Verteilte Systeme

3. Protokollfamilie TCP/IP

Einordnung in OSI-Modell

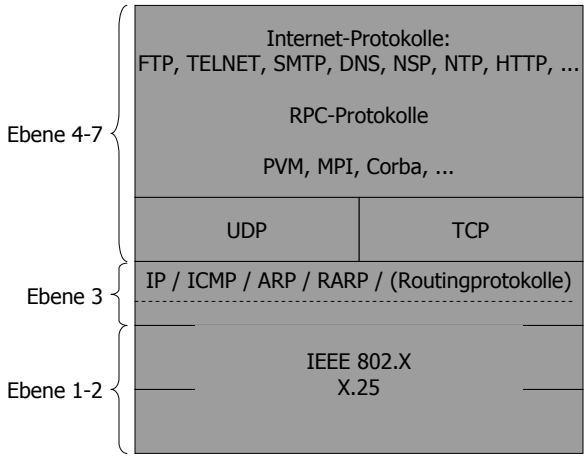

IP-Adressen (IPv4)

- Class A: 2^7-2 Netze mit jeweils bis zu 2^{24}-2 Rechnern

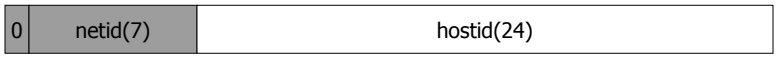

- Class B: 2^{14}-2 Netze mit jeweils bis zu 2^{16}-2 Rechnern

- Class C: 2^{21}-2 Netze mit jeweils bis zu 2^8-2 Rechnern

Verteilte Systeme, Sommersemester 1999 Folie 3.3

IP-Adressen (cont.)

- Schreibweise: „Dotted Decimal"

10001000	11000111	00110110	11010010

= 136.199.54.210
  - Ist ein Class X-Netz?
  - Netzanteil?
  - Hostanteil?
- Symbolische Namen
  - 131.199.54.210 = balvenie.uni-trier.de
  - Über verteilte „Datenbank" (DNS, NSP, LADP, ...)
- IP-Netadresse
  - Hostanteil ist 0

Verteilte Systeme, Sommersemester 1999 Folie 3.4

Multicast- und Broadcast-Adressen

- Multicast

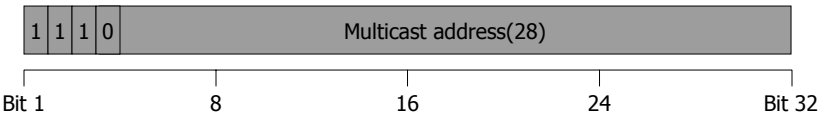

  - Direkte Abbildung bei Multicast-fähigen Netzen
  - Flooding-Algorithmen sonst
  - Beispiel: Mbone
    - Tunneln bei Unicast-Strecken
- Verwaltung der Multicast-Gruppen
  - IGMP = Internet Group Management Protocol
- Broadcast
  - Nur innerhalb eines Netzes
  - Hostanteil alles 1

Verteilte Systeme, Sommersemester 1999 Folie 3.5

Subnetze

- Maximale Rechnernanzahl in Class-A- und Class-B-Netzen für ein Netz (z.B. Ethernet) zu groß
  - Class A: 16.777.214 Rechner
  - Class B: 65.534 Rechner
- Unterteilung in Unternetze

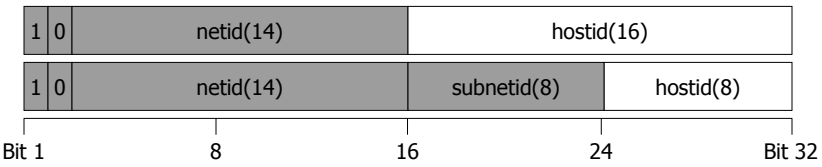

- Netzmaske definiert Grenze zwischen Subnetz und Hostanteil

Verteilte Systeme, Sommersemester 1999 Folie 3.6

ARP und RARP

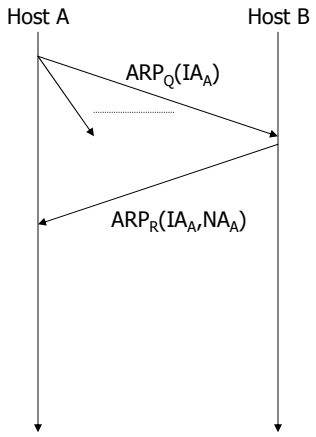

- ARP = Address Resolution Protocol
  - Ermittlung einer Netzwerkadresse im gleichem Netz
    - Gegeben IA
    - Gesucht NA
  - Voraussetzung Broadcast-fähiges Netz
    - Bei dedizierten Leitungen Konfigurationssache
- RARP = Reverse ARP
  - Gegeben NA, Gesucht IA
  - Diskless Clients

IP-Protokoll (IPv4)

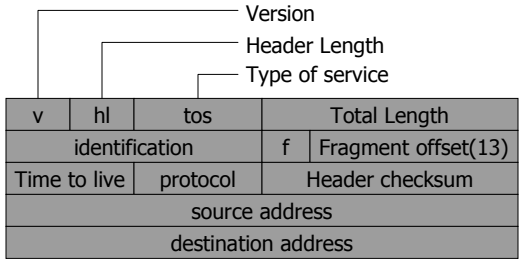

- 20 Byte Header
- Maximale Größe IP-Datagramm: 64 Kbyte inkl. Header
- Type of Service (tos)
  - Hohe Zuverlässigkeit, Hoher Durchsatz, Geringe Latenz, Prioritäten
- Fragmentierung
  - Identifikation zusammengehörender Fragmente
  - Offset des Fragments im IP-Datagramm
- Time-to-live
  - Hop-Count; wird von Routern dekrementiert

Aufgaben der IP-Netzwerkebene

- Übertragung von IP-Datagrammen
  - Routing
  - Fragmentierung und Assembly
- Netzverwaltung und Melden von Fehlern
  - ICMP

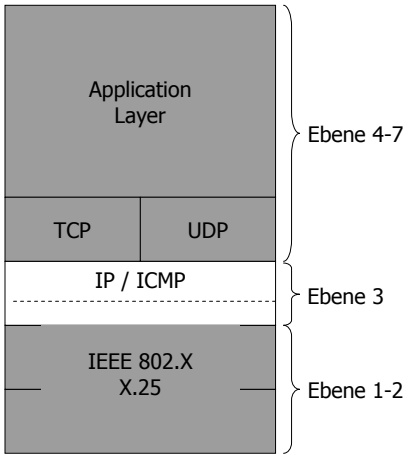

Verteilte Systeme, Sommersemester 1999 Folie 3.9

IP: Routing

- „Normale" Rechner
  - Empfänger im selben Netz
    - ARP falls notwendig
    - Direkt Senden
  - Empfänger in anderem Netz
    - Nachricht an „Default Router"
- Router
  - Routingtabelle durchsuchen
    - Host-Match
    - Network-Match
    - Default Router
  - An ermittelte NA weiterleiten
  - „Routing Mechanism"
- Routing Policy meist durch zusätzliche Protokolle (Applikationsebene)

Host	Forward-NA
Netz	Forward-NA
sonst	Forward-NA

Verteilte Systeme, Sommersemester 1999 Folie 3.10

Routing-Protokolle

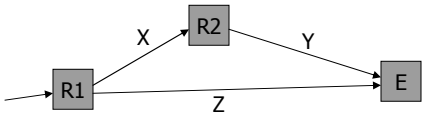

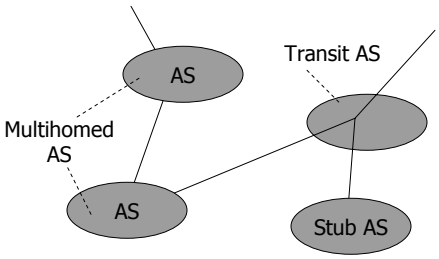

- Autonome Systeme (AS)
  - Verwaltungseinheiten
- Interior Gateway Protocols
  - Distanzvektor-basiert
    - RIP (Routing Information Protocol)
    - RIP-2
  - Link-state-basiert
    - OSPF (Open Shortest Path First)
- Exterior Gateway Protocols
  - EGP
  - BGP (Border Gateway Protocol)
- Größe der Routingtabellen
  - CIDR (Classless Interdomain Routing)

Verteilte Systeme, Sommersemester 1999 Folie 3.11

IP: Fragmentierung und Assembly

- Intranet-Fragmentierung
  - An jedem Hop Assembly und anschließende Fragmentierung für ausgehende MTU
  - Vorteil: Nutzung volle MTU
  - Nachteil: Zusätzliche Kosten
  - Problem: Fragmentverluste
- Internet-Fragmentierung
  - Nur Fragmentierung an Hops mit kleiner werdender MTU
  - Vor- und Nachteile?
- MTU-Path-Discovery
  - Kleinste MTU auf dem Weg zum Empfänger bestimmen und entsprechend fragmentieren
  - Wann sinnvoll?

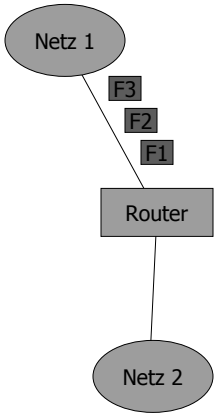

Verteilte Systeme, Sommersemester 1999 Folie 3.12

ICMP = Internet Control Message Protocol

- Echo (Ping)
  - request
  - reply
- Destination Unreachable
  - network unreachable
  - host unreachable
  - protocol unreachable
  - port unreachable
  - fragmentation needed but don´t fragment bit set
  - source route failed
  - destination network unknown
  - destination host unknown
  - destination administratively prohibited
  - network/host unreachable for TOS
  - ...
- Source Quench
- Redirect
  - redirect for network
  - redirect for host
  - redirect for TOS and network
  - redirect for TOS and host
- Router
  - advertisement
  - solicitation
- Time exceeded
- Anfragen
  - timestamp request
  - information request
  - address mask request

UDP

Source port	Destination port
UDP length	UDP checksum

- UDP = User Datagram Protocol
  - End-to-End-Version von IP (Portnummer)
- Best-Effort
  - Nachrichtenverluste
  - Keine Ordnung
  - Keine Flußkontrolle
- 8 Byte Header
- Maximale Datagramm-Länge: 64 Kbyte inkl. Header
- UDP-Multicast möglich
  - Angabe einer Multicast-IP-Adresse als Empfänger
  - Meist von Sysadmins ausgeschaltet

TCP

source port			destination port
Sequence number			
hl		flags	Window size
checksum			Urgent pointer

- TCP = Transmission Control Protocol
- Reliable Stream
  - Verbindungsorientiert
  - Flußkontrolle (Sliding-Window)
  - Duplex
- Segmente
  - Maximale Datenmenge die in einem Schritt übertragen wird
  - Maximale Segmentgröße (MSS) „handeln" Sender und Empfänger aus

Verteilte Systeme, Sommersemester 1999 Folie 3.15

Socketschnittstelle in UNIX

- Socket = Kommunikationsendpunkt (Ebene 4)
- UDP- oder TCP-Adresse:

```
struct sockaddr_in {
    u_short sin_family;
    u_short sin_port;
    u_long sin_addr;
    }
```

  - `sin_family` = Protokollfamilie (TCP/IP = `PF_INET`)
  - `sin_addr` = IP-Adresse
  - `sin_port` = Portnummer
- Erzeugen und Schließen von Sockets vergleichbar Dateideskriptor
- Zugriffsfunktionen
  - UDP: `sendto` und `recvfrom`
  - TCP: Einbettung in Dateischnittstelle (`read` und `write`)

Verteilte Systeme, Sommersemester 1999 Folie 3.16

Sockets erzeugen und schließen

- Erzeugung:

```
int sock;
sock = socket (PF_INET, service, 0);
```

  - UDP: service = SOCK_DGRAM
  - TCP: service = SOCK_STREAM
  - Es wird noch keine Portnummer vergeben
- Schließen:

```
close (sock);
```

Portnummer zuweisen

- Funktion `bind`:

```
int bind (
   int socket,
   sockaddr_in *addr,
   int addr_len
   )
```

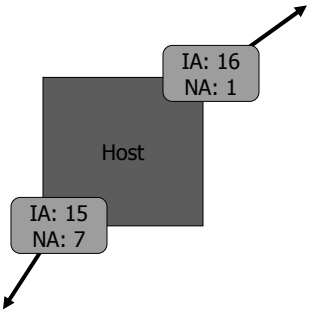

- Aufrufvarianten
  - Portnummer:
    - Transient: `port = 0`
    - Fest (z.B. ftp-Server TCP-Port 21): `port = <Portnummer>`
  - Netz-Interface:
    - Bestimmtes Interface: `sin_addr = <IP-Adresse>`
    - An allen angeschlossenen Interfaces: `sin_addr = INADDR_ANY`
- Zahlen müssen im Netzwerkstandard angegeben werden
  - Konvertierungsroutinen: `htonl`, `htons`, ...

Beispiel: TCP-Port 21 erzeugen

```
int s;
struct sockaddr_in saddr;
int ret;

s = socket(AF_INET,SOCK_STREAM,0);
bzero(&saddr,sizeof saddr);
saddr.sin_family = AF_INET;
saddr.sin_addr.s_addr = INADDR_ANY;
saddr.sin_port = htons(21);
ret = bind(s,&saddr,sizeof(saddr));
assert(ret != -1);

...
```


UDP-basierte Kommunikation

- Senden eines Datagramms:

```
retcode = sendto (
    int socket,
    char *msg, int msg_len,
    int flags,
    sockaddr_in *recv, int recv_len
    )
```

- Empfangen eines Datagramms:

```
rectcode = recvfrom (
    int socket,
    char *msgbuf, int msgbuf_len,
    int flags,
    sockaddr_in *sender, int *sender_len
    )
```

  - Rückgabewert ist die tatsächliche Datagrammlänge

TCP-basierte Kommunikation

- Asymmetrischer Verbindungsaufbau
- Passive Seite (Server):
  1. Socket erzeugen
  2. Socket an Portnummer binden
  3. Initialisierung der Verbindungsannahme (**`listen`**)
  4. Auf Verbindungswunsch warten (**`accept`**)
- Aktive Seite (Client):
  1. Socket erzeugen
  2. Server ermitteln (IP-Adresse, Portnummer)
  3. Verbindung aufbauen (**`connect`**)

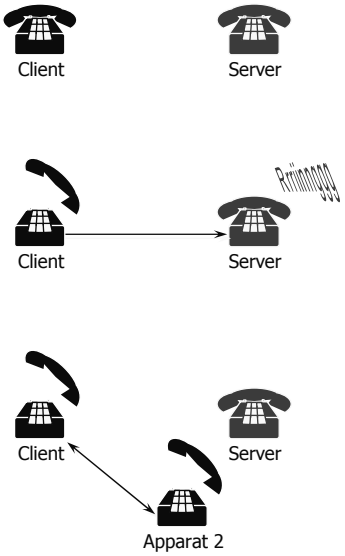

Verteilte Systeme, Sommersemester 1999 Folie 3.21

Listen, Accept und Connect

Server-Seite

- Initialisierung des passiven Wartens:
  - `retcode = **listen** ( int socket, int queue_length )`
    - Socket wird passiv
- Auf Verbindungswünsche warten:
  - `retcode = **accept** ( int socket, sockaddr_in *client, int *client_len )`

Client-Seite

- Verbindungswunsch herstellen:
  - `retcode = **connect** ( int socket, sockaddr_in *server, int server_len )`

Verteilte Systeme, Sommersemester 1999 Folie 3.22

Ablauf eines Verbindungsaufbaus
(1) Sockets erzeugen


```
cs = socket(...,SOCK_STREAM,0);    as = socket(..., SOCK_STREAM,0);
```


Ablauf eines Verbindungsaufbaus
(2) Server-Adresse (Portnummer) festlegen

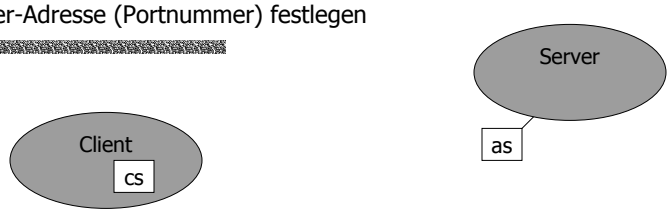


```
cs = socket(...,SOCK_STREAM,0);    as = socket(..., SOCK_STREAM,0);
                                   bind(as,server_port);
```

Ablauf eines Verbindungsaufbaus
(3) Server-Socket wird passiv


```
cs = socket(...,SOCK_STREAM,0);
```

```
as = socket(..., SOCK_STREAM,0);
bind(as,server_port);
listen(as,4);
```


Ablauf eines Verbindungsaufbaus
(4) Verbindungswunsch des Clients

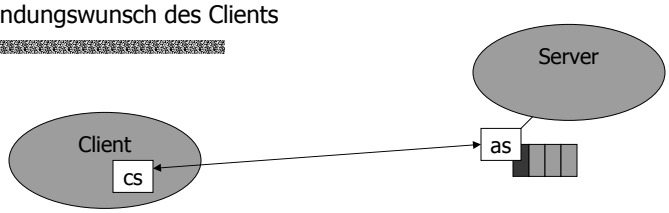


```
cs = socket(...,SOCK_STREAM,0);
```

```
connect(cs,server(host,port));
```

```
as = socket(..., SOCK_STREAM,0);
bind(as,server_port);
listen(as,4);
```

Ablauf eines Verbindungsaufbaus
(5) Server akzeptiert Verbindungswunsch

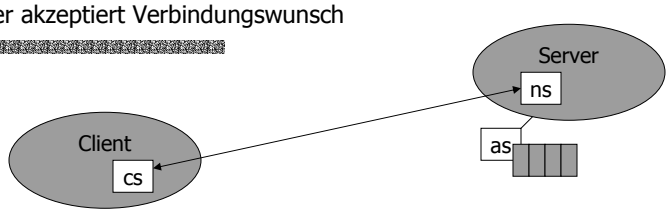


```
cs = socket(...,SOCK_STREAM,0);      as = socket(..., SOCK_STREAM,0);
                                     bind(as,server_port);
                                     listen(as,4);
connect(cs,server(host,port));
                                     ns = accept(ss,...);
```


Ablauf eines Verbindungsaufbaus
(6) Datenübertragung

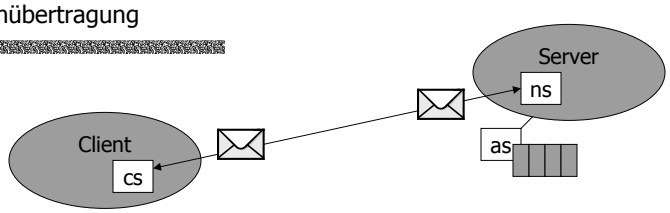


```
cs = socket(...,SOCK_STREAM,0);      as = socket(..., SOCK_STREAM,0);
                                     bind(as,server_port);
                                     listen(as,4);
connect(cs,server(host,port));
                                     ns = accept(ss,...);
write(cs,...);
write(cs,...);
                                     read(ns,...);
```

Nicht-selektives Warten

- Auf verschiedene Ereignisse blockierend Warten
  - Empfangs- und sendebereite Sockets
  - Lese- und schreibbereite Dateien
- Funktion **`select`**:

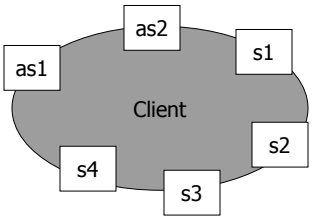


```
int sock1, sock2;
fd_set fds;
sock1 = socket(...);
sock2 = socket(...);
FD_ZERO(&fds);
FD_SET(sock1,&fds);
FD_SET(sock2,&fds);
ret = select(FD_SETSIZE,&fds,...,timeout);
...
if (FD_ISSET(sock1,&fds) { ... };
```

- Zugegeben, die Funktion ist etwas komplex :-)

Windows 95/NT und TCP/IP

- Winsock-Schnittstelle
- Alle relevanten Datenstrukturen und Funktionen der Socket-Schnittstelle sind definiert

```
#include <winsock.h>
int main ( int ac, char **av ) {
    struct WSAData wsad;
    int ret;
            ret = WSAStartup(0x0101,&wsad);
    if (ret != 0) {
            fprintf(stderr,"WSAStartup: failed\n");
            return 0;
    }
    printf("# WSA Info:\n");
    printf("# Version %xd\n",wsad.wVersion);
    printf("# Highest Version %xd\n",wsad.wHighVersion);
    printf("# Description: %s\n",wsad.szDescription);
    printf("# System Status: %s\n",wsad.szSystemStatus);
    printf("# Maximal %d open sockets per process\n",wsad.iMaxSockets);
    printf("# Maximum size of UDP packet in bytes:%d\n",wsad.iMaxUdpDg);

    ...

    WSACleanup();
}
```

FTP

- File Transfer Protocol
  - TCP-basierte Kommunikation, Port 21
  - Unterstützt beschränkte Menge an Dateitypen (ASCII, Binär, ...) und Dateistrukturen (Byte Stream, Records)
- Zwei TCP-Verbindungen
  - Kontrollverbindung
    - FTP-Server passiv
    - FTP-Client aktiv
  - Datenverbindung
    - Client öffnet passiven Socket
    - IP-Adresse und Portnummer wird über die Kontrollverbindung an Server übertragen
    - Server stellt Verbindung her

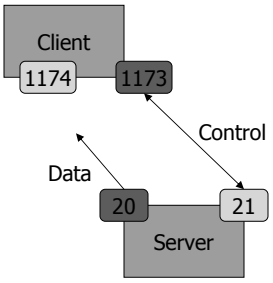

Literatur

- D.E. Comer, D.L. Stevens
  Internetworking with TCP/IP, Volume I-III
  Prentice-Hall, 1993
- W. Stevens
  TCP/IP Illustrated, Volume 1: The Protocols (1994)
  TCP/IP Illustrated, Volume 3: T/TCP, HTTP, ... (1996)
  Addison-Wesley
- G. Wright, W. Stevens
  TCP/IP Illustrated, Volume 2: The Implementation
  Addison-Wesley, 1995