

— VS —

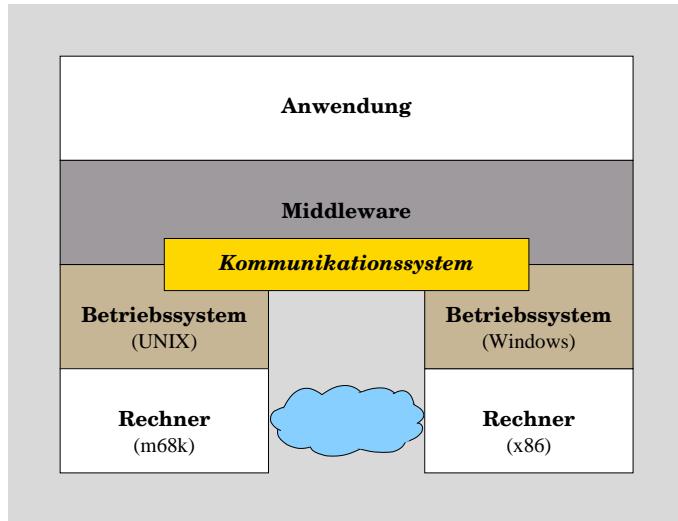
Kommunikationssystem

Verteilte Systeme, ©Wolfgang Schröder-Preikschat

Überblick

• Interprozesskommunikation	3
– Botschaftenaustausch	
* (a)synchron, (un)gepuffert, (nicht)blockierend, (un)zuverlässig	
– IPC-Semantiken und -Varianten, Zustellungsfehler	
– aktive Nachrichten	
• Kommunikationsendpunkte	39
– Briefkasten, Pforte, Prozessinkarnation, Prozedur	
– Kommunikationsverlauf	
• Zusammenfassung	55

Funktionseinheit von Middleware und Betriebssystem



VS — Kommunikationssystem, ©wosch

2

Interprozesskommunikation

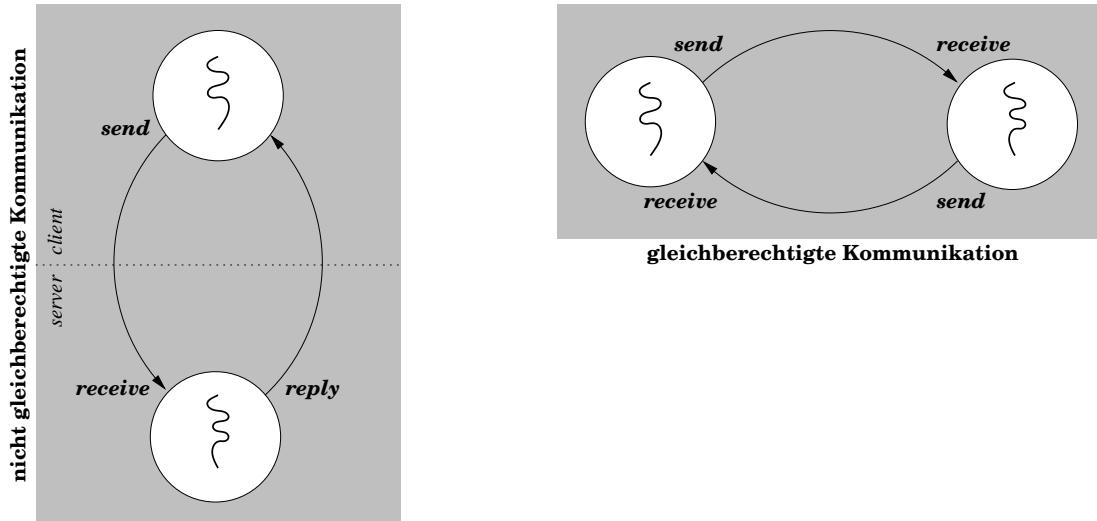
IPC *inter process communication*

- als Konsequenz der physikalischen und logischen Verteiltheit
 - d.h., der Trennung der Komponenten eines verteilten Systems
- die Interaktionen basieren auf **Botschaftenaustausch**
 - d.h., der Übermittlung von Nachrichten (*message passing*)
- eine **Prozessinkarnation**[5] bildet dabei eine kommunizierende Instanz
 - gleichberechtigte vs. nicht gleichberechtigte Kommunikation
 - Gruppen- bzw. Mehrteilnehmerkommunikation
- die Mechanismen sind von Plattform zu Plattform unterschiedlich

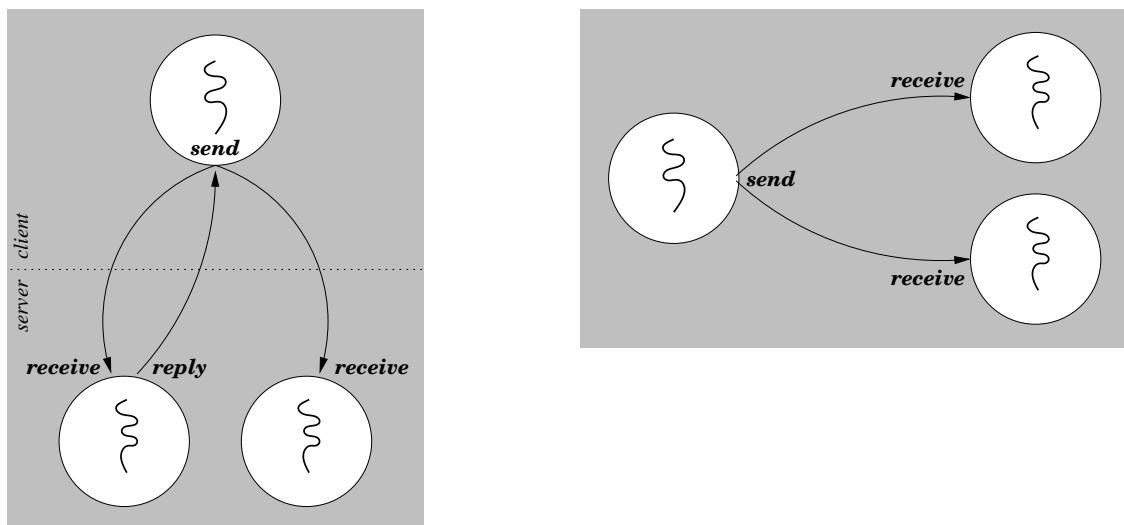
VS — Kommunikationssystem, ©wosch

3

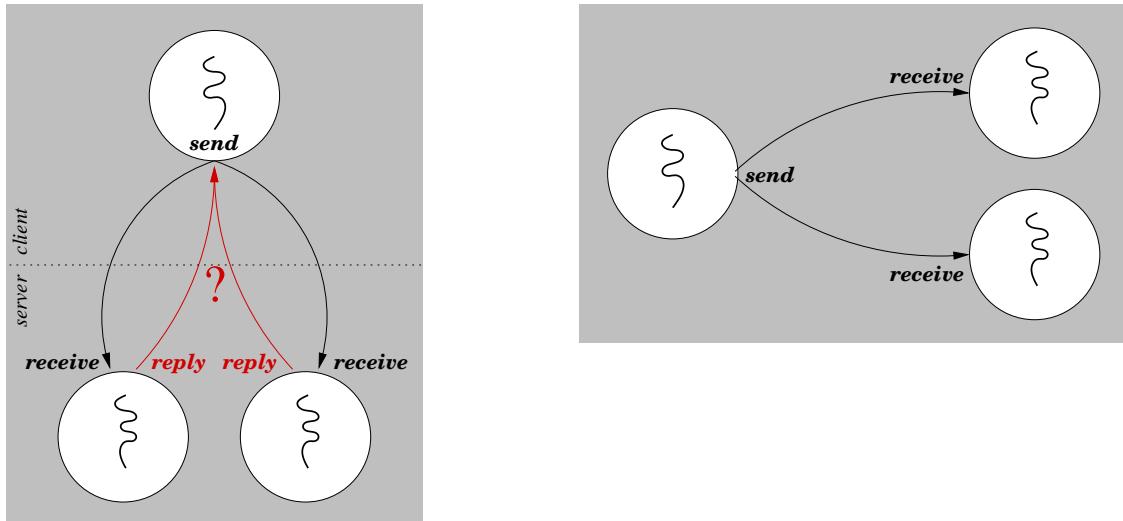
{,Nicht} Gleichberechtigte Kommunikation



Gruppenkommunikation (1)



Gruppenkommunikation (2)



IPC — Prinzipielle Aktionen

Datentransfer vom Sende- zum Empfangsprozessaddressraum

- Botschaftenaustausch über einen gemeinsamen Kommunikationskanal

Synchronisation von Sende- und Empfangsprozess

- der Fortschritt des Empfangsprozesses hängt ab vom Sendeprozess
 - die Nachricht ist ein konsumierbares Betriebsmittel
 - der Sendeprozess muss dem Empfangsprozess eine Nachricht zustellen
- der Fortschritt des Sendeprozesses hängt ab vom Empfangsprozess
 - der Nachrichtenpuffer ist ein wiederverwendbares Betriebsmittel
 - der Empfangsprozess muss Nachrichten verarbeiten und Puffer entsorgen
- die Koordination geschieht implizit mit der angewandten Primitive

Botschaftenaustausch — Message Passing

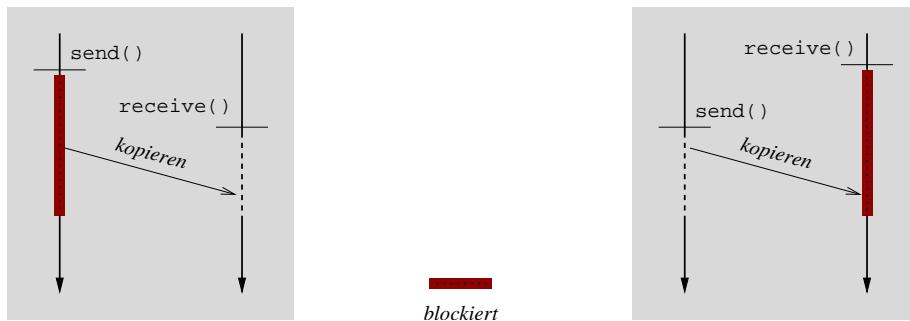
synchron und blockierend

- der Sender wartet passiv im `send()` auf das `receive()` des Empfängers
- der Empfänger wartet passiv im `receive()` auf das `send()` des Senders
- Unterstützung von End-zu-End Datentransfers ohne Zwischenpufferung

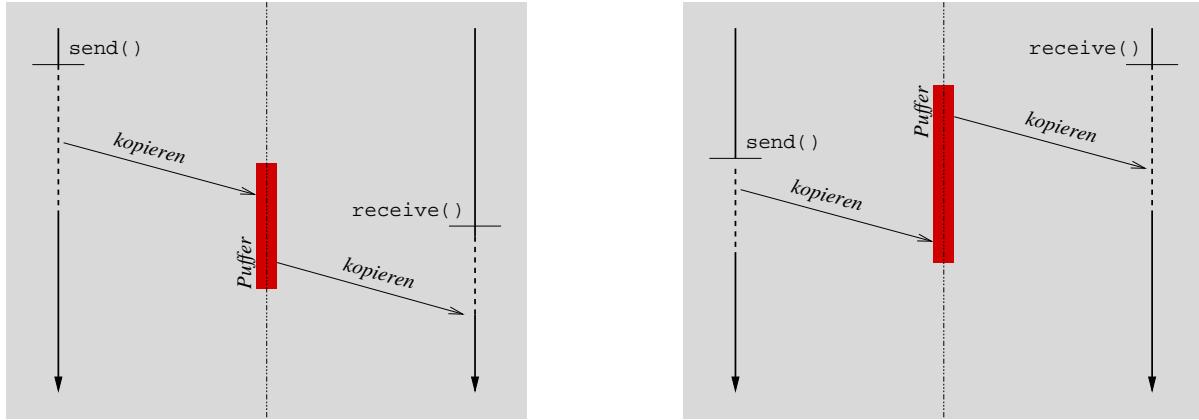
asynchron und blockierend oder nicht-blockierend

- passives Warten im `send()` bzw. `receive()` erfolgt ausnahmebedingt
 - im Falle von Zwischenpufferung der Nachrichten (*bounded buffer*)
 - zur Abwendung von Pufferüber- und/oder -unterlauf
- Unterstützung bzw. Ausnutzung von Fließbandverfahren (*pipelining*)

IPC — Synchrone Kommunikation



IPC — Asynchrone Kommunikation



IPC — *copy on write* — COW

- Kommunikation beeinflusst die „Fähigkeit“ (*capability*) von Prozessen:
 - send() entzieht dem Sender das Schreib- und übergibt dem Empfänger das Lesezugriffsrecht auf die Nachricht
 - receive() beansprucht das Lesezugriffsrecht auf die Nachricht durch den Empfänger
- Kopieren wird dadurch zum **Ausnahmefall** [8]: *segment swapping* bzw. *paging*
 - wenn der Sender nach dem send() die Nachricht zu überschreiben wünscht
 - wenn der Empfänger nach dem receive() die Nachricht zu lesen wünscht
- **Nachrichten** müssen vom Betriebssystem als **Segmente** verwaltet werden

Blockierende vs. Nichtblockierende Kommunikation

- die Blockade synchronisiert den Prozess auf die Betriebsmittelbereitstellung

Sender benötigt ein wiederverwendbares Betriebsmittel „Puffer“

synchrone IPC ⇒ in den Zielpuffer

asynchrone IPC ⇒ in den Zwischenpuffer

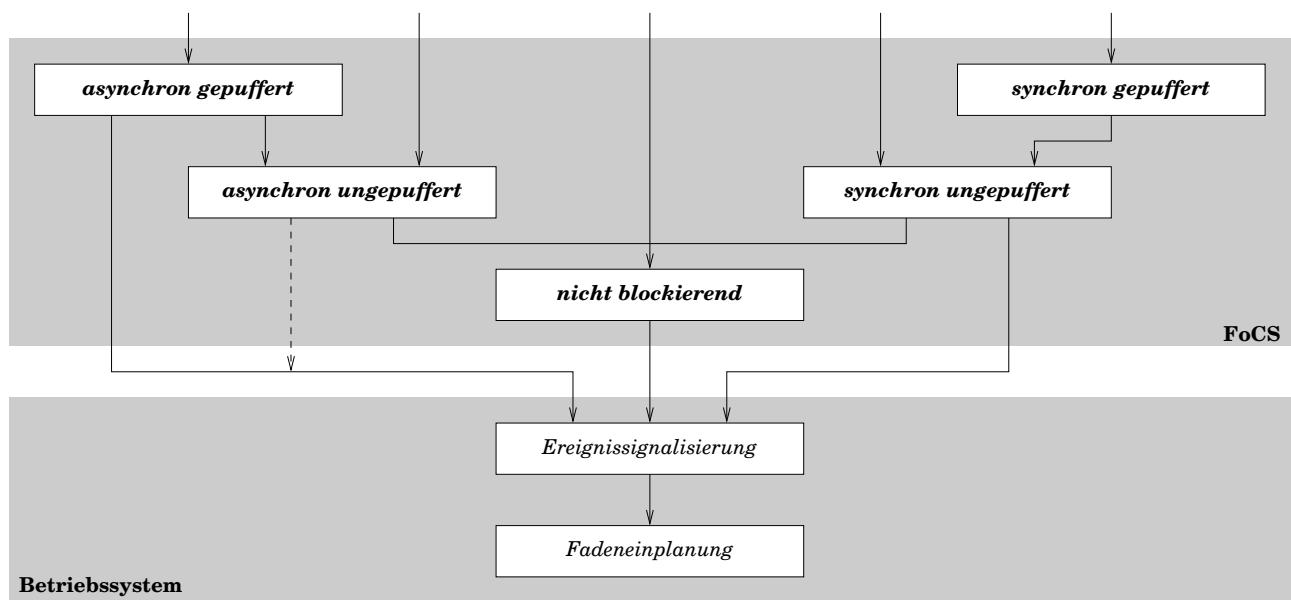
Empfänger benötigt ein konsumierbares Betriebsmittel „Nachricht“

synchrone IPC ⇒ aus dem Quellpuffer

asynchrone IPC ⇒ aus dem Zwischenpuffer

- beide Verfahren haben ihre Vor- und Nachteile, sie ergänzen sich einander

Family of Communication Systems (FoCS) — Fox



gepuffert nach Übergabe an das Kommunikationssystem kann der durch die Nachricht belegte Speicherbereich wiederverwendet werden

- Kopieraufwand ist durch Einsatz von *Wechselpufferverfahren* vermeidbar

ungepuffert eine sofortige Wiederverwendung des durch die Nachricht belegten Speicherbereichs ist konfliktbehaftet

- ein *Signal* zeigt an, dass eine Konfliktgefahr nicht (mehr) besteht¹

Beide Verfahren wirken sich **blockierend** auf den Sendeprozess aus, wenn (a) ein *Pufferdeskriptor* als Betriebsmittel nicht verfügbar ist und (b) die dadurch entstehende Ausnahmesituation nicht zum Scheitern der Operation führen soll.

¹Im Normalfall bedeutet dies den (erfolgreichen) Abschluss des Kommunikationsvorgangs.

gepuffert nach Übergabe an das Kommunikationssystem kann der durch die Nachricht belegte Speicherbereich von einem anderen Faden desselben Programms wiederverwendet werden

- das Programm kann problemlos ausgelagert werden (*swapping, paging*)

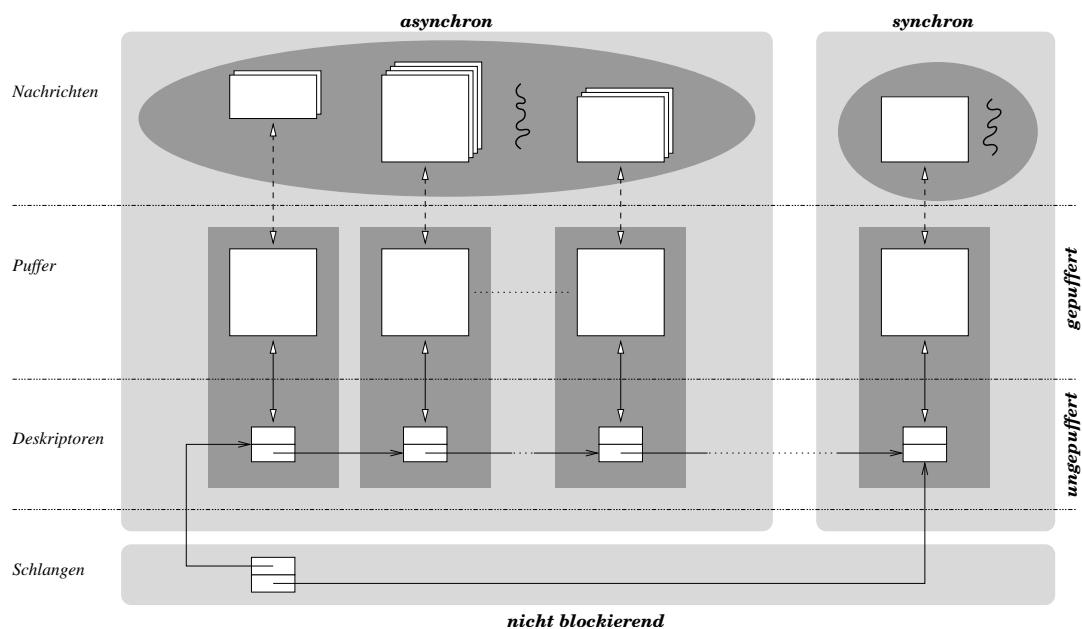
ungepuffert der Datentransfer kann End-zu-End, d.h., direkt zwischen dem Sende- und Empfangsadressraum stattfinden

- der Kommunikationsvorgang läuft (im System) sehr effizient ab

Beide Verfahren wirken sich **blockierend** für den Sendeprozess aus. Die Operation kann nicht wegen Betriebsmittelmangel scheitern, da der Sendeprozess zu einem Zeitpunkt nicht mehr als einen Kommunikationsvorgang auslösen kann.

- alle erforderlichen Betriebsmittel werden „von oben“ geliefert:
Puffer direkt von der Anwendungsebene oder von der Systemebene, die gepufferte Kommunikation implementiert
Pufferdeskriptor von der Systemebene, die ungepufferte Kommunikation implementiert
- die *Kommunikationsbetriebsmittel* werden lediglich „delegiert“
 - sie werden Verarbeitungseinheiten (Protokollmaschine, Treiber) zugeführt
 - ihre Freigabe wird den Prozessen signalisiert
- den Prozessen obliegt es, ggf. auf diese Signale („oben“) zu warten

Kommunikationsart vs. Betriebsmittel



IPC Semantiken

no-wait send der Sendeprozess wartet, bis die Nachricht im Transportsystem zum Absenden bereitgestellt worden ist

- Pufferung oder *Signalisierung* (dass der übergebene Puffer wieder frei ist)

synchronization send der Sendeprozess wartet, bis die Nachricht vom Empfangsprozess angenommen worden ist

- *Rendezvous* zwischen Sende- und Empfangsprozess

remote-invocation send der Sendeprozess wartet, bis die Nachricht vom Empfangsprozess verarbeitet und beantwortet worden ist

- *Fernauftrag* einer vom Empfangsprozess auszuführenden Funktion

IPC Varianten (1)

non-blocking send → *no-wait send*

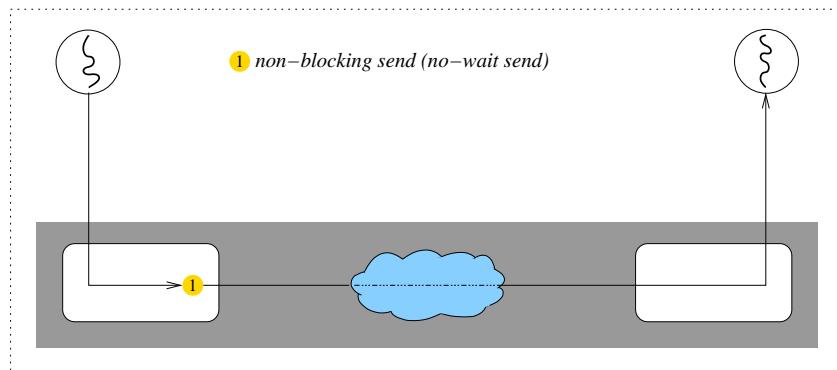
blocking send der Sendeprozess wartet, bis die Nachricht den Rechner verlassen hat, d.h., bis sie ausgegeben und ins Netz eingespeist worden ist

reliable-blocking send der Sendeprozess wartet, bis die Nachricht beim Empfangsrechner eingetroffen ist bzw. von dem den Empfangsprozess verwaltenden Betriebssystem angenommen worden ist

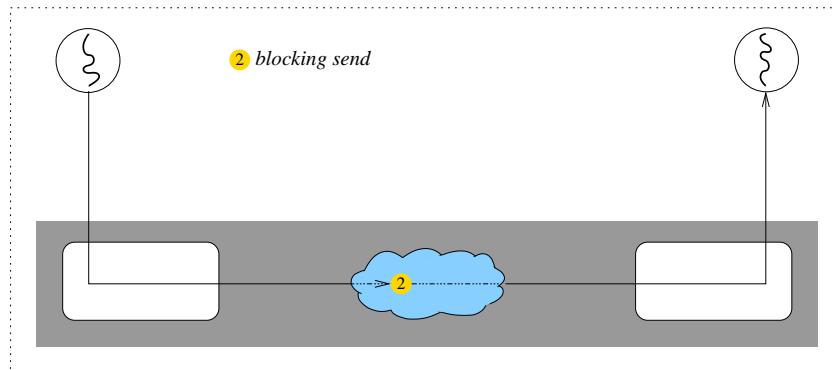
explicit-blocking send → *synchronization send*

request/reply → *remote-invocation send*

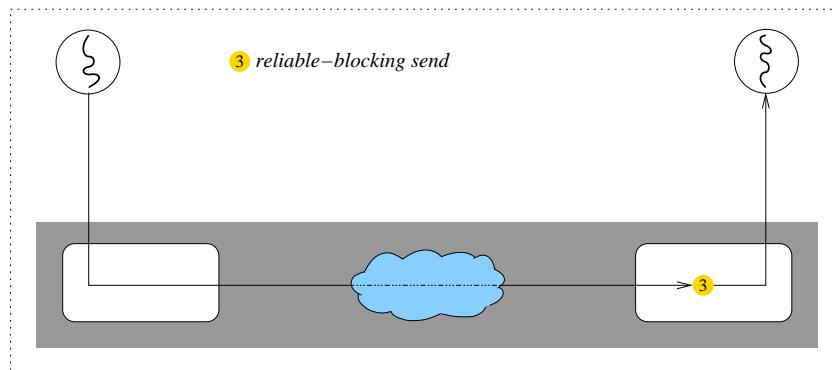
IPC Varianten (1.1)



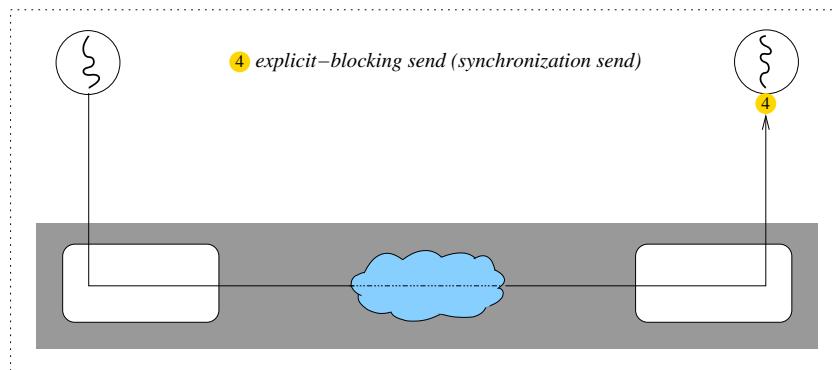
IPC Varianten (1.2)



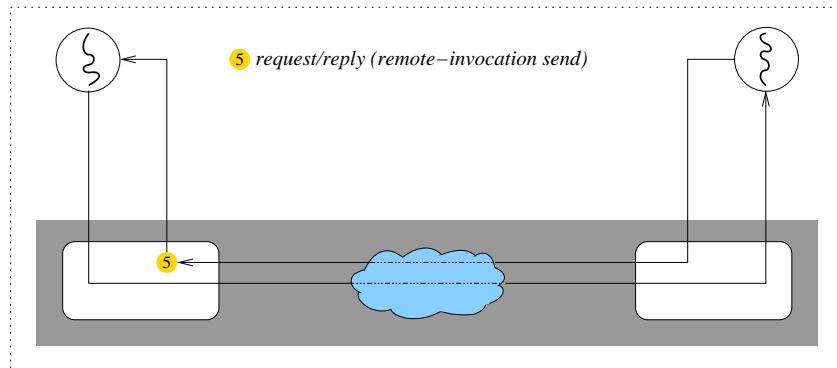
IPC Varianten (1.3)



IPC Varianten (1.4)



IPC Varianten (1.5)



IPC vs. Fernauftrufe

- miteinander kommunizierende Prozesse kennen die *Bedeutung* der Nachrichten
 - sie ist ihnen *implizit* durch den Verarbeitungsalgorithmus bewusst oder
 - sie machen sie sich gegenseitig *explizit* über „Anweisungen“ bekannt
- die Nachrichten enthalten (problemspezifische) Daten und/oder Text:
 - function shipping** der Empfangsprozess interpretiert Programme
 - mobiler Kode (Java Bytecode, PostScript) ggf. mit Daten unterfüttert
 - data shipping** der Empfangsprozess interpretiert Daten
- im „Normalfall“ bewirken Nachrichten die Ausführung entfernter Routinen
 - die aufzurufenden Prozeduren/Funktionen sind implizit oder explizit kodiert

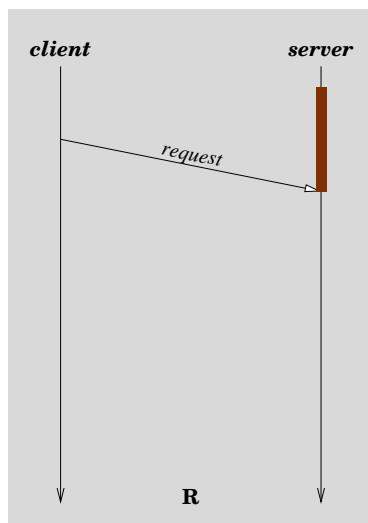
IPC Protokolle für Fernaufrufe (1)

request (R) kann genutzt werden, wenn die entfernte Prozedur/Funktion keinen Rückgabewert liefert und der Sendeprozess keine Bestätigung für die erfolgte Ausführung benötigt 1 Nachricht

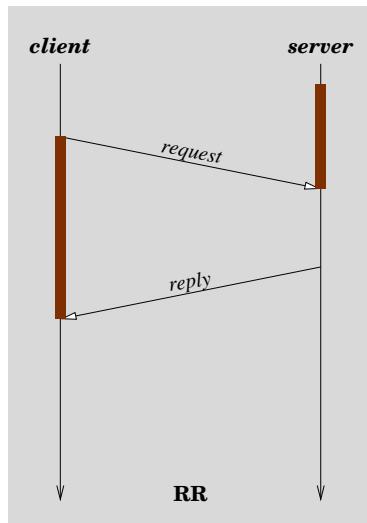
request-reply (RR) ist das geläufige Verfahren, da die Antwortnachricht implizit die Anforderungsnachricht bestätigt und dadurch explizite Bestätigungen entfallen 2 Nachrichten

request-reply-acknowledge reply (RRA) gestattet es, die zum Zwecke der Fehlermaskierung (beim Server) gespeicherten Antwortnachrichten zu verwerfen, wenn (vom Client) keine weitere Anforderungsnachricht gesendet wird 3 Nachrichten

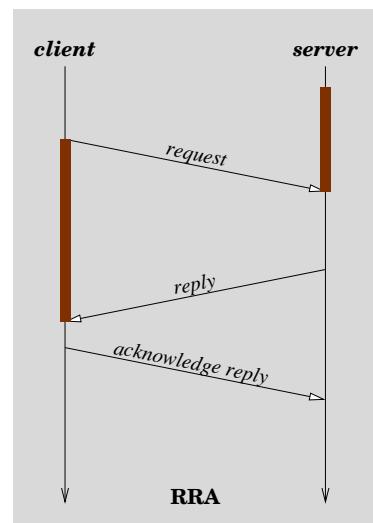
IPC Protokolle für Fernaufrufe (1.1)



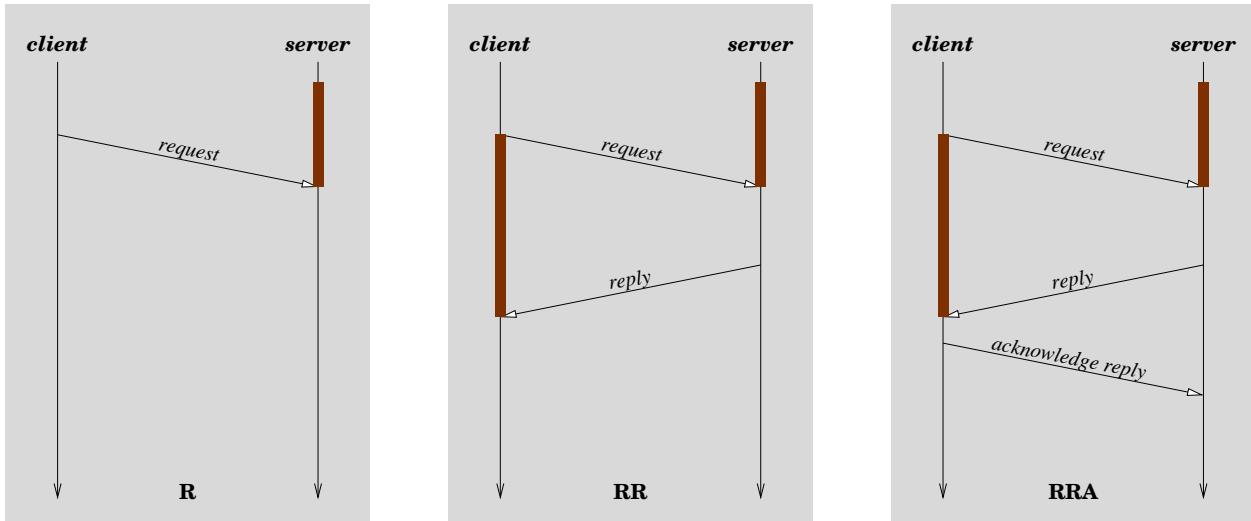
IPC Protokolle für Fernaufrufe (1.2)



IPC Protokolle für Fernaufrufe (1.3)



IPC Protokolle für Fernauftrufe (2)



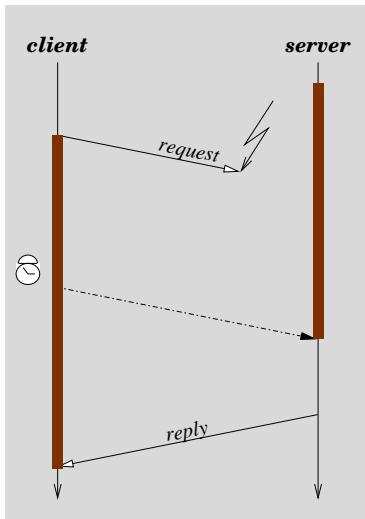
Zustellungsfehler

- Botschaftsaustausch unterliegt bestimmten (typischen) *Fehlerannahmen*:
 1. Nachrichten können verloren gehen
 - beim Sender, beim Empfänger oder im Netz
 2. Netzwerke können sich partitionieren
 - ein oder mehrere Rechner (Knoten) werden „abgetrennt“
 3. Prozesse können scheitern (d.h. „abstürzen“)
 - Prozess-, Rechner- oder Netzwerkausfälle sind nicht unterscheidbar
 4. Daten können verfälschen
- als Folge sind unterschiedliche (typische) *Protokollvarianten* [6] entstanden

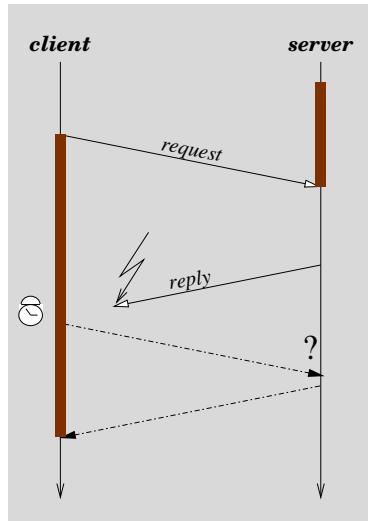
Fehlermaskierung (1)

- Anforderungs- und ggf. auch Antwortnachrichten wiederholen
 - nach einer Pause (*time-out*) werden die Nachrichten erneut versendet
 - die „optimale“ Länge der Pause zu bestimmen ist äußerst schwierig
- eingetroffene Nachrichtenduplikate sind zu erkennen und zu ignorieren
 - ggf. bereits versandte Antwortnachrichten wiederholt versenden
 - auf Client- bzw. Server-Seite ist ggf. „*duplicate suppression*“ anzuwenden
- *idempotente Operationen*/Zustandsfreiheit tolerieren Anforderungsduplikate

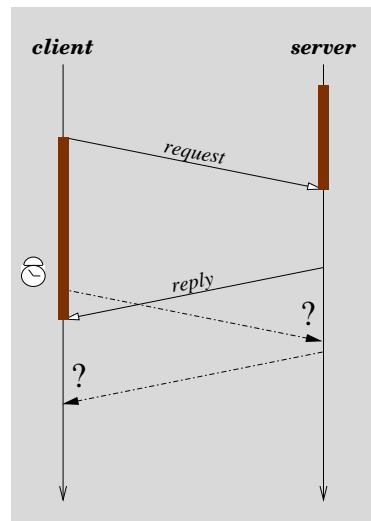
Fehlermaskierung (1.1)



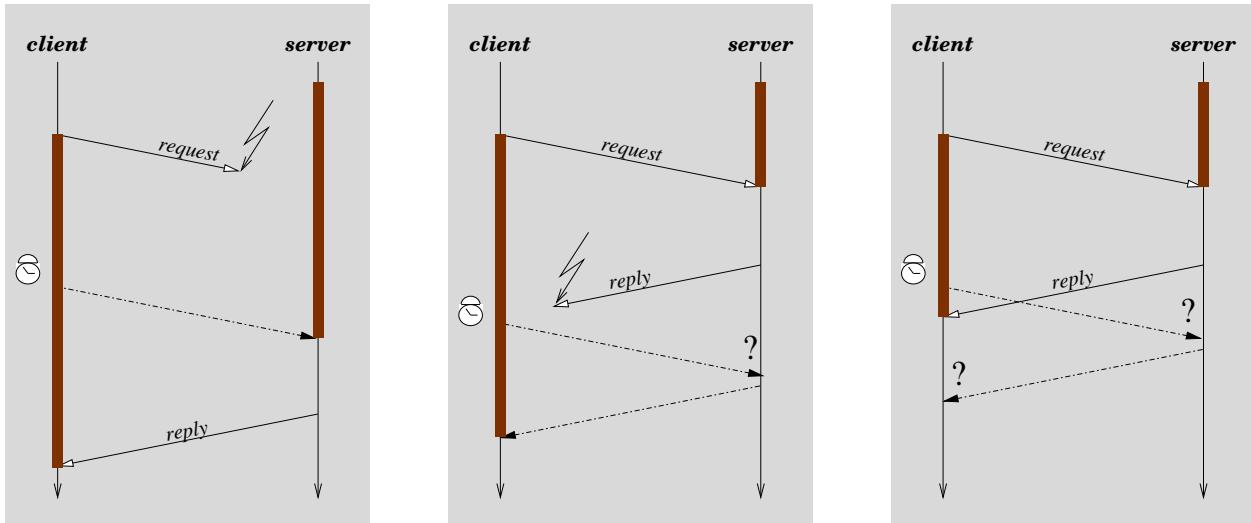
Fehlermaskierung (1.2)



Fehlermaskierung (1.3)



Fehlermaskierung (2)

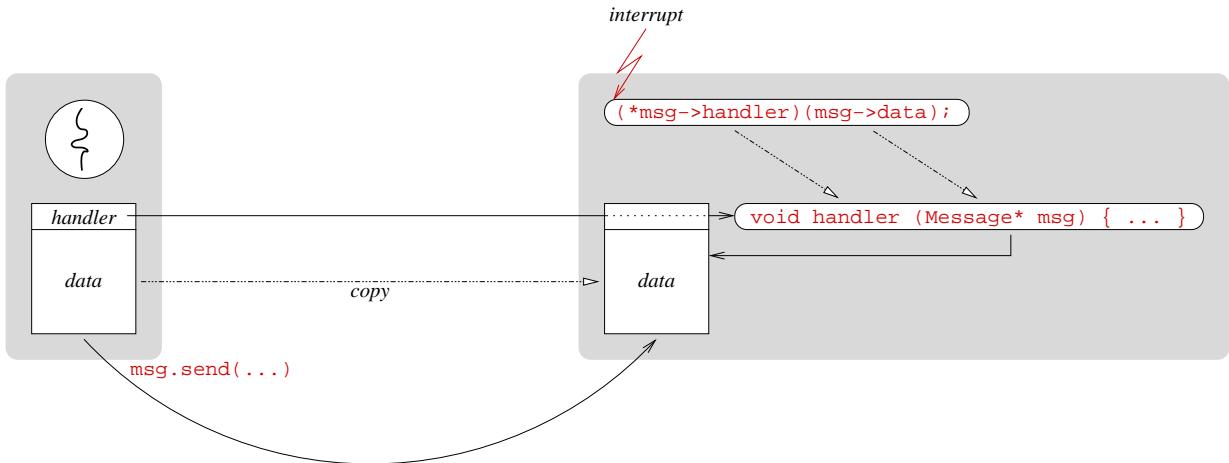


Aktive Nachrichten (1)

- die Nachricht enthält die Programmadresse der sie verarbeitenden Prozedur
 - im Zuge des Nachrichtenempfangs wird an die angegebene Stelle verzweigt
 - die Verarbeitung läuft als **asynchrone Programmunterbrechung** ab
 - die Behandlungsroutine ist eine Methode des Objektes „Nachricht“²
- die durch die Nachricht unterbrochene Prozessinkarnation ist der „Empfänger“
 - seine Aufgabe ist es, die Daten in die laufende Berechnung einzuspeisen
 - eine prompte Vorgehensweise, die die *Kommunikationslatenz* verringern kann
 - ursprünglich entwickelt zum *high-performance parallel computing* [7]

²Womit nicht gesagt sein soll, dass es sich hierbei um ein strikt objektorientiertes Modell handelt. Eine objektorientierte Umsetzung des Konzeptes liegt jedoch nahe und ist empfehlenswert [4].

Aktive Nachrichten (2)

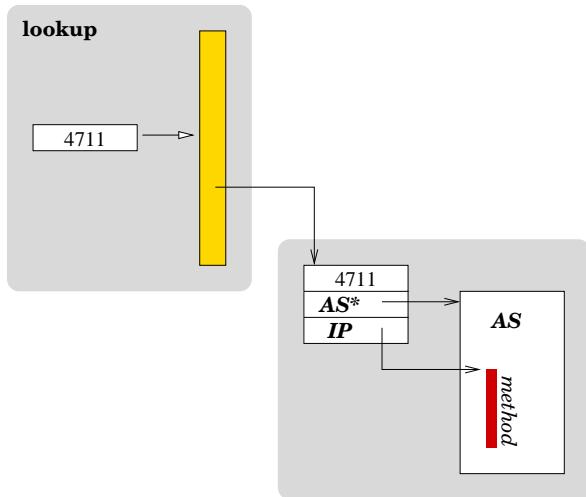


Kommunikationsendpunkt (1)

- der Bezeichner (*identifier*) des Bestimmungsortes einer Nachricht
 - seine „Bedeutung“ ist je nach Anforderung/Auslegung orts{,un}abhängig
 - ein *trade-off* zwischen Performanz und Flexibilität bzw. Transparenz
- je nach Modell werden darüber unterschiedliche Instanzen identifiziert:
 - Prozedur** das die Nachricht verarbeitende passive Objekt *method*
 - Prozessinkarnation** das die Nachricht verarbeitende aktive Objekt ... *thread*
 - Tor** das die Nachricht weiterleitende Objekt *port*
 - Briefkasten** das die Nachricht zwischenspeichernde Objekt *mailbox*
- sein Wert muss (für eine gewisse Zeitdauer) **systemweit eindeutig** sein

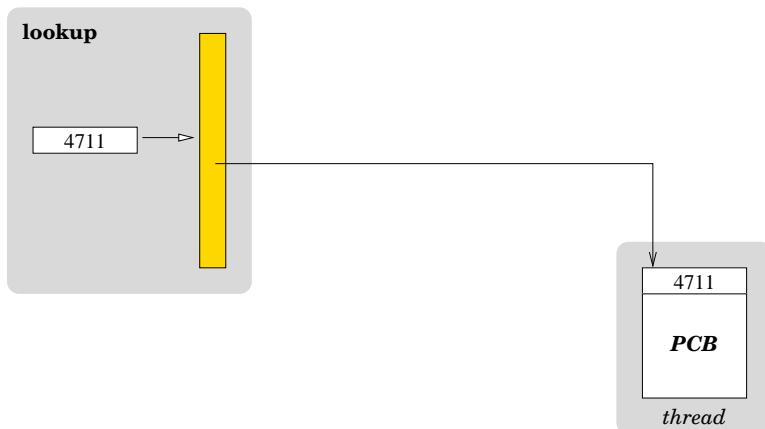
Kommunikationsendpunkt (1.1)

Prozedur



Kommunikationsendpunkt (1.2)

Prozessinkarnation



Kommunikationsendpunkt (1.3)

Tor



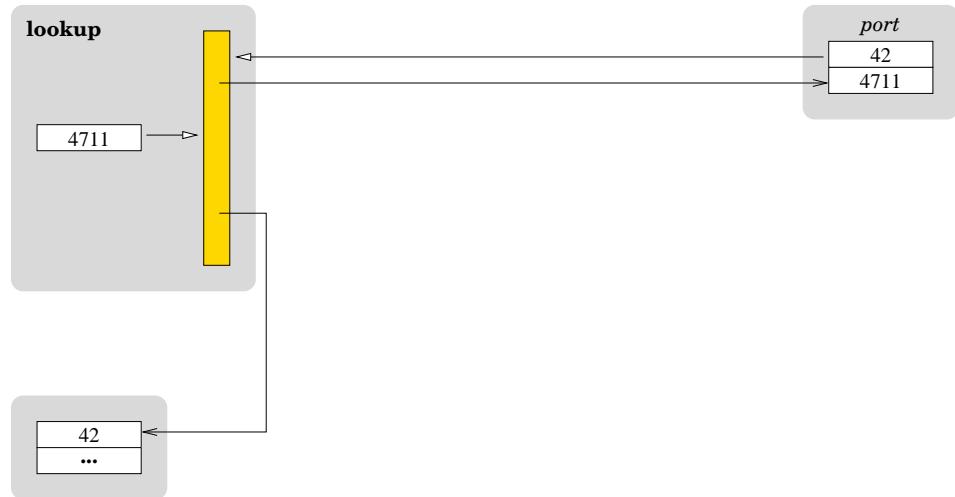
Kommunikationsendpunkt (1.4)

Briefkasten

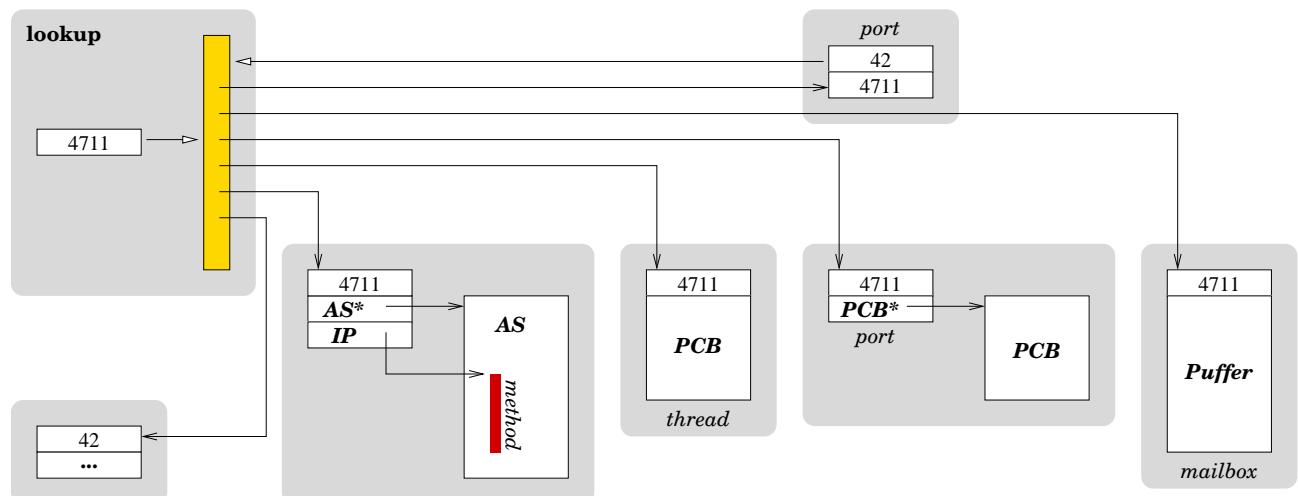


Kommunikationsendpunkt (1.5)

Torkette



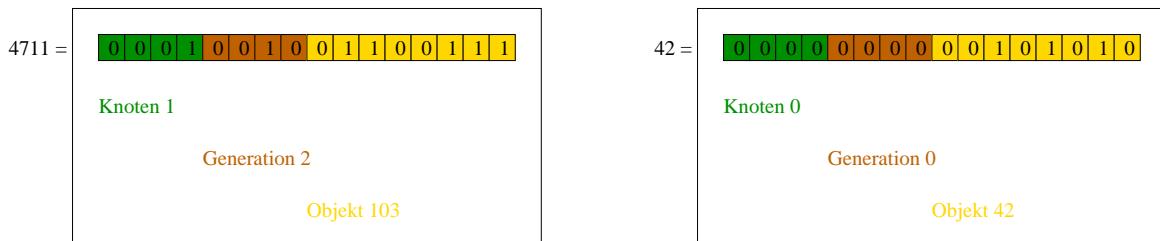
Kommunikationsendpunkt (2)



Eindeutigkeit

- dem Bezeichner ist ein Wert zu geben, der Mehrdeutigkeiten ausschließt:
Zufallszahl steht und fällt mit der Güte des Zufallszahlengenerators
Zeitstempel setzt eine einheitliche Zeitbasis voraus
Prozessornummer die „Hardware-Adresse“ ist abhängig vom Hersteller
- auch lokal ist bereits die eindeutige Wertzuordnung erforderlich:
Unikat eine nur einmal vergebene Objektidentifikation → UNIX *pid*
Generationsnummer zählt die Wiedervergabe einer Objektidentifikation
Adresse des Objektes im Hauptspeicher
- der *Eindeutigkeitsgrad* hängt stark ab vom gewählten Wertebereich → Y2K

Strukturierte Bezeichner



- die Struktur ist im Regelfall „nach außen“ nicht sichtbar, sie ist transparent
 - „nach innen“ gestattet sie ein effizientes Auffinden des Bestimmungsortes
- der Bezeichner bleibt damit ortsunabhängig, enthält jedoch „Ortshinweise“

Kommunikationsverlauf

direkt der Bezeichner identifiziert eine Prozessinkarnation oder Prozedur

- Nachrichten werden direkt einem Adressraum bzw. Prozess zugestellt

indirekt der Bezeichner identifiziert ein Tor oder einen Briefkasten

- Nachrichten werden einem Prozess indirekt über ein Tor zugestellt
- Prozesse nehmen Nachrichten indirekt über Briefkästen in Empfang

verbindungsorientiert der Bezeichner identifiziert ein Tor

- die Verbindungen bestehen zwischen Toren: einem Sende- und Empfangstor
- der Verbindungsaufbau dient u.a. der *Betriebsmittelreservierung*

Direkte Kommunikation (1)



- adressiert wird die **entfernte Prozedur** zur *Nachrichtenverarbeitung*
 - die Botschaft wird als aktive Nachricht [7] verschickt und behandelt
 - die Verarbeitung erfolgt nebenläufig zum entfernten aktiven Prozess
- das Schema unterstützt weder Migrationstransparenz noch Fehlertransparenz

Direkte Kommunikation (2)



- adressiert wird der **entfernte Prozess** zur *Nachrichtenverarbeitung*
 - den Moment der Nachrichtenannahme bestimmt die *Fadeneinplanung*
 - die Verzögerung (*scheduling latency*) bedingt eine Zwischenlagerung
- das Schema unterstützt weder Migrationstransparenz noch Fehlertransparenz

Indirekte Kommunikation (1)



- adressiert wird das **entfernte Tor** zur *Nachrichtenweiterleitung*
 - der Empfangsprozess ist „lose“ mit einem *Eingangstor* gekoppelt
 - die Bindung ist dynamisch und kann sich auf mehrere Eingangstore beziehen
- das Schema unterstützt Migrationstransparenz, aber Fehlertransparenz nicht

Indirekte Kommunikation (2)



- adressiert wird der **entfernte Briefkasten** zur *Nachrichtenspeicherung*
 - mehrere Prozesse können sich denselben Briefkasten teilen
 - typisch ist die *mehrfädige Verarbeitung* eingegangener Nachrichten
- das Schema unterstützt weder Migrationstransparenz noch Fehlertransparenz

Verbindungsorientierte Kommunikation (1)



- adressiert wird das **lokale Tor** zur *Nachrichtenweiterleitung*
 - die Bindung zwischen *Ausgangstor* und entferntem Prozess ist dynamisch
 - der Bezeichner des entfernten Prozesses kann als *Replikat* verteilt vorliegen
- das Schema unterstützt Migrationstransparenz und Fehlertransparenz

Verbindungsorientierte Kommunikation (2)



- adressiert wird das lokale Tor zur *Nachrichtenweiterleitung* über eine **Torkette**
 - die dynamische Bindung „*Ausgangstor* zu *Eingangstor*“ ist 1 : 1 oder N : 1
 - durch Rechnerausfälle ggf. aufgebrochene Ketten sind wieder zu schließen
- das Schema unterstützt Migrationstransparenz und Fehlertransparenz

Zusammenfassung

- Interprozesskommunikation ist in vielfältiger Art und Weise möglich:
 - {,a}synchron, {,un}gepuffert, {,nicht}blockierend, {,un}zuverlässig
 - {no-wait,blocking,reliable-blocking,synchronization,remote-invocation} send
 - {request,request-reply,request-reply-acknowledge reply} Protokoll
- Kommunikationsendpunkte können sehr unterschiedliche Bedeutungen besitzen
 - Bezeichner für Tore, Briefkästen, Prozessinkarnationen und/oder Prozeduren
 - systemweite Eindeutigkeit ist (je nach Anwendungsszenario) zu gewährleisten
- die Kommunikation verläuft direkt, indirekt oder verbindungsorientiert

Referenzen

- [1] W. M. Gentleman. Message Passing between Sequential Processes: The Reply Primitive and the Administrator Concept. *Software Practice and Experience*, 11(5):435–466, May 1981.
- [2] B. H. Liskov. Primitives for Distributed Computing. In *Proceedings of the Seventh ACM Symposium on Operating System Principles*, volume 13 of *Operating Systems Review*, pages 33–42, 1979.
- [3] J. H. Saltzer, D. P. Reed, and D. D. Clark. End-To-End Arguments in System Design. *Transactions on Computer Systems*, 2(4):277–288, Nov. 1984.
- [4] W. Schröder-Preikschat. *The Logical Design of Parallel Operating Systems*. Prentice Hall International, 1994. ISBN 0-13-183369-3.
- [5] W. Schröder-Preikschat. Betriebssysteme. <http://www4.informatik.uni-erlangen.de>, 2002.
- [6] A. Z. Spector. Performing Remote Operations Efficiently on a Local Computer Network. *Communications of the ACM*, 25(4):246–260, 1982.
- [7] T. von Eicken, D. E. Culler, S. C. Goldstein, and K. E. Schauser. Active Messages: A Mechanism for Integrated Communication and Computation. Technical Report UCB/CSD 92/675, University of California, Berkeley, CA, 1992.
- [8] M. Young, A. Tevanian, R. Rashid, D. Golub, J. Eppinger, J. Chew, W. Bolosky, D. Black, and R. Baron. The Duality of Memory and Communication in the Implementation of a Multiprocessor Operating System. In *Proceedings of the Eleventh ACM Symposium on Operating System Principles*, volume 21 of *Operating Systems Review*, pages 63–76, Austin, TX, 1987.