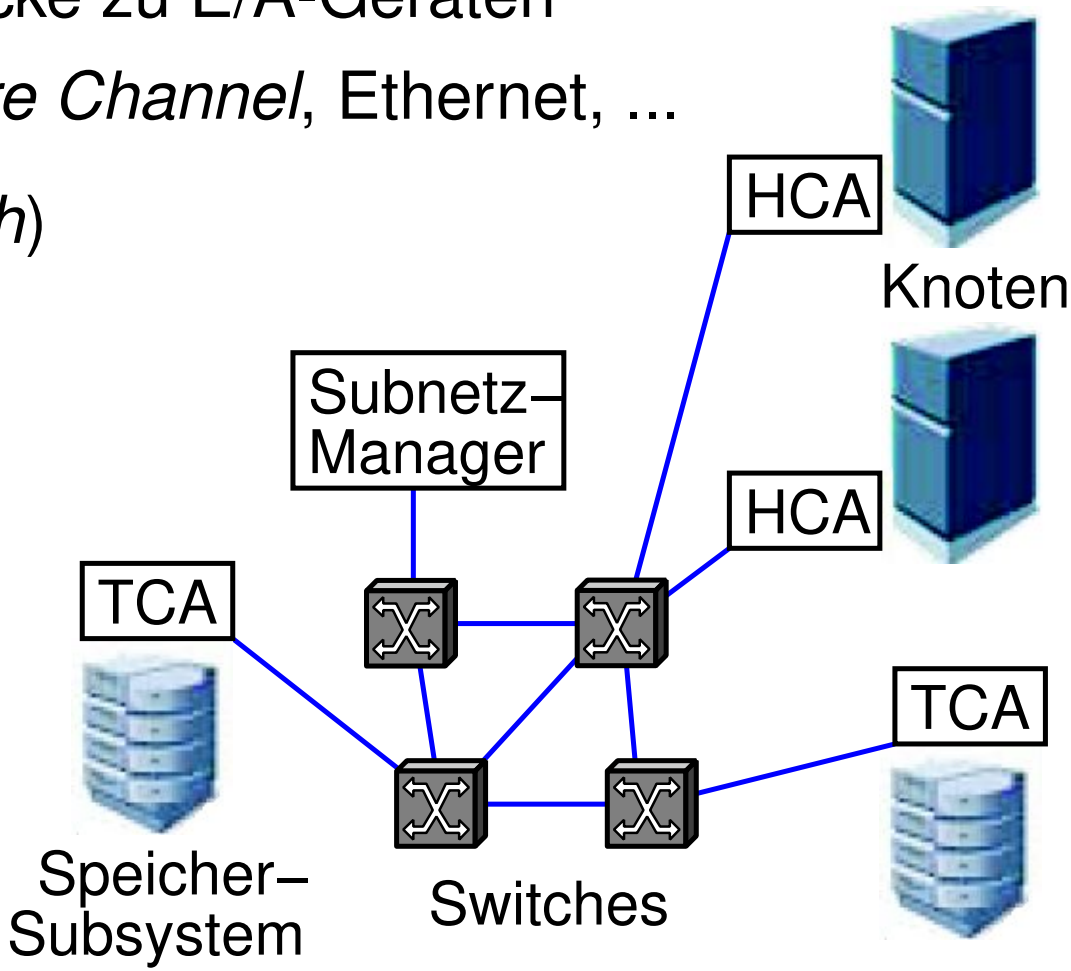

Adressierung

- LID (*Local ID*): 16-Bit Adresse innerhalb des Subnetzes
  - wird vom Subnetz Manager zugewiesen
- GUID (*Globally Unique ID*): weltweit eindeutige 64-Bit Adresse
  - analog zur MAC-Adresse bei Ethernet
- GID (*Global ID*): gültige IPv6 Adresse
  - z.B. gebildet aus Subnetz-Präfix und GUID

Paketformat

- Lokaler und globaler Header (Schicht 2 bzw. 3), ggf. weitere
- Zwei CRCs: für Ende-zu-Ende und *Hop-by-Hop* Fehlererkennung
- Wählbare MTU: 256 B, 1 KB, 2 KB, 4 KB

Bitübertragungsschicht

- Unterschiedliche Datenraten
  - SDR (2 Gb/s), DDR (4 Gb/s), QDR (8 Gb/s), FDR (14 Gb/s), EDR (25 Gb/s)
- Verbindungsleitungen: Kupfer oder Glasfaser
  - ein Kabelpaar (bzw. eine Faser) pro Übertragungsrichtung
  - Bündelung von 4 bzw. 12 Leitungen möglich (4x / 12x Link)
  - max. Länge ca. 10-17m (Kupfer), 125m-10km (Glasfaser)
- *Auto-negotiation* für Datenrate und Linkbreite
- Codierung:
  - 8B10B bei SDR, DDR und QDR; 64B66B bei FDR und EDR
  - Kontrollcodes für Framing, Auto-negotiation, Training, ...

Sicherungsschicht

- Physische Links unterteilt in 2-16 virtuelle Verbindungen (*Virtual Lanes*, VLs)
  - VLs besitzen unterschiedliche Prioritäten (für QoS)
  - jeweils eigene Warteschlange, *Weighted RR* Scheduling
  - VL 15 (höchste Priorität) reserviert für Netzwerkmanagement
- Innerhalb jeder VL (außer VL 15)
  - paketweise Flußkontrolle
  - Überlastkontrolle (ähnlich DECbit, optional)

Transportschicht

- Verbindungslose und verbindungsorientierte Dienste
  - jeweils unzuverlässig und zuverlässig
  - zusätzlich *Raw*-Modus zum Transport von z.B. IPv6 Paketen
  - Paketierung und Sicherungsprotokoll in Hardware realisiert
- Verbindungsorientierte Dienste unterstützen Fehlertoleranz
  - Aufbau von zwei alternativen Verbindungen möglich
    - automatisches Umschalten im Fehlerfall
  - Anhalten („Leerlaufen lassen“) der Warteschlagen möglich
    - Verbindung wird dann durch Software umkonfiguriert
- Neben Send/Receive auch RDMA (Read/Write/Atomics)
  - jeweils mit *OS-Bypass* (ähnlich zu VIA)

9.4 Fazit / Zusammenfassung

- Optimierung von (Bisektions-)Bandbreite und Latenz
  - Kosten (oft) sekundär
- Heute Vernetzung i.d.R. mit *Crossbar*-Switches
  - blockierungsfrei
  - *Virtual-Cut-Through* bzw. *Wormhole*-Routing
    - feingranulare Flußkontrolle auf Bitübertragungsebene
  - bei höherer Knotenzahl: z.B. Clos-Netze
- Trend: *Software Defined Networking*
- Zur Reduktion der Latenz:
  - Einsatz von RDMA („*zero copy*“)
  - Betriebssystem-*Bypass*, z.B. VIA