— VS —

Kommunikationssystem

Funktionseinheit von Middleware und Betriebssystem

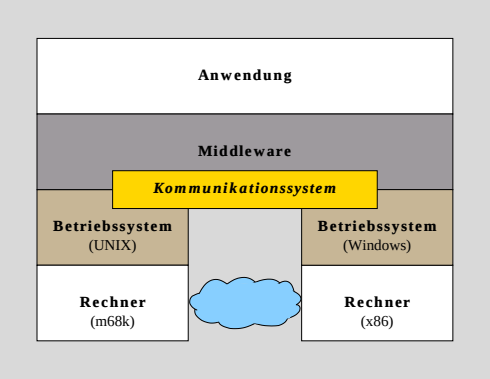

Überblick

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

{,Nicht} Gleichberechtigte Kommunikation

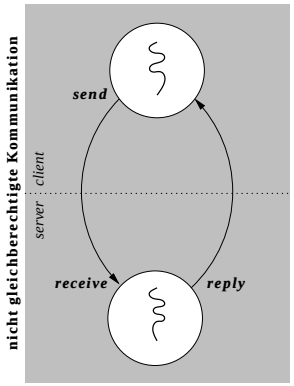

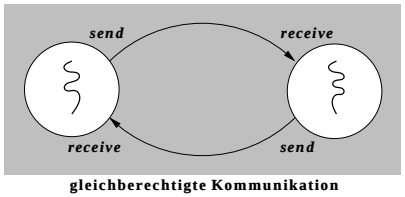

gleichberechtigte Kommunikation

Gruppenkommunikation (1)

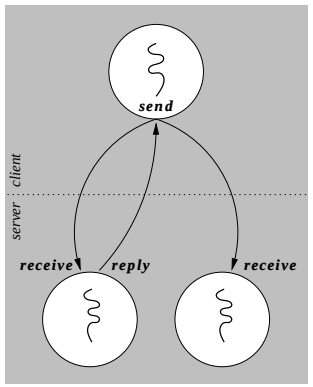

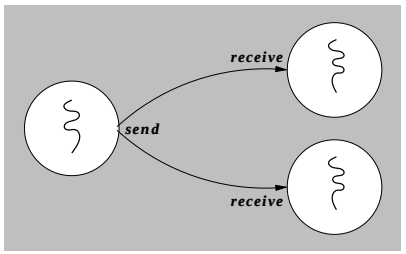

Gruppenkommunikation (2)

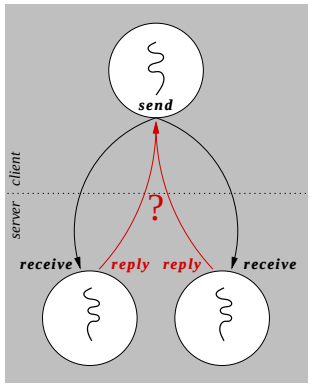

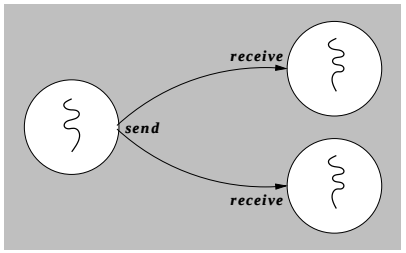

IPC — Prinzipielle Aktionen

Datentransfer vom Sende- zum Empfangsprozessadressraum

- 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

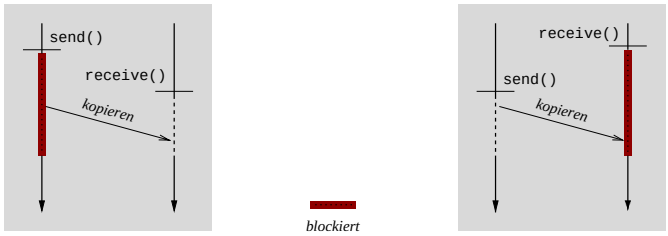

IPC — Asynchrone Kommunikation

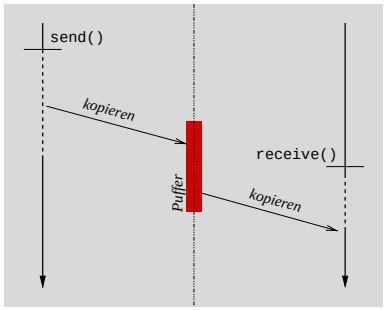

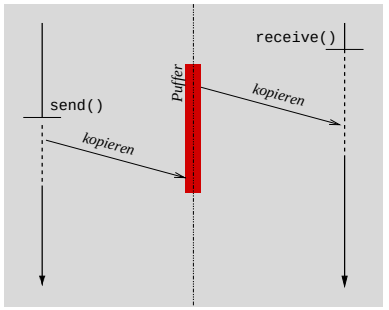

IPC — *copy on write* — COW

- 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“
  synchroner IPC ⇒ in den Zielpuffer
  asynchroner IPC ⇒ in den Zwischenpuffer
  Empfänger benötigt ein konsumierbares Betriebsmittel „Nachricht“
  synchroner IPC ⇒ aus dem Quellpuffer
  asynchroner IPC ⇒ aus dem Zwischenpuffer

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

Family of Communication Systems (FoCS) — Fox

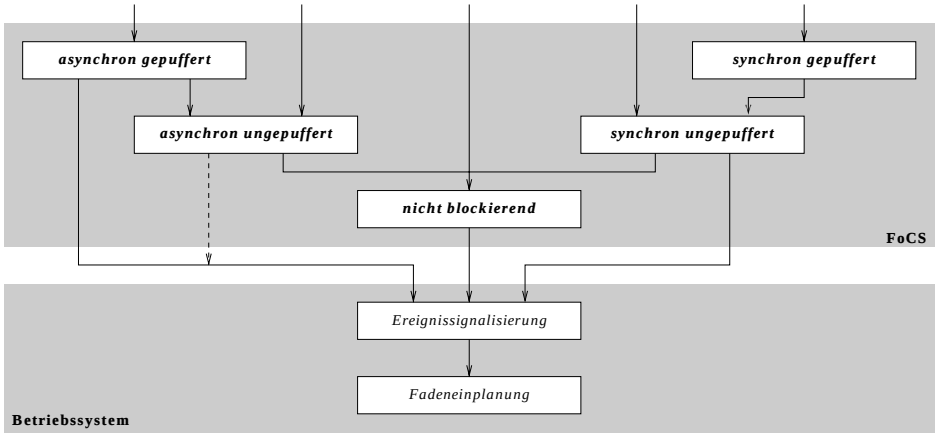

Fox — Asynchrone Kommunikation

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) besteht[1]

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.

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

Fox — Synchrone Kommunikation

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.

Nichtblockierende Kommunikation

FOX

- 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

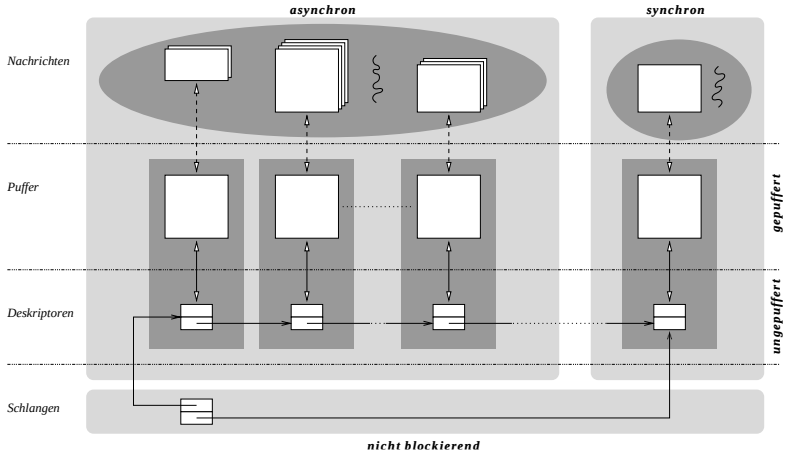

IPC Semantiken

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

- *Fernaufruf* 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 (2)

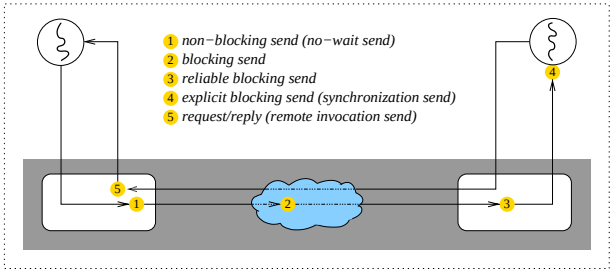

IPC vs. Fernaufrufe

- 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 (2)

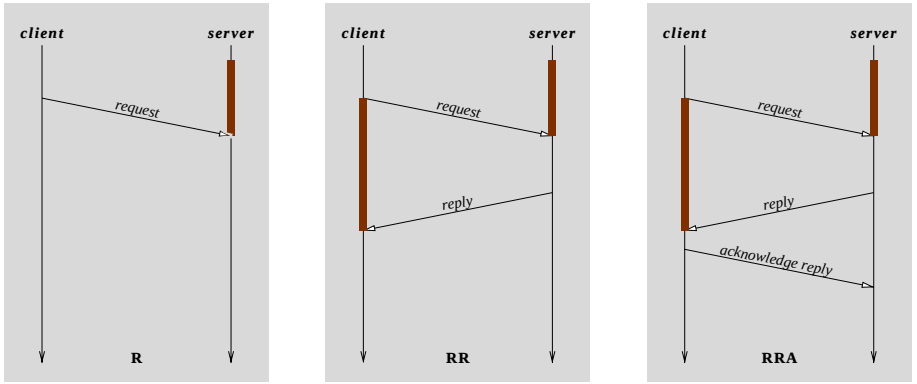

Zustellungsfehler

- Botschaftenaustausch 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 supression*“ anzuwenden

- *idempotente Operationen*/Zustandsfreiheit tolerieren Anforderungsduplikate

Fehlermaskierung (2)

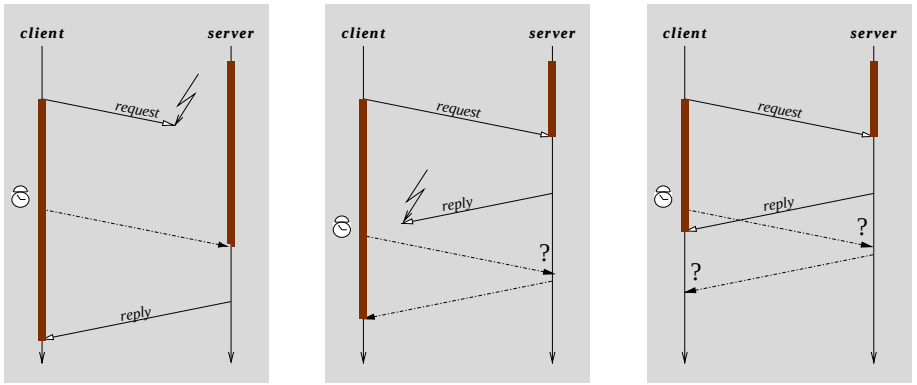

Aktive Nachrichten (1)

- 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]

[2] Womit 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)

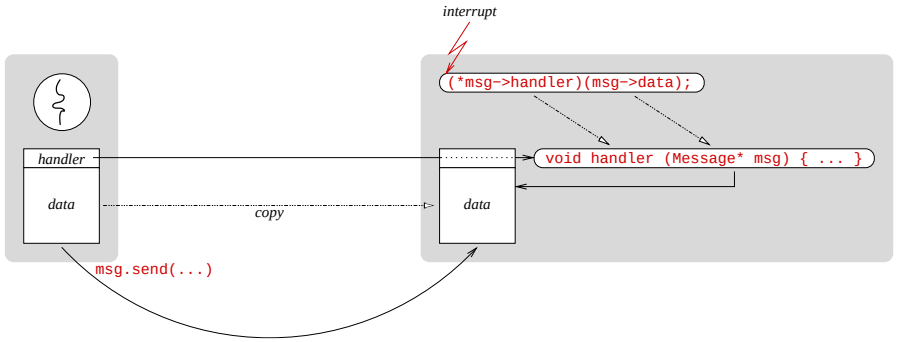

Kommunikationsendpunkt (1)

- 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 (2)

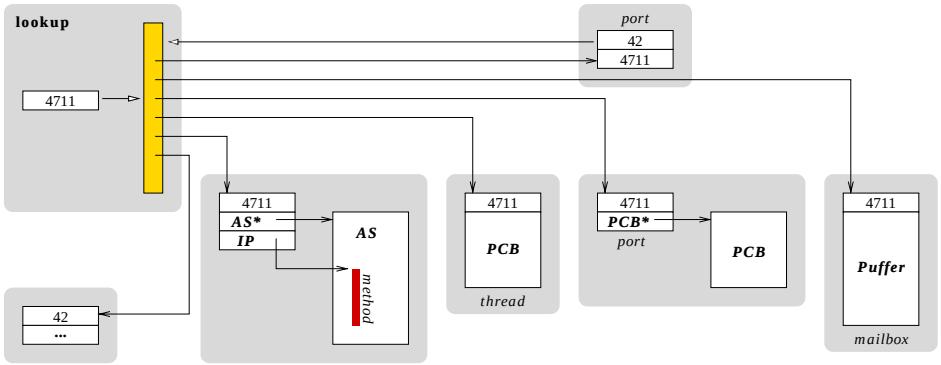

Eindeutigkeit

- 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

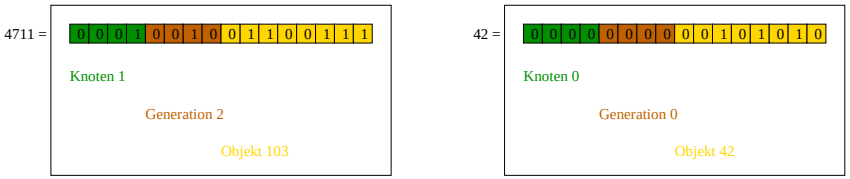

- die Struktur ist im Regelfall „nach außen“ nicht sichtbar, sie ist transparent
  - „nach innen“ gestattet sie ein effizientes Auffinden des Bestimmungsortes
- der Bezeichner bleibt damit ortsunabhängig, enthält jedoch „Ortshinweise“

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)

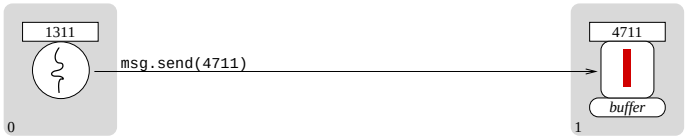

- adressiert wird die **entfernte Prozedur** zur *Nachrichtenverarbeitung*
  - die Botschaft wird als aktive Nachricht [7] verschickt und behandelt
  - die Verarbeitung erfolgt nebenläufig zum entfernten aktiven Prozess
- das Schema unterstützt weder Migrationstransparenz noch Fehlertransparenz

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)

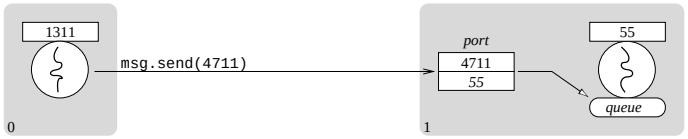

- adressiert wird das **entfernte Tor** zur *Nachrichtenweiterleitung*
  - der Empfangsprozess ist „lose“ mit einem *Eingangstor* gekoppelt
  - die Bindung ist dynamisch und kann sich auf mehrere Eingangstore beziehen
- das Schema unterstützt Migrationstransparenz, aber Fehlertransparenz nicht

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)

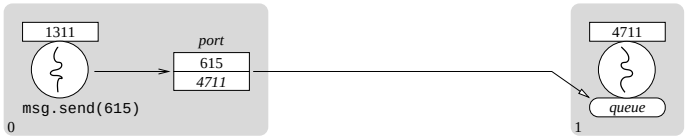

- adressiert wird das **lokale Tor** zur *Nachrichtenweiterleitung*
  - die Bindung zwischen *Ausgangstor* und entferntem Prozess ist dynamisch
  - der Bezeichner des entfernten Prozesses kann als *Replikat* verteilt vorliegen
- das Schema unterstützt Migrationstransparenz und Fehlertransparenz

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.