Verteilte Betriebssysteme

3. Kapitel
# Architekturen

Prof. Matthias Werner
Professur Betriebssysteme



## Wiederholung: Klassifikation nach FLYNN

- Das bekannteste und einfachste Klassifikationsschema unterscheidet nach Einfachheit oder Vielfachheit von Befehls- und Datenströmen
- Durch Kombination gelangt man zu vier Klassen:

| | SI (single instruction) | MI (multiple instruction) |
|---|---|---|
| SD (single data) | **SISD**<br>klassischer von-Neumann-Rechner, Havard-Rechner | **MISD**<br>Pipeline, Datenflussarchitektur (?) |
| MD (multiple data) | **SIMD**<br>Vektorrechner, Feldrechner (Cray-1, CM2, MasPar) | **MIMD**<br>Multiprozessorsysteme, Verteilte Systeme (Cray T3E, Cluster, ....) |





## Wiederholung: Klassifikation nach FLYNN (FORTS.)

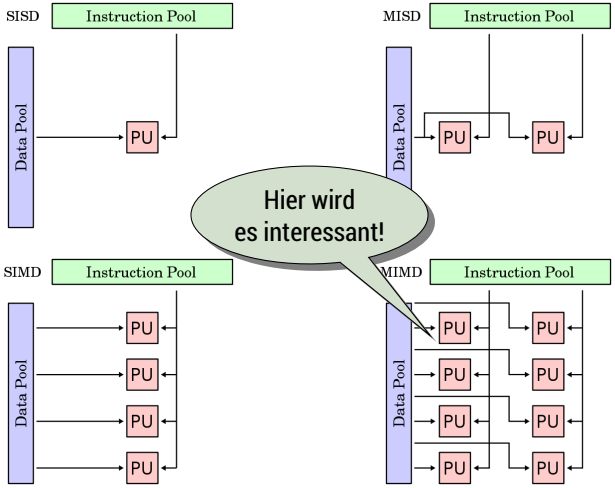


Bildquelle: wikipedia





## MIMD-Maschinen

a) **Multiprozessorsysteme** (**shared memory systems, tightly coupled systems**)
- Alle Prozessoren greifen über ein gemeinsames Kommunikationsnetz auf gemeinsame Speichermodule zu

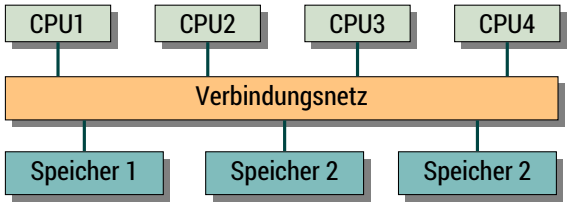


- Nach der Art der Erreichbarkeit der Speichermodule kann weiter unterschieden werden:
  - einheitlicher Speicherzugriff (**uniform memory access**, **UMA**)
    ➡ Zugriffszeit zum Speichermodul ist unabhängig von der Adresse des Prozessors oder des Speichermoduls
  - uneinheitlicher Speicherzugriff (**nonuniform memory access**, **NUMA**)
    ➡ Zugriffszeit hängt von Adresse ab

# MIMD-Maschinen (Forts.)

b) **Multirechnersysteme** (**message passing systems**, **loosely coupled systems**)

- Jeder Prozessor verfügt über einen eigenen Speicher, auf den nur er Zugriff hat
- Datenaustausch geschieht durch Versenden von **Nachrichten** über ein Verbindungsnetzwerk

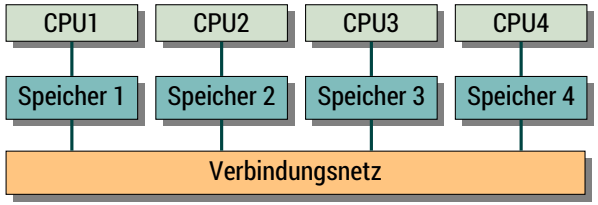


Wenn nichts anderes gesagt, gehen wir in dieser Lehrveranstaltung stets von Multirechnersystemen aus.





- Anwendungen sollen in möglichst transparenter Weise unterstützt werden, d.h. es wird eine SW-Infrastruktur benötigt, welche die Verteiltheit weitgehend **verdeckt**

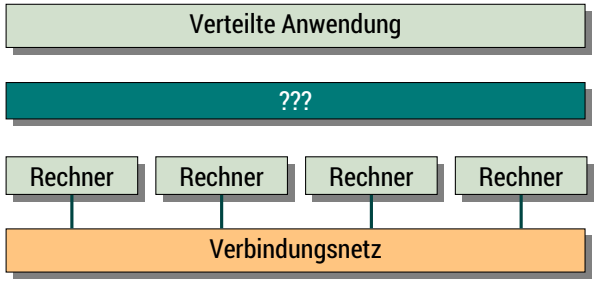






# Architekturansätze für verteilte Systeme

- **Verteiltes Betriebssystem** ➡ Das Betriebssystem selbst stellt bereits die verteilungsrelevante Funktionen zur Verfügung

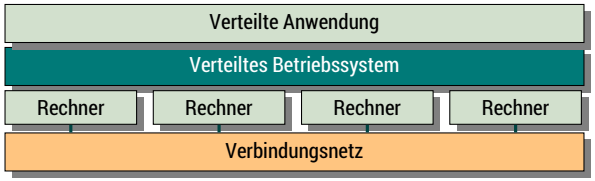


- **Netzwerk-Betriebssystem** ➡ Die lokalen Betriebssysteme werden ergänzt um eine weitere Schicht (Netzwerkbetriebssystem, Middleware), welche die verteilten Funktionen anbietet

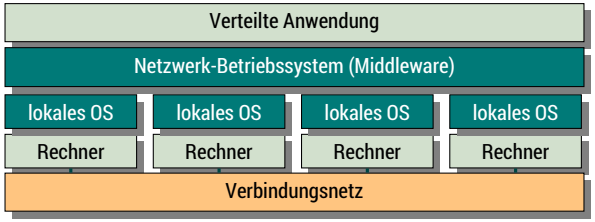






# Architektur lokaler Betriebssysteme

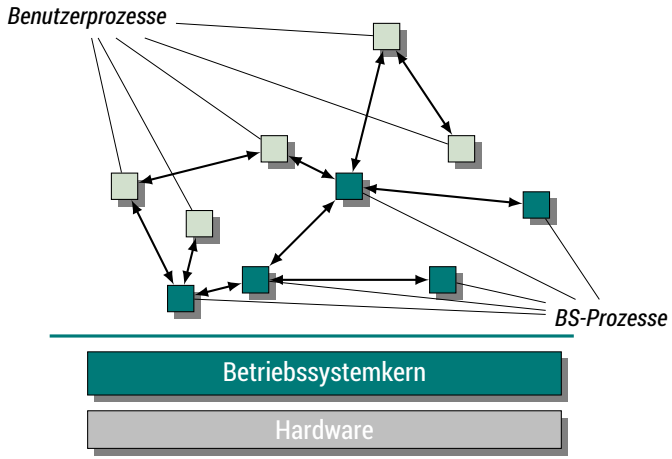

# Architektur verteilter Betriebssysteme

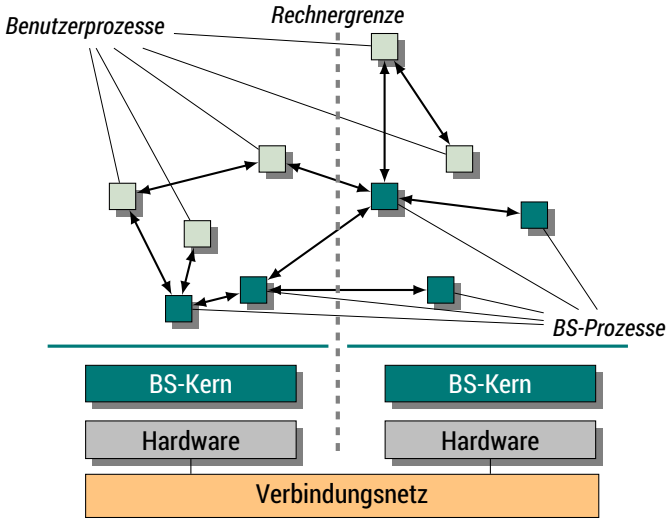






# Prozesskommunikation

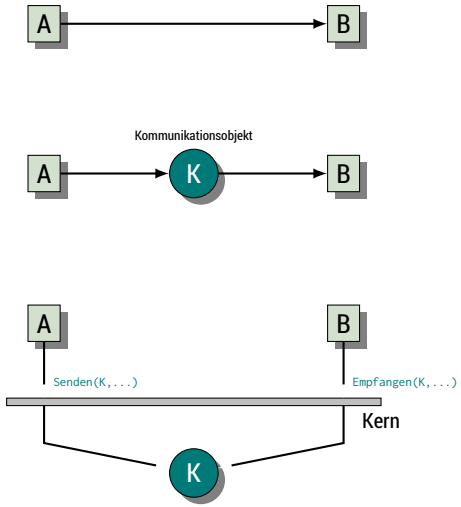






# Architekturvarianten

- In verteilten Systemen müssen zur Prozessinteraktion Rechnergrenzen überwunden werden
- Erforderliche Kommunikationssoftware kann nun
  - im Betriebssystemkern integriert sein ➡ **Kernverbund** (***kernel federation***) oder
  - als spezielle Komponente außerhalb des Kerns existieren ➡ **Prozessverbund**
- Beim **Kernverbund** ist die Verteiltheit unter der Kernschnittstelle verborgen
  - Kernaufrufe können sich auf beliebige Objekte im Netz beziehen
  - Die Vereinigung aller Kerne bildet den **Verbundkern**
- Beim **Prozessverbund** (***process federation*** oder ***server federation***) bleibt die lokale Kernschnittstelle unangetastet
  - Der lokale Kern ist sich nicht „bewusst“, dass er Teil eines verteilten Systems ist
  - Auf diese Weise können bestehende Betriebssysteme zu verteilten Betriebssystemen erweitert werden





# Kernverbund

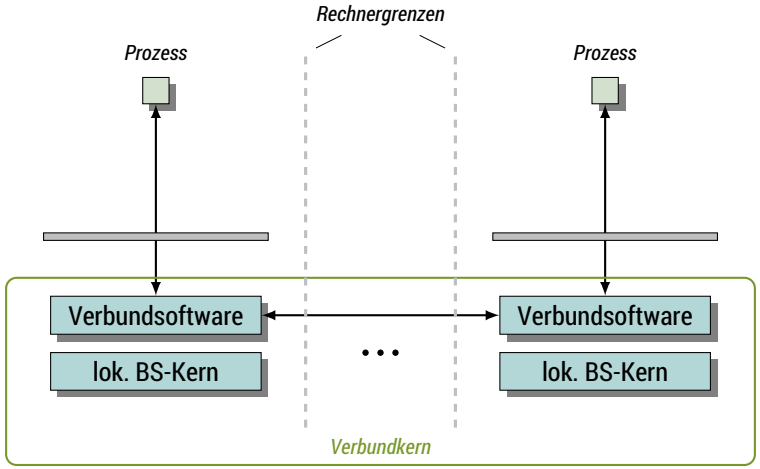

## Prozessverbund

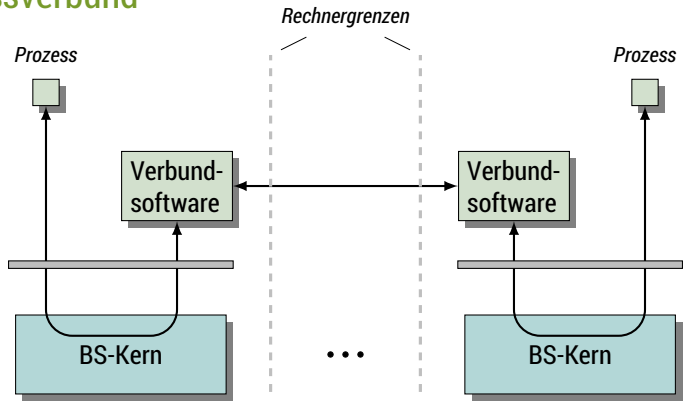


**Anmerkung**

Die Abgrenzung zwischen verteilten Betriebssystemen mit Prozessverbund und Netzwerk-Betriebssystemen sind fließend.





## Abgrenzung verteilter Betriebssysteme

| | Multiprozessor-BS | Verteiltes BS | Netzwerk-BS |
|---|---|---|---|
| Alle Knoten mit gleichem BS? | ja | ja | nein |
| # lokaler BS-Instanzen | 1 | $n$ | $n$ |
| Gemeinsame Prozesswarte-schlange? | ja | nein | nein |
| Kommunikation | gemeinsamer Speicher | Nachrichtenaustausch | Nachrichtenaus-tausch / gemeinsame Daten |





## Brückenprinzip

- Komplexere Programmsysteme können nach dem **Client-Server-** oder **Peer-to-Peer-**Prinzip als Geflecht kommunizierender Prozesse aufgebaut werden
- Kanalansatz ist problemlos auf verteilte Systeme übertragen werden
- Zu klären: **Wie** wird Kanal-Prinzip über Rechnergrenzen hinweg realisiert?

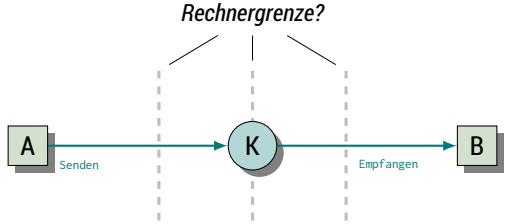






## Brückenprinzip (Forts.)

- Wegen Verteilungstransparenz sollten Schnittstellen der beteiligten Prozesse unverändert bleiben

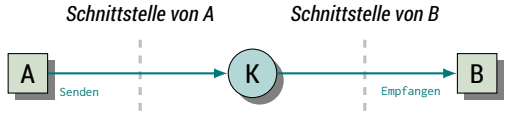


- Umsetzung: Jedem Prozess wird die lokale Existenz des Kommunikationspartners „vorgegaukelt“
- Dies führt zur folgenden Konstruktion:

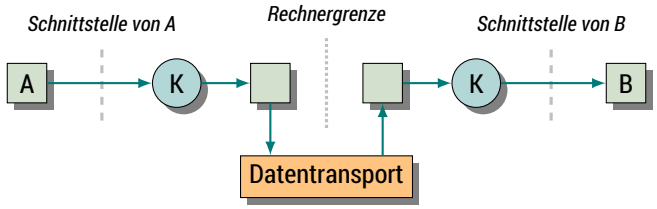

# Brückenprinzip (Forts.)

- Komplexere Programmsysteme können nach dem **Client-Server-** oder **Peer-to-Peer-**Prinzip als Geflecht kommunizierender Prozesse aufgebaut werden
- Kanalansatz ist problemlos auf verteilte Systeme übertragen werden
- Zu klären: **Wie** wird Kanal-Prinzip über Rechnergrenzen hinweg realisiert?

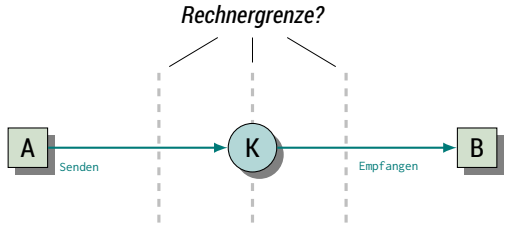






# Analogie: Gespräch zwischen Menschen

- Lokale Kommunikation


- Entfernte Kommunikation via Telefon

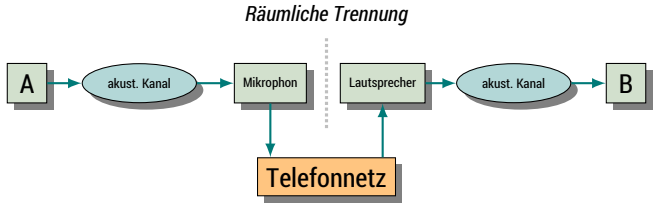






# Grobstruktur einer Brücke

- Lokale Beziehung zwischen Prozessen / Prozeduren


- Beziehung im verteilten Fall

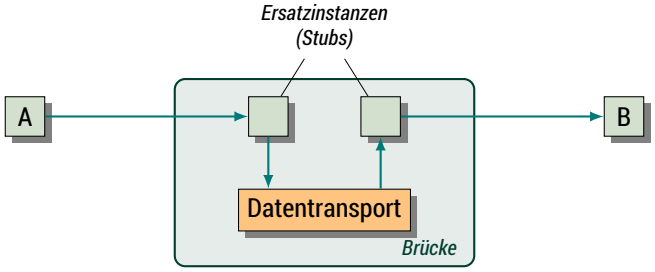






# Brücke im Kernverbund

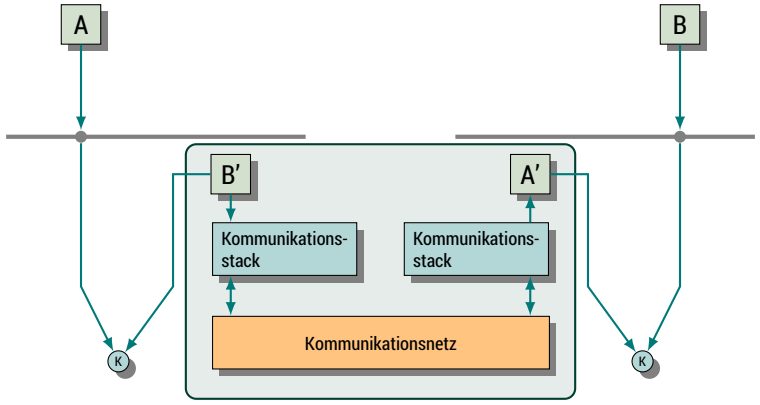

# Brücke im Prozessverbund

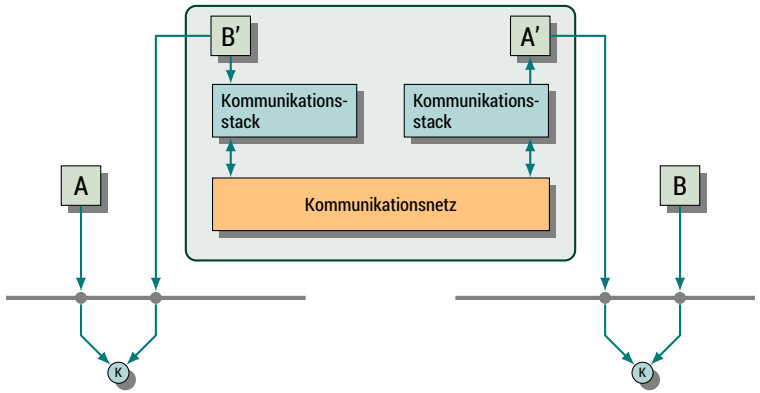






# Realisierung der Brücken

- **Kernverbund**
  - Brücken im Kern prozedural realisiert
  - Meist einfach, auf das Nötigste beschränkt
  - Meist nicht oder kaum fehlertolerant
  - Häufig in Parallelrechnern
- **Prozessverbund**
  - Brücken durch Prozesse realisiert
  - Meist flexibel, mächtig, aufwendig
  - Meist fehlertolerant
  - Häufig in heterogenen verteilten Systeme





# Dienstleistungsbeziehung im verteilten Fall

- Bei Client-Server-Strukturen ist in der Regel eine Kommunikation in beiden Richtungen erforderlich
- Eine Brücke muss in diesem Fall Ersatzinstanzen bereitstellen, die in beide Richtungen kommunizieren

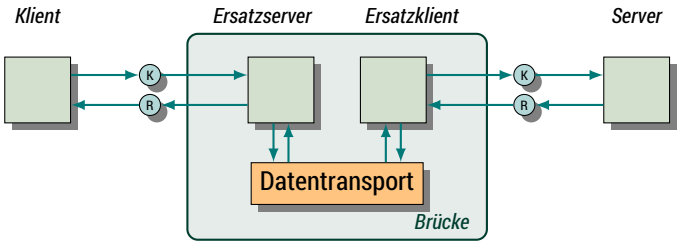






# Aufgaben der Ersatzinstanzen

- Exakte Nachbildung der Schnittstelle (Syntax und Semantik)
- Ein- und Auspacken der Parameter (**Marshaling**/**Demarshaling**)
- Behandlung von Wert- bzw. Referenzübergabe
- Umgang mit Heterogenität (z.B. Wandlung von Formaten)
- Für bestimmte Fälle können Ersatzinstanzen automatisch generiert werden (**stub generator**)
- In komplexeren Fällen sind Ersatzinstanzen umfangreichere Gebilde (z.B. mehrere Prozesse)

- Realisierung von Dienstleistungsbeziehungen durch Prozesskommunikation ist für Anwendungsprogrammierer etwas umständlich
- Im lokalen Fall sind Aufträge an das Betriebssystem i.d.R. hinter Bibliotheksprozeduren versteckt
- **Idee**: Übertragung auf verteilten Fall ➡ Dienstleistung, die auf einem anderen Rechner erbracht wird, wird durch Prozeduraufruf zur Verfügung gestellt
- Mechanismus ist als **Remote Procedure Call** (**RPC**) bekannt
  - Meistverwendete Realisierung von Dienstleistungsbeziehungen in verteilten Systemen
  - Eigentliche Interprozesskommunikation zwischen Rechnern bleibt dann unter RPC-Schnittstelle verborgen





## Client-Server-Beziehung mit Prozesskommunikation

- Explizite Kommunikation

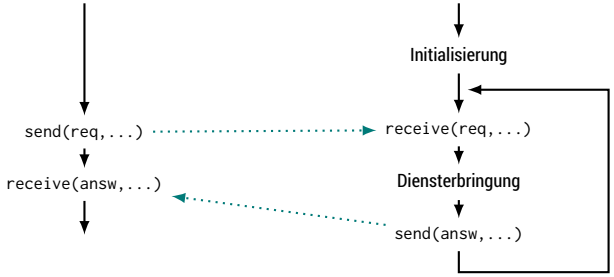


- RPC

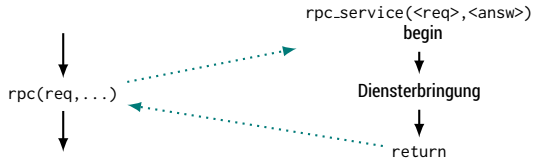






## Parameterübergabe

- Wertübergabe (**call by value**)
  - Standardfall, einfach zu realisieren
  - Werte werden eingepackt und im Nachrichtenpaket verschickt
- Referenzübergabe (**call by reference**)
  - Referenzübergabe schon im lokalen Fall schwierig ➡ verschiedene Adressräume möglich
  - im verteilten Fall vermeiden
- Ersatz durch **call by copy/restore** (auch: **call by value/result**)
  - Bei Aufruf: Übertragung zum Server wie bei Wertaufruf
  - Nach Beendigung: Zurückkopieren zum Client, Überschreiben der alten Werte
  - **Achtung:** andere Semantik





## Beispiel Parameterübergabe

- Entfernte Prozedur:

```
procedure p(var integer x, var integer y)
   begin
     x := x+1;
     y := y*y;
   end;
```

- Aufruf:

```
i := 4;
p(i,i);
print(i);
```

- Ergebnis:
  - bei Call-by-reference: **25**
  - bei Call-by-copy/return: **???**

## RPC in heterogener Umgebung

- Rechner verwenden unterschiedliche Zahl- und Zeichendarstellungen („little endian“/„big endian“, EBCDIC/ASCII, ...)
- Konvertierung erforderlich
- Übertragung entweder...
  - direkt in das Format des Kommunikationspartners
    oder
  - in kanonisches Format
- Wird in der Regel automatisch durchgeführt





## RPC in heterogener Umgebung (Forts.)

- Darstellung von `0x1A2B3C4D` ab Adresse `10000`
- Kleinste Adresseinheit ist ein Byte

| | Big Endian | | Little Endian | |
|---|---|---|---|---|
| **Adresse** | **Hex** | **Binär** | **Hex** | **Binär** |
| 10000 | 1A | 00011010 | 4D | 01001101 |
| 10001 | 2B | 00101011 | 3C | 00111100 |
| 10002 | 3C | 00111100 | 2B | 00101011 |
| 10003 | 4D | 01001101 | 1A | 00011010 |

- **Big-Endian-Architekturen**: IBM Großrechner, Motorola 680X0, SPARC
- **Little-Endian-Architekturen**: Intel x86, VAX, Transputer





## RPC – Fehlersituationen

- Verlust von Auftragsnachrichten
- Verlust von Ergebnisnachrichten
- Server-Ausfall
  - Vor Auftragsausführung
  - Nach Auftragsausführung
- **Allgemeine Lösung:** Client-Stub verwendet Frist (**time out**) und wiederholt Auftrag gegebenenfalls
- **Probleme:**
  - Idempotenz der Server-Operation: Ist ein evtl. mehrmaliges Ausführen der Operation tolerierbar?
- Unterscheidung:
  - **at-most-once-Semantik**: Auftrag wird **höchstens** einmal ausgeführt
  - **at-least-once-Semantik**: Auftrag wird **mindestens** einmal ausgeführt
  - **maybe-Semantik**: keine Aussage möglich





## RPC-Ablauf: Fehlerfreier Fall

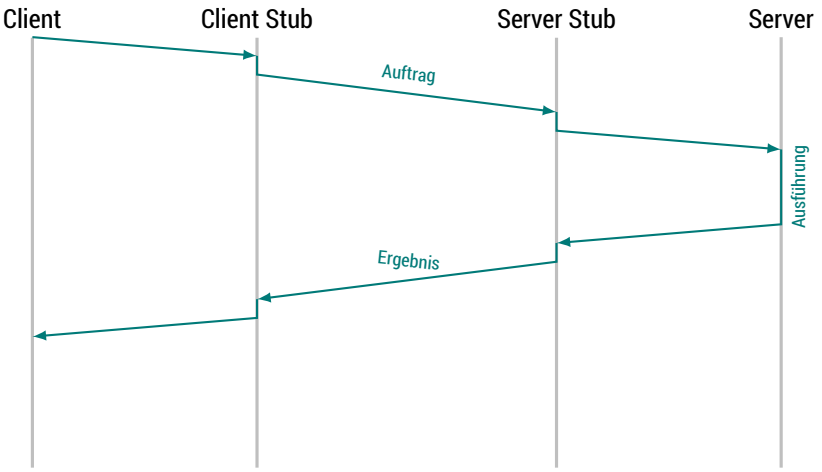

## RPC-Ablauf: Verlust der Auftragsnachricht

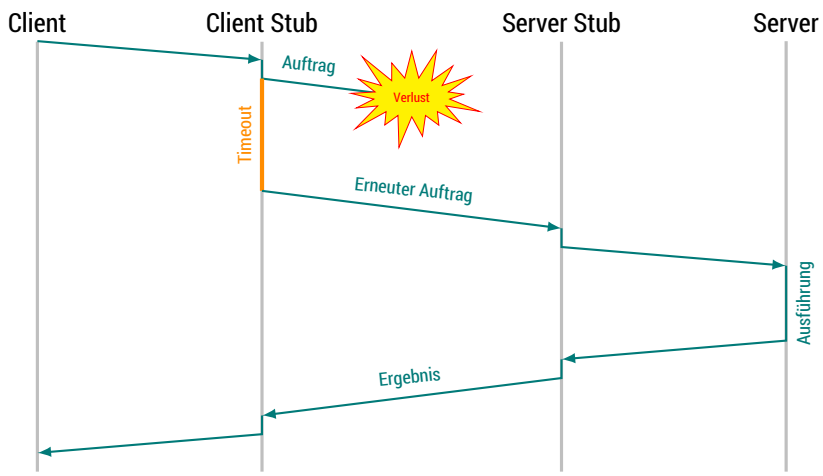






## RPC-Ablauf: Verlust der Ergebnisnachricht

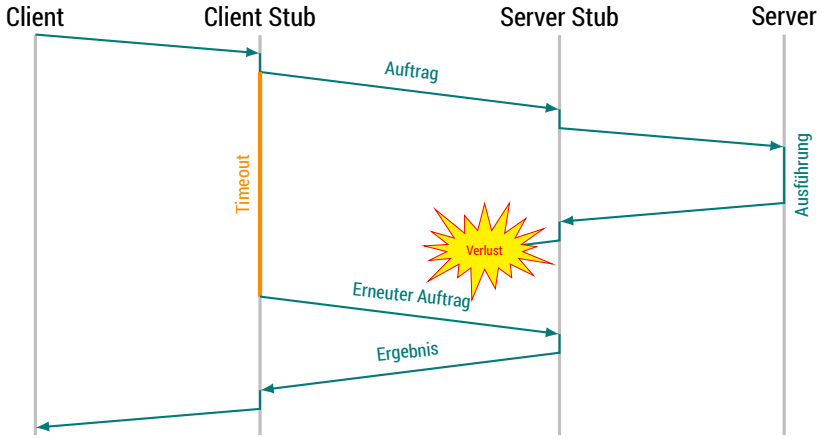


- Erfordert Nummerierung der Auftragsnachrichten und „Gedächtnis“ auf Serverseite





## RPC-Ablauf: Server-Ausfall nach Ausführung

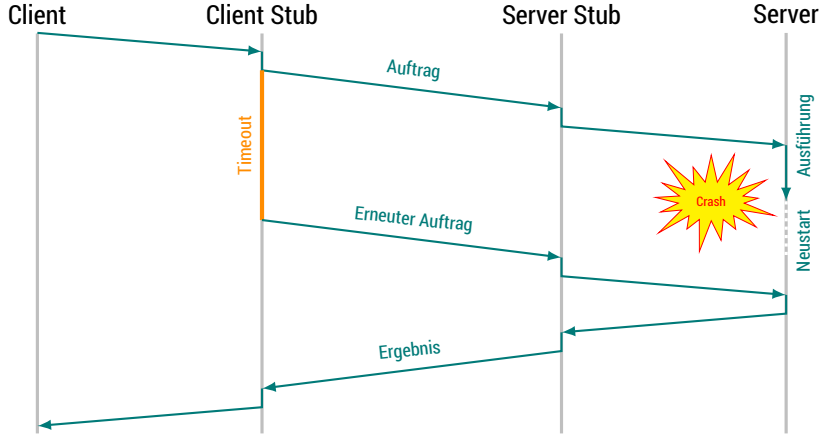


- Erfordert Nummerierung der Auftragsnachrichten und persistente Protokollierung (Gedächtnis) auf Festplatte (Serverseite)





## Implementationsvariante: Sun RPC

| OSI-Modell | Sun RPC |
|---|---|
| Anwendung | RPC |
| Darstellung | XDR |
| Sitzung | – |
| Transport | UDP oder TCP |
| Vermittlung | IP |
| Sicherung | IEEE 802 (z.B. Ethernet) |
| Bitübertragung | – |

- Durch `rpcgen` automatische Generierung von
  - Client-Stub
  - Server-Stub
- Automatische Hin- und Rücktransformation der Daten in XDR-Format
- Wahl des Timeout-Werts
- Wahl der Zahl der Wiederholungen
- Semantik abhängig von gewähltem Transportprotokoll:
  - UDP: maybe-Semantik
  - TCP: at-most-once-Semantik

## Automatische Generierung mit `rpcgen`

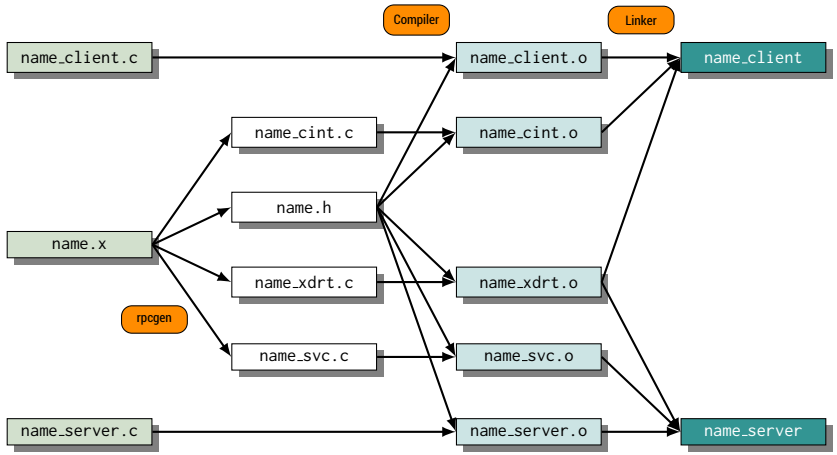


- Einen solche Generierung mit Hilfe einer **Interface Description Language (IDL)** wird häufig genutzt (Corba, DCE, XCB, . . . )





## Diskussion

- RPC bietet eine einfache und komfortable Programmierschnittstelle, jedoch keinerlei Parallelität (Nebenläufigkeit) zwischen Client und Server
- Leistungsfähigere Dienstleistungsstrukturen durch allgemeines Kanalkonzept
- Im verteilten Fall ist die Kanal-Kommunikation durch entsprechende Brücken zu ergänzen
  - Im Prozessverbund ist die Brücke durch Prozesse und lokale Kanäle realisiert
  - Im Kernverbund ist die Brücke im Kern angesiedelt: Eine der beiden Kommunikationsoperationen greift über die Brücke auf einen Kanal auf einem anderen Rechner zu





## Literatur

[BHB96] R. Butenuth, H.-U. Heiss und W. Burke. „Cosy – An Operating System for Highly Parallel Computers“. In: *ACM Operating Systems Review* 30.2 (1996)

[ADG90] Klaus Autenrieth, Henry Dappa und Michael Grevel. *Technik verteilter Betriebssysteme. Konzepte, Trends, Realisierungen*. Hüthig, 1990, Anhang A

[TS02] Andrew S. Tanenbaum und Maarten van Steen. *Distributed Systems*. Prentice Hall, 2002, Chapter 1

[Sin97] Pradeep K. Sinha. *Distributed Operating Systems. Concepts and Design*. IEEE Press, 1997, Chapter 4