Rechnernetze & Verteilte Systeme

Ludwig-Maximilians-Universität München

Sommersemester 2016

Prof. Dr. D. Kranzlmüller

MNM TEAM

Kapitel 3: Transportschicht

ISO/OSI-Schicht 4

(Engl.: Transport layer)

MNM TEAM

Inhalt von Kapitel 3

1. Ziele und Rahmenbedingungen des Transportdienstes
2. Techniken zur Realisierung verbindungsorientierter Ansätze
3. Flussteuerung und Staukontrolle
4. Ports und Sockets
5. Transmission Control Protocol (TCP)
6. User Datagram Protocol (UDP)

Einordnung von Kapitel 3

- Kapitel 2: Querschnittsthema „Namen und Adressen“
  - inkl. Dienst der Anwendungsschicht - Domain Name System (DNS)
- Dienste der Anwendungsschicht benötigen
  - **zuverlässige** Übertragung von Nachrichten
  - über **unzuverlässige** Transitnetze
- Aufgabe der Transportschicht:
  - Bereitstellung der gewünschten Zuverlässigkeit unter Verwendung der Dienste der Vermittlungsschicht (Kapitel 4)

Kapitel 3.1
Ziele und Rahmenbedingungen des Transportdienstes

Ende-zu-Ende Argument (Saltzer et al., 1984)

- Grundproblem:
  - Aus Sicht der Nutzer von Endsystemen: Transitsysteme allgemein außerhalb der eigenen Kontrolle und oft unzuverlässig (vgl. Kapitel 1.8: Fehlertypen)
- Ende-zu-Ende Argument:
  - um mit der Unzuverlässigkeit der Transitsysteme umzugehen ➔ akzeptieren und umfangreiche Fehlerbehandlung in den Endsystemen.

Ende-zu-Ende Betrachtung als Grafik (Wiederholung)

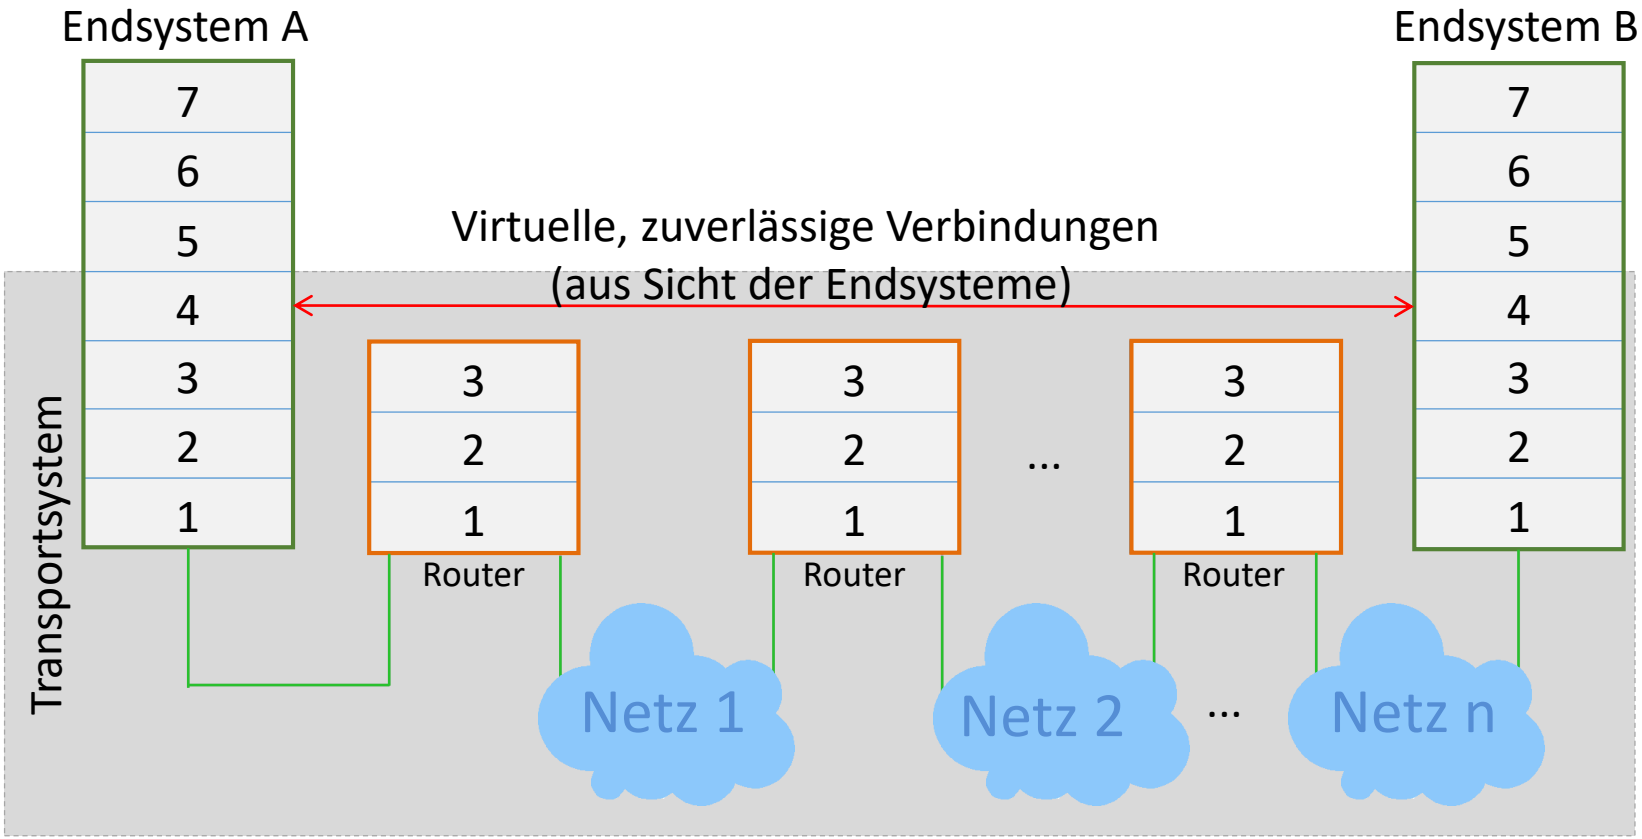

Ende-zu-Ende Betrachtung als Grafik (Wiederholung)

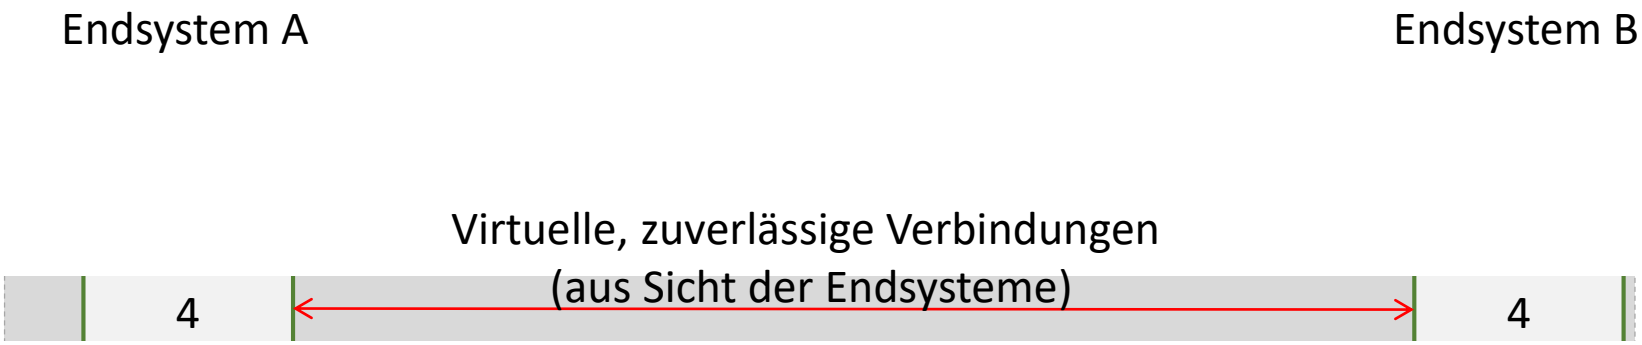

Vermittlungsschicht als Rahmenbedingung (1/2)

- Transportschicht bietet Anwendungssystem ihre Dienste *unter Verwendung der Dienste der Vermittlungsschicht* an
- Zum Verständnis: Vorschau auf Dienste der Vermittlungsschicht:
  - Ausführliche Behandlung im Kapitel 4
  - Protokolle der Vermittlungsschicht (z.B. IP) arbeiten i.d.R. nach dem *best effort* Prinzip - nach besten Möglichkeiten wird versucht, einzelne Pakete möglichst effizient an ihr Ziel zu bringen
  - Bei Überlastung oder wenn kein Weg zum Ziel gefunden wird, können Pakete verworfen werden

Vermittlungsschicht als Rahmenbedingung (2/2)

- Zum Verständnis: Vorschau auf Dienste der Vermittlungsschicht:
  - Nicht vorhersehbare Verzögerungen können bei der Zustellung einzelner Pakete auftreten (z.B. weil ein einzelnes Paket einen anderen Weg nimmt)
  - Aufgrund der Gegebenheiten noch tiefer liegender Schichten gibt es allgemein eine maximale Paketgröße (MTU – engl.: Maximum Transmission Unit*), die auf einem gegebenen Pfad übertragen werden kann.
- Zusammenfassung Vermittlungsschicht:
  - Verzögerungen kommen vor
  - Pakete können nicht beliebig groß sein
  - Die Fehlerarten (Verfälschung, Verlust, Duplikate, falsche Reihenfolge) aus dem Kapitel 1.8 kommen vor

* Oft auch „Maximum Transfer Unit“

Verbindungslos oder Verbindungsorientiert?

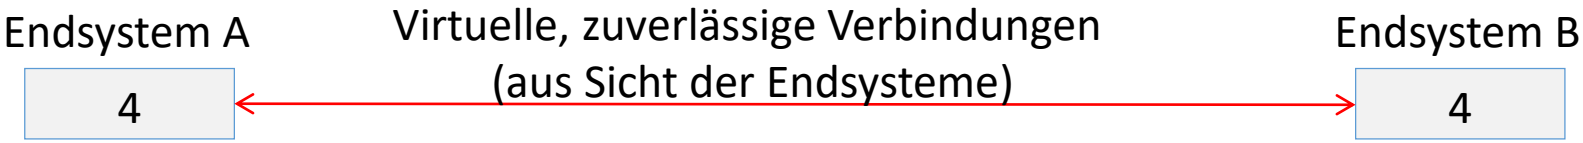

- Grundsätzlich: Realisierung des Transportdienstes:
- **Verbindungslos**:
  - Vergangenheit irrelevant
  - geringe Möglichkeiten zur Fehlererkennung/-korrektur
  - aber (aufgrund des geringen Verarbeitungsaufwands) ➔ hohe **Performanz**
- **Verbindungsorientiert**:
  - Vergangenheit relevant (Kontext)
  - umfangreiche Fehlerbehandlung (**Zuverlässigkeit**)
  - (notwendigerweise) höherer Verarbeitungsaufwand

Kapitel 3.2
Techniken zur Realisierung verbindungsorientierter Ansätze

Sequenznummern, Quittungen, Fenstertechnik

Drei-Wege-Handschlag

Motivation/Einordnung

- In diesem Unterkapitel: *allgemeine Techniken* zur *Realisierung* verbindungsorientierter Dienste
  - kommen sowohl in verbindungsorientierten *Transportprotokollen* (TCP)
  - als auch in verbindungsorientierten Protokollen anderer Schichten zum Einsatz.
- Es handelt sich um schichtunabhängige Konzepte

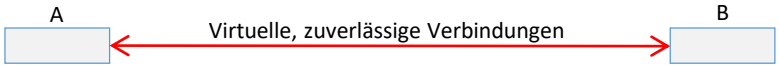

Techniken zur Realisierung verbindungsorientierter Dienste

- Sequenznummer und Quittungen
  - Größe des Sequenznummernraumes
  - Maximale Lebensdauer von Nachrichten
  - Fenstertechnik
- Verbindungsaufbau/-abbau
- Flusssteuerung und Staukontrolle

- Ports und Sockets
- TCP / UDP

Sequenznummern und Quittungen

- Verbindungsorientierter Protokolle werden oft mit Sequenznummern realisiert
- Wenn gesendete Nachrichten durchnummeriert werden, können verloren gegangene Nachrichten neu angefordert, Duplikate verworfen, und Nachrichten in falscher Reihenfolge richtig angeordnet werden.
- Wenn zusätzlich Quittungen (der Empfänger bestätigt empfangene Nachrichten) verwendet werden, kann außerdem die **Flusssteuerung** geregelt werden:
  - Der Sender schickt erst dann weitere Nachrichten, wenn ausreichend viele, bereits gesendete Nachrichten quittiert wurden.
  - So wird verhindert, dass ein langsamer Empfänger (oder auch ein langsames Transitsystem) von einem schnellen Sender überlastet wird.

Sequenznummern Notation

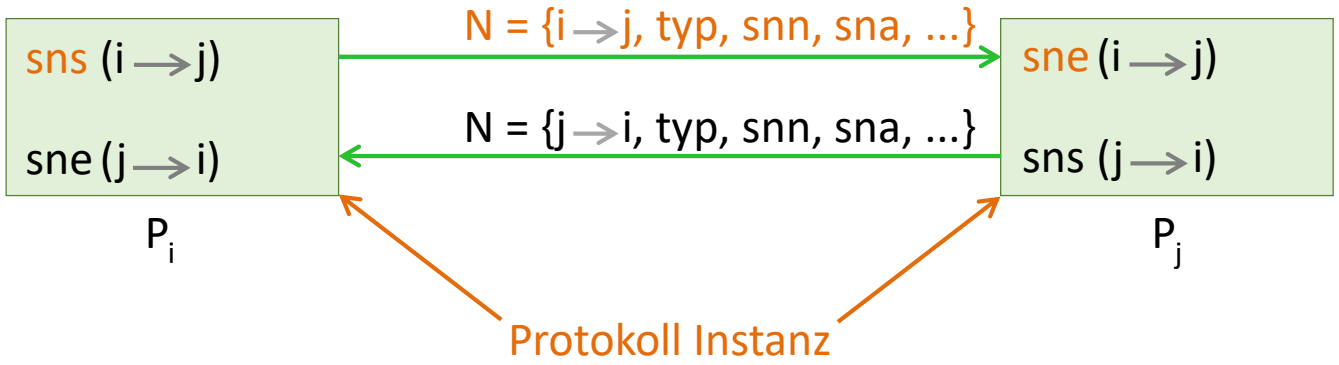

sns (i → j): Nummer der nächsten zu sendenden Nachricht

sne (i → j): Nummer der nächsten erwarteten Nachricht

N = {i → j, typ, snn, sna...} = Nachricht

i → j: Verbindungs- und Richtungskennung

typ: ∈NN, ACK, NAK, SYN, CLS,...
mit NN normale Nachricht, ACK/NAK pos./neg. Quittung
SYN Synchronisations-/Aufbauwunsch, CLS engl.: Close/Abbauwunsch

snn: Sequenznummer einer Nachricht

sna: Sequenznummer der nächsten erwarteten Nachricht (= sne)

Quittungsvarianten

- Quittungen können positiv oder negativ sein („Die PDU Nr. n ist angekommen/nicht angekommen“).
- Sammelquittung: Einzelne Quittung für mehrere aufeinander folgende PDUs („Die PDUs bis Nr. n sind angekommen“).
- Selektive Quittung: Nur eine Untermenge der Nachrichten wird quittiert.
- Quittungen werden oft in Verbindung mit Timern verwendet (erfolgt eine erwartete Quittung nicht innerhalb eines gewissen Zeitfensters, wird neu gesendet).

Beispiel:

Nachricht

```
The quick brown fox jumps over the lazy frog.
```

PDU = Protocol Data Unit

Sequenznummer (snn): 1 Ziffer pro PDU

UD =

1	h
2	e
3	␣
4	q
5	u
6	i
⋮	

5?

0,1,2,3,4,5,6	✓

6	✓

Quittung

Größe des Sequenznummernraumes (1/2)

- Sequenznummernräume sind i.d.R. **endlich** (und haben meist eine feste Größe).
- Im Beispiel:
  - 10 unterschiedliche Sequenznummern (0,1,...,9).
  - Nachricht 11 verwendet eine Sequenznummer (=0), die bereits früher einmal verwendet wurde.
  - **Gefahr**: **verzögerte Nachricht** mit derselben Sequenznummer (=0) ist noch im Netz unterwegs
  - Würde die verzögerte Nachricht vor Nachricht 11 ankommen:
    - Empfänger interpretiert die falsche Nachricht als erwartete Nachricht 11 und
    - verwirft danach ankommende Nachricht 11 als Duplikat

Größe des Sequenznummernraumes (2/2)

- *Wie lange kann eine Nachricht im Netz unterwegs sein?*
- **Gesucht**: Mechanismus, um die Dauer der maximalen Verzögerung einer Nachricht zu bestimmen
- Wähle Sequenznummernraum so, dass innerhalb der maximalen Verzögerung nie dieselbe Sequenznummer doppelt verwendet werden muss
- **Möglichkeit**: Sequenznummernraum > Senderate x RTD (engl.: Round Trip Delay).
- Beispiel:
  - Sei RTD = 15s, Senderate 200/s
  - Benötigt: 12 Bits zur Codierung der Sequenznummern

Maximale Lebensdauer von Nachrichten

- Begrenzung der Lebensdauer verzögerter Nachrichten auf ein Maximum:
  - alle Nachrichten erhalten einen **Zeitstempel** und eine **Lebensdauer**
  - zu alte Nachrichten werden einfach verworfen
- Erfordert aufwändige Schätzung oder bestenfalls synchronisierte Uhren.

- Andere Möglichkeit: Zählung der Hops (“Sprünge“)

Idee Fenstertechnik (Tanenbaum: „Schiebefensterprotokoll“)

- Festlegung eines Teilbereiches des Sequenznummernraumes als
  - Sendefenster:
    - Größe w
    - Beginn Sendefenster: zuletzt (lückenlos) quittierte Sequenznummer snq
    - Sender sendet nur Nachrichten mit Sequenznummern innerhalb des Sendefensters (Flusssteuerung/Staukontrolle)
  - Empfangsfenster
    - Größe w*
    - Beginn Empfangsfenster: nächste erwartete Sequenznummer (sne)
    - Nachrichten mit Sequenznummern außerhalb des Empfangsfensters werden vom Empfänger verworfen
- Fenster werden verschoben, wenn Nachrichten quittiert oder empfangen werden

Fenstertechnik als Animation

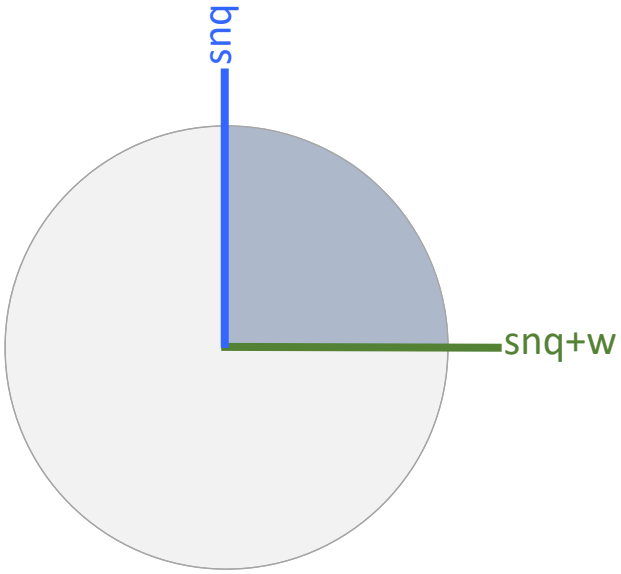

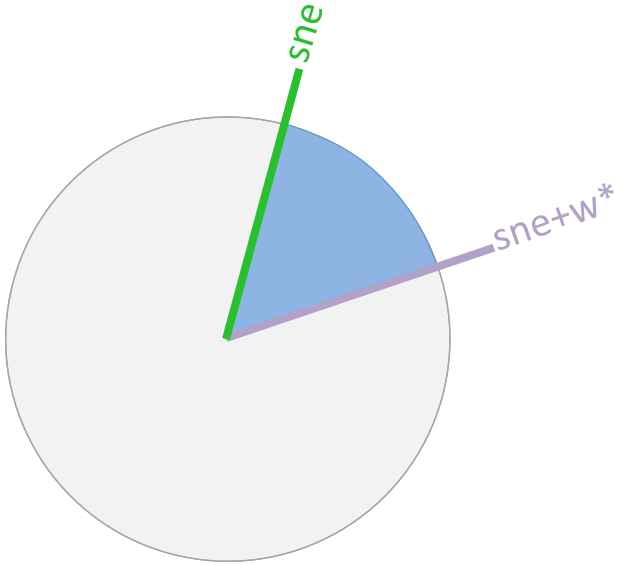

snq

snq + w

sne

snq + w*

- Lage Sendefenster und Empfangsfenster i.A. verschieden
- snq ≤ sne ≤ snq +w
- w und w*können differieren
- Fenstertechnik impliziert Flusssteuerung
- Sequenznummern i.A. schichtspezifisch eingesetzt

Nachricht

```
The quick brown fox jumps over the lazy frog.
```

Quelle

0	T
1	h
2	e
3	␣
0	q
1	u

⋮

Senke

⋮

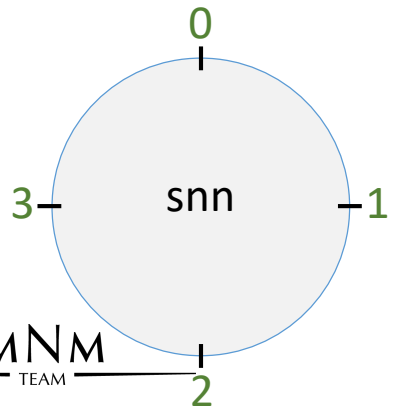

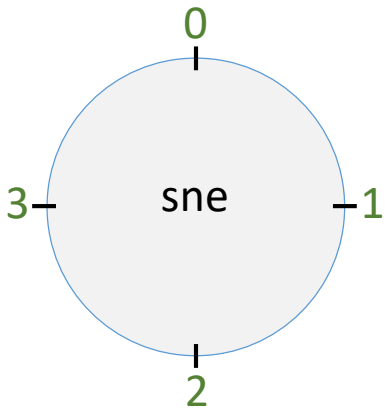

MNM TEAM

- Problem: Ist snn neu oder Duplikat?
- Ansatz: Fenstertechnik

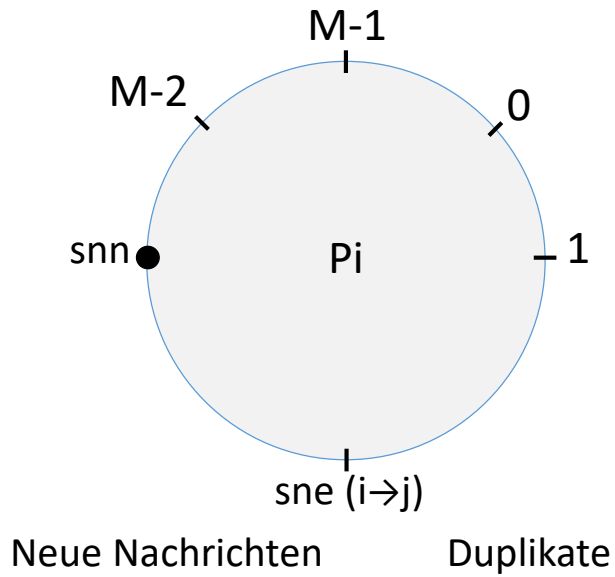

Nachricht

```
The quick brown fox jumps over the lazy frog.
```

Quelle

1	u

Senke

0	T
1	h
2	e
3	␣
0	q

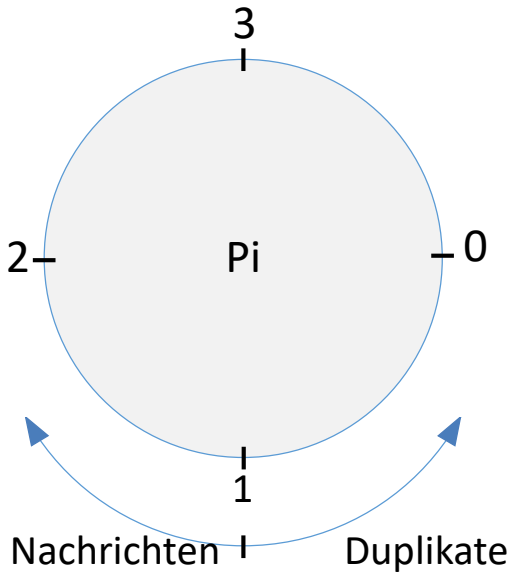

MNM TEAM

Vorteile der Fenstertechnik

- Fenstertechnik ist sehr allgemein und kann flexibel an die Bedürfnisse konkreter Protokolle angepasst werden
- Fenstergröße = 1: „Stop-and-Wait“ Protokoll.
- Je nach Protokoll: dynamische Anpassung von Fenstergrößen, u.a. zur Flusssteuerung
- Beispiel: beim Sender oder Empfänger ist begrenzter Pufferspeicherplatz aufgebraucht

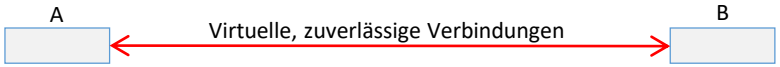

Techniken zur Realisierung verbindungsorientierter Dienste

- Sequenznummer und Quittungen
  - Größe des Sequenznummernraumes
  - Maximale Lebensdauer von Nachrichten
  - Fenstertechnik
- Verbindungsaufbau/-abbau
- Flusssteuerung und Staukontrolle

- Ports und Sockets
- TCP / UDP

Verbindungsaufbau

- **Sonderfall**: Synchronisation am Beginn einer Kommunikation
- *Wie wird einem Kommunikationspartner bei einer neuen Verbindung die erste verwendete Sequenznummer mitgeteilt?*
- **Problem**: auf Empfängerseite müssen verzögerte Duplikate alter Aufbauwünsche von aktuellen Aufbauwünschen unterschieden werden
- Lösungsansatz: Handschlag-Protokoll

Zwei-Wege-Handschlag

Ein einfache Bestätigung eines Aufbauwunsches (2-Wege-Handschlag) (SYN und SYNACK) reicht u.U. nicht aus

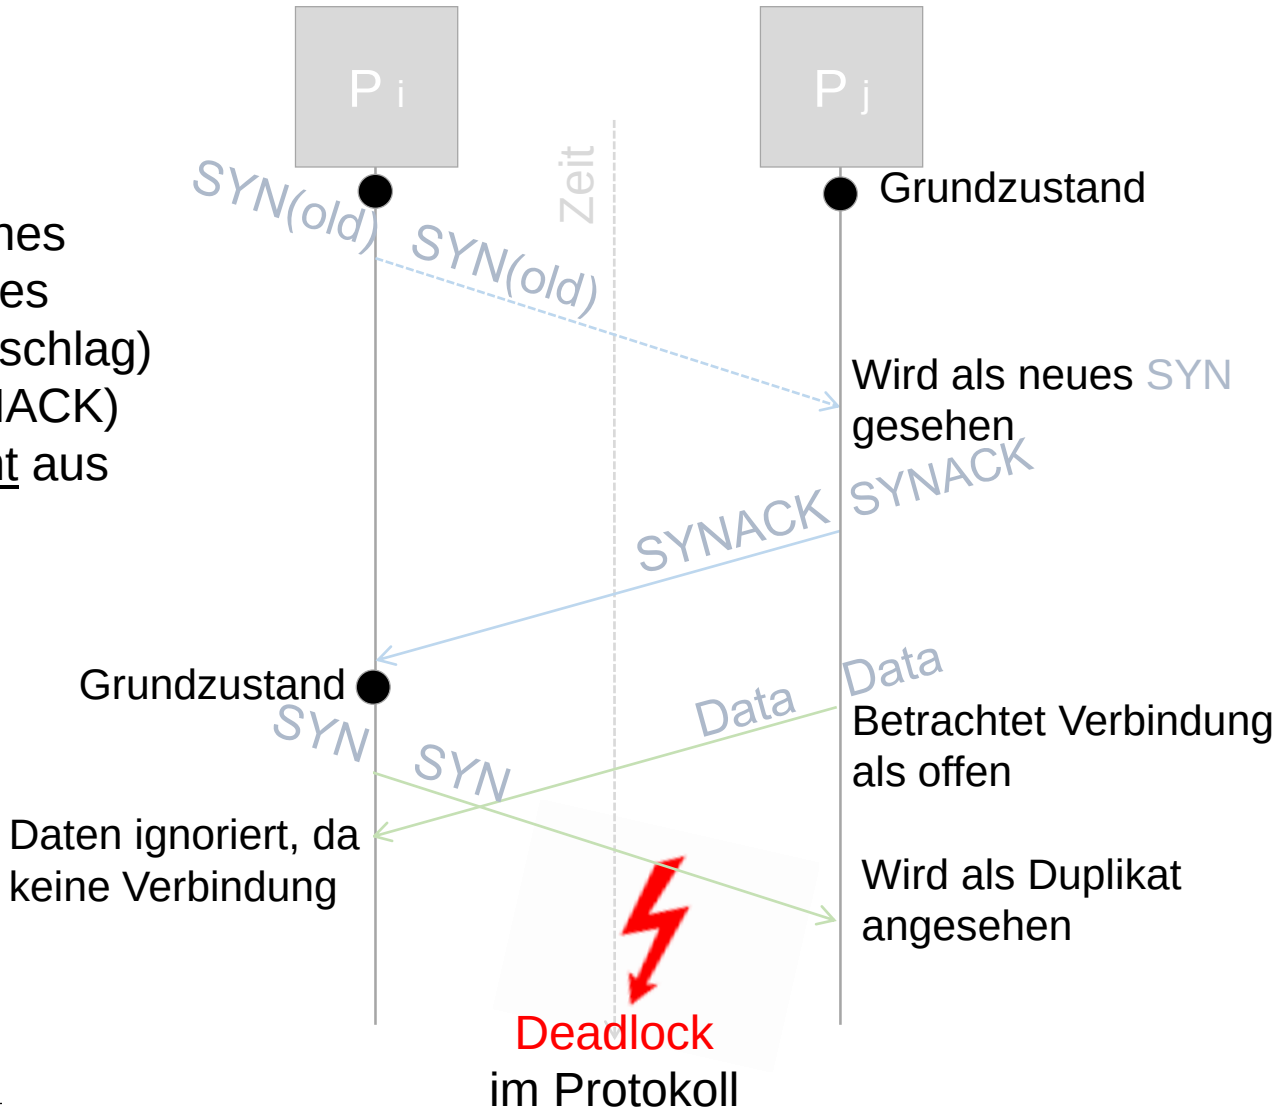

Drei-Wege-Handschlag (1/2)

Verbesserter Ansatz:
Drei-Wege-Handschlag

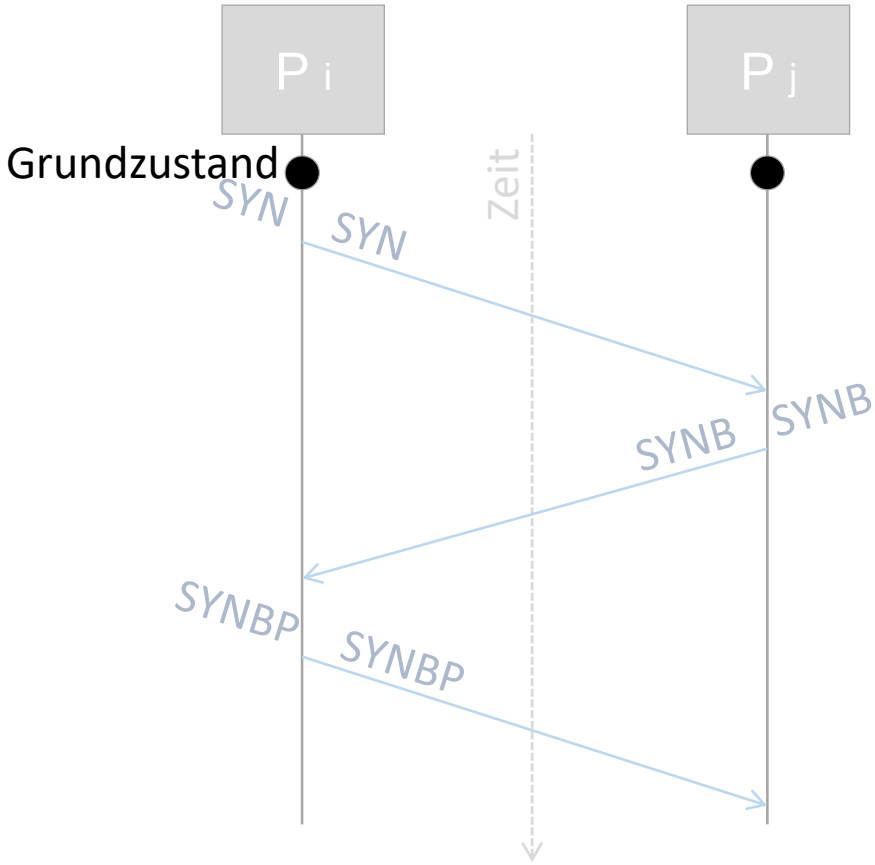

Neue PCI Typen

- SYN: Aufbauwunsch
- SYNB: Aufbauwunsch - Bestätigung
- SYNBP/N: pos./neg. Bestätigung der Bestätigung

Drei-Wege-Handschlag (2/2) (Engl.: Three-Way-Handshake)

- In erster Nachricht (SYN) ist erste Sequenznummer für den Verkehr von P_i nach P_j enthalten
- Antwort (SYNB) bestätigt Sequenznummer und enthält erste Retoursequenznummer für den Verkehr von P_j nach P_i.
- Bestätigung (SYNBP) bestätigt Retoursequenznummer (und kann je nach Implementierung auch bereits erste Daten enthalten).
- Verzögerte Duplikate alter SYN oder SYNB Nachrichten können anhand der verwendeten Sequenznummern erkannt werden

Verbindungsabbau

Neue PCI (Protocol Control Information) Typen:

- CLS ("close") Abbauwunsch
- CLSB Abbauwunsch-Bestätigung
- CLS und CLSB müssen von beiden Partnern gegeben werden ➔ beide „Halbverbindungen" werden explizit geschlossen (symmetrische Verbindungsfreigabe)
- **Übungsaufgabe**:
  Entwerfe ein vollständiges Zustandsübergangsdiagramm einschließlich Fehlerfälle!

Kapitel 3.3 Flusssteuerung und Staukontrolle

Begriffseinführung

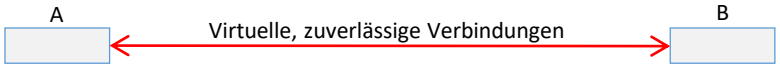

Techniken zur Realisierung verbindungsorientierter Dienste

- Sequenznummer und Quittungen
  - Größe des Sequenznummernraumes
  - Maximale Lebensdauer von Nachrichten
  - Fenstertechnik
- Verbindungsaufbau/-abbau
- Flusssteuerung und Staukontrolle

- Ports und Sockets
- TCP / UDP

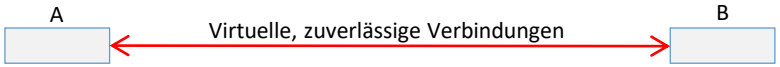

Einordnung/Motivation:

- Warteschlangen in technischen Systemen sind endlich ➔ Rückstaumechanismen erforderlich
  - für Verbindungen, für Schnittstellen, für Netze
- **Flusssteuerung (engl. flow control):** Maßnahmen gegen die Überlastung eines Empfängers durch den zugehörigen Sender.
- **Staukontrolle (engl. congestion control):** Maßnahmen gegen die Überlastung der Transitnetze durch eine relevante Menge individueller Kommunikationsbeziehungen.

Warteschlangen (Grafik)

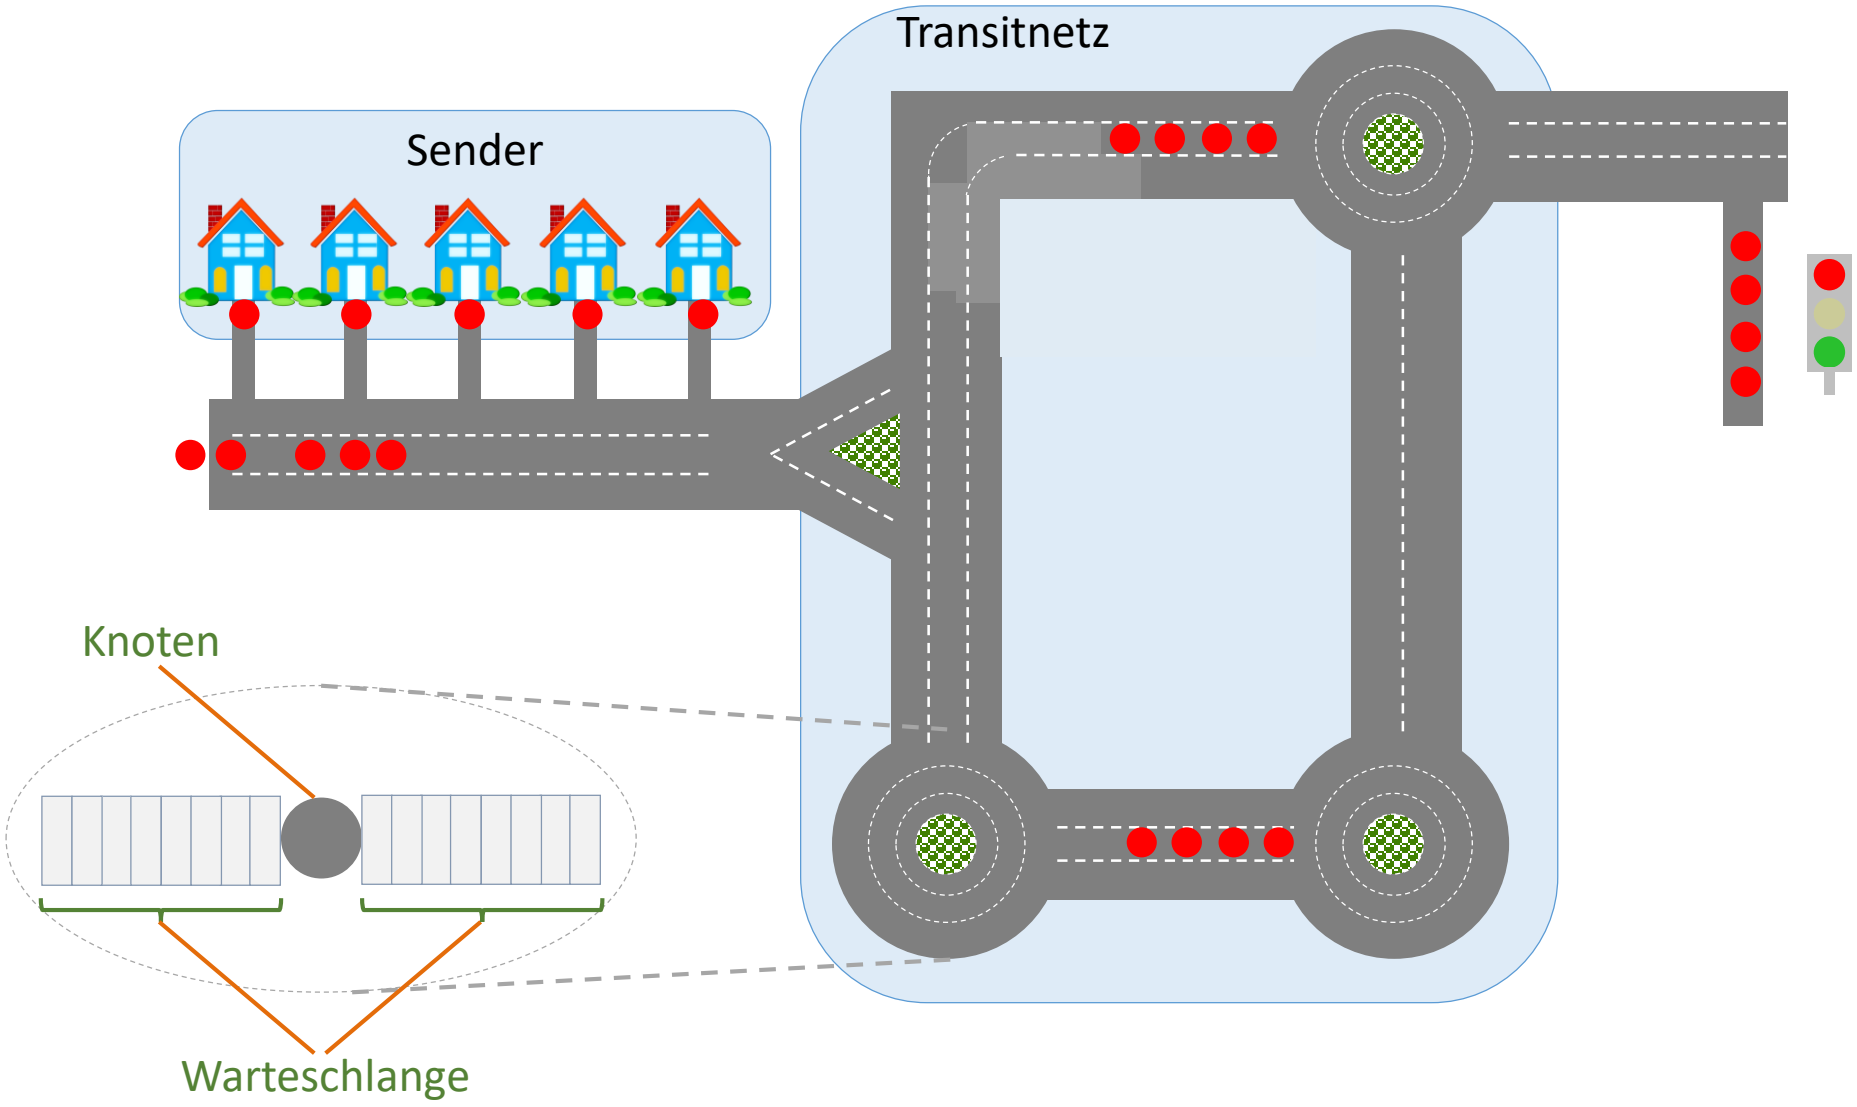

Lösungsansätze Staukontrolle

- virtuelle Kanäle: sicher, aber Puffervergeudung und Aufbauzeit
- Begrenzung des Nachrichtenflusses in das Netz
  - Begrenzung der Anzahl von Verbindungen pro Host/Prozess
  - Begrenzung der Nachrichtenrate (traffic contract, leaky bucket)
- Sicherstellung des Abflusses aus dem Netz
  - garantierte Abnahmerate durch Empfänger
  - Reassembly im Host
- Wegwurf von Paketen bei Überlast (z.B. im Internet)
- Konstante Last im Netz (Taxi-Verfahren, nicht optimal)
- Füllungsregelung pro Verbindung

Lösungsansätze Flussteuerung

- Sender verlangt Pufferreservierung vor Sendung, Senden nach Bestätigung ➔ zusätzliche Nachrichten und Verzögerung
- Empfänger stellt Credit über Allokationsnachrichten (z.B. TCP) ➔ Verfahren nicht robust
- Fenstertechnik (mit festem oder dynamischem Fenster) ➔ Problem bei Fensterverkleinerung
- Stop and Go–Technik ➔ Oszillierendes Verhalten, schlecht bei großem RTD
- Zeitrasterabhängiges Senden

Kapitel 3.4
Ports und Sockets

Adressierung auf der Transportschicht

Multiplexen über Anwendungen

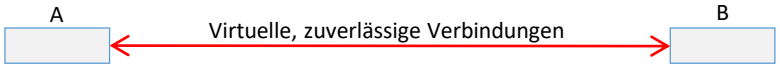

Techniken zur Realisierung verbindungsorientierter Dienste

- Sequenznummer und Quittungen
  - Größe des Sequenznummernraumes
  - Maximale Lebensdauer von Nachrichten
  - Fenstertechnik
- Verbindungsaufbau/-abbau
- Flusssteuerung und Staukontrolle

- Ports und Sockets
- TCP / UDP

Einordnung

- Im Kapitel 2 „Namen und Adressen“
  - Adressierung auf der Vermittlungsschicht im Internet mithilfe von IPv4 Adressen
  - Insbesondere: mit IPv4 Adressen können wir Hosts (bzw. Netzschnittstellen) adressieren
- In der Regel: nicht nur bestimmte Hosts, sondern bestimmte Anwendungen (Prozesse) auf diesen Hosts adressieren
- Im Internet: **Ports** der Transportschicht.
- Neutraler Begriff für „Port“:
  „**TSAP**“ (engl.: Transport Service Access Point)

Begriffsklärung

- **Port** (TSAP):
  - Adresse für Kommunikationsendpunkt einer Schicht 4 Protokollinstanz (auf gegebenem Host)
  - Flacher Adressraum (16-Bit Binärzahl)
- **Socket**: Tupel bestehend aus IP-Adresse und Port.
  - Socket ist netzglobaler Kommunikationsendpunkt
- **Verbindung** besteht zwischen zwei Sockets
- Sockets:
  - vom Betriebssystem bereitgestellt
  - dienen als die **Schnittstelle** für Zugriff auf Transportdienst

Der Multiplex Begriff

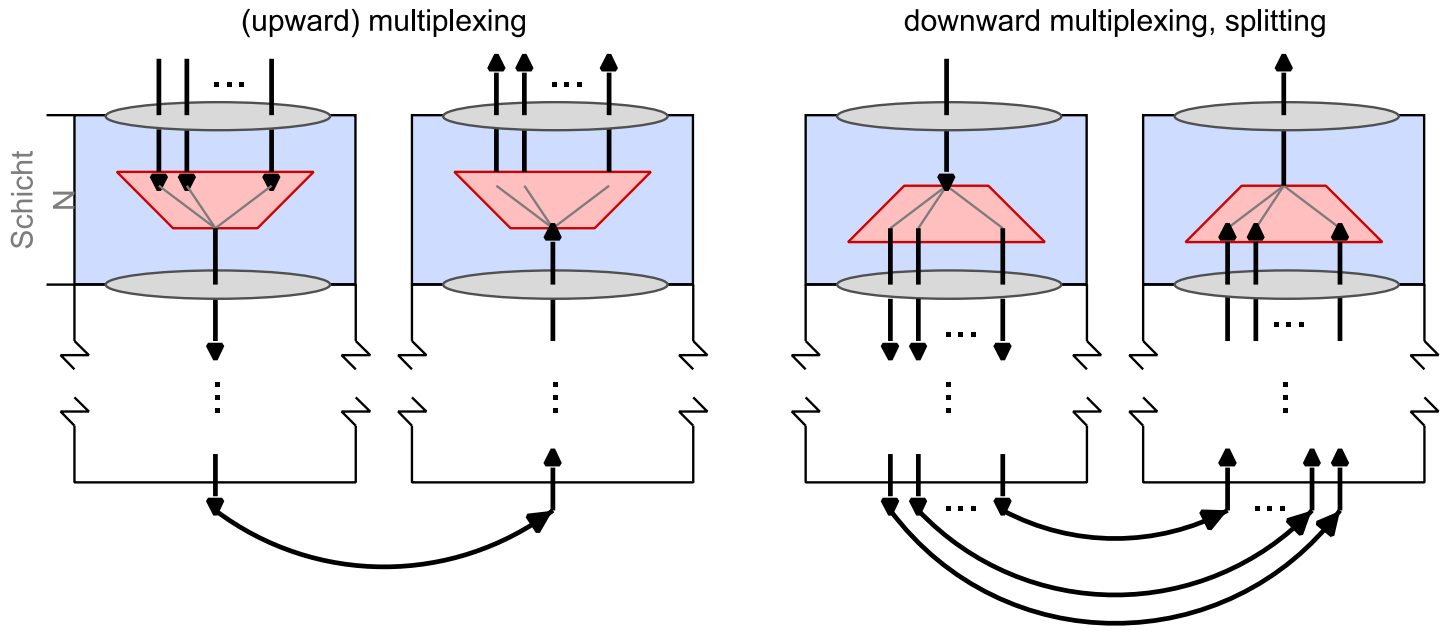

- upward multiplexing: Viele Kanäle einer höheren benachbarten Schicht werden zu einem Kanal einer niedrigeren benachbarten Schicht vereint.
- downward multiplexing: Ein Kanal einer höheren benachbarten Schicht wird in viele Kanäle einer niedrigeren benachbarten Schicht aufgeteilt.

Multiplexing (oft: „Mux“)

Abbilden von N-Connections auf (N-1)-Connections in Schicht K.

(upward) multiplexing

downward multiplexing, splitting

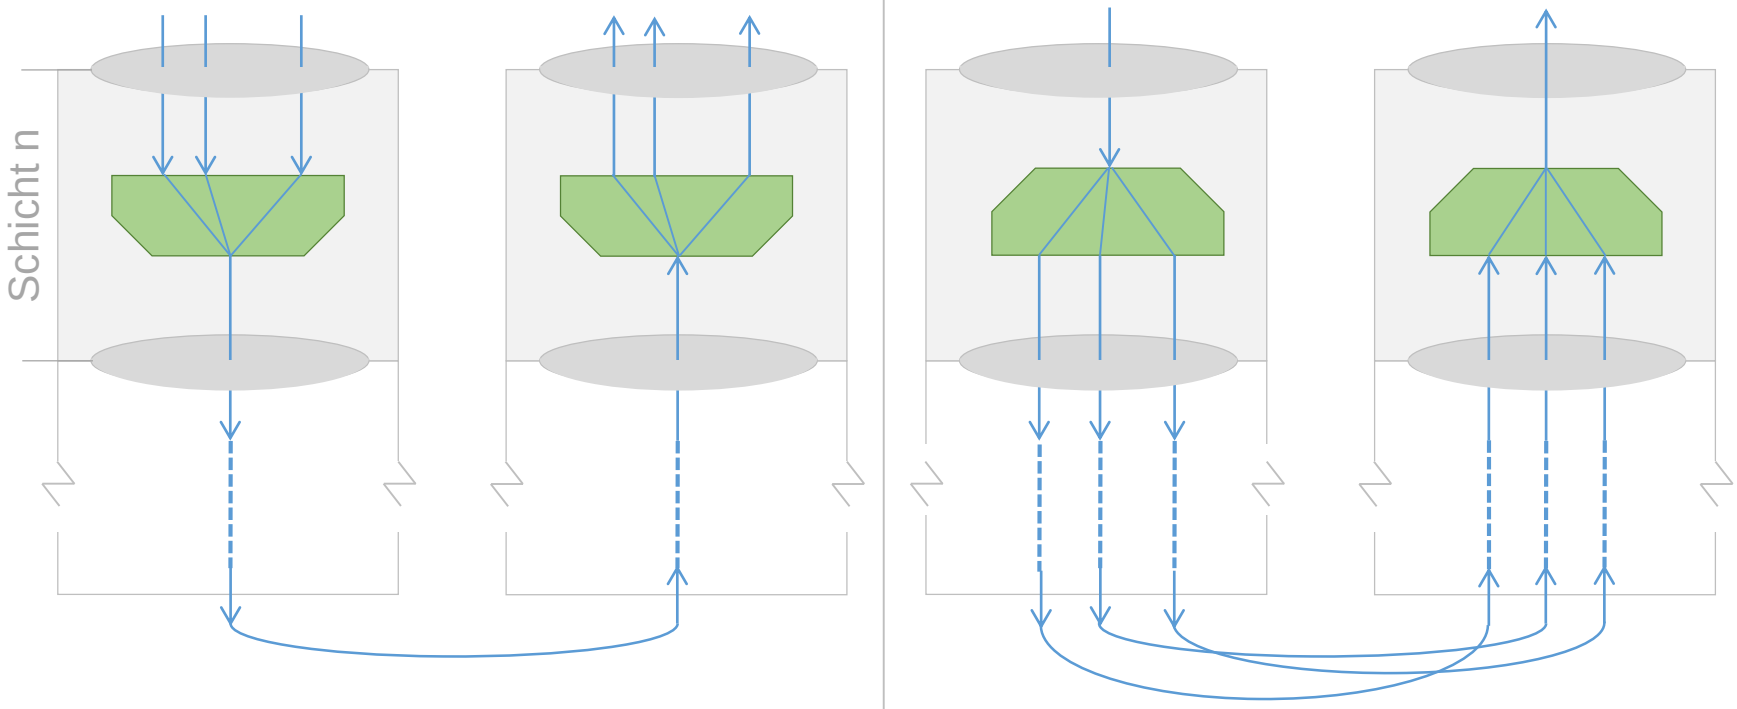

Multiplexen auf der Transportschicht im Internet

- Auf den Endsystemen im Internet gibt es i.d.R. viele Anwendungsprozesse, die über eine einzige Netzschnittstelle (IP-Adresse) Verbindungen aufbauen.
- Dies funktioniert, indem jeder solche Anwendungsprozess eigene Sockets mit einem eigenen Port verwendet.
- Über die Ports der Transportschicht wird also ein (upward) Multiplex über Anwendungsprozesse realisiert.

Multiplexen über Anwendungsprozesse

Eine Transportschicht-verbindung zwischen einem Anwendungsprozess und einem Server.

Prinzipiell können weitere Anwendungsprozesse auf Host 1 über weitere TSAPs (z.B.: Ports) Verbindungen über den selben NSAP (engl.: network service access point) aufbauen.

➔ Multiplexen über Anwendungsprozesse

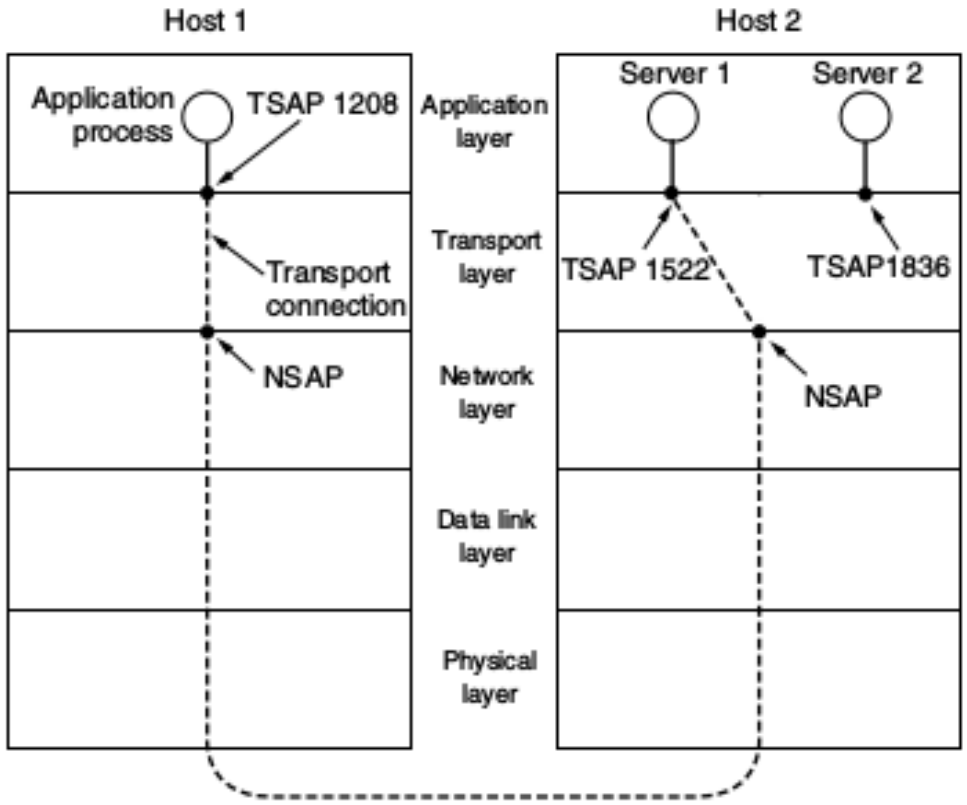

Kapitel 3.5 Transmission Control Protocol (TCP)

Das verbindungsorientierte Transportprotokoll des Internets

Überblick TCP

- Zuverlässiges Internet Transportprotokoll (z.B.: RFC 793)
- unterstützt Ende-zu-Ende-Transportverbindungen
  - Vollduplex (gleichzeitiges Senden und Empfangen in beide Richtungen)
  - mit Fehlerbehandlung (Verlust, Duplikate, usw.)
  - mit Flusssteuerung und Staukontrolle
- Byte-Strom-orientiert: Sequenz- und Quittungsnummern beziehen sich auf Bytes.
- Verbindungsorientiert: Aufbau per Drei-Wege-Handschlag
- unterstützt das Multiplexen zwischen Anwendungen und Vermittlungsdienst.
- TCP-Nutzer (Anwendungen) sind über Sockets adressierbar.
- Dienstdaten werden zwischengespeichert.
- Eine TCP-PDU wird als **Segment** bezeichnet.

TCP Header (PCI) (1/3)

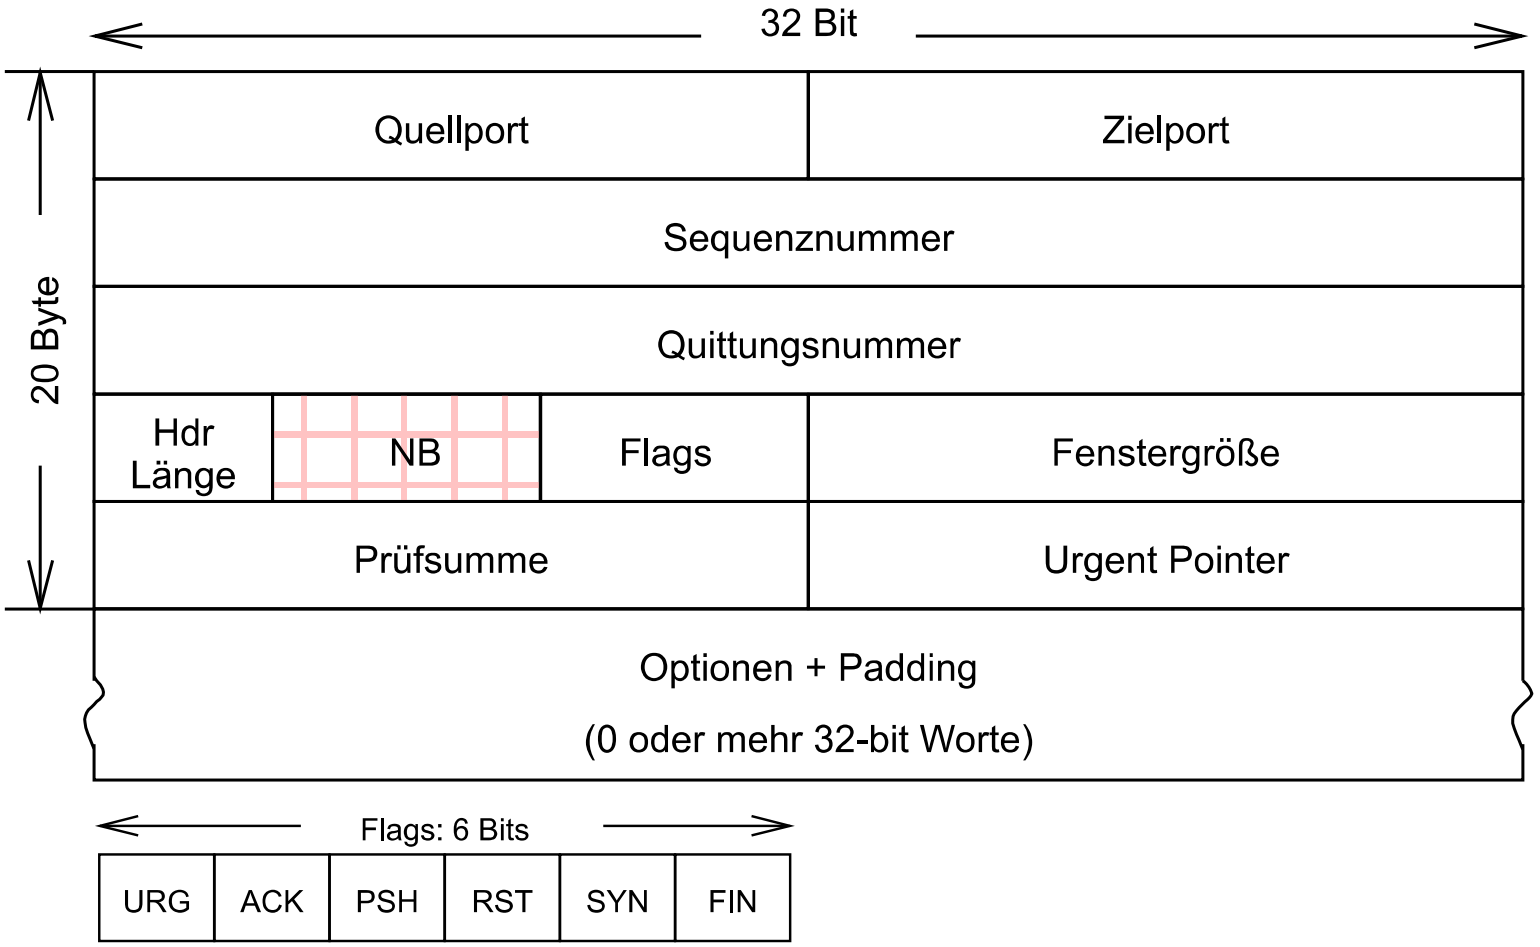

TCP Header (PCI) (2/3)

- **Quellport/Zielport** (je 16 Bit): Endpunkte der Verbindung
- **Sequenznummer** (32 Bit): Bytestromnummer des ersten Nutzdaten-Bytes des Segments.
- **Quittungsnummer** (32 Bit): Bytestromnummer des nächsten erwarteten Nutzdaten-Bytes – nur lückenlos fehlerfrei empfangene Daten werden quittiert.
- **Header Länge** (4 Bit): Anzahl der 32 Bit Wörter im Header.
- **NB** (6 Bit): werden nicht benutzt.
- **Flags** (je 1 Bit):
  - URG: *Urgent Pointer* verwendet (Interrupt Data)
  - ACK: *Acknowledged* (Quittungsnummer gültig)
  - PSH: *Pushed Data* (nicht puffern, sondern sofort zustellen)
  - RST: *Reset Connection* (Host abgestürzt, Aufbauwunsch abgelehnt, etc.)
  - SYN: *Synchronize* (SYN=1, ACK=0 für Aufbauwunsch, beides 1 zur Bestätigung)
  - FIN: *Finished* (Abbauwunsch/keine weiteren Daten zu senden)

Der TCP Header (PCI) (3/3)

- **Fenstergröße** (16 Bit): Anzahl der Bytes, die ab letzter Quittung gesendet werden dürfen.
- **Prüfsumme** (16 Bit): Einerkomplement der Summe aller 16-Bit-Worte über Pseudoheader und TCP-Segment (Der Pseudoheader enthält die folgenden Felder aus dem IP-Header: Quell- und Zieladresse, Protokoll, und Länge des TCP-Segments).
- **Urgent Pointer** (16 Bit): Zeigt auf letztes Byte in einer Kette von Daten (engl.: out-of-band data).
- **Optionen** (n * 32 Bit): Wählbare Eigenschaften, wie z.B. maximale Segmentgröße und Timestamp-Option.

TCP Ports

- 16 Bit Binärzahl (65536 Ports)
- Portnummern werden von der IANA (engl.: Internet Assigned Numbers Authority) verwaltet.
- *Well Known* Ports (0-1023)
  - TCP-Anwendungen (1-255)
  - UNIX-Anwendungen (256-1023)
- *Registered* Ports (1024-49151): meist herstellerspezifisch
- *Dynamic* and/or *Private* Ports (49152-65535): frei nutzbar

Beispiele für Well Known Ports	
21	FTP
22	Secure Shell (SSH)
23	telnet
25	SMTP
80	HTTP
143	IMAP
Beispiele für Registered Ports	
2628	DICT
2481	Oracle GIOP
6000	X Windows

Sockets

- TCP Sockets bieten Anwendungen eine Schnittstelle zur zuverlässigen Byte-Strom-Übertragung.
- Eine Verbindung (gegeben durch ein Socket-Paar) adressiert die Kommunikationsendpunkte auf zwei Endsystemen

- Ende-zu-Ende-Verbindung an Dienst bzw. Applikation gebunden
- Socket: Endpunkt für Kommunikation
  - beschrieben durch Schicht-3-Adresse und Portnummer
  - wird erzeugt von und „gehört“ einem Prozess
  - bietet Schnittstelle für Übertragung
- Verbindung gegeben durch ein Socket-Paar

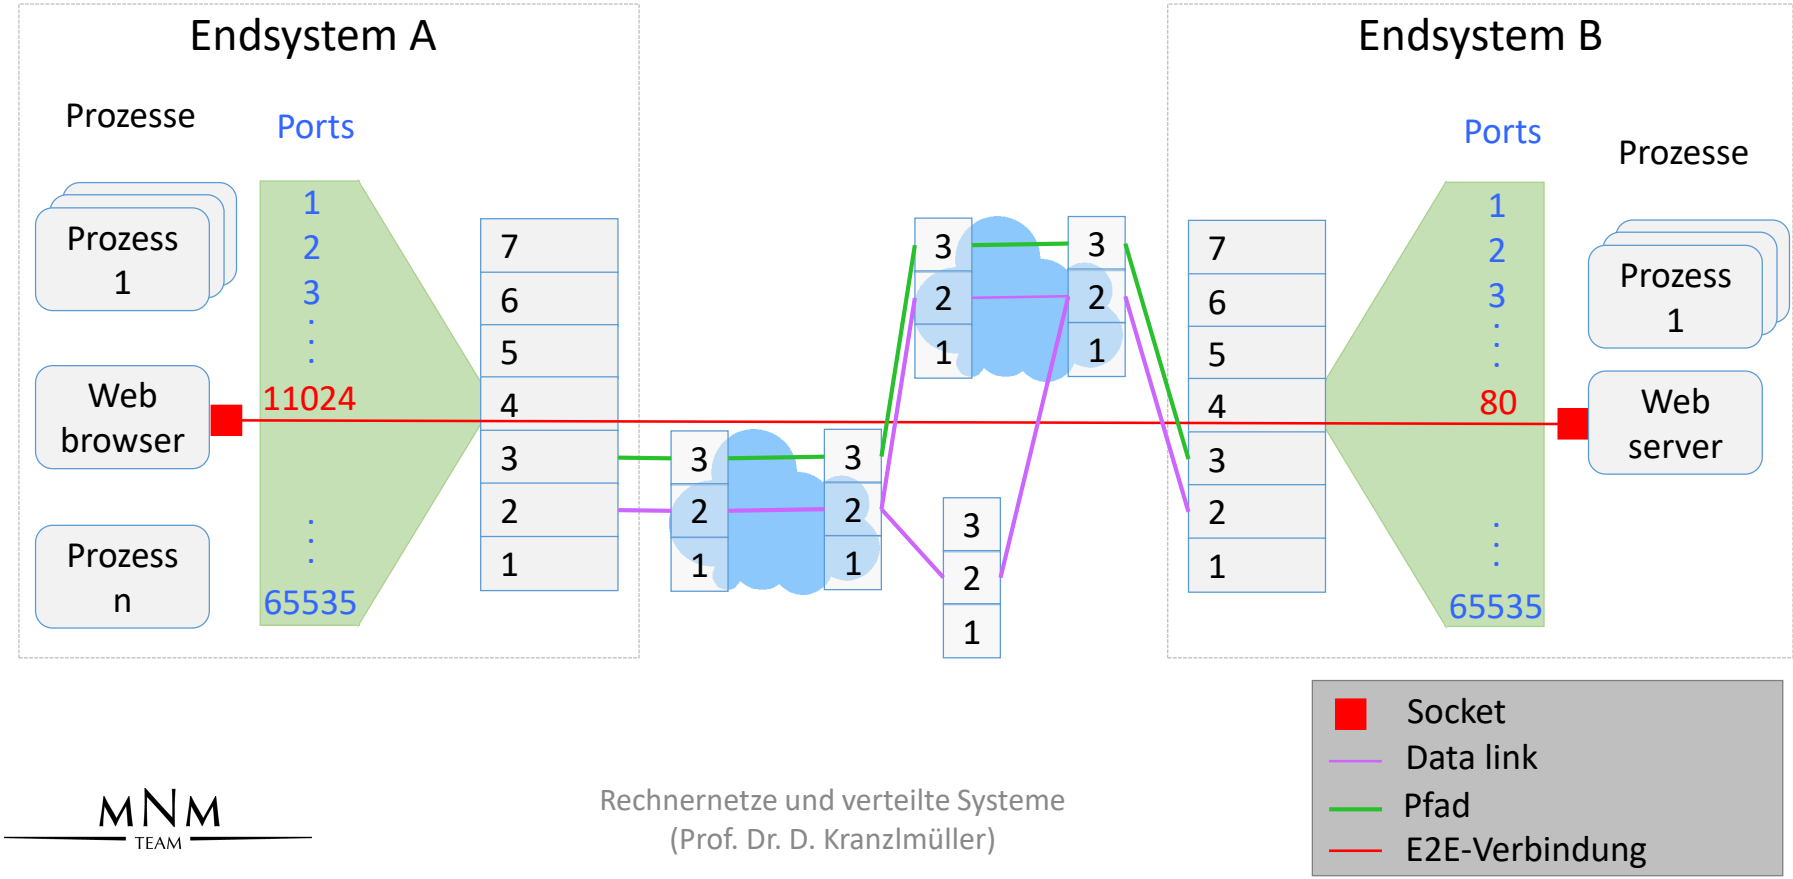

Socket Programmierung

- Socket API in BSD 4.1 UNIX (1981)
- Schnittstelle zwischen Anwendung und Transportprotokoll
- Umgang mit Socket ähnlich wie mit einer Datei
  - Socket wird erzeugt/geöffnet
  - Es wird zum Socket geschrieben / vom Socket gelesen
  - Socket wird geschlossen/zerstört
- Client-Server-Paradigma
  - Server Socket: wartet auf Verbindungsanfragen von Clients
  - Normales Socket: wird nach dem Verbindungsaufbau von Client- sowie Serverprozessen zur Kommunikation genutzt.
  - Server/Daemonen: erzeugen neue Threads/Prozesse zur Abwicklung der Kommunikation nach dem Verbindungsaufbau.

Beispiel: Verbindungssocket

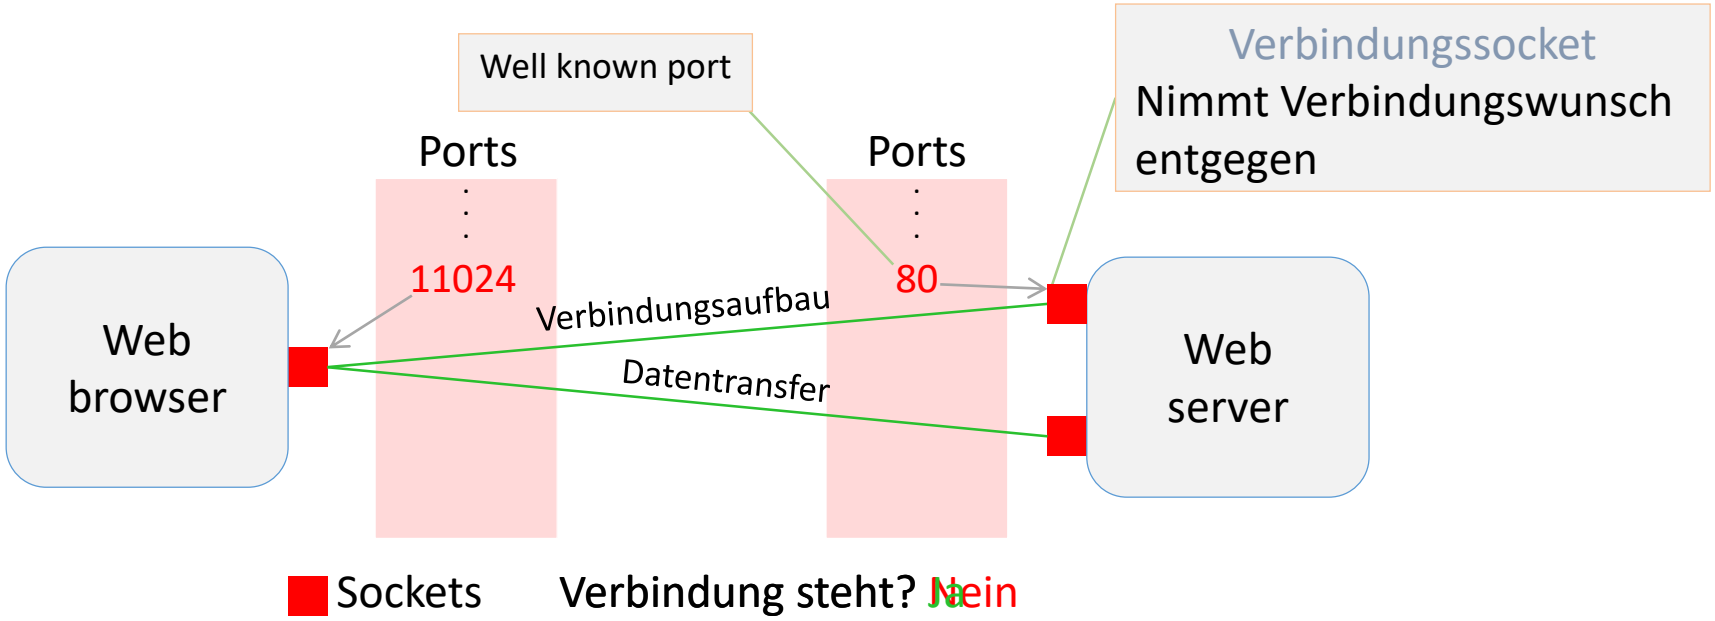

TCP-Socket-Programmierungsbeispiel

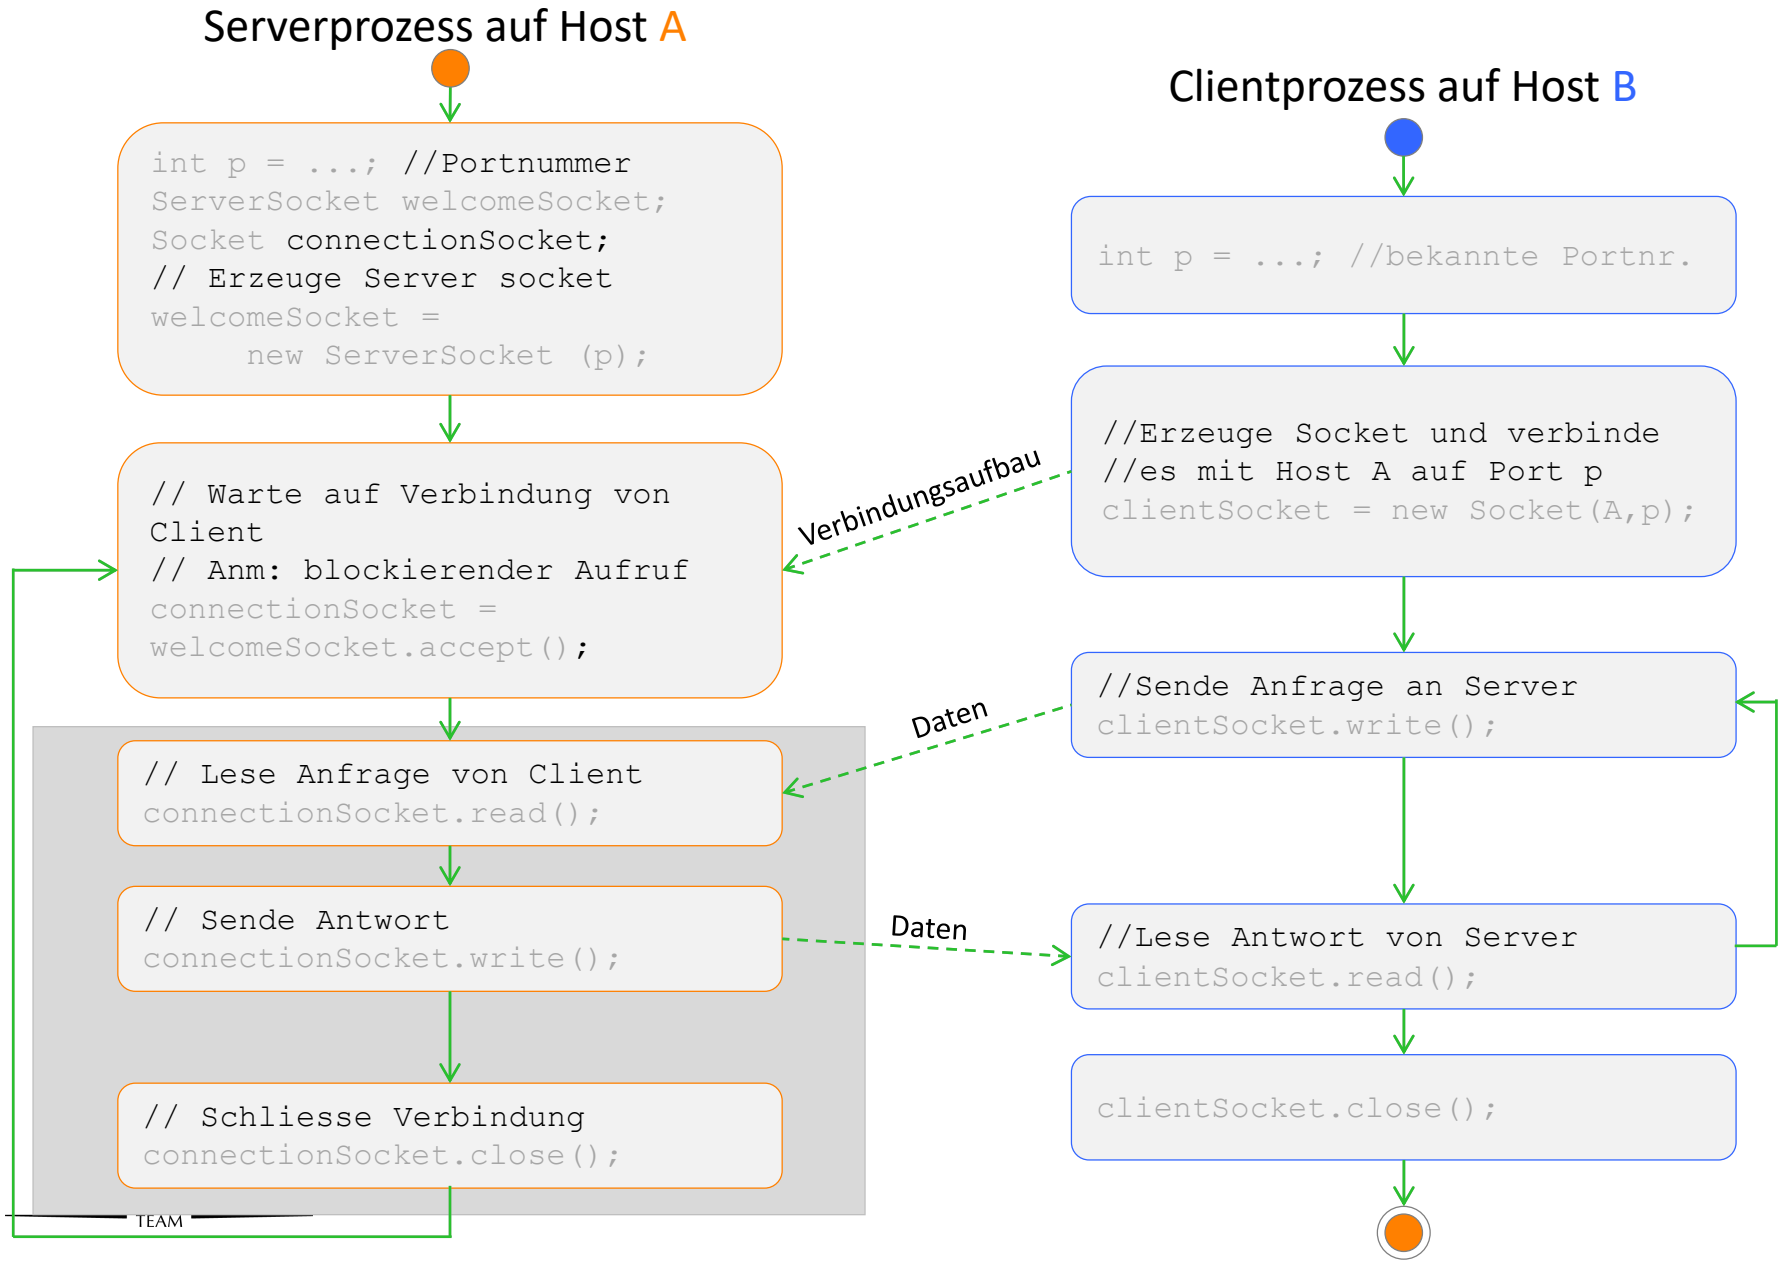

Verbindungsaufbau: Drei-Wege-Handschlag

Initiale Sequenznummern
- gewählt aufgrund Zeitgeber
- Eindeutigkeit bei oft auf-/abgebauten Verbindungen

Sequenznummern werden erhöht aufgrund von
- Segmenten mit Nutzdaten (um 1 pro Byte)
- SYN und FIN (Schutz des Verbindungsmanagement)
- sonst: „leere“ Segmente -> „alte“ Seq. Nr. (z.B. Quittungen)

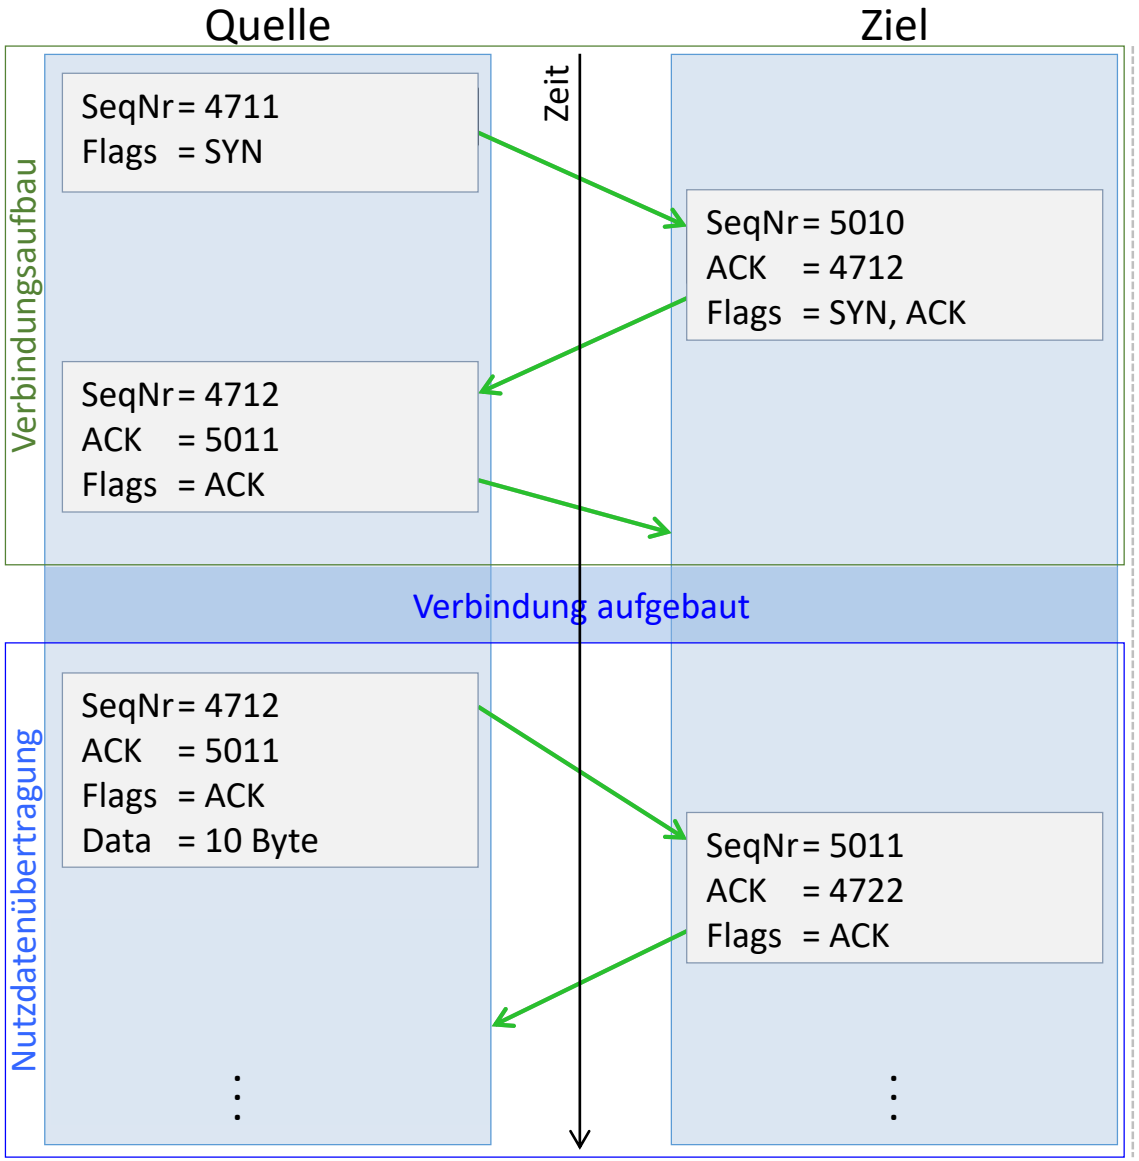

Beidseitiger Verbindungsabbau

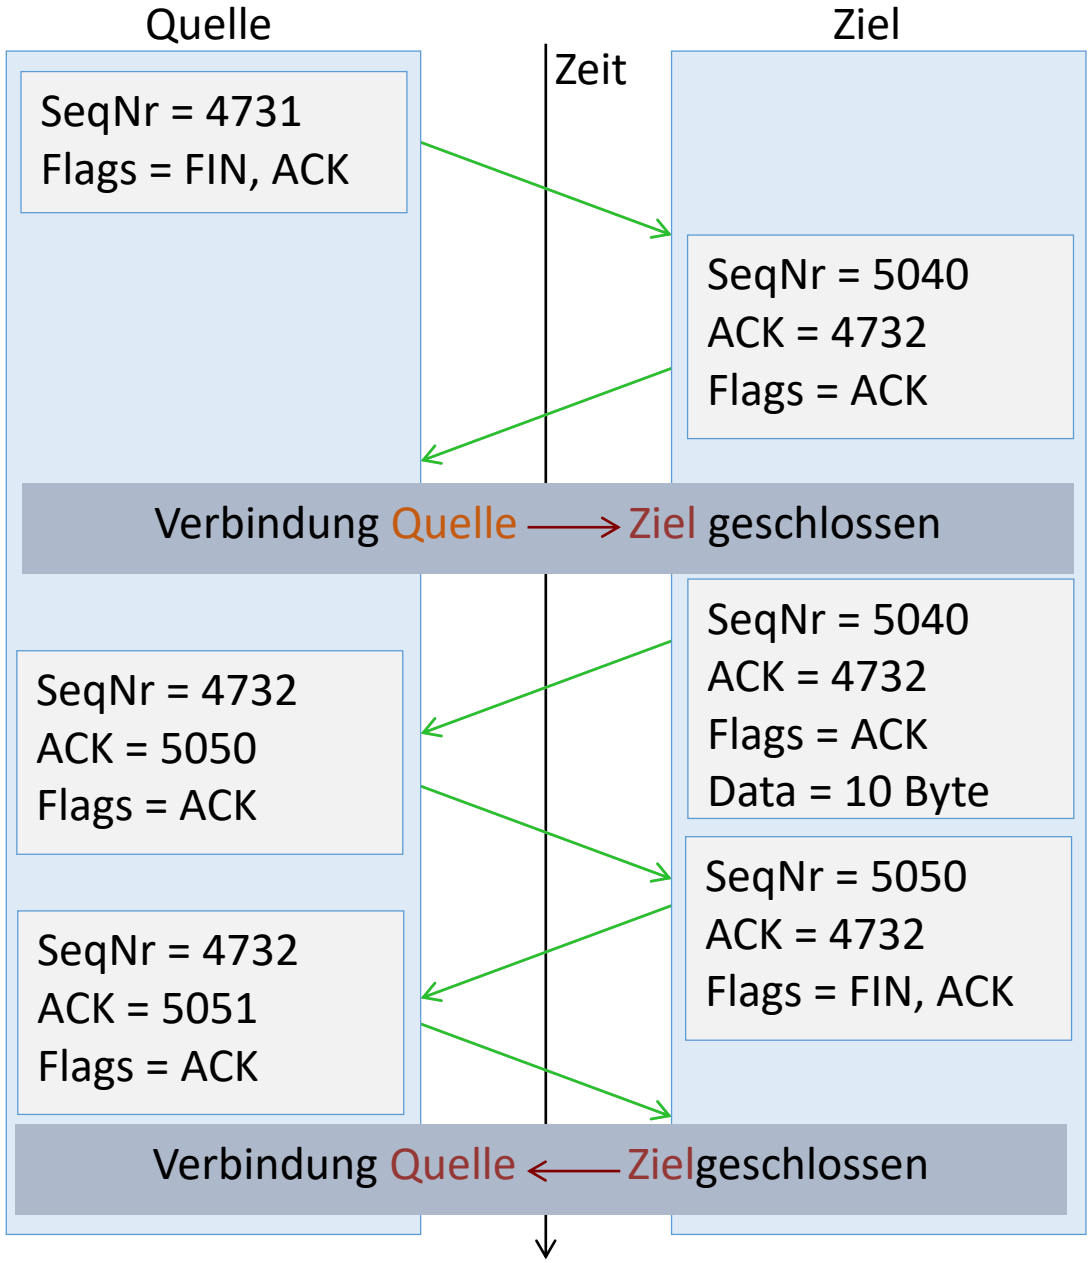

Typische TCP-Zustände im Client

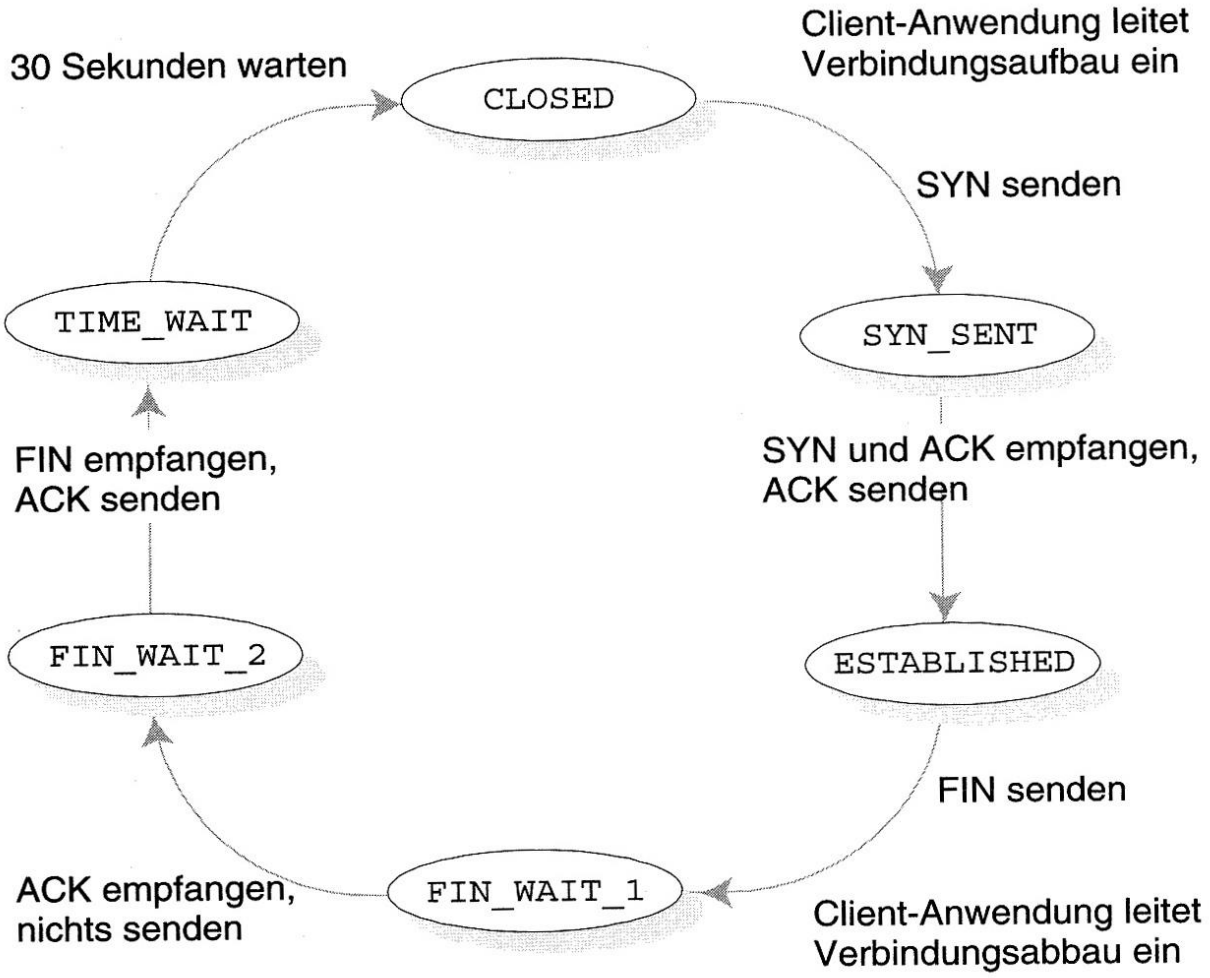

Typische TCP-Zustände im Server

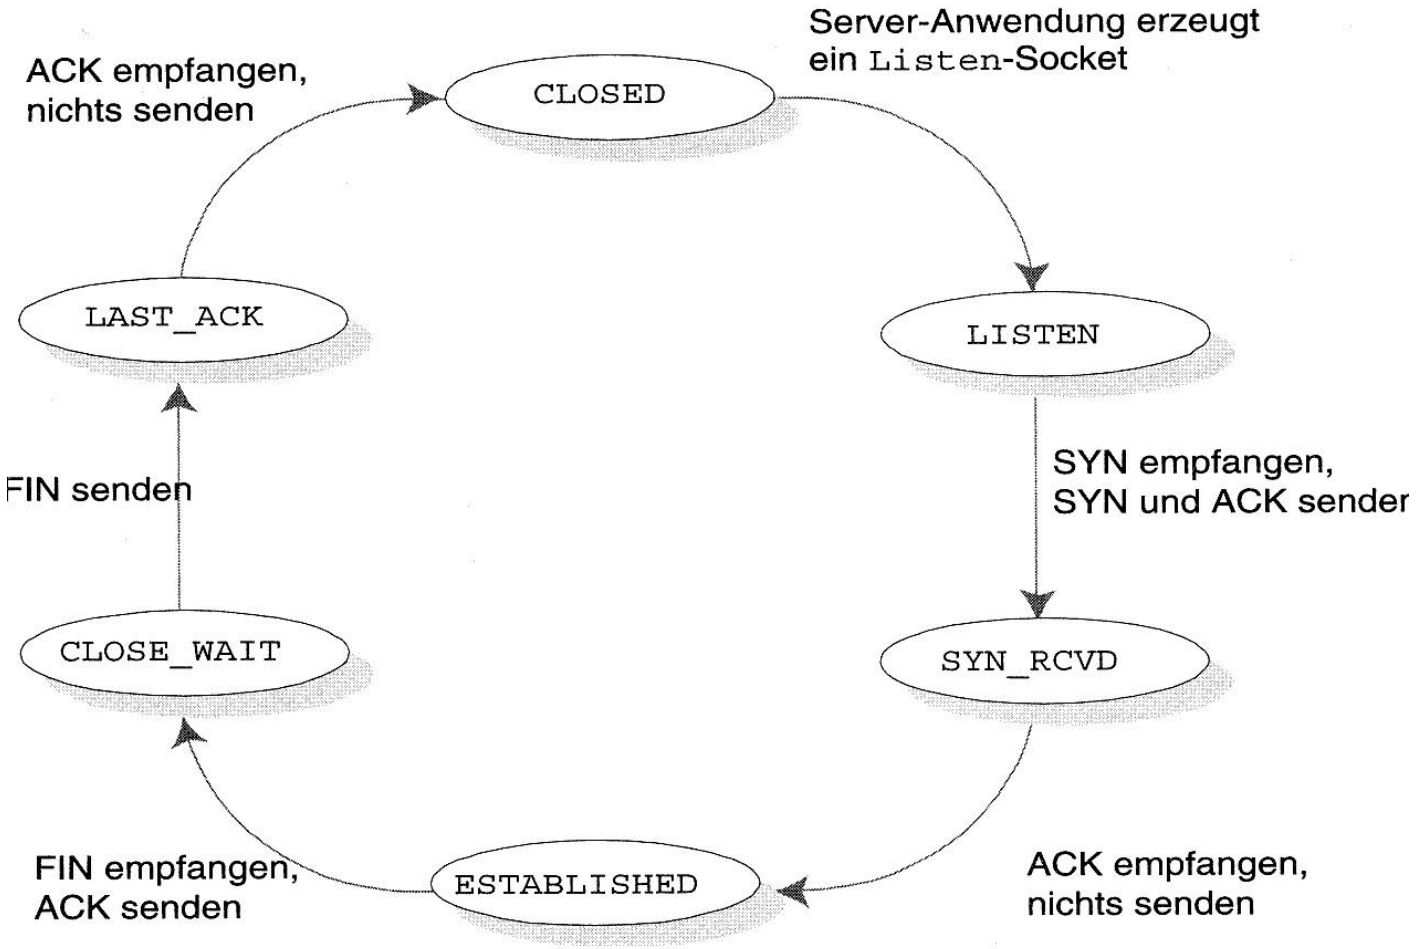

Flussteuerung (1/2)

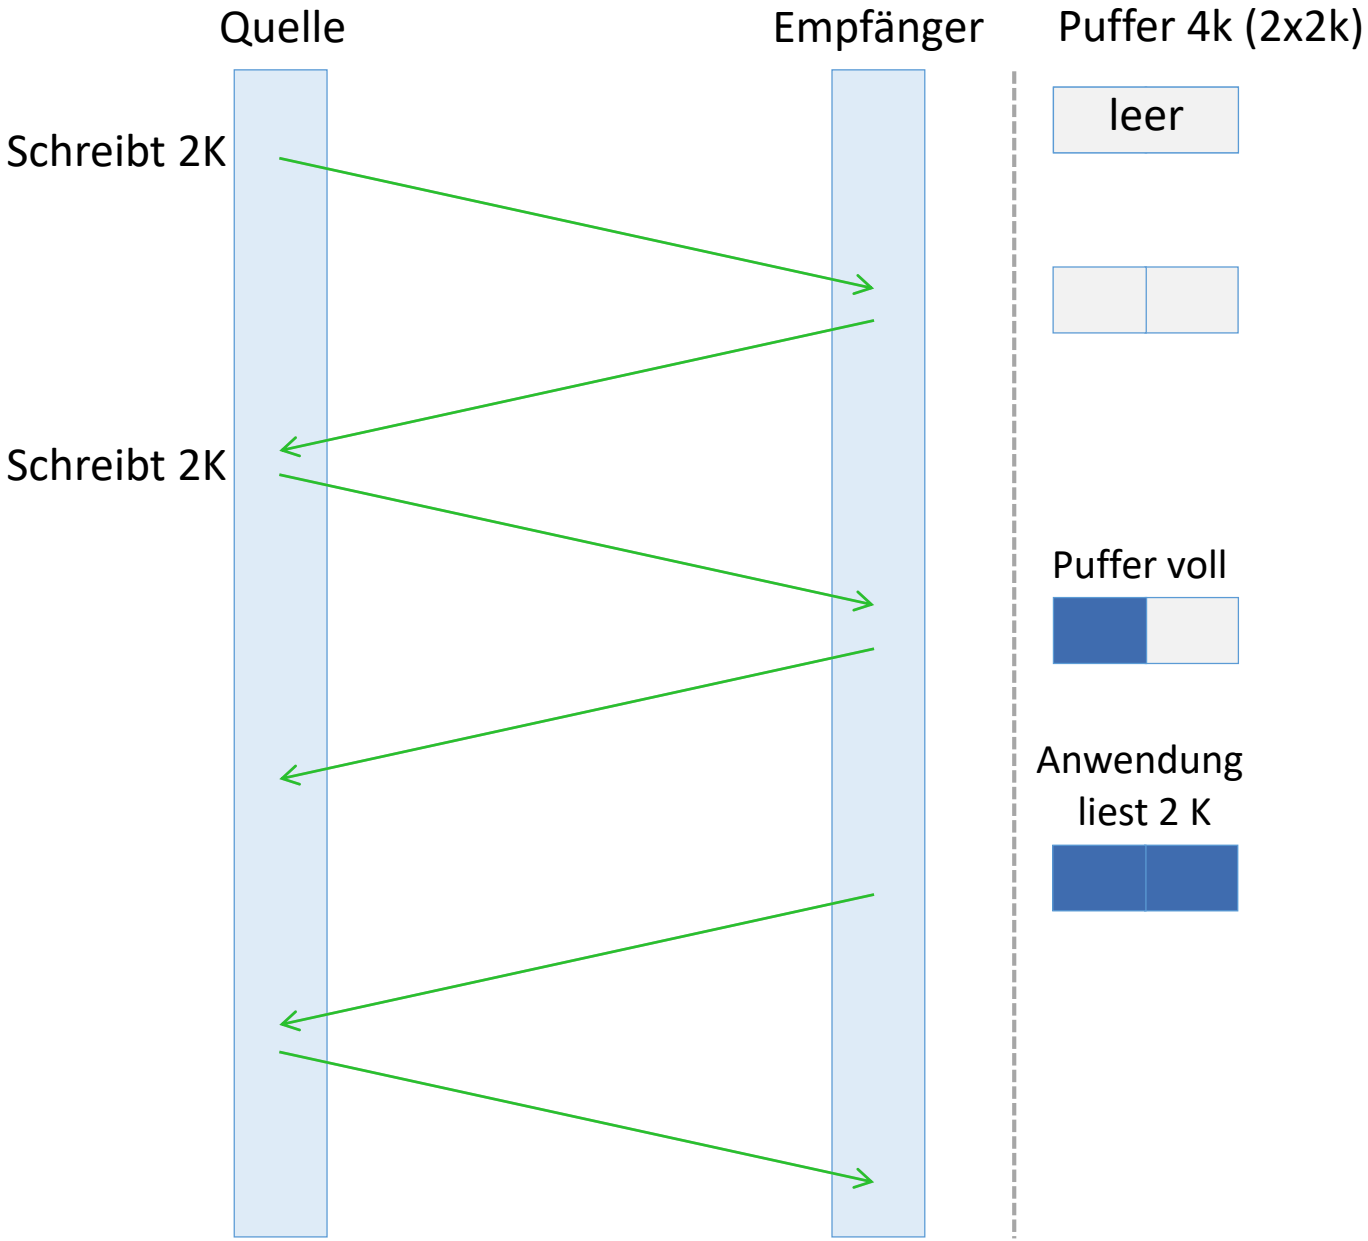

Flussteuerung (2/2)

- Variablen des Senders:
  - RcvWindow
  - LastByteSent
  - LastByteAcked

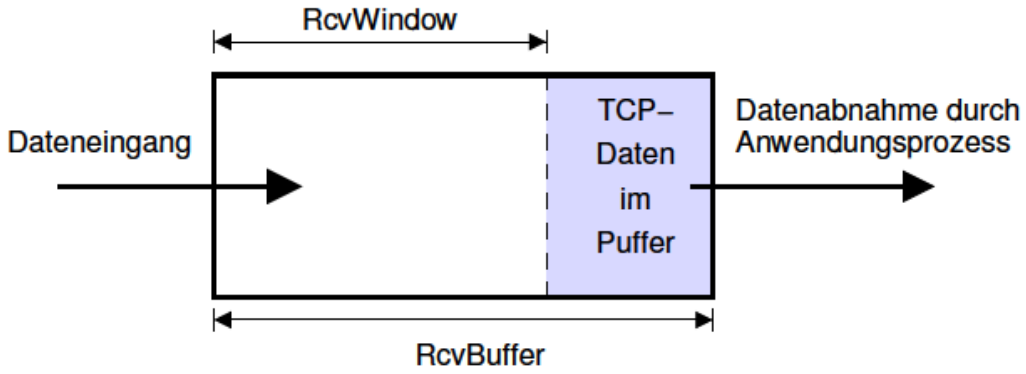

- Variablen des Empfängers:
  - RcvBuffer
  - LastByteRcvd: angekommen, aber noch nicht gelesen (im Puffer)
  - LastByteRead: bereits vom Anwendungsprozess gelesen
- RcvWindow = RcvBuffer – (LastByteRcvd – LastByteRead)
- LastByteSent – LastByteAcked ≤ RcvWindow
- Summenquittungen über mehrere Segmente

Einordnung Staukontrolle (Überlastungskontrolle)

- Vergleich:
  - Flussteuerung: Empfänger nicht überlasten
  - Staukontrolle (Überlastungskontrolle): Netze nicht überlasten
- **Überlastung der Netze**: wenn viele Transportinstanzen auf vielen Endsystemen gleichzeitig zu viele Pakete zu schnell ins Netz einspeisen

  ➔ Überlastung der Router auf der Vermittlungsschicht

- Fragen:
  - Wie kann auf Transportschicht festgestellt werden, dass eine Überlastung der Transitnetze besteht?
  - Wie kann man das Sendeverhalten einzelner Transportinstanzen anpassen, damit keine Überlastung der Transitnetze entsteht?

Überlastungserkennung auf der Transportschicht

- Die Möglichkeiten, die der Transportschicht zur Verfügung stehen, um eine Netzüberlastung zu erkennen, können in zwei Gruppen eingeteilt werden.
- Entweder es wird ein Protokoll verwendet, mit dessen Hilfe überlastete Router den Endpunkten explizit mitteilen können, dass sie überlastet sind (z.B.: XCP – engl.: eXplicit Congestion Protocol)
- Oder die Transportinstanzen stellen die Netzüberlastung anhand indirekter Indikatoren wie Paketverlust fest.

Überlastungskontrolle (Benötigte Variablen)

- Ansatz: Einführung eines Überlastfensters (engl.: congestion window)
- Analog dem Empfangsfenster (engl.: receive window) zur Flusssteuerung.

Überlastungskontrolle (Benötigte Variablen)

- Beide TCP Instanzen benötigen folgende Variablen:
  - CongWindow (congestion window): steuert die Einspeisung ins Netz wie folgt:
    LastByteSent – LastByteAcked ≤ CongWindow
  - Effektives Fenster: min(RcvWindow, CongWindow)
  - MSS (maximum segment size): maximale Datenmenge pro Segment.
  - Threshold: obere Schranke für das schnelle Wachstum des Überlastfensters (CongWindow).
  - RT (retransmission timer): nach Ablauf des Timer werden nicht bestätigte Segmente neu gesendet.

Senderate nach Tahoe-Algorithmus (**bei Netz ohne Last**) (1/2)

Slow Start:

- zum Start der Übertragung fangen wir mit einem kleinen Überlastfenster an (CongWin = 1 MSS).

Exponentielles Wachstum:

- Bis zum Erreichen eines *Threshold* inkrementieren wir CongWin bei jeder erhaltenen Quittung um eins ➔ CongWin verdoppelt sich nach jeder Übertragungsrunde (Es werden jeweils doppelt so viele Nachrichten wie in der Runde davor quittiert).
- Eine Übertragungsrunde entspricht in etwa einer RTD

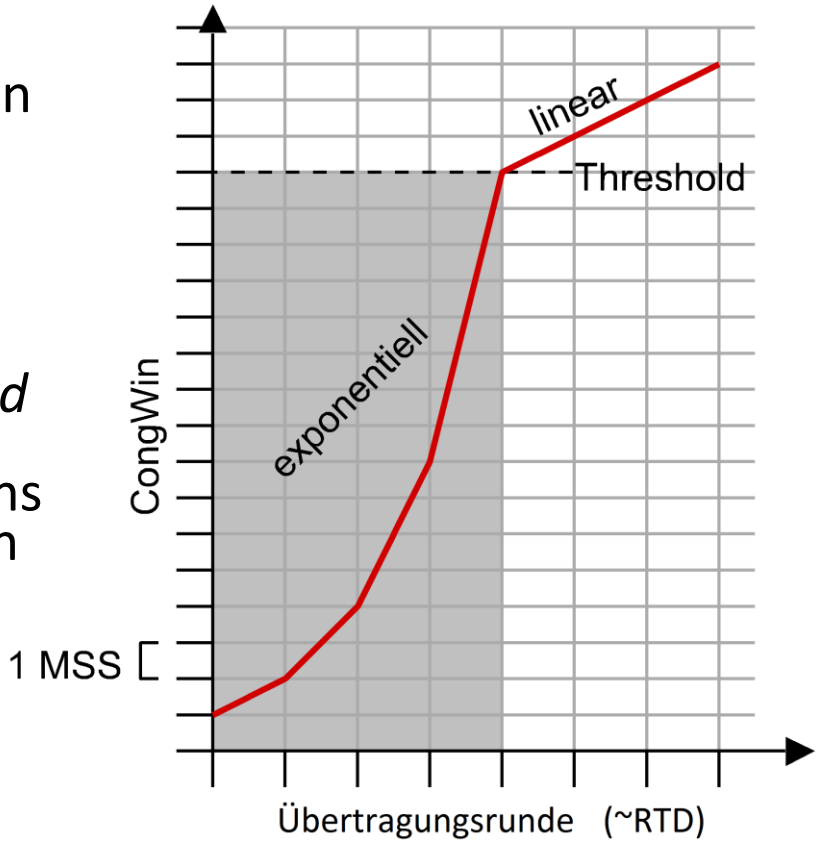

Senderate nach Tahoe-Algorithmus (**bei Netz ohne Last**) (2/2)

Lineares Wachstum:

- Nach erreichen des *Threshhold* wächst CongWin pro Übertragungsrunde (daher wenn alle Segmente der Runde erfolgreich quittiert wurden) um eins.
- Diese Phase geht so lange weiter bis ein Segment verloren geht (Timeout) ➔ lineares Wachstum solange das Netz nicht überlastet ist.

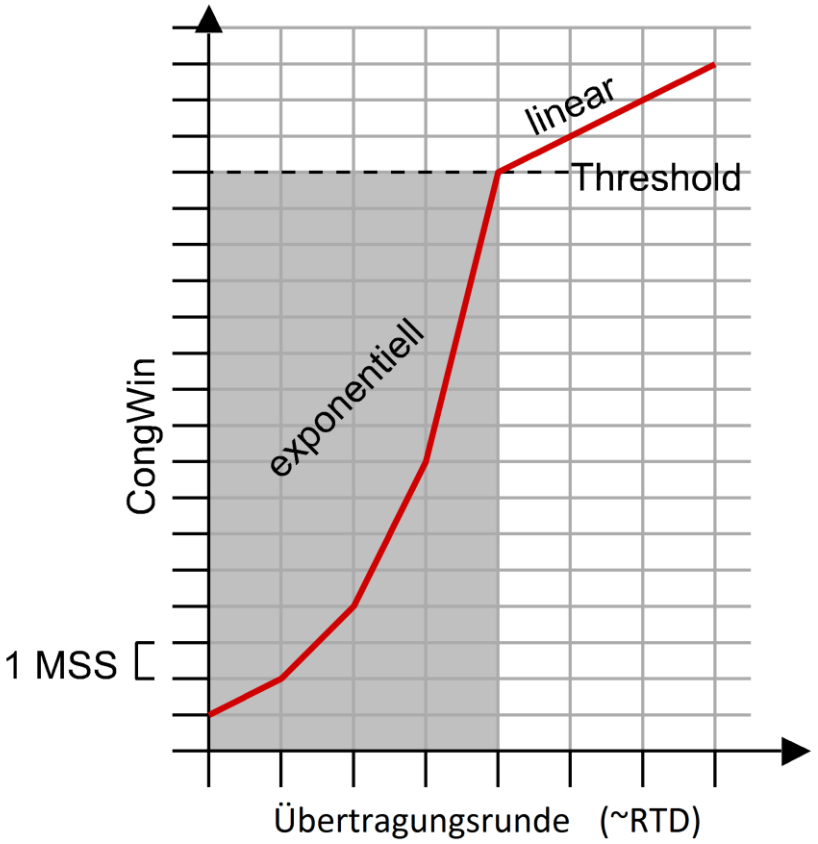

Senderate nach Tahoe-Algorithmus (**bei Netzüberlastung**)

Bei Timeout (Retransmission Timer) Reduzierung der Senderate wie folgt:

- Reduzierung des Threshold auf die Hälfte der derzeitigen Fenstergröße: Threshold=CongWin/2
- Neustart mit Slow Start: CongWin = 1 MSS

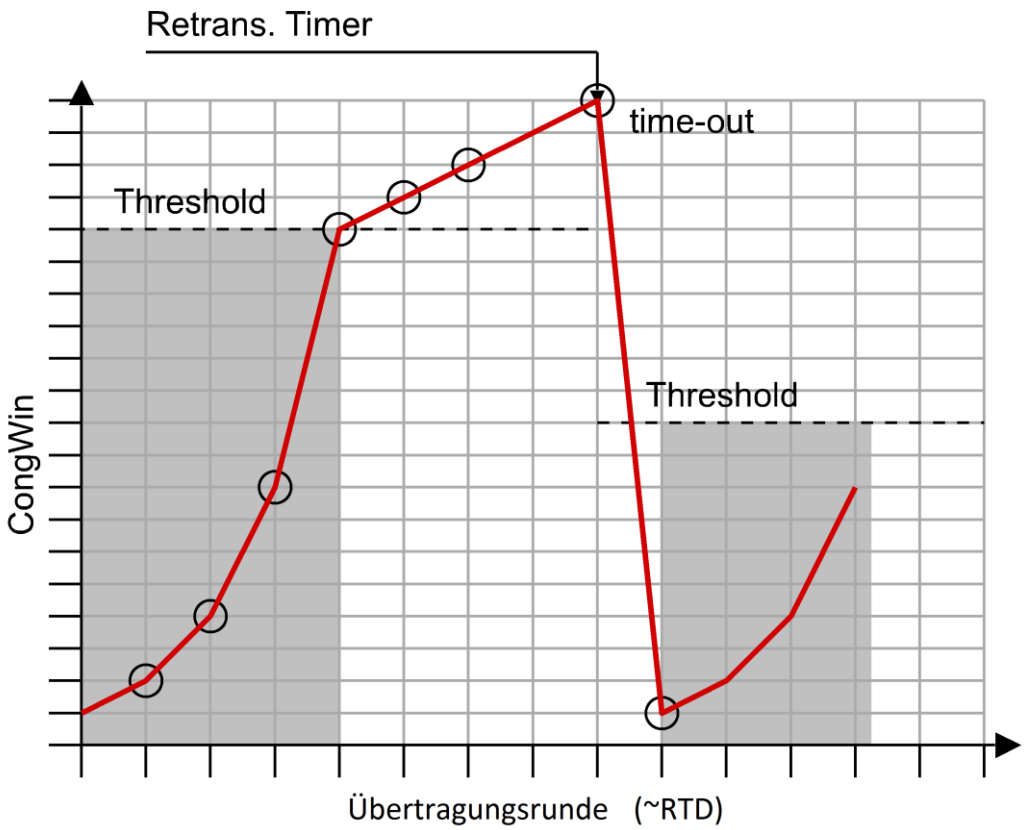

Senderate nach Tahoe-Algorithmus (Alternative Grafik)

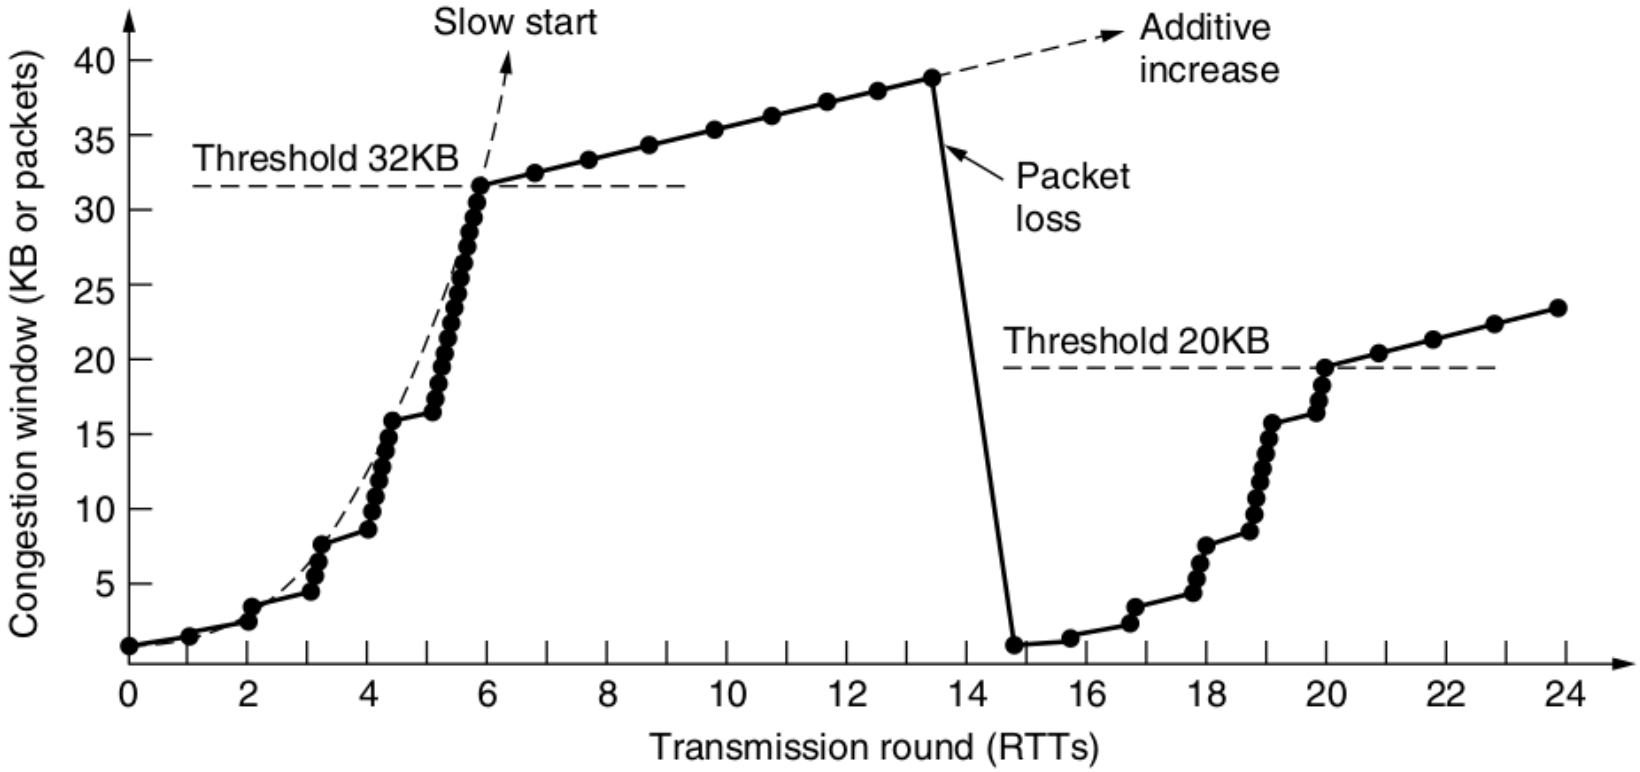

Quelle: Tanenbaum, Computer Networks 5th Edition

Optimierung bei Verlust (RFC 5681)

- Grundlage:
  Geht ein Segment verloren, so werden darauf folgende, empfangene Segmente alle mit der gleichen Quittungsnummer (ACK-Nummer) quittiert (Byte-Strom-Orientierung).
- **Quittungsduplikate** weisen also frühzeitig (noch vor dem Timeout) auf den Verlust oder den Empfang eines Segments außer der Reihe hin.

Optimierung bei Verlust (RFC 5681)

- **Schnelle Neuübertragung** (engl.: fast retransmit): Der Sender wiederholt nach Empfang eines Quittungsduplikats das auf die ACK-Nummer folgende Segment (noch vor dem Timeout).
- **Schnelle Wiederherstellung** (engl.: fast recovery): Regelt Sendeverhalten nach der schnellen Neuübertragung:
  - Pro empfangenem Quittungsduplikat wird ein Segment neuer Daten gesendet.
  - CongWin wird respektiert aber nicht verändert.
  - ab drittem Segment: Neuberechnung CongWin (ohne Slow Start)

Senderate mit Schneller Wiederherstellung (Grafik)

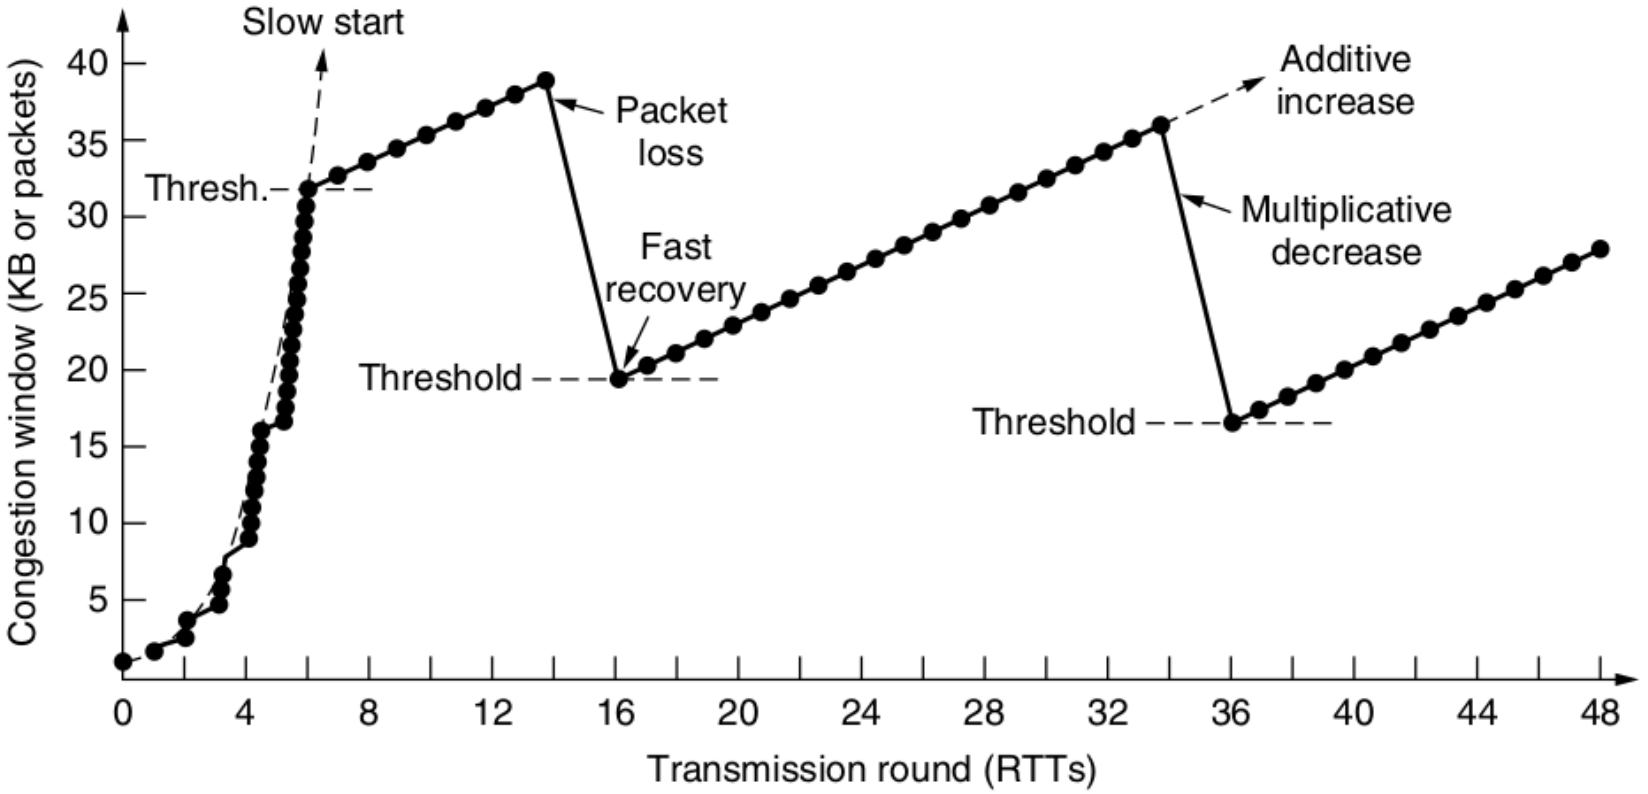

Quelle: Tanenbaum, Computer Networks 5th Edition

Retransmission Timer

- Timer sollte größer als RTT (engl.: round trip time) sein.
- Wir leiten den Timer aus der Zeit zwischen dem Versand eines Segments und dem Erhalt der Empfangsbestätigung ab (SampledRTT):

```
EstimatedRTT = 3;    //typische Initialisierung (in Sekunden)
x = 0.125;           //typischer Startwert

EstimatedRTT = (1-x) * EstimatedRTT + x * SampledRTT;
Abweichung = (1-x) * Abweichung + x * |SampledRTT - EstimatedRTT|
Timer = EstimatedRTT + 4 * Abweichung;
```

RTD- und MTU-Ermittlung

Kern-Algorithmus: Verbesserung der RTD-Schätzung

- Ziel: Anpassung des Timerwertes RTT (Round Trip Time)
- Wiederholung eines Segments ➔ RTT wird nicht aktualisiert
- Fehlgeschlagene Übertragung (d.h. Timeout) ➔ RTT wird verdoppelt

Bestimmung der kleinsten MTU (engl.: maximum transmissible unit) auf dem tatsächlich verwendeten (Vermittlungsschicht) Pfad ➔ Anpassung der Segmentgröße zum Verhindern von IP-Paketfragmentierung.

Optimierung bei kurzen Segmenten

Nagle-Algorithmus: Zusammenfassung (Blocking) mehrerer kurzer TCP-Segmente.

- Problem: Datenübergabe an TCP in kleinen Portionen (z.B. telnet, remote shell, secure shell) ➔ viele, kleine Segmente, sehr großer Overhead (z.B. 1 Byte/Segment ➔ 4000%)
- Lösung: Spekulatives Warten, bis „genug" Daten, dann geblockt übertragen
- Nachteil: Wartezeit auch bei insgesamt kleiner zu übertragenden Datenmenge
- TCP CORK: gesonderter Dienstaufruf bei manchen Implementierungen, um geringe Datenmenge zu übergeben

Kapitel 3.6
User Datagram Protocol (UDP)

Das verbindungslose Transportprotokoll des Internets

Überblick UDP

- Verbindungsloses, unzuverlässiges Internet Transportprotokoll (RFC 768)
  - kein Verbindungsaufbau, -abbau, oder -status
  - unregulierte Senderate
  - keine Sequenznummern
    ➔ keine Reihenfolgesicherung, Duplikats- oder Verlusterkennung
- 8 Byte Header (vgl. mit mindestens 20 Byte bei TCP)
- Unterstützt das Multiplexen über Anwendungen mit Hilfe von UDP-Ports (wie bei TCP)
- Bsp. Protokolle, die UDP verwenden: TFTP, DNS, RPC, SNMP
- UDP-Nutzer (Anwendungen) sind über UDP-Sockets adressierbar.

Der UDP Header (PCI)

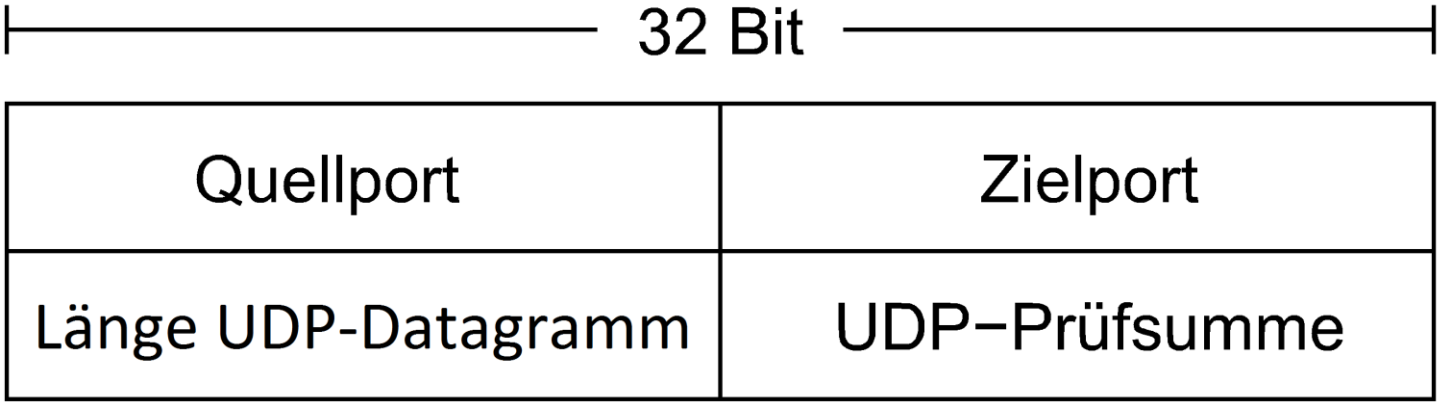

- **Quellport/Zielport** (je 16 Bit): zur Adressierung
- **Datagrammlänge** (16 Bit): Maximallänge von 65515 Bytes (bei Verwendung von IPv4)
- **Prüfsumme** (16 Bit): (optionale) Prüfsumme über IP-Pseudoheader und UDP-Datagramm

Verwendung von UDP

- Programmierung mit UDP Sockets
  - Senden/Empfangen isolierter Datagramme
  - Sicht auf lokales Socket
  - Senden/Empfangen zu/von mehreren Hosts (IP-Adresse und Port des Empfängers werden i.d.R. beim Senden jedes einzelnen Datagramms angegeben)
- Reihenfolgesicherung, Verlust- und Duplikatsbehandlung, sowie die Steuerung der Senderate obliegen dem Anwendungsprogramm.

Beispiel: UDP-Socket-Programm

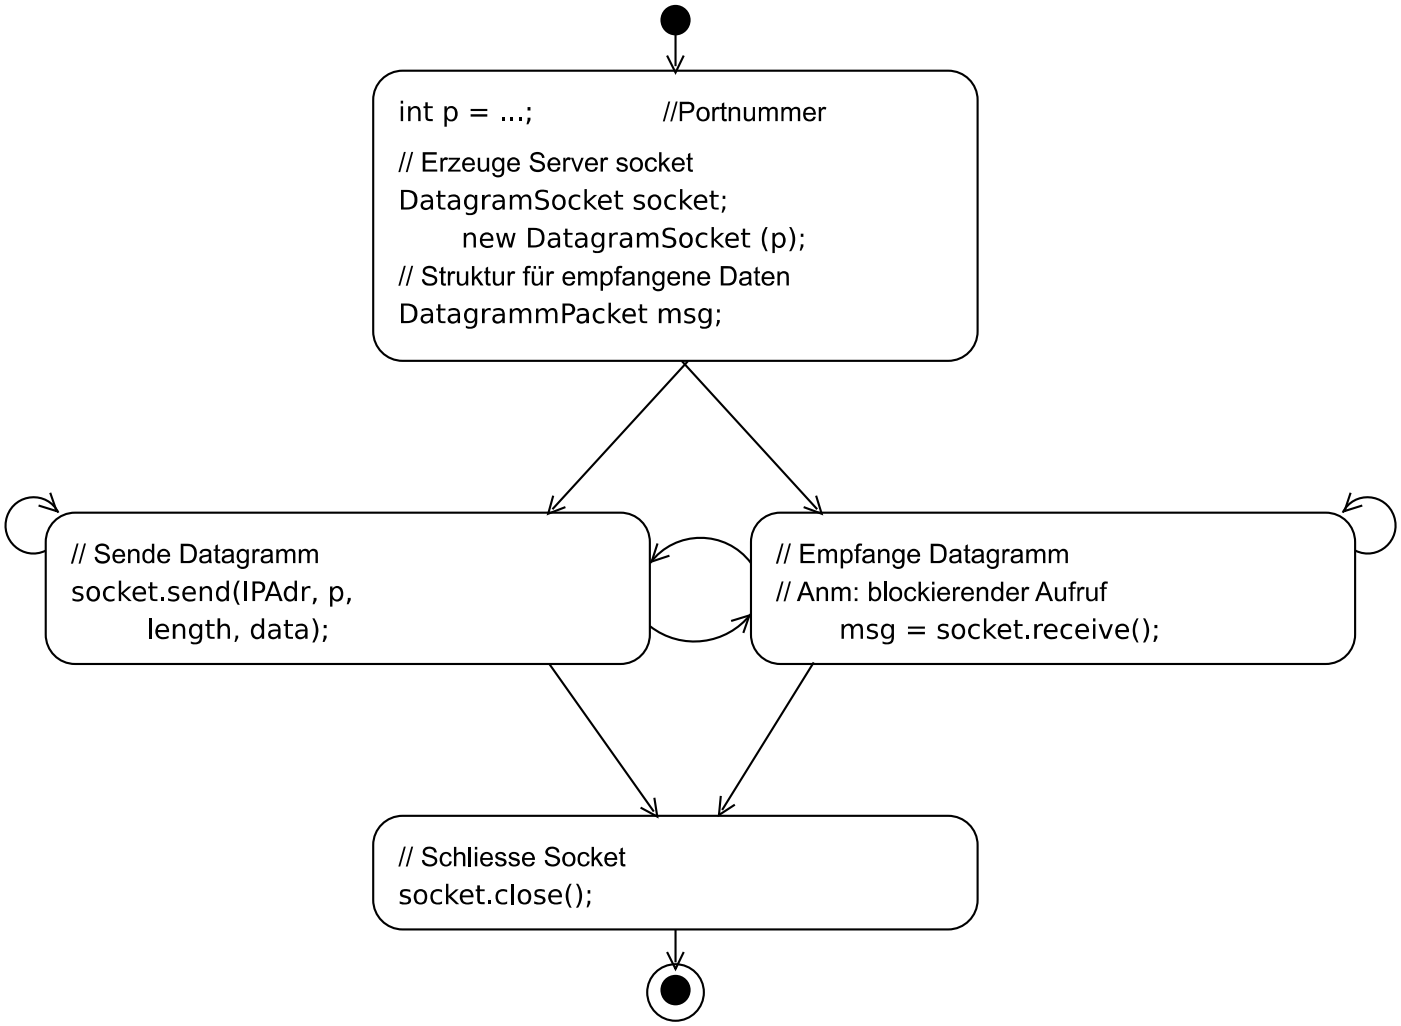

Zusammenfassung Transportschicht

- Netzunabhängiger Transport von Nachrichten zwischen Endsystemen
- Verschattung der Wege durchs Netz
- Fehlerbehandlung Ende-zu-Ende
- Anpassung der Übertragungsqualitäten
- Splitting/Multiplex über Anwendungen/Prozesse
- Verbindungsloser oder -orientierter Dienst
- z.B. im Internet: TCP (verbindungsorientiert), UDP (verbindungslos)

Fragen zu Kapitel 3 (1/2)

- Was sind Einflussgrößen für die Größe des Sequenznummernraumes?
- Wozu kann die Fenstertechnik (Schiebefensterprotokoll) eingesetzt werden?
- Wie wird Eindeutigkeit der Sequenznummern sichergestellt?
- Wie wirken sich zu kleine Fenster aus, wie zu kleine Sequenznummernräume?
- Unter welchen Voraussetzungen genügt ein Zwei-Wege-Handschlag für einen Verbindungsaufbau?
- Warum ist für einen sicheren Verb.-Aufbau auf einer Transportschicht i.A. ein Drei-Wege-Handschlag erforderlich?
- Warum sollte ein Verbindungsabbau i.A. beidseitig geschehen?
- Was ist der Unterschied zwischen Flusssteuerung und Staukontrolle?

Fragen zu Kapitel 3 (2/2)

- Wann ist es für eine Anwendung sinnvoll UDP zu verwenden?
- Wie sichert man für eine Anwendung, die über UDP läuft, trotzdem einen zuverlässigen Datentransfer?
- A sendet 2 TCP-Segmente (mit Sequenznummern 90 und 110) an B.
  - Wie viele Daten enthält das erste Segment? Wie lang ist es insgesamt?
  - Wie lautet die Quittungsnummer in der Bestätigung von B nach A, wenn nur das erste Segment verloren geht?
- Welche Mechanismen bietet TCP für eine zuverlässige Ende-zu-Ende Verbindung?
- Welches Transportprotokoll unterstützt ein Multiplexen von Anwendungen?