U1 Interprozesskommunikation mit Sockets

- Organisatorisches
- IPC-Grundlagen
- Adressierung in IP-Netzwerken
- Betriebssystemschnittstelle zur IPC
- POSIX-I/O vs. Standard-C-I/O

U1-1 Organisatorisches

- Rechnerübungen von Systemprogrammierung 1 und 2 finden gleichzeitig statt (vgl. UnivIS "Rechnerübungen zu Systemprogrammierung 1 und 2")
- Nächste SP2-Tafelübungen ab Donnerstag, 10.05.2012
  - Terminplan: **`http://www4.cs.fau.de/Lehre/SS12/V_SP2/Uebung/folien.shtml`**
- Projektverzeichnisse in diesem Semester unter **`/proj/i4sp2`**
- SP1-Abgaben weiterhin in eurem Repository aus dem letzten Semester verfügbar
  - **`https://www4.informatik.uni-erlangen.de/i4sp/ws11/sp1/<login>`**

U1-2 IPC-Grundlagen

1 Client-Server-Modell

★ Ein ***Server*** ist ein Programm, das einen **Dienst** *(Service)* anbietet, der über einen Kommunikationsmechanismus erreichbar ist
(vgl. Vorlesung *B VI-2*, Seite 30, ungleichberechtigte Kommunikation)

- Server
  - **akzeptieren Anforderungen**, die von außen kommen
  - **führen** ihren angebotenen **Dienst aus**
  - **schicken** das **Ergebnis zurück** zum Sender der Anforderung
  - *Server* sind normalerweise als normale Benutzerprozesse realisiert
- Client
  - ein Programm wird ein ***Client***, sobald es
    - eine **Anforderung an einen Server** schickt und
    - auf eine Antwort wartet

2 Kommunikation innerhalb eines Systems

- Intuitiv: Auffinden des Kommunikationspartners über dessen Prozess-ID

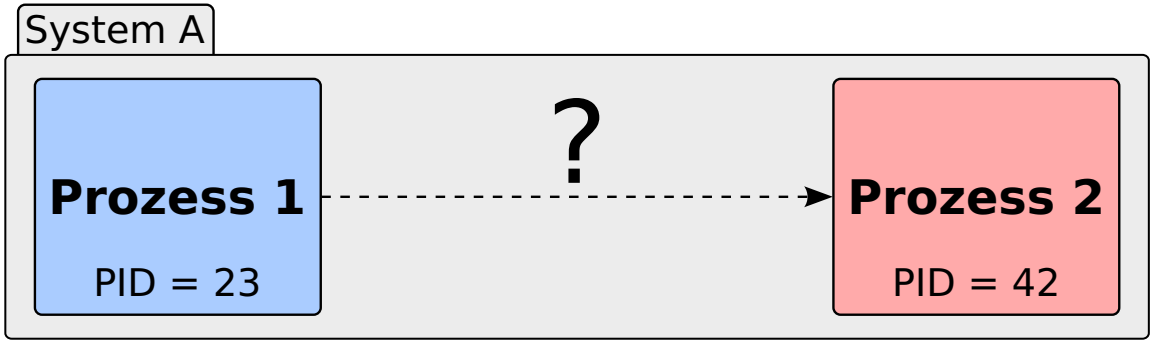

  - Prozesse werden allerdings dynamisch erzeugt und vernichtet; PID ändert sich

- Besser: Verwendung eines abstrakten "Namens" (Beispiel: UNIX-Socket)

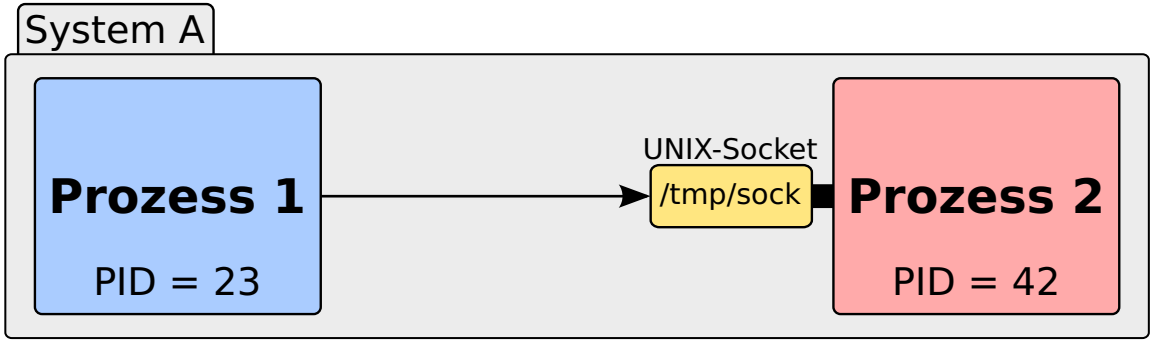

  - Prozess 2 ist so über speziellen Eintrag im Dateisystem erreichbar

3 Kommunikation über Systemgrenzen hinweg

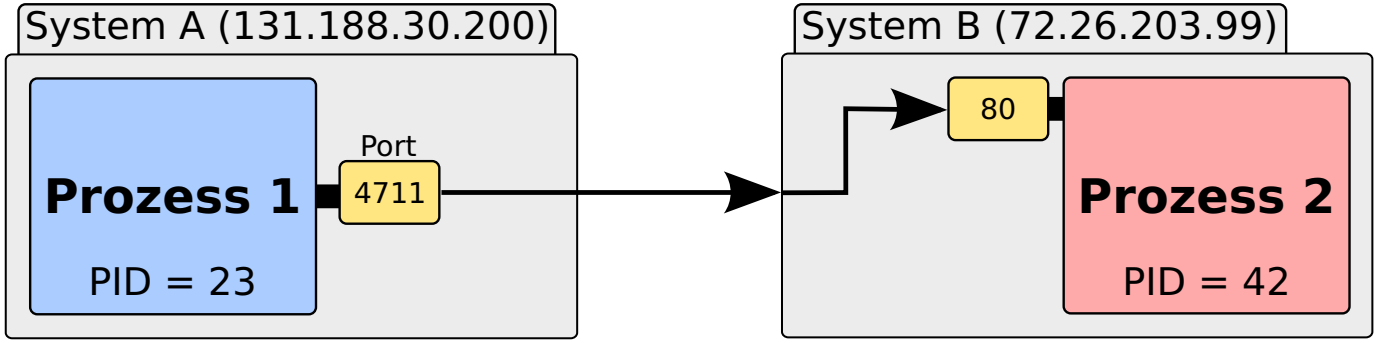

- Auffinden eines Kommunikationspartners über zweistufigen Socket-"Namen" (Beispiel: Internet Protocol - dazu gleich mehr):
  - Zunächst Auffinden des Systems (*hier: per IP-Adresse*)
  - Danach Auffinden des Prozesses im System (*hier: per Port-Nummer*)
  - Mittels IP-Adresse und Port-Nummer ist der Prozess eindeutig identifizierbar

4 Adressierung in IP-Netzwerken

- Adressierung des Systems mittels Internet Protocol (IP)
  - Netzwerkprotokoll zur Bildung eines virtuellen Netzwerkes auf der Basis mehrerer physischer Netze (Routing)
  - unzuverlässige Datenübertragung
  - Adressierung bei IPv4: 4 Bytes
    - Notation: 4 mit '.' getrennte Byte-Werte in Dezimaldarstellung
    - z. B. **`131.188.30.200`**
  - Adressierung bei IPv6: 16 Bytes
    - Notation: acht mit ':' getrennte 2-Byte-Werte in Hexadezimaldarstellung
    - z.B.: **`2001:638:a00:1e:219:99ff:fe33:8e75`**
    - in der Adresse kann einmalig '::' als Kurzschreibweise einer Nullfolge verwendet werden
    - Beispiel: IPv6 localhost-Adresse: **`0:0:0:0:0:0:0:1 = ::1`**

4 Adressierung in IP-Netzwerken

- Transparente IPv4-in-IPv6-Unterstützung
  - Spezieller Adressbereich ::ffff:0:0/96 zur Abbildung von IPv4 auf IPv6
  - z.B. 131.188.30.200 auf ::ffff:83bc:1ec8 (auch ::ffff:131.188.30.200)
  - Bei Verwendung von IPv6 besteht automatisch die Möglichkeit, IPv4-Verbindungen aufzubauen/anzunehmen
    - dem Prozess erscheinen eingehende IPv4-Verbindungen als IPv6-Verbindungen aus diesem Adressbereich
  - ausgehende IPv6-Verbindungen an diesen Adressbereich werden auf entsprechende IPv4-Verbindungen abgebildet
- Anmerkung zu IPv6:
  - Einführung von IPv6 schleppend
  - 1998 verabschiedet, Verbreitung immer noch sehr gering
  - Am 03. Februar 2011 wurden die letzten verfügbaren IPv4-Adressen durch die IANA (Internet Assigned Numbers Authority) vergeben

4 Adressierung in IP-Netzwerken

- Adressierung des Prozesses mittels Portnummern:
  - 16-Bit-Zahlen, d. h. kleiner als 65536
  - Portnummern < 1024: privilegierte Ports für *root* (in UNIX)(z. B. www=80, Mail=25, finger=79)

5 Zusätzliche Abstraktion: Rechnername statt IP-Adresse

- ... mit Hilfe des DNS-Protokolls

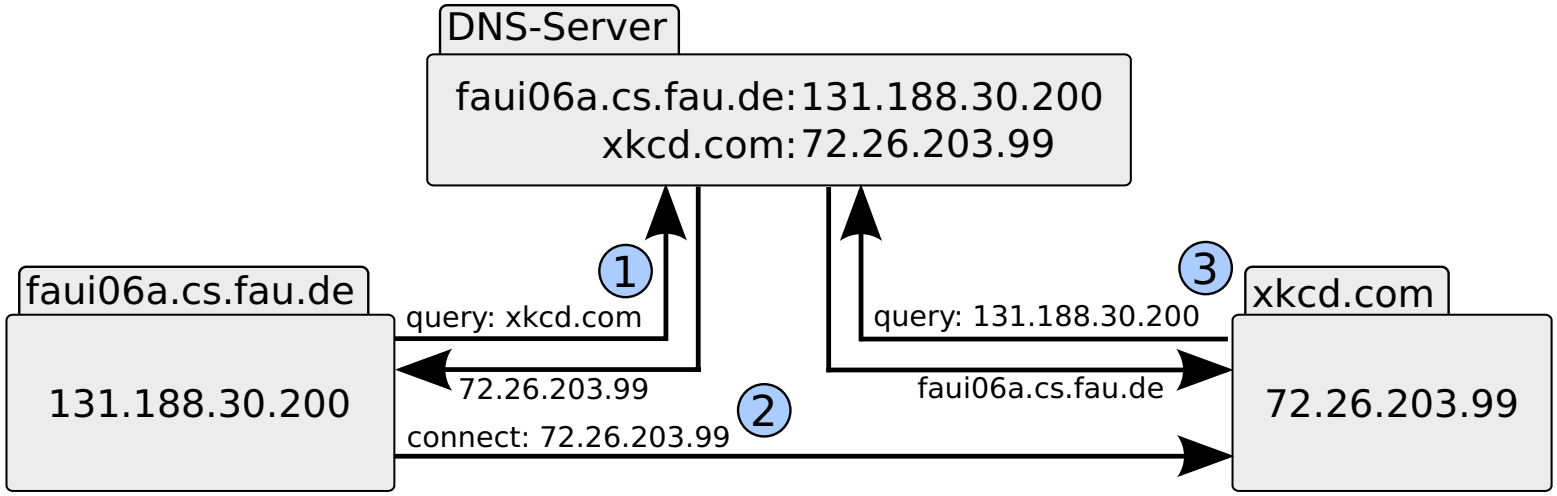

- Nachschlagen der IP-Adresse für einen bestimmten Rechnernamen ("forward DNS lookup") und umgekehrt ("reverse DNS lookup")
- Schritt 3 ist optional - nur nötig, wenn der Server wissen will, wie sein Gesprächspartner heißt

6 Kommunikation: Arten des Datenaustausches

- Datenstromorientiert:
  - Gesicherte Kommunikation (gegen Verlust und Duplizierung von Daten)
  - Die Reihenfolge der gesendeten Daten bleibt erhalten
  - Vergleichbar mit einer Pipe – allerdings bidirektional
  - Implementierung: Transmission Control Protocol (TCP)
- Paketorientiert:
  - Datentransfer unsicher (Verlust und Duplizierung möglich)
  - Empfänger kann Datenpakete möglicherweise in falscher Reihenfolge erhalten
  - Grenzen von Datenpaketen bleiben im Gegensatz zu datenstromorientierten Verbindungen erhalten
  - Implementierung: User Datagram Protocol (UDP)
    - Übertragung von Paketen (sendto, recvfrom), unzuverlässig (Fehler werden erkannt, nicht aber Datenverluste)

6 Vorsicht Fallstrick!

- Beim Austausch von binären Datenwörtern ist die Reihenfolge der einzelnen Bytes zur richtigen Interpretation wichtig
- Kommunikation zwischen Rechnern verschiedener Architekturen - z. B. Intel x86 (*litte endian*) und Sun SPARC (*big endian*) - setzt einen Konsens über die verwendete Byteorder voraus
- Definierter Standard: Netzwerk-Byteorder ist auf *big endian* festgelegt
- Beispiel:

Wert	Repräsentation	0	1	2	3
0xcafebabe	big endian	ca	fe	ba	be
	little endian	be	ba	fe	ca

U1-3 Betriebssystemschnittstelle zur IPC

1 Sockets

- Generische Abstraktion zur Interprozesskommunikation:
  - Verwendung im Programm ist unabhängig von der Kommunikations-Domäne
    - ... egal, ob der Kommunikationspartner ein Prozess auf dem selben Rechner ist oder ob er tausende von Kilometern entfernt ist
  - Betriebssystemseitige Implementierung ist abhängig von der jeweiligen Kommunikations-Domäne:
    - Innerhalb des selben Systems: z. B. UNIX-Socket - Adressierung über Dateinamen, Kommunikation über gemeinsamen Speicher, keine Sicherungsmechanismen notwendig
    - Über Rechnergrenzen hinweg: z. B. TCP/UDP-Socket - Adressierung über IP-Adresse + Port, nachrichtenbasierte Kommunikation, Sicherungsmechanismen bei TCP

2 Erzeugen eines Sockets

- Sockets werden mit dem Systemaufruf *socket(2)* angelegt

```
#include <sys/socket.h>
int socket(int domain, int type, int protocol);
```

  - **`domain`**, z. B.
    - **`PF_UNIX`** (UNIX-Domäne), **`PF_INET`** (IPv4-Domäne), **`PF_INET6`** (IPv6)
  - **`type`** innerhalb der Domain:
    - **`SOCK_STREAM`**: Stream-Socket (bei PF_INET(6) = TCP-Protokoll)
    - **`SOCK_DGRAM`**: Datagramm-Socket (bei PF_INET(6) = UDP-Protokoll)
  - **`protocol`**
    - Standard-Protokoll für Domain/Type Kombination: **`0`**

- Ergebnis ist ein numerischer Socket-Deskriptor
  - Entspricht einem Datei-Deskriptor und unterstützt (bei Stream-Sockets) die selben Operationen

2 Exkurs: Datei-Deskriptoren

- Philosophie von Unix: "Alles, was irgendwie Ein-/Ausgabe betreibt, ist eine Datei"
- Einen Datei-Deskriptor erhält man je nach Gerät auf anderem Weg:
  - Datei: **`open(2)`**
  - Serielle Schnittstelle: **`open(2)`** auf Pseudo-Datei **`/dev/ttyS{0,1,...}`**
  - Netzwerksocket: **`socket(2)`**
  - ...
- Danach Benutzung über eine einheitliche Systemaufruf-Schnittstelle:
  - Lesen: **`read(2)`**
  - Schreiben: **`write(2)`**
  - Schließen (**wichtig!**): **`close(2)`**
  - ...

3 Binden eines Sockets an einen Namen - allgemein

- Ein neu erzeugter Socket ist zunächst namenlos und somit nutzlos
- Erst nach dem "Binden" an einen Namen kann er verwendet werden
- Der Systemaufruf ***bind(2)*** stellt eine generische Schnittstelle zum Binden von Sockets in unterschiedlichen Domänen bereit

```
int bind(int s, const struct sockaddr *name, socklen_t namelen);
```

  - **s**: socket
  - **name**: Protokollspezifische Adresse
    Socket-Interface (**<sys/socket.h>**) ist zunächst protokoll-unabhängig

```
struct sockaddr {
   sa_family_t    sa_family;      /* Adressfamilie */
   char           sa_data[14];    /* Adresse */
};
```

  - **namelen**: Länge der konkret übergebenen Struktur in Bytes

4 Namensgebung für IPv4-Sockets

- Name durch IP-Adresse und Port-Nummer definiert

```
struct sockaddr_in {
    sa_family_t         sin_family;    /* = AF_INET */
    in_port_t           sin_port;      /* Port */
    struct in_addr      sin_addr;      /* Internet-Adresse */
    char                sin_zero[8];   /* Füllbytes */
};
```

  - **sin_port:** Port-Nummer
  - **sin_addr:** IP-Adresse
    - **`INADDR_ANY`**: wenn Socket auf allen lokalen Adressen (z. B. allen Netzwerkinterfaces) Verbindungen akzeptieren soll

- **`sin_port`** und **`sin_addr`** müssen in Netzwerk-Byteorder vorliegen!
  - Umwandlung mittels **`htons`**, **`htonl`**: Wandle Host-spezifische Byteordnung in Netzwerk-Byteordnung (*big endian*) um (**`htons`** für **`short int`**, **`htonl`** für **`long int`**)

5 Namensgebung für IPv6-Sockets

- Name durch IP-Adresse und Port-Nummer definiert

```
struct sockaddr_in6 {
   uint16_t          sin6_family;   /* = AF_INET6 */
   uint16_t          sin6_port;     /* Port */
   uint32_t          sin6_flowinfo;
   struct in6_addr   sin6_addr;     /* IPv6-Adresse */
   uint32_t          sin6_scope_id;
};
struct in6_addr {
   unsigned char     s6_addr[16];
};
```

  - **sin6_addr:** IPv6-Adresse
    - ➤ **in6addr_any / IN6ADDR_ANY_INIT**:
      auf allen lokalen Adressen Verbindungen akzeptieren

- Die **IN6ADDR**_-Werte liegen bereits in Netzwerk-Byteorder vor

6 Verbindungsaufbau durch Client

- ***connect(2)*** meldet Verbindungswunsch an Server

```
int connect(int sockfd, const struct sockaddr *addr,
                socklen_t addrlen);
```

  - **`sockfd`**: Socket über den die Kommunikation erfolgen soll
  - **`addr`**: Beeinhaltet abstrake "Adresse" (bei uns: IP-Adresse und Port) des Servers
  - **`addrlen`**: Länge der **`addr`**-Struktur

- **`connect`** blockiert solange, bis Server Verbindung annimmt
- Falls Socket noch nicht lokal gebunden ist, wird gleichzeitig eine lokale Bindung hergestellt (Port-Nummer wird vom System gewählt)
- Socket wird an die remote Adresse gebunden

7 Das Domain-Name-System (DNS)

- Zum Ermitteln der Werte für die **`sockaddr`**-Struktur kann das DNS-Protokoll verwendet werden

- **`getaddrinfo`** liefert nötige Werte

```
int getaddrinfo(const char *node, const char *service,
   const struct addrinfo *hints, struct addrinfo **res);
```

  - **`node`** gibt den DNS-Namen des Hosts an (oder IP-Adresse als String)
  - **`service`** gibt entweder numerischen Port als String (z.B. "25") oder den Dienstnamen (z.B. "smtp", **getservbyname(3)**) an
  - Mit **`hints`** kann die Adressauswahl eingeschränkt werden (z.B. auf IPv4-Sockets). Nicht verwendete Felder auf **`0`** bzw. **`NULL`** setzen.
  - Ergebnis ist eine verkettete Liste von Socket-Namen; ein Zeiger auf das Kopfelement wird in **`*res`** gespeichert
  - Fehlerbehandlung siehe **getaddrinfo(3)**

- Freigabe der Ergebnisliste nach Verwendung mit **freeaddrinfo(3)**

7 Das Domain-Name-System (DNS)

```
struct addrinfo {
   int              ai_flags;    // flags zur Auswahl (hints)
   int              ai_family;   // z.B. PF_INET6
   int              ai_socktype; // z.B. SOCK_STREAM
   int              ai_protocol; // Protokollnummer
   size_t           ai_addrlen;  // Größe von ai_addr
   struct sockaddr *ai_addr;     // Adresse f. bind/connect
   char            *ai_canonname;// offizieller Hostname
   struct addrinfo *ai_next;     // nächste Addresse oder NULL
};
```

- **`ai_flags`** relevant zur Anfrage von Auswahlkriterien (**`hints`**)
  - **`AI_ADDRCONFIG:`** Auswahl von Adresstypen, für die auch ein lokales Interface existiert (z.B. werden keine IPv6-Adressen geliefert, wenn der aktuelle Rechner gar keine IPv6-Adresse hat)
- **`ai_family, ai_socktype, ai_protocol`** für **socket(2)** verwendbar
- **`ai_addr, ai_addrlen`** für **bind(2)** und **connect(2)** verwendbar

7 Das Domain-Name-System (DNS) - Beispiel

```
char *hostname = "lists.informatik.uni-erlangen.de";
int gai_ret, sock;
struct addrinfo *sa_head, *sa, hints;

memset(&hints,0,sizeof(hints));
hints.ai_socktype = SOCK_STREAM; // nur TCP-Sockets
hints.ai_family = PF_UNSPEC;     // beliebige Protokollfamilie
hints.ai_flags = AI_ADDRCONFIG;  // nur lokal verf. Adresstypen

gai_ret = getaddrinfo(hostname, "25", &hints, &sa_head);
if(gai_ret != 0 ) { /* Fehlerbehandlung s. Manpage */ }

/* Liste der Adressen durchtesten */
for(sa = sa_head; sa!=NULL; sa=sa->ai_next) {
    sock= socket(sa->ai_family,sa->ai_socktype,sa->ai_protocol);
    if(0 == connect(sock, sa->ai_addr, sa->ai_addrlen)) {
        break;
    }
    close(sock);
}
if(sa == NULL) { /* Fehler */ }

freeaddrinfo(sa_head);
```

U1-4 POSIX-I/O vs. Standard-C-I/O

- Für Ein- und Ausgabe stehen verschiedene Funktionen zur Verfügung

Ebene	Variante	Ein-/Augabedaten	Funktionen
2	blockorientiert	Puffer + Länge	read(), write()
3	blockorientiert	Array, Elementgröße, Anzahl	fread(), fwrite()
3	zeichenorientiert	Einzelbyte	getc(), putc()
3	zeilenorientiert	null-terminierter String	fgets(), fputs()
3	formatiert	Formatstring + beliebige Variablen	fscanf(), fprintf()

  - Ebene 2: POSIX-Systemaufrufe
    - Arbeiten mit Filedeskriptoren (`int`)
  - Ebene 3: Bibliotheksfunktionen
    - Greifen intern auf die Systemaufrufe zurück
    - Wesentlich flexibler einsetzbar
    - Arbeiten mit File-Pointern (`FILE *`)

- Auf Grund ihrer Flexibilität eignen sich `FILE*` für String-basierte Ein- und Ausgabe wesentlich besser.

U1-4 POSIX-I/O vs. Standard-C-I/O

- Konvertierung von Filedeskriptor nach Filepointer

```
FILE *fdopen(int fd, const char *type);
```

  - type kann sein "r", "w", "a", "r+", "w+", "a+"
    (**`fd`** muss entsprechend geöffnet sein!)
    - Sockets sollten mit "a+" geöffnet werden

- Schließen des erzeugten Filepointers mittels **`fclose(3)`**

```
int fclose(FILE *stream);
```

  - Darunterliegender Filedeskriptor wird dabei geschlossen
  - Erneutes **`close(2)`** nicht notwendig