

BP 1	Verteilte Systeme: Nachrichtenmechanismen
2	<p>Nachrichtenmechanismen</p> <ul style="list-style-type: none"> ◆ Spezielle Literatur <p>Comer, D.: Operating System Design - Volume II, Internetworking with Xinu. Prentice-Hall, Englewood Cliffs, New Jersey, 1987.</p> <p>Comer, Douglas and Stevens, David L.: Internetworking with TCP/IP Vol. II (3rd Edition) 1999 ISBN 0-13-973843-6</p> <p>Fletcher, J. G.: Serial Link Protocol Design: A Critique of the X.25 Standard, Level 2. Computer Communication Review, Vol. 14, No. 2, 1984, pp. 26-33.</p> <ul style="list-style-type: none"> ◆ Einschlägige Links (überprüft am 4.10.2001) <ul style="list-style-type: none"> • Protokolle http://www.protocols.com Einstieg zu Beschreibungen aller gängigen Protokolle • XINU-Hompage http://public.ise.canberra.edu.au/~chrisc/xinu.html

11.10.01	Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig	2-1
BP 1	Verteilte Systeme: Nachrichtenmechanismen	

BP 1**Verteilte Systeme: Nachrichtenmechanismen**

Untergliederung

2.1 Strukturen der Kommunikation

2.2 Beispiel einer Implementierung

2.2.1 Maschinensprachebene

2.2.2 Das Internet

2.2.3 Struktur der Systemsoftware und ihre Realisierung

2.2.4 Systemanlauf, Adreßauflösung

2.2.5 Internet-Protokoll (IP)

2.2.6 Internet-Kontrollnachrichten (ICMP)

2.2.7 Datagrammdienst (UDP)

2.2.8 Verschiedene höhere Protokolle (TCP, FTP, SMTP)

11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

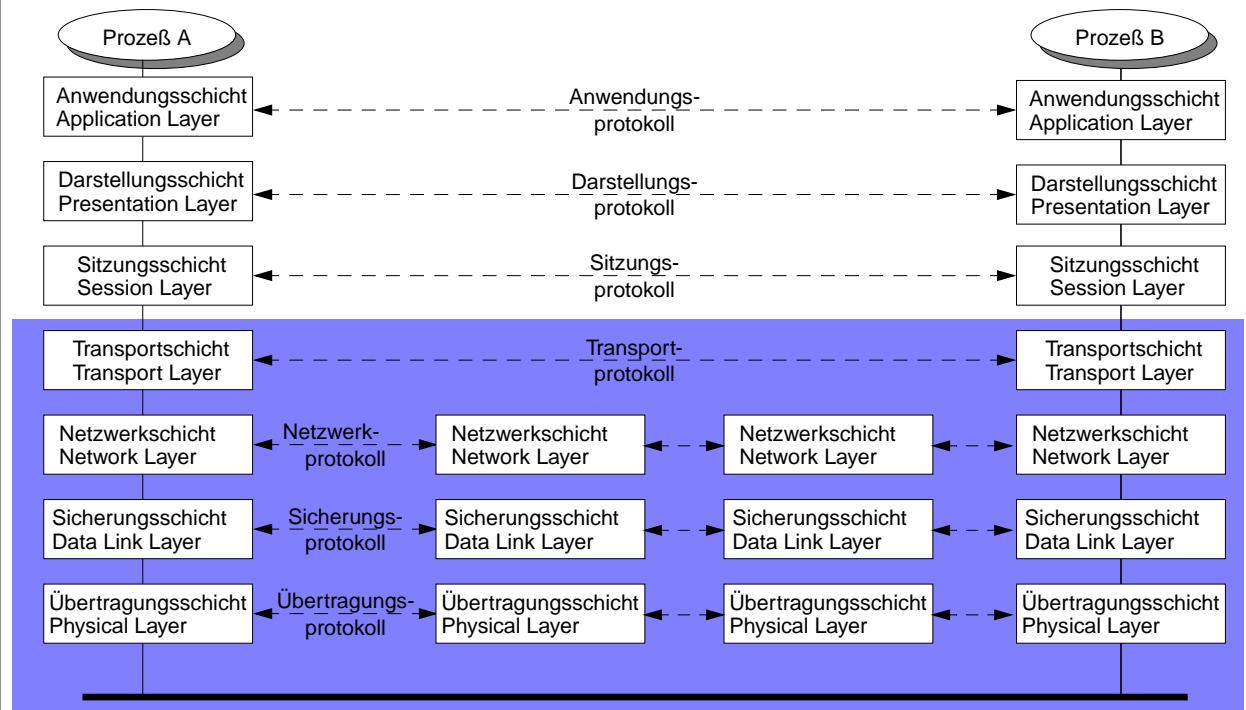
2-3

BP 1**Verteilte Systeme: Nachrichtenmechanismen**

2.1

Strukturen der Kommunikation

ISO/OSI-Referenzmodell



11.10.01

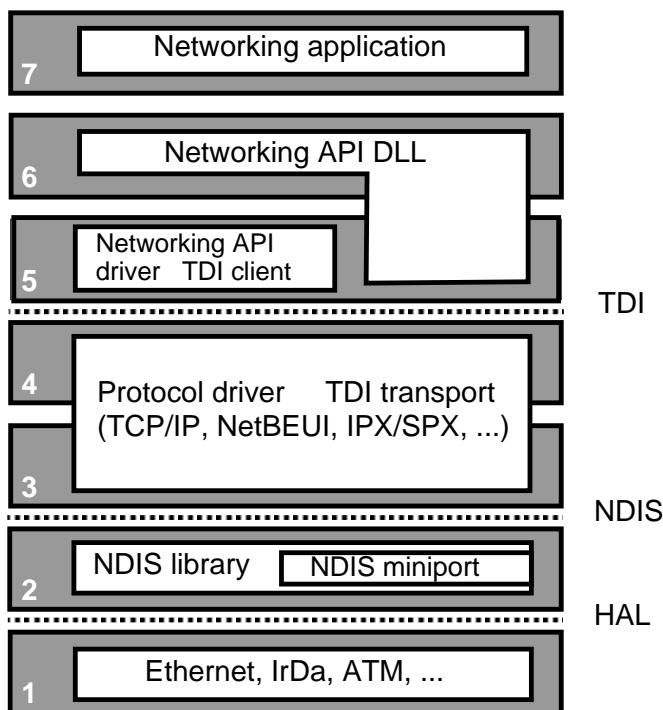
Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann

Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-4

1. Übertragungsschicht
 - Ungesicherte Übertragung eines Bitstroms
 - Charakteristika der benutzten Signalformen sind Gegenstand der Standardisierung
2. Sicherungsschicht
 - Übertragung von Bitblöcken zwischen direkt physisch verbundenen Einheiten
 - Synchronisation, Fehler- und Flußkontrolle, evtl. Nachrichtenwiederholung
3. Netzwerkschicht
 - Virtuelle Verbindung zwischen zwei Einheiten, evtl. unter Zwischenschaltung anderer Einheiten
4. Transportschicht
 - Zuverlässiger, transparenter Nachrichtentransport zwischen Endpunkten
 - Zerlegen von Nachrichten in Transportpakete und Wiederzusammensetzen
 - Flußkontrolle und Fehlerbehandlung

◆ Beispiel: Windows 2000



API application programming interface

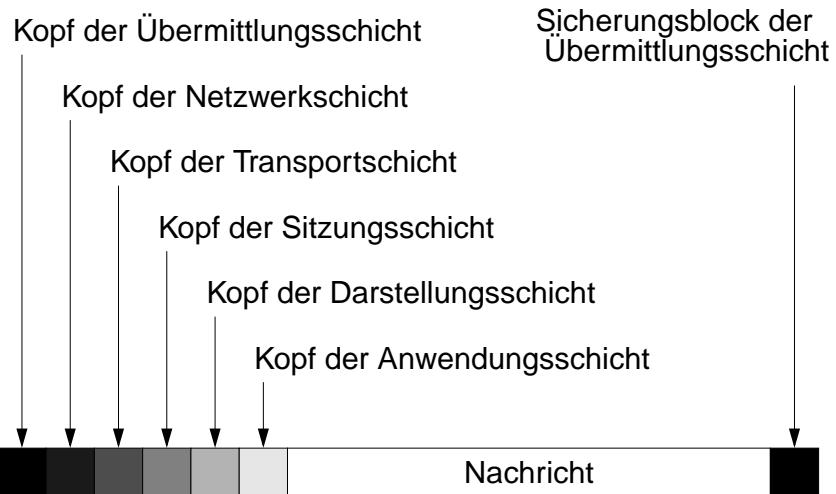
DLL dynamic-link libraries

HAL hardware abstraction layer

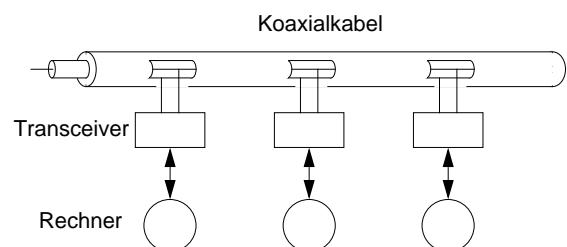
NDIS Network Driver Interface Specification

TDI Transport Driver Interface

Nachrichtenformat geschichteter Protokolle

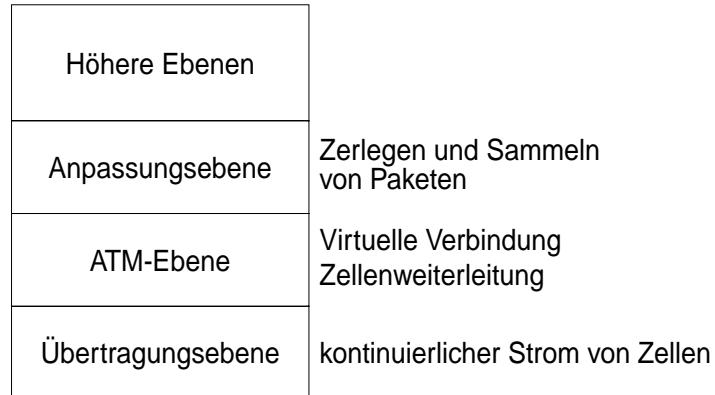


- Ethernet
- ◆ Entwickelt von Xerox PARC ab etwa 1970
- ◆ Standardisiert von Xerox, Intel und DEC 1978
- ◆ Transaktionsorientiert
- ◆ Zugriffsverfahren CSMA/CD
(Carrier Sense Multiple Access
with Collision Detection)
- ◆ Pakete mit 46 bis 1522 Byte Nutzinformation
- ◆ Übertragungsgeschwindigkeit
 - Standard: 10 MBit/s
 - Fast Ethernet: 100 MBit/s
 - Gigabit Ethernet: 1 GBit/s



BP 1**Verteilte Systeme: Nachrichtenmechanismen**

- ATM: Asynchronous Transfer Mode
 - ◆ Transaktionsorientiert
 - ◆ Zellen fester Größe (53 Byte) werden über virtuelle Verbindungen übertragen
 - ◆ Geeignet zur Übermittlung von Sprache, Video und digitalen Daten
 - ◆ Übertragungsraten reichen von 155 MBit/s bis 622 MBit/s
 - ◆ ATM-Referenzmodell



11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
 Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-9

BP 1**Verteilte Systeme: Nachrichtenmechanismen**

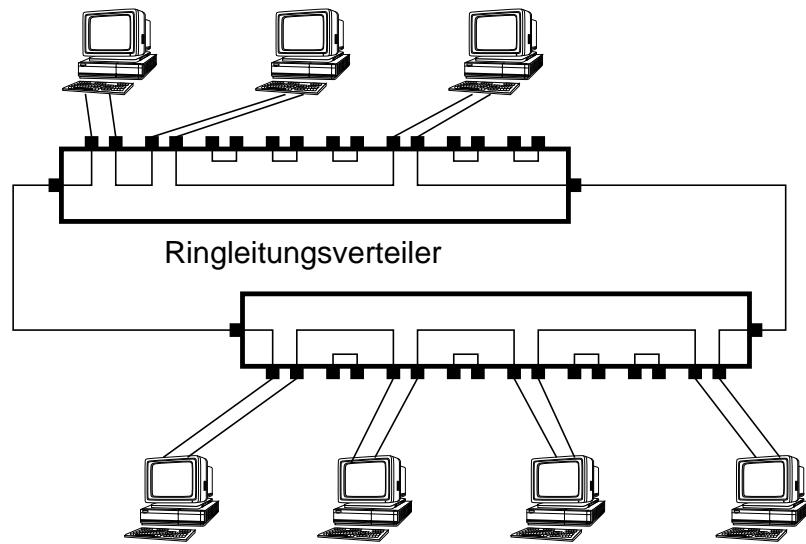
- Token-Bus
 - ◆ Token durchläuft ständig einen Ring und kann Daten mit sich führen.
 - Ein Knoten kann 'freies' Token belegen durch Anfügen von Daten.
 - Knoten, die ein 'belegtes' Token erhalten, können die Daten entnehmen; auf jeden Fall reichen sie es weiter, wenn sie es nicht belegt haben.
 - Wenn der belegende Knoten das Token erhält, gibt er es wieder frei.
 - ◆ Übertragungsraten
 - 4 MBit/s
 - 16 MBit/s

11.10.01

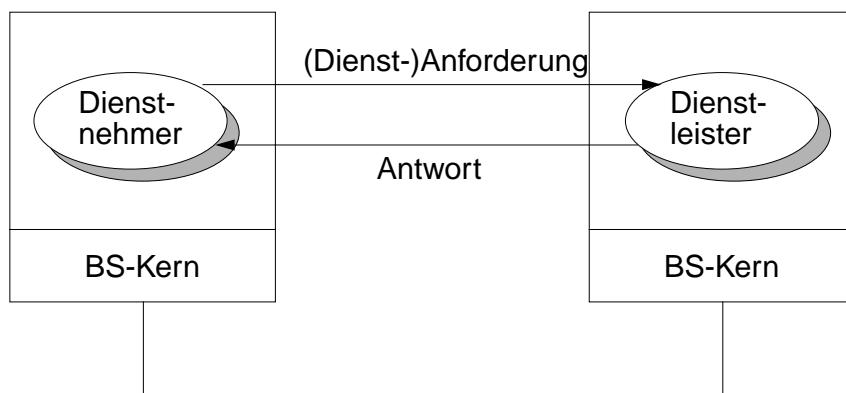
Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
 Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-10

- ◆ Hardwarestruktur des 'Token Bus'



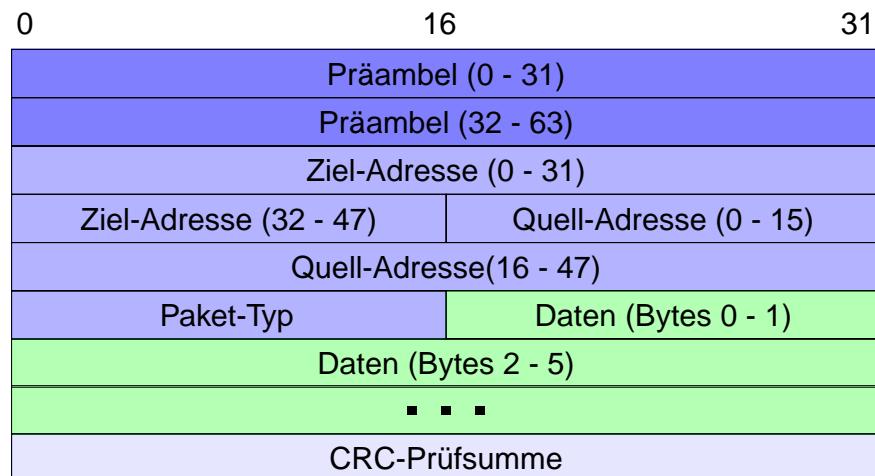
- Das Dienstnehmer-/Dienstleister-Modell (Client/Server Model)



- ◆ Problem: Adressierung



Ethernet packet



Ethernet Link-Level Protocol Format

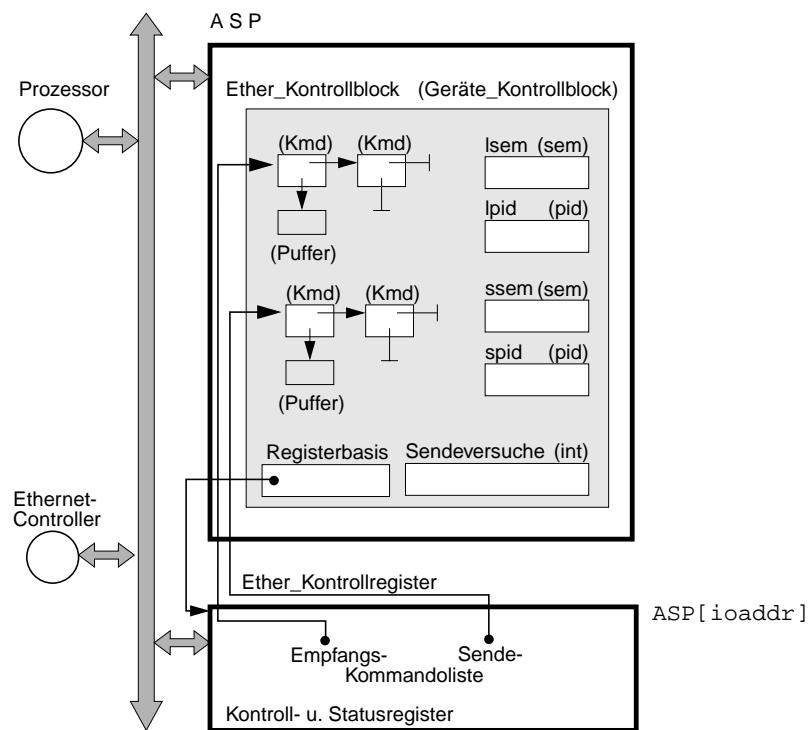
```

class EtherAddress {
    public static final int EMINPAK = 64; // minimum packet length in bytes
    public static final int EMAXPAK = 1266; // maximum packet length in bytes
    public static final int EHLEN = 14; // size of ether header
    public static final int EDLEN = EMAXPAK - EHLEN;
    public static final int EPADLEN = 6; // length of phys. address
    public static final byte[] EBCAST = {(byte)0377, (byte)0377, (byte)0377,
                                        (byte)0377, (byte)0377, (byte)0377};
                                // Ethernet broadcast address
    byte[] address = new byte[EPADLEN];
}

class EtherPacket {
    // Structure of ethernet header
    byte[] preamble = new byte[8];
    EtherAddress e_dest; // destination host address
    EtherAddress e_src; // source host address
    short e_ptype; // packet type
    public static final int EP_IP = 0x00000800; // DARPA Internet protocol
    public static final int EP_ARP = 0x00000806; // address resolution protocol
    public static final int EP_RARP = 0x00008035; // reverse addr. resol. protocol
    byte[] ep_data = new byte[len]; // 46 <= len <= 1522
    unsigned crc;
}

```

Der Ethernet-Anschluß des Rechners am Beispiel des Digital Equipment Q-bus Network Adapter



11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-15

Die Register des DEQNA (Digital Equipment Q-bus Network Adapter)

Byte-Nr.	Bedeutung beim Lesen	Bedeutung beim Schreiben
0/1	Byte 0 der eigenen phys. Ethernetadr.	bedeutungslos
2/3	Byte 1 der eigenen phys. Ethernetadr.	bedeutungslos
4/5	Byte 2 der eigenen phys. Ethernetadr.	Bits 0 bis 15 der Adresse der Eingabebefehlsliste
6/7	Byte 3 der eigenen phys. Ethernetadr.	Bits 16 bis 21 der Adresse der Eingabebefehlsliste
8/9	Byte 4 der eigenen phys. Ethernetadr.	Bits 0 bis 15 der Adresse der Ausgabebefehlsliste
10/11	Byte 5 der eigenen phys. Ethernetadr.	Bits 16 bis 21 der Adresse der Ausgabebefehlsliste
12/13	Adresse des Interruptvektors	Adresse des Interruptvektors
14/15	Kontroll- und Statusregister	Kontroll- und Statusregister

11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-16

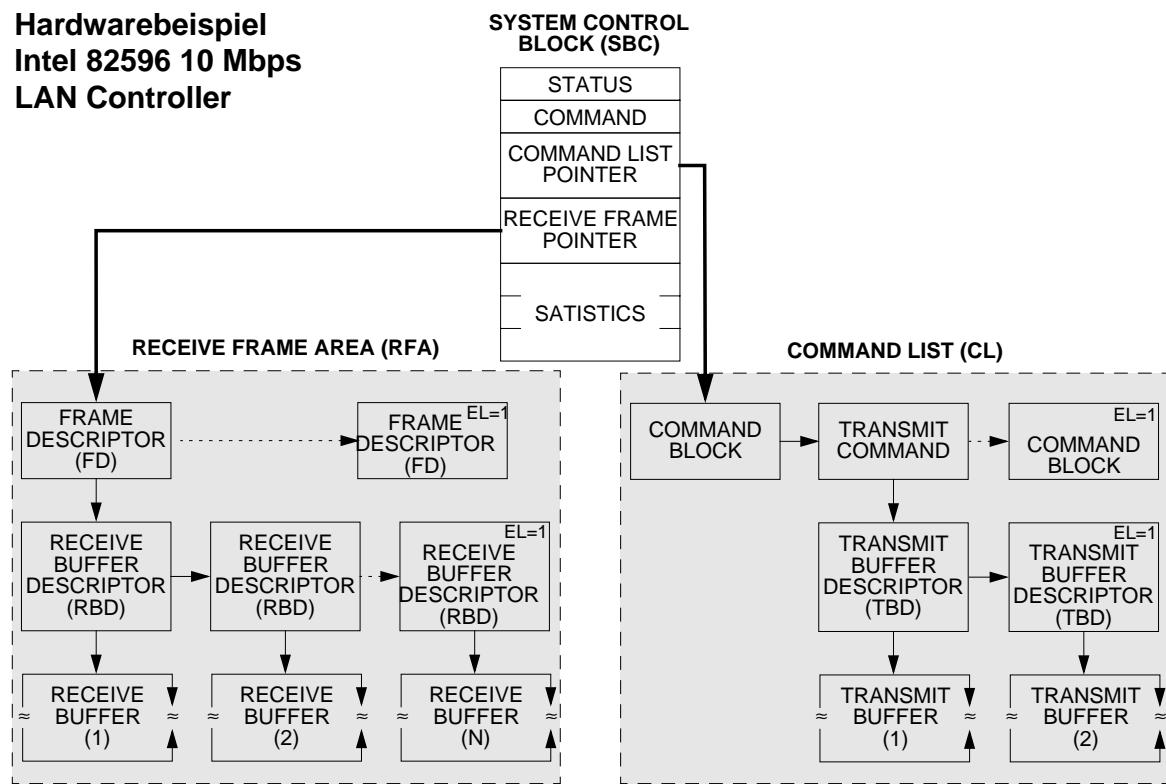
Bedeutung des Kontroll- und Statusregisters

Bit	Bezeichnung	Bedeutung
15	DQ_RINT	Eingabe-Interrupt (auf 1 gesetzt, wenn ein Eingabevorgang abgeschlossen ist, muß vom Betriebssystem auf 0 gesetzt werden)
13	DQ_CARR	Trägersignal vorhanden (hat Wert 1, wenn Trägersignal vorhanden)
7	DQ_XINT	Ausgabe-Interrupt (auf 1 gesetzt, wenn ein Ausgabevorgang abgeschlossen ist, muß vom Betriebssystem auf 0 gesetzt werden)
6	DQ_IEN	Interrupts erlaubt (Eingabe- und Ausgabe-Interrupt werden nur gesetzt, wenn dieses Bit 1 ist)
5	DQ_RLI	Eingabeliste ungültig (wird von der HW auf 1 gesetzt, wenn die Eingabeliste abgearbeitet ist)
4	DQ_XLI	Ausgabeliste ungültig (wird von der HW auf 1 gesetzt, wenn die Ausgabeliste abgearbeitet ist)
1	DQ_REST	Rücksetzen (mit 1 beschreiben, wenn die HW in Anfangszustand versetzt werden soll)
0	DQ_ENBL	Empfang erlaubt (muß nach dem Einschalten auf 1 gesetzt werden, um den Empfang von Paketen zu erlauben)

Befehlsaufbau

Bytes 0/1	Indikator
Bytes 2/3	Bits 8 bis 15: Festlegung der Bedeutung der nachfolgenden Adresse (Pufferadresse, Befehlsadresse) bzw. Kennzeichnung als letzter Befehl Bits 0 bis 7: Bits 16 - 21 der Adresse
Bytes 4/5	Bits 0 bis 15 der Adresse
Bytes 6/7	Pufferlänge
Bytes 8/9	Zustandswort 1 (u. a. Fehleranzeigen)
Bytes 10/11	Zustandswort 2 (??)

Hardwarebeispiel
Intel 82596 10 Mbps
LAN Controller



11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
 Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

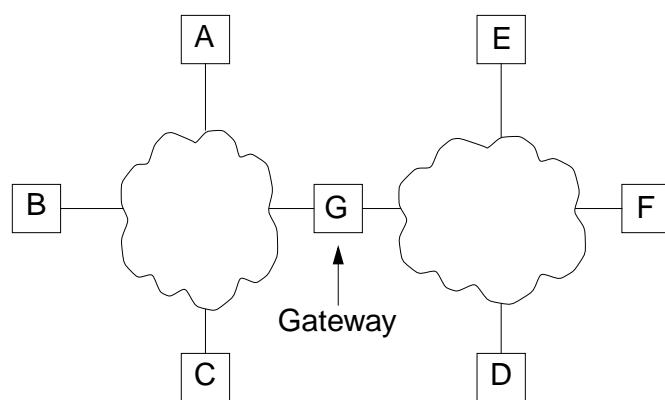
2-19

The textbook definitions of Ethernet have little to do with current practice.

H. Gilbert, Yale

Although the OSI model is useful, the TCP/IP protocols don't match its structure exactly.

C. Hunt, In: TCP/IP, Network Administration.

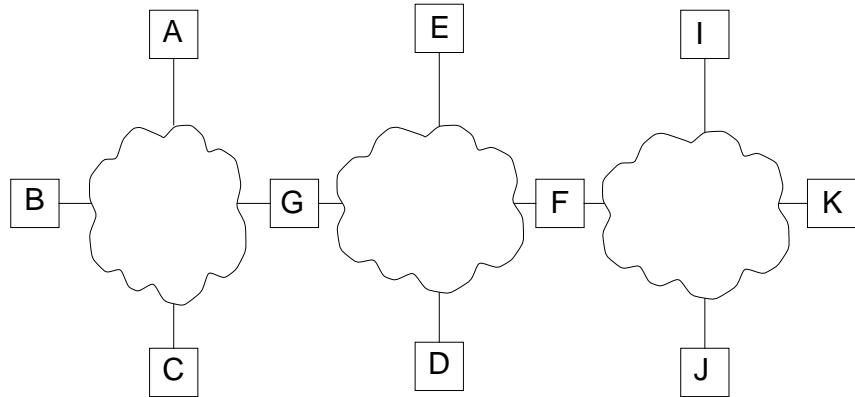


11.10.01

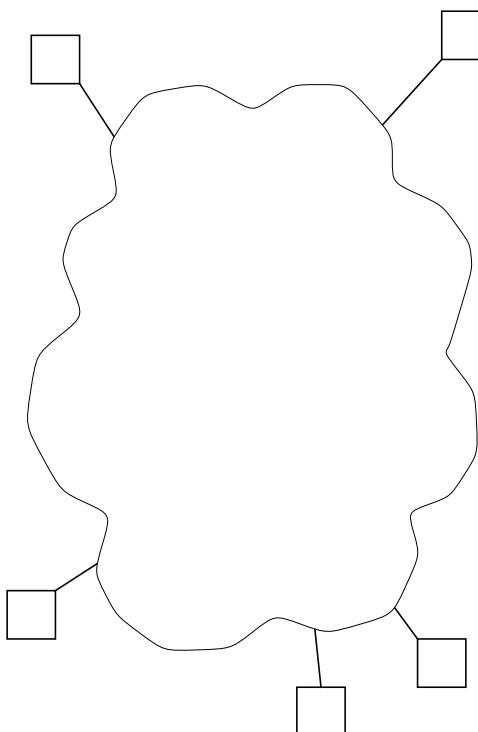
Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
 Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-20

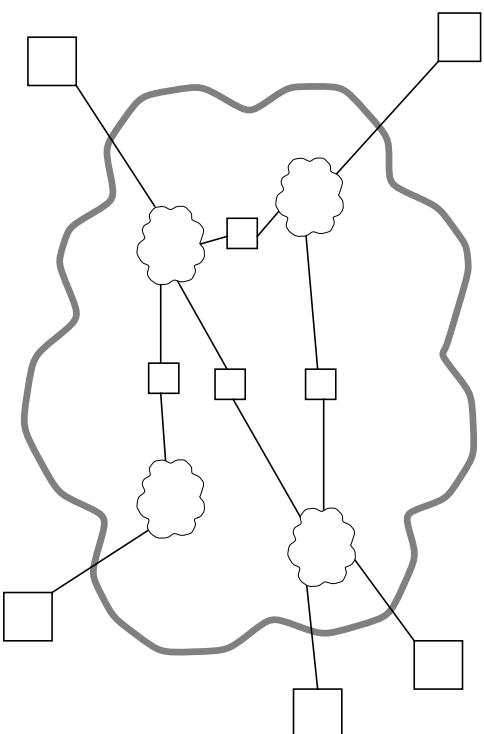
Verknüpfung von drei Netzwerken



Benutzersicht



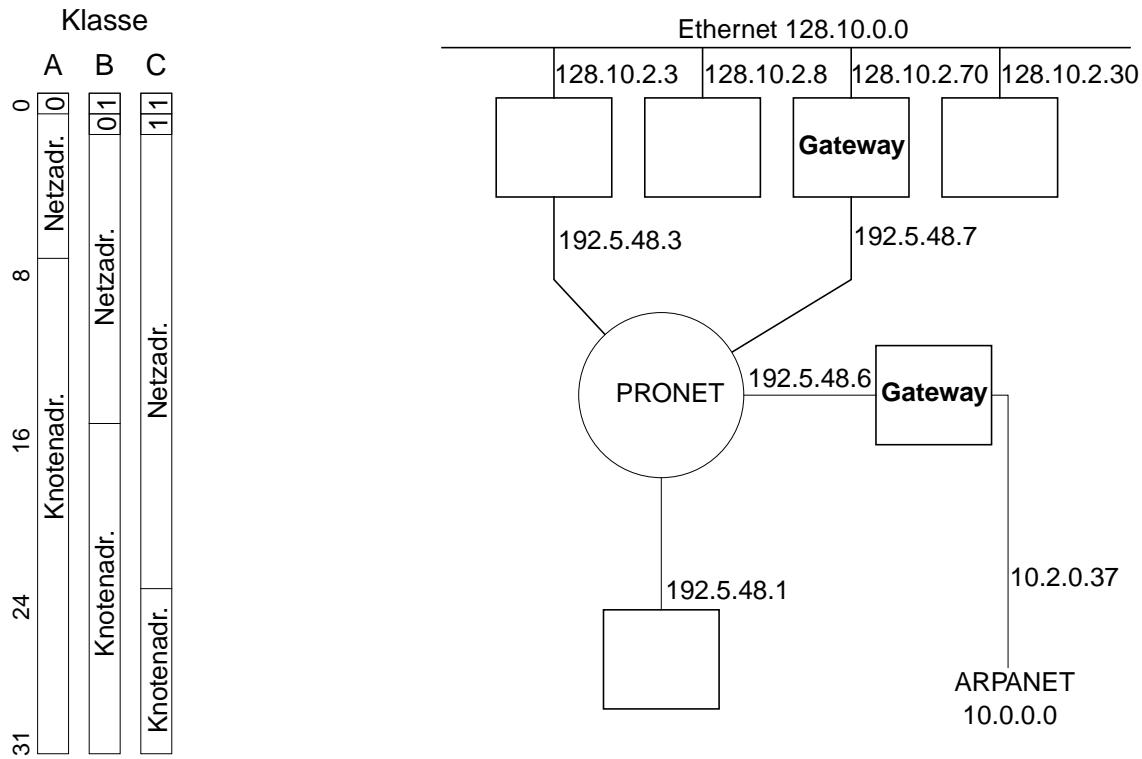
Systemsicht



BP 1

Verteilte Systeme: IP-Adressen und ihre Darstellung

IP-Adressen und ihre Darstellung



11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-23

BP 1

Verteilte Systeme: Aufbau von IP-Paketen

Aufbau von IP-Paketen

	Version (0x40), Kopflaenge (5)	Diensttyp
Paketlnge (in Bytes)	Fragmentidentifikator	
Fragmentadresse	Max. Zahl an 'hops'	Protokoll
Prfsumme	IP-Adresse der Quelle (0 - 15)	
IP-Adresse der Quelle (16 - 31)	IP-Adresse des Ziels (0 - 15)	
IP-Adresse des Ziels (16 - 31)	Optionen	
Optionen	Fllbyte	Daten (Bytes 0 - 1)
Daten (Bytes 2 - 5)		
■ ■ ■		

11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-24

IP packet

```

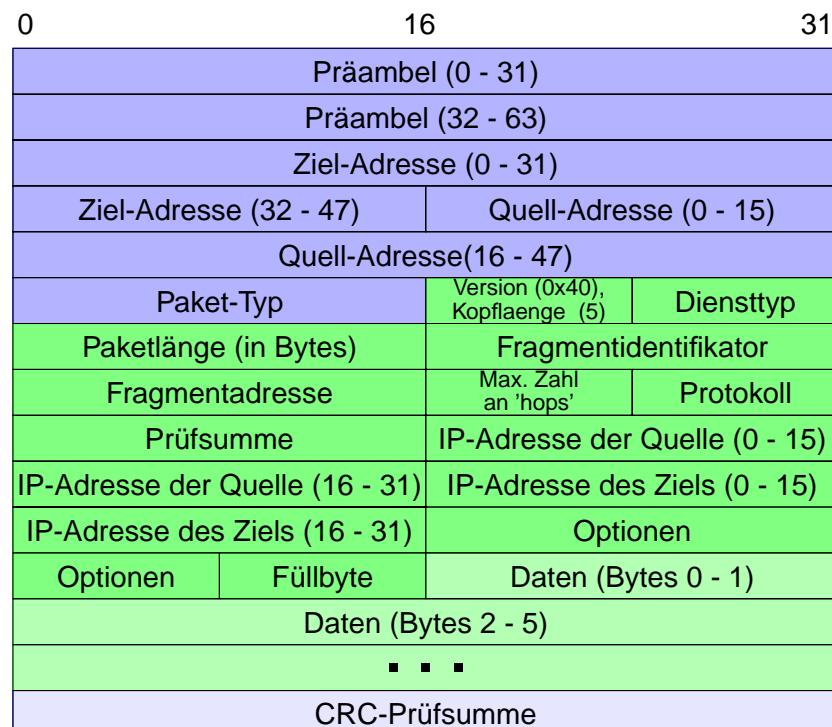
public class IPPacket {
    static public final short IPHLEN = 20;
    static public final int IVERLEN = 0x45;
    static public final int ISVCTYP = 0;
    static public final int IFRAGOFF = 0;
    static public final int ITIM2LIV = 10;

    byte      verlen;           // IP vers. (0x40) + hdr len in longs (5)
    byte      svctyp;          // service type (0 => normal service)
    short     paclen;          // packet length in octets (bytes)
    short     id;               // datagram id (to help gateways frag.)
    short     fragoff;         // fragment offset (0 for 1st fragment)
    byte      tim2liv;         // time to live in gateway hops (10)
    byte      proto;           // IP protocol (UDP is assigned 17)
    short     cksum;           // 1s compl. of sum of shorts in header
    IPAddress src;            // IP address of source
    IPAddress dest;           // IP address of destination

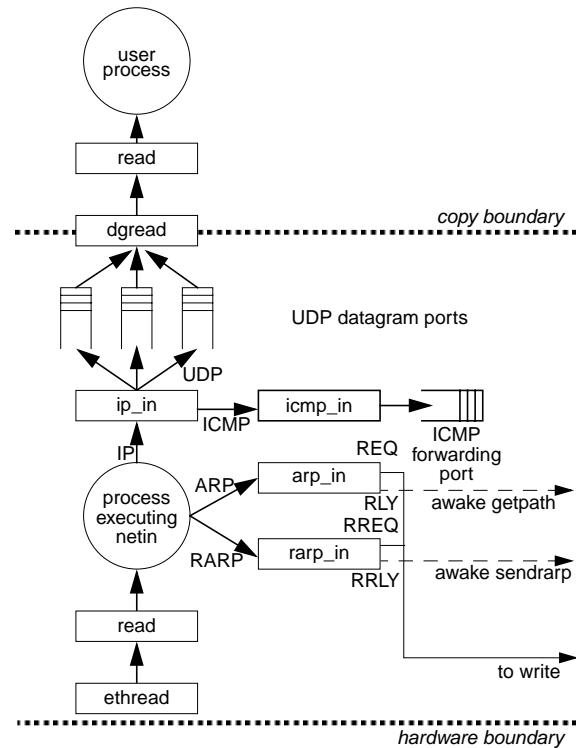
    byte[]    data = new byte[paclen - 20]; // IP datagram data area
}

```

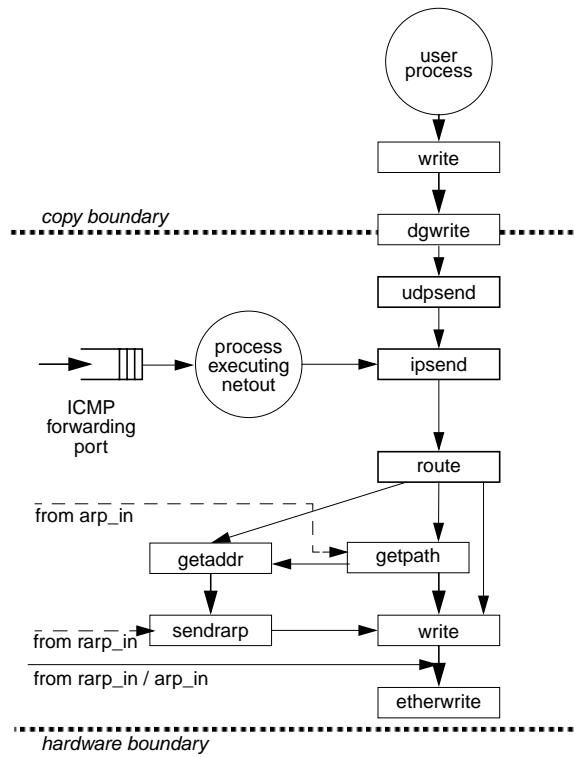
In Ethernet-Paket eingebettetes Internet-Paket



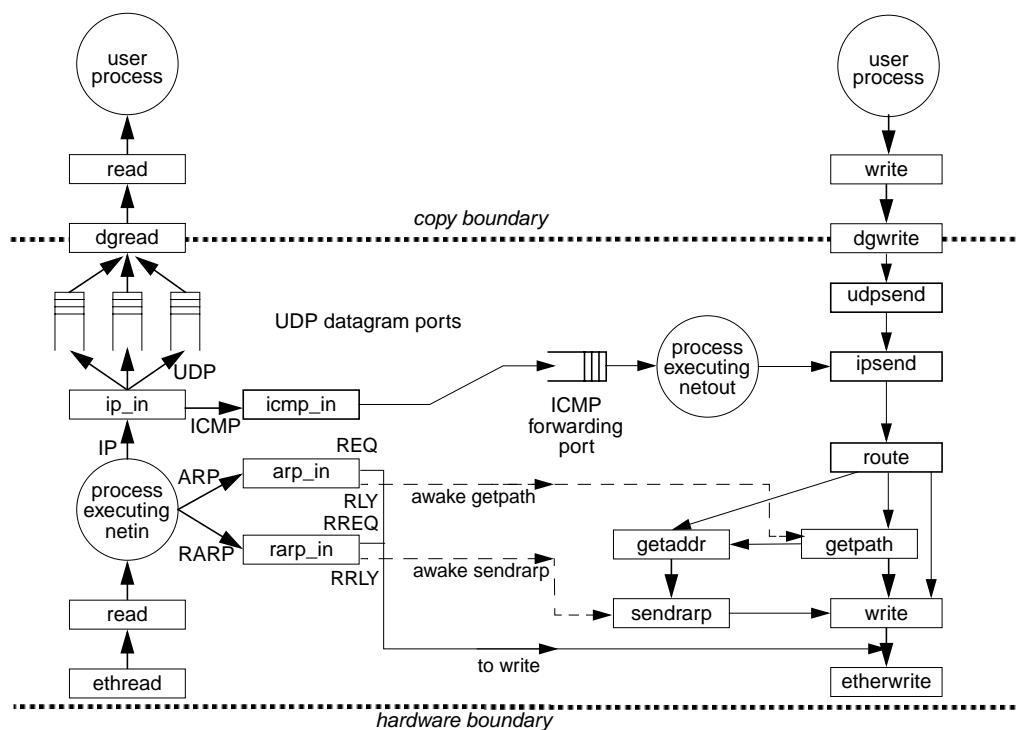
Struktur der Empfangs-Seite



Struktur der Sende-Seite



Gesamtstruktur



Methoden der Ethernet-Ebene

EtherControlBlock

```

public EtherControlBlock()

public int read(EtherPacket f_packet)

public int write(short type,
                 EtherAddress destination,
                 byte[] message)

public void ethinter()
    // Systemthread!

```

```

public int read(EtherPacket f_packet) {
    int returncode = 0;
    etrsem.p();
    startreading(f_packet);
    etrpid = Thread.currentThread().getName();
    deqna.scheduler.suspend();
    Dcmd dcmpptr = ercmd[0];
    if ((dcmpptr.dc_st1 & Dcmd.DC_LUSE) == Dcmd.DC_ERRU) {
        returncode = XINU.SYSERR;
    } else {
        returncode = 0;
        int msglen = (L->dcmpptr->dc_st1 & DC_HLEN) |
                      (L->dcmpptr->dc_st2 & DC_LLEN);
    }
    etrsem.v();
    return returncode;
}

```

```

public void startreading(EtherPacket f_packet) {
    Dcmd dcmpptr;
    DqRegs dqptr;
    dcmpptr = ercmd[0];
    dcmpptr.dc_bufh = Dcmd.DC_VALID;
    dcmpptr.dc_buf = f_packet;
    dcmpptr.dc_len = f_packet.ep_length;
    dcmpptr.dc_st1 = dcmpptr.dc_st2 = Dcmd.DC_INIT;
    dcmpptr.dc_flag = Dcmd.DC_NUSED;
    dqptr = deqna.eioaddr;
    deqna.setRcmd(dcmpptr);
}

public void setRcmd(Dcmd dcmpptr) {
    eioaddr.d_csr = (short)
        ((eioaddr.d_csr | DqRegs.DQ_RLI) ^ DqRegs.DQ_RLI);
    eioaddr.d_rcmd = dcmpptr;

    // the next two lines describe (simulate) the effect of
    // reading from bytes 6/7 of the DEQNA registers
    eioaddr.d_rcmdh = 0;
    scheduler.resume(myName);
}

```

BP 1**Verteilte Systeme: Methoden der Ethernet-Ebene**

```
// Procedure ethwrite on page 38; write a single packet to the ethernet
public int etherwrite(short type,
                      EtherAddress destination,
                      byte[] message) {
    EtherPacket packet = new EtherPacket(ethpaddr, destination, message);
    packet.ep_hdr.e_ptype = type;
    if (packet.ep_length > EtherAddress.EMAXPAK - 18) {
        return SYSERR;
    }
    if (packet.ep_length < EtherAddress.EMINPAK - 18) {
        return SYSERR;
    }
    etwsem.p();
    startwriting(packet, Dcmd.DC_NORM);
}
```

11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-33**BP 1****Verteilte Systeme: Methoden der Ethernet-Ebene**

```
public void startwriting(EtherPacket packet, int setup) {
    Dcmd dcmptr;
    DqRegs dqptr;
    dqptr = deqna.eioaddr;
    while ((dqptr.d_csr & DqRegs.DQ_XLI) == 0) ;
    dcmptr = ewcmd[0];
    dcmptr.dc_bufh = Dcmd.DC_VALID | Dcmd.DC_ENDM | (etsetup = setup);
    if ((packet.ep_length % 2) == 1) dcmptr.dc_bufh |= Dcmd.DC_LBIT;
    dcmptr.dc_buf = packet;
    dcmptr.dc_len = packet.ep_length;
    dcmptr.dc_st1 = dcmptr.dc_st2 = Dcmd.DC_INIT;
    dcmptr.dc_flag = Dcmd.DC_NUSED;
    deqna.setWcmd(dcmptr);
    return ;
}

public void setWcmd(Dcmd dcmptr) {
    eioaddr.d_csr = (short) ((eioaddr.d_csr | DqRegs.DQ_XLI) ^ DqRegs.DQ_XLI);
    eioaddr.d_wcmd = dcmptr;
    // the next two lines describe (simulate) the effect of
    // writing to bytes 10/11 of the DEQNA registers
    eioaddr.d_wcmdh = 0;
    scheduler.resume(myName);
}
```

11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-34

BP 1**Verteilte Systeme: Methoden der Ethernet-Ebene**

```
public void ethinter() {
    Dcmd dcmpptr = null;
    DqRegs dqptr = deqna.eioaddr;
    short csr = dqptr.d_csr;
    dqptr.d_csr = (short)((csr | DqRegs.DQ_RINT | DqRegs.DQ_XINT | Dcmd.DC_ERRU)
                           ^ (DqRegs.DQ_RINT | DqRegs.DQ_XINT | Dcmd.DC_ERRU));
    boolean doresch = false;
    if ((csr & DqRegs.DQ_RINT) != 0) {
        // interrupt after reading
        dcmpptr = ercmsg[0];
        if ((dcmpptr.dc_st1 & Dcmd.DC_LUSE) != Dcmd.DC_ERRU) {
            // received packet correct
            doresch = true;
        } else { // error, so retry
            dcmpptr.dc_st1 = dcmpptr.dc_st2 = DC_INIT;
            dcmpptr.dc_flag = DC_NUSED;
            deqna.setRcmd(dcmpptr);
        }
    }
}
```

11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-35**BP 1****Verteilte Systeme: Methoden der Ethernet-Ebene**

```
if ((csr & DqRegs.DQ_XINT) != 0) {
    // interrupt after sending
    dcmpptr = ewcmd[0];
    if ((dcmpptr.dc_st1 & Dcmd.DC_LUSE) != Dcmd.DC_ERRU) {
        // packet successfully delivered to the ethernet
        etwsem.v();
    } else {
        // sending erroneous, retry
        ...
    }
}
if (dioresch) {
    deqna.scheduler.resume(etpid);
}
```

11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-36

BP 1

Verteilte Systeme: Adreßauflösung

- Adreßumsetzung Ethernet ↔ Internet
(reverse) address resolution packet

```
class ArpPacket {  
    short hrd; // type of hardware (Ethernet = 1)  
    short prot; // format of proto. (IP=0x0800)  
    byte hlen; // hardware address length (6 for Ether)  
    byte plen; // protocol address length (4 for IP)  
    short op; // arp operation  
    // ARP request to resolve address  
    //     internet addr. --> ethernet addr.  
    // reply to a resolve request  
    // reverse ARP request (RARP packet)  
    //     ethernet addr. --> internet addr.  
    // reply to a reverse request  
    //     (RARP pack.)  
    EtherAddress sha; // sender's physical hardware address  
    IPAddress spa; // sender's protocol address (IP addr.)  
    EtherAddress tha; // target's physical hardware address  
    IPAddress tpa; // target's protocol address (IP)  
}
```

11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-37

BP 1

Verteilte Systeme: Adreßauflösung

Aufbau von "address resolution packets"

Hardwaretyp (1 = Ethernet)				
Format der Protokolladresse	Länge der Hard-wareadresse (6)	Länge der Proto-kolladresse (4)		
Operation	Ethernetadr. der Quelle (0 - 15)			
Ethernetadresse der Quelle (16 - 47)				
IP-Adresse der Quelle (0 - 31)				
Ethernetadresse des Ziels (0 - 31)				
Ethernetadr. des Ziels (32 - 47)	IP-Adresse des Ziels (0 - 15)			
IP-Adresse des Ziels (16 - 31)				

11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-38

```

void rarp_in(ArpPacket packet)
    // handle RARP packet coming from Ethernet network

receive_timed(int maxwait)

void send(int pid, int message)

void make_arp(short type, short op,
             IPAddress source_process_addr,
             IPAddress target_process_addr)

```

Cache for address resolution protocol

```

int getpath(IPAddress addr)
    // Find route table index for
    // a given IP address

arpfind(IPAddress faddr)
    // Find or insert entry in ARP cache
    // and return its index

arp_in(ArpPacket packet, int device)

```

IP packet

```
class IPPacket {
    byteverlen;// IP vers.(0x40) + hdr len in longs (5)
    bytesvctyp;// service type (0 => normal service
    shortpaclen;// packet length in octetts
    shortid;// datagram id (to help gateways frag.)
    shortfragoff;// fragment offset (0 for first fragment)
    bytetim2liv;//                                         time to live in gateway hops (10)
    byteproto;// IP protocol (ICMP is assigned 1
               // UDP  is assigned 17)
    shortchksum;// 1s compl. of sum of shorts in header
    IPAddresssrc;// IP address of source
    IPAddressdest;// IP address of destination
    byte[]data = new byte[paclen - 20];// IP datagram data area
}
```

```
void ipsend(IPAddress faddr,
            EtherPacket packet, int datalen)

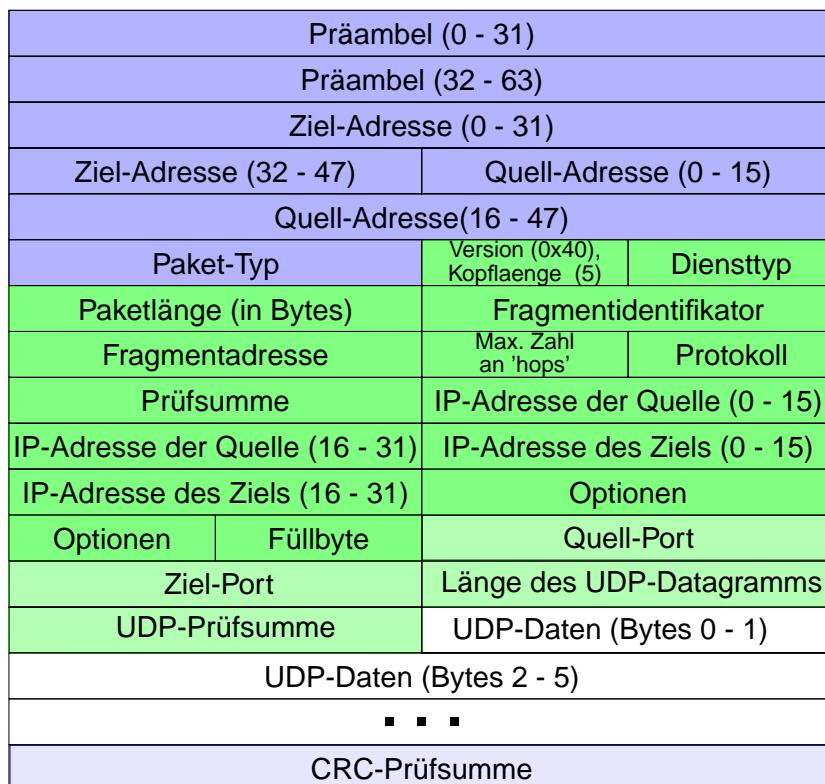
void route(IPAddress faddr,
           EtherPacket packet, int totlen)
```

Type	ICMP message type
0	Echo Reply
3	Destination unreachable
4	Source Quench
5	Redirect (change a route)
8	Echo Request
11	Time Exceeded for a Datagram
12	Parameter Problem on a Datagram
13	Timestamp Request
14	Timestamp Reply
15	Information Request
16	Information Reply

```
void icmp_in(EtherPacket packet,
             int icmp, int lim)
```

UDP packet

```
class UDPPacket
    short sport; // Source UDP port number
    short dport; // Destination UDP port number
    short dplen; // Length of UDP data
    short cksum; // UDP checksum (0 => no checksum)
    byte[] data; // Data in UDP message
}
```



```

void udpsend(IPAddress faddr,
              short fport, short lport,
              EtherPacket packet, int datalen)

void netin()
// thread

void netout(int icmp)
// thread

void ip_in(EtherPacket packet, int icmp, int lim)

```

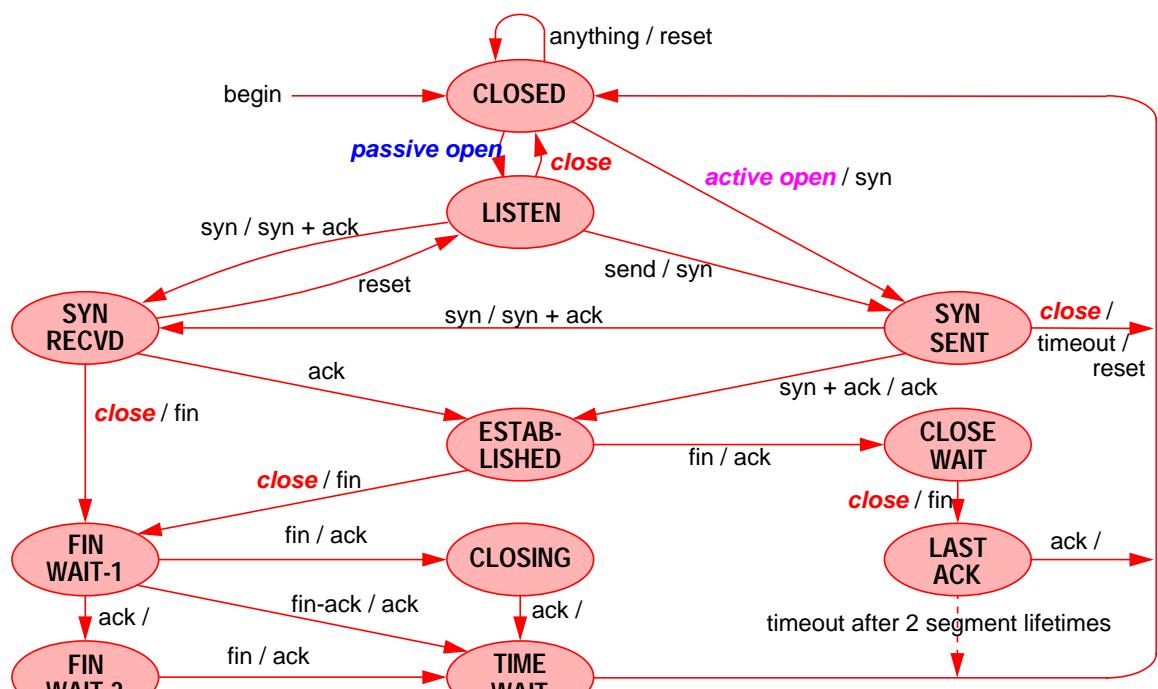
- TCP (Transmission Control Protocol)
- Verbindungsauftbau (3-way handshake), entnommen aus RFC 793
 - ◆ Einseitig

1. CLOSED		CLOSED		
2. CLOSED		(passive open)		
3. (active open)		LISTEN		
SYN-SENT	-->	<SEQ=100><CTL=SYN>	-->	SYN-RECEIVED
4. ESTABLISHED	<--	<SEQ=300><ACK=101><CTL=SYN,ACK>	<--	SYN-RECEIVED
5. ESTABLISHED	-->	<SEQ=101><ACK=301><CTL=ACK>	-->	ESTABLISHED
6. ESTABLISHED	-->	<SEQ=101><ACK=301><CTL=ACK><DATA>	-->	ESTABLISHED

◆ Gleichzeitig in beiden Richtungen

- | | |
|---|-------------------------------|
| 1. CLOSED | CLOSED |
| 2. (active open)
SYN-SENT --> <SEQ=100><CTL=SYN> | ... |
| 3. SYN-RECEIVED <-- <SEQ=300><CTL=SYN> | (active open)
<-- SYN-SENT |
| 4. ... --> <SEQ=100><CTL=SYN> | --> SYN-RECEIVED |
| 5. SYN-RECEIVED --> <SEQ=100><ACK=301><CTL=SYN,ACK> | ... |
| 6. ESTABLISHED <-- <SEQ=300><ACK=101><CTL=SYN,ACK> | <-- SYN-RECEIVED |
| 7. ... --> <SEQ=101><ACK=301><CTL=ACK> | --> ESTABLISHED |

□ TCP-Zustandsdiagramm (standardisiert)



BP 1**Verteilte Systeme: TCP**

❑ Verbindungsabbau

◆ Einseitig

- | | | |
|----------------|------|---------------------------------|
| 1. ESTABLISHED | | ESTABLISHED |
| 2. (close) | | |
| FIN-WAIT-1 | --> | <SEQ=100><ACK=300><CTL=FIN,ACK> |
| 3. FIN-WAIT-2 | <--> | <SEQ=300><ACK=101><CTL=ACK> |
| 4. (Close) | | |
| TIME-WAIT | <--> | <SEQ=300><ACK=101><CTL=FIN,ACK> |
| 5. TIME-WAIT | --> | <SEQ=101><ACK=301><CTL=ACK> |
| 6. (2 MSL) | | |
| CLOSED | | |

11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-51

BP 1**Verteilte Systeme: TCP**

◆ Gleichzeitig von beiden Seiten

- | | | |
|----------------|------|---------------------------------|
| 1. ESTABLISHED | | ESTABLISHED |
| 2. (close) | | (close) |
| FIN-WAIT-1 | --> | <SEQ=100><ACK=300><CTL=FIN,ACK> |
| | <--> | <SEQ=300><ACK=100><CTL=FIN,ACK> |
| | ...> | <SEQ=100><ACK=300><CTL=FIN,ACK> |
| 3. CLOSING | --> | <SEQ=101><ACK=301><CTL=ACK> |
| | <--> | <SEQ=301><ACK=101><CTL=ACK> |
| | ...> | <SEQ=101><ACK=301><CTL=ACK> |
| 4. TIME-WAIT | | TIME-WAIT |
| 5. (2 MSL) | | (2 MSL) |
| 6. CLOSED | | CLOSED |

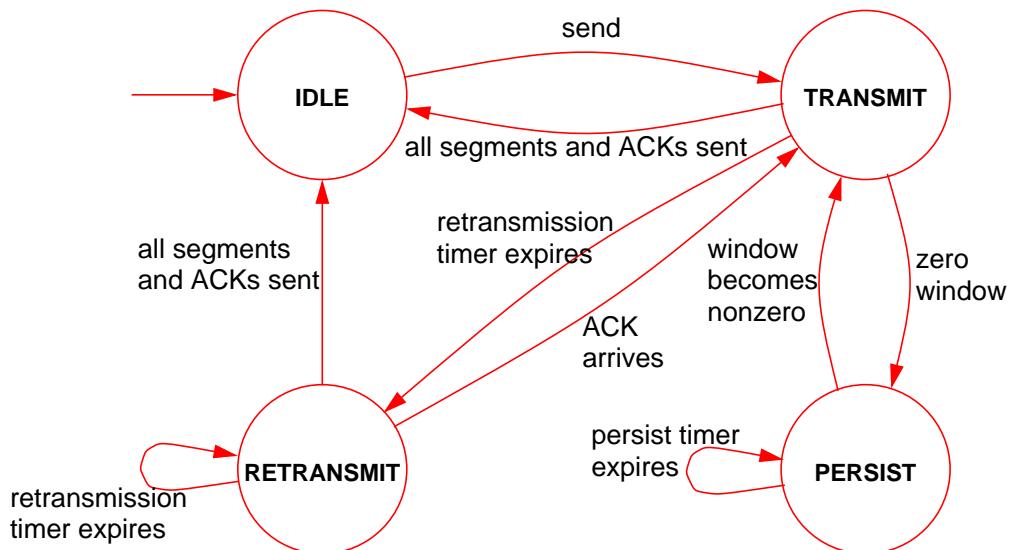
11.10.01

Universität Erlangen-Nürnberg, IMMD IV, F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

2-52

- Laufende Übertragung: Nicht formal standardisiert

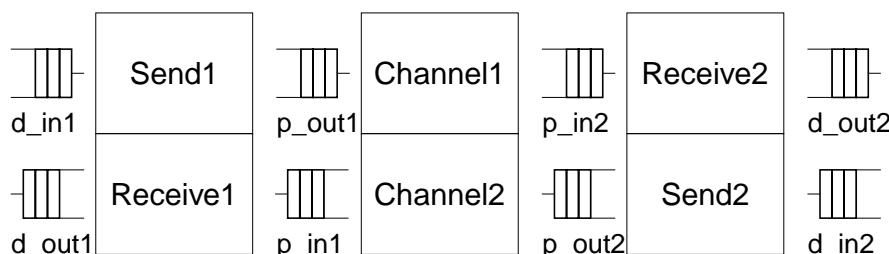
Basiert auf Zustandsdiagramm



- Ein Verbindungsprotokoll (ALP, A Link Protocol)

Basiert auf Zustandaustauschmethode

Gesamstruktur



Vereinfachende Annahme:

Der Kanal kann keine Pakete speichern

- Trivialerweise gegeben bei Ethernet
- Verletzt bei Vernetzung mittels Gateway-Rechnern

- ◆ Zustandaustauschmethode
 - Paket enthält vollständige Sicht des Senders
 - Paketaustausch bis zum Angleich der Sichten

Dazu versendet der Sender ein Paket, wenn

 - (1) der Sender seine Sicht ändert,
 - (2) der Empfänger veranlaßt werden soll, den Zustand zu ändern,
 - (3) ein Paketempfang Unstimmigkeiten der Sichten erkennen läßt,
 - (4) ein fehlerhaftes Paket empfangen wird,
 - (5) der Sender mit dem Zustand unzufrieden ist.

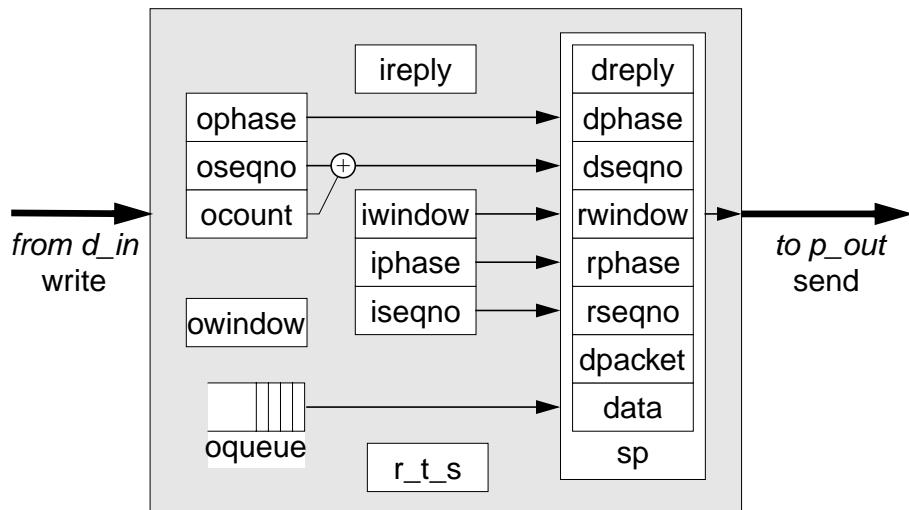
- ◆ Algorithmus
 - Variable

dseqno	Sequenznummer zur Numerierung abgehender Pakete.
iseqno	nächste akzeptable Sequenznummer.
dpacket	gibt an, ob das Paket Daten enthält.
dreply	gibt an, ob der Absender eine Antwort fordert.

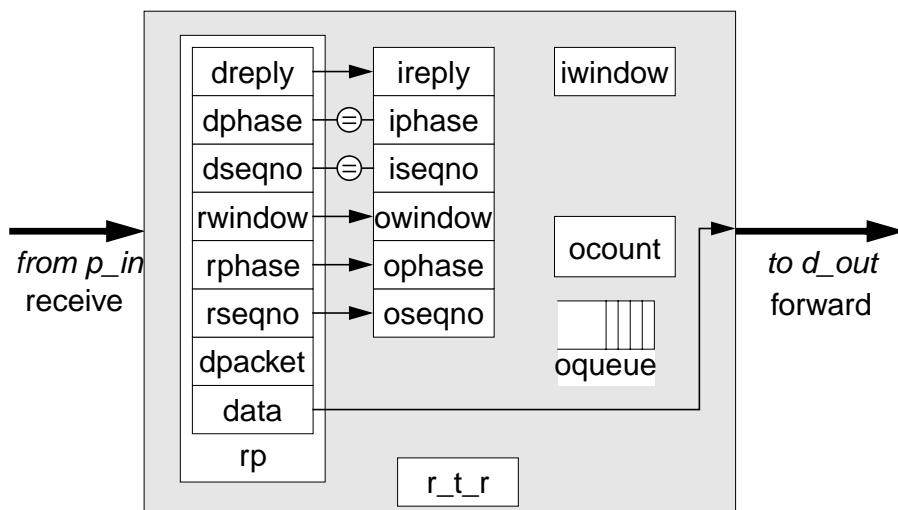
Bei Feststellung eines Paketverlustes, wird die "Übertragungsphase" gewechselt. Der Phasenwechsel veranlaßt, daß noch nicht bestätigte Pakete erneut übermittelt werden. Die Phasenangabe muß erlauben, alte und neue Pakete unterscheiden zu können. Es zeigt sich, daß es ausreichend ist, die Phasen modulo 2 zu zählen.

- | | |
|---------|-------------------------------------|
| dphase | Phase aus der Sicht des Senders. |
| rphase | Phase aus der Sicht des Empfängers. |
| owindow | Fensterbreite beim Sender. |
| iwindow | Fensterbreite beim Empfänger. |

Sender



Empfänger



```

class Packet {
    boolean dreply; // indicates that receiver should send a packet
    int dphase; // phase in which packet is sent
    int dseqno; // sequence number of packet
    int rwindow; // receive window of sender
    int rphase; // phase in which receiver should be
    int rseqno; // sequence number for next packet of the receiver
    boolean dpacket; // indicates that message contains user data
    String data; // user data
}

```

```

/* 1 */ // This algorithm should be executed after receipt of each
/* 2 */ // non-erroneous frame.
/* 3 */ { f = receive();
/* 4 */     if (f->dseqno == iseqno && f->dphase == iphase) {
/* 5 */         if (f->dpacket == 1 && iwindow > 0) {
/* 6 */             // An input packet has arrived in sequence. Accept it
/* 7 */             iseqno = (iseqno + 1) % m; forward(f->data); }
/* 8 */     } else {
/* 9 */         // An input packet has been lost. Prepare to accept retransmission.
/* 10 */         iphase = 1 - f->dphase; ireply = 1; }
/* 11 */     if ((f->rseqno - oseqno) % m <= ocount) {
/* 12 */         // The received reverse sequence number is not anomalous.
/* 13 */         while (f->rseqno != oseqno) { // Discard accepted output packets.
/* 14 */             pop(oqueue); oseqno = (oseqno + 1) % m; ocount--; olength--; }
/* 15 */         owindow = f->rwindow; }
/* 16 */     if (f->rphase != ophase) { // Prepare to retransmit rejected output packets
/* 17 */         ophase = f->rphase; oseqno = f->rseqno; ocount = 0; }
/* 18 */     if (f->dreply == 1 || olength > 0) { // state is unsatisfactory.
/* 19 */         ireply = 1; }
/* 20 */     discard(f);
/* 21 */ }

```

```
/* 1 */ // This algorithm should be executed
/* 2 */ // (1) after a packet is pushed on oqueue and olength is incremented and
/* 3 */ // (2) after execution of the preceding algorithm for receipt
/* 4 */ //      of a non-errorous frame.
/* 5 */
/* 6 */ // Also ireply should be set to 1 and this algorithm then executed
/* 7 */ // (3) after receipt of an erroneous frame,
/* 8 */ // (4) after iwindow is changed,
/* 9 */ // (5) after a give-up timeout and any associated purging of the output queue,
/* 10 */ // (6) after initialization, and perhaps
/* 11 */ // (7) periodically so long as olength > 0.
/* 12 */ { while (ocount < min(owindow, olength) || ireply == 1) {
/* 13 */     f = new packet;
/* 14 */     ireply = 0; f->dphase = ophase; f->dseqno = (oseqno + ocount) % m;
/* 15 */     if (ocount < min(owindow, olength)) {
/* 16 */         // A packet should be included in the frame.
/* 17 */         f->dpacket = 1; f->data = oqueue[ocount++];
/* 18 */     }
/* 19 */     if (olength > 0) { // Not all output packets have as yet been accepted.
/* 20 */         f->dreply = 1;
/* 21 */     }
/* 22 */     f->rphase = iphase; f->rseqno = iseqno; f->rwindow = iwindow; send(f);
/* 23 */ }
/* 24 */ }
```