Version vom 28. Oktober 2016

Verteilte Systeme

Friedemann Mattern

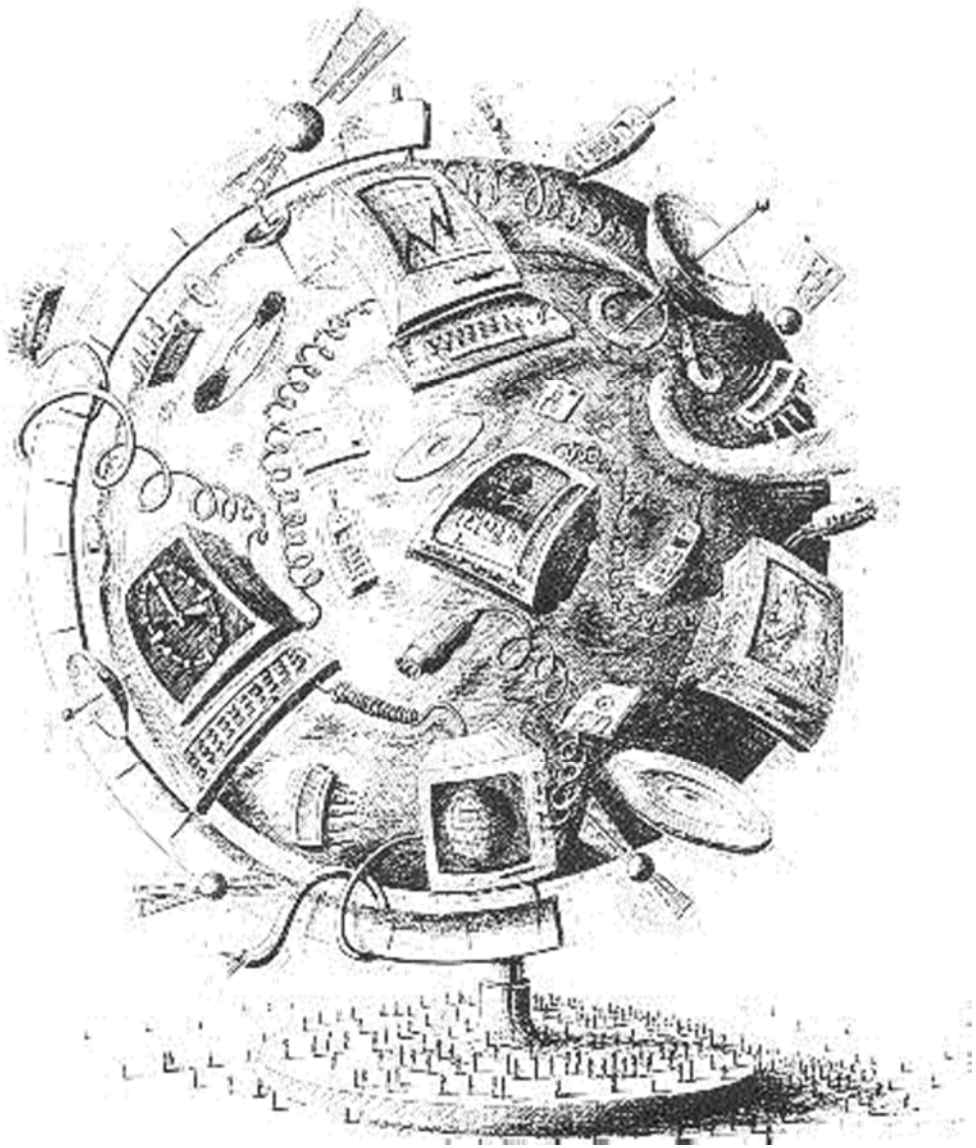

Prüfungsrelevant ist der Inhalt der Vorlesung, nicht alleine der Text dieser Foliensammlung!

Wer bin ich? Wer sind wir?

Prof. Friedemann Mattern

+ mehrere Assistenten
und Assistentinnen

Fachgebiet „Verteilte Systeme“
im Departement Informatik,
Institut für Pervasive Computing

Wer bin ich? Wer sind wir?

Prof. Friedemann Mattern

+ mehrere Assistenten und Assistentinnen

Leyna Sadamori
Ansprechperson für organisatorische Aspekte
leyna.sadamori@inf.ethz.ch

Fachgebiet „Verteilte Systeme“
im Departement Informatik,
Institut für Pervasive Computing

Mit was beschäftigen wir uns?

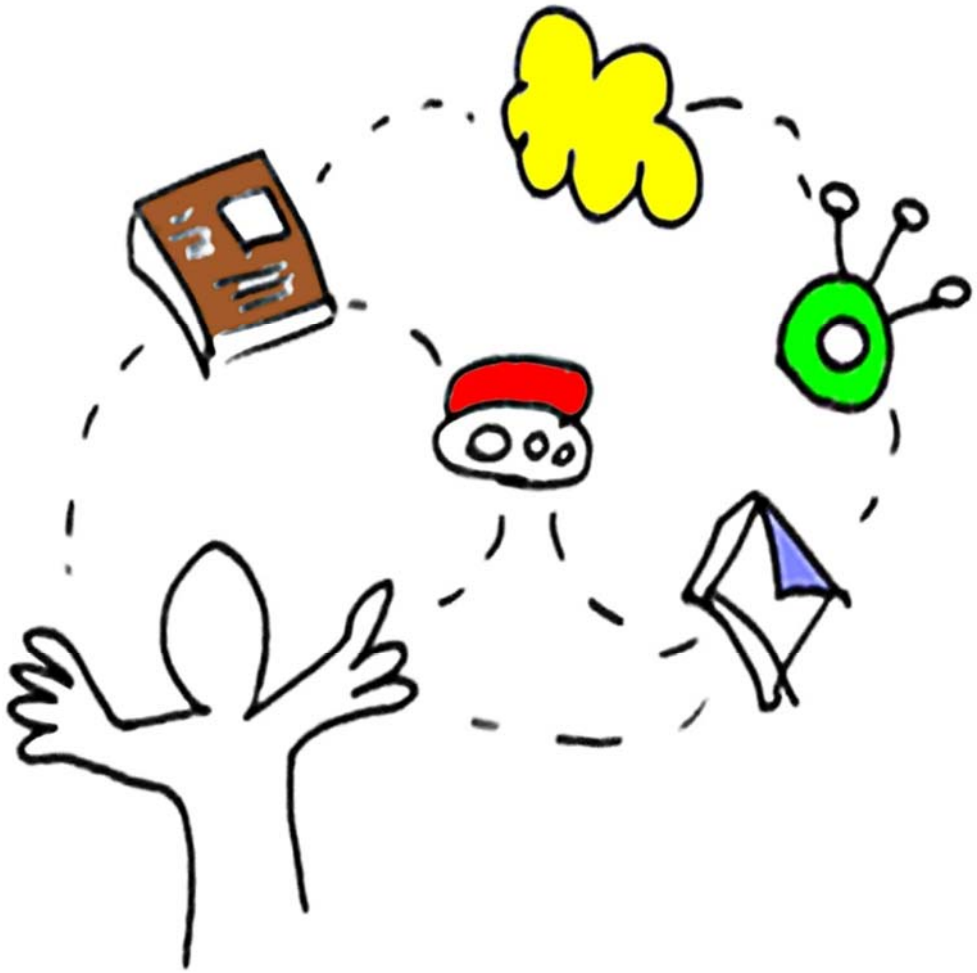

- Infrastruktur für verteilte Systeme
- Internet der Dinge
- Ubiquitous Computing
- Smart energy
- Verteilte Anwendungen und Algorithmen

Mehr zu uns:
www.vs.inf.ethz.ch

Organisatorisches zur Vorlesung

- Format: 6G+1A: Vorlesung und Praktikum integriert
  - Mo 9:15 - 12:00 **CAB G 11**; Fr 9:15 - 12:00 **CAB G 61**

Organisatorisches zur Vorlesung

- Format: 6G+1A: Vorlesung und Praktikum integriert
  - Mo 9:15 - 12:00 **CAB G 11**; Fr 9:15 - 12:00 **CAB G 61**

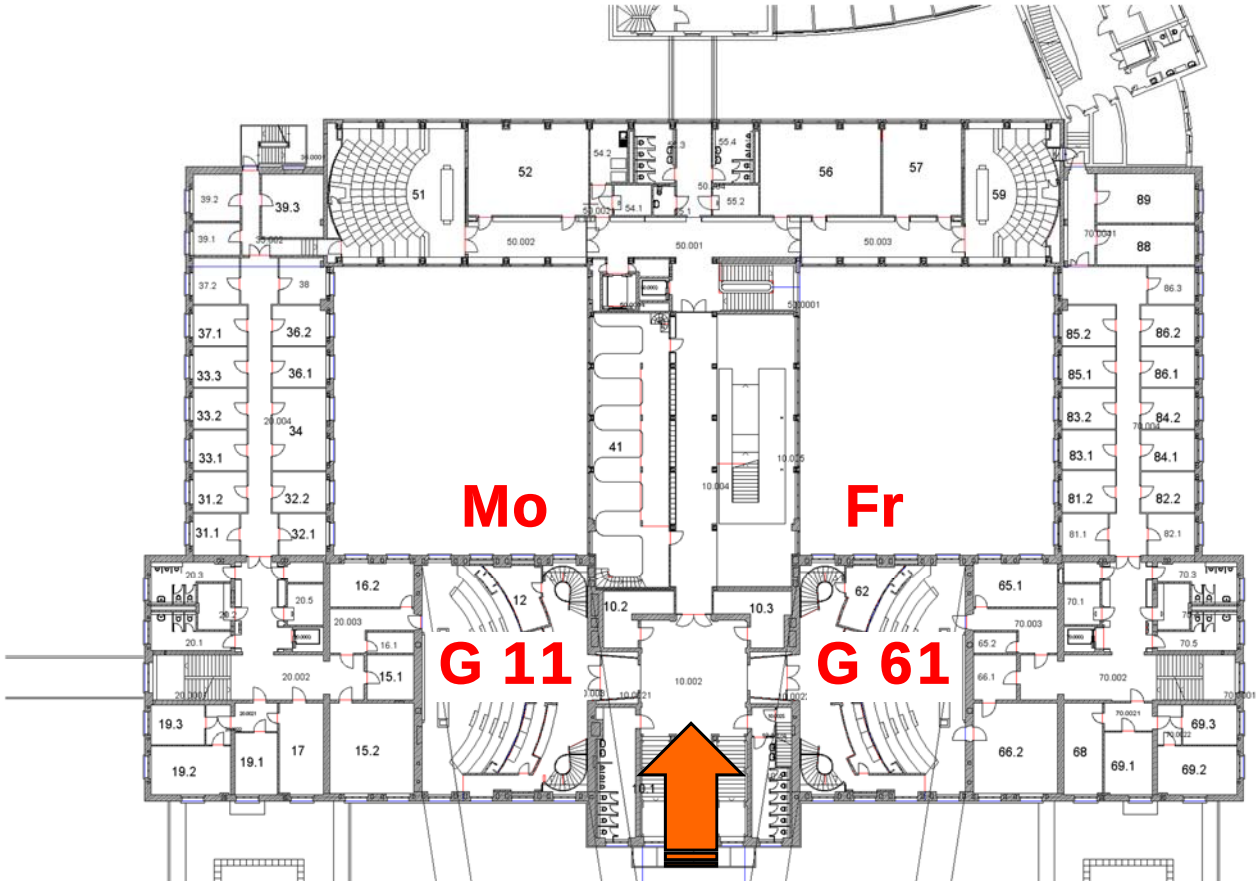

Organisatorisches zur Vorlesung

- Format: 6G+1A: Vorlesung und Praktikum integriert
  - Mo 9:15 - 12:00 **CAB G 11**; Fr 9:15 - 12:00 **CAB G 61**
  - Praktikum ist inhaltlich *komplementär zur Vorlesung* (mobile Kommunikationsplattformen und Smartphones mit Android etc.)
    - Praktikumsaufwand ist z.T. abgegolten durch den „+1A"-Kreditpunkt (= ca. 30 Stunden); zusätzlicher Bonus: anrechenbare Klausurpunkte bei Erfolg
  - Gelegentliche *Assistentenstunden* (zu den üblichen Terminen) zur Vertiefung des Stoffes und Besprechung der Praktikumsaufgaben
    - Ansonsten „freie" Übungsstunden auch für das Praktikum nutzen!
- Sinnvolle Vorkenntnisse (Grundlagen)
  - 4 Semester der Bachelorstufe Informatik; insbesondere:
  - Grundkenntnisse Computernetze und Betriebssysteme (z.B. Prozessbegriff, Synchronisation)
  - UNIX, Java ist hilfreich

Organisatorisches (2)

- Folienkopien
  - jetzt vorläufige, ab November endgültige Version
  - im pdf-Format bei www.vs.inf.ethz.ch/edu
- Prüfung schriftlich
  - bewertete Praktikumsaufgaben gehen in die Prüfungsnote ein
- Vorlesung ab November: Prof. Roger Wattenhofer

Einordnung der Vorlesung

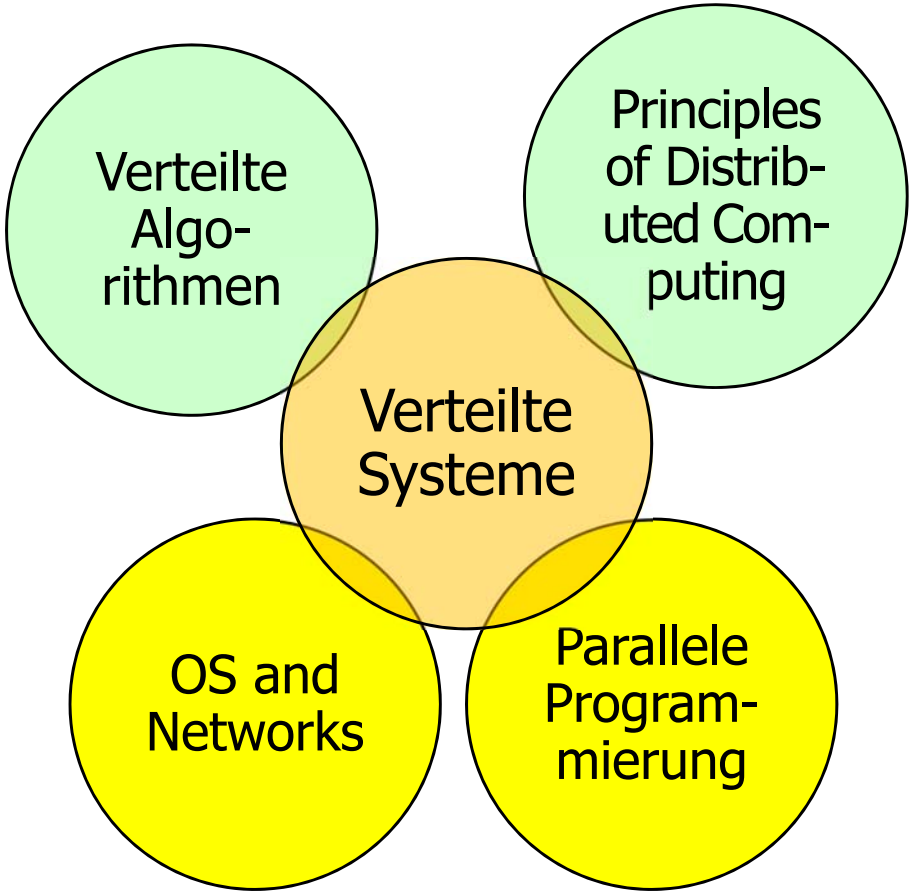

- „Verteilte Systeme“ ist ein Querschnittsthema
- Kleine Überschneidungen mit anderen Vorlesungen unvermeidlich

Literatur

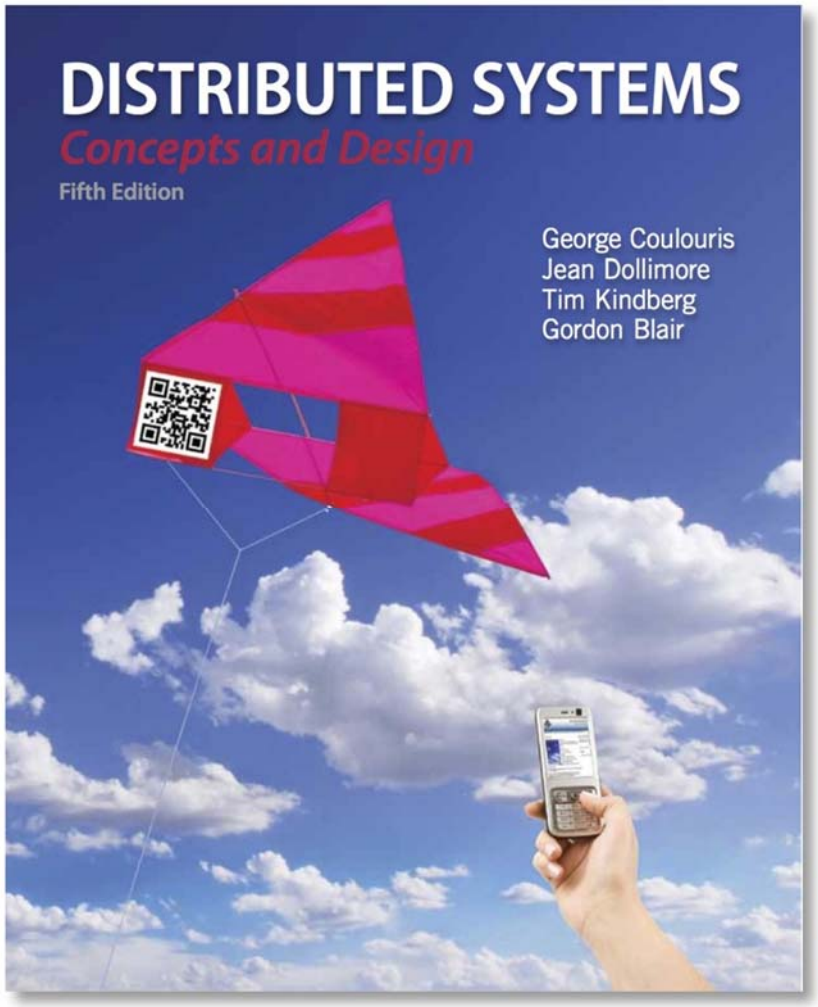

- G. Coulouris, J. Dollimore, T. Kindberg, G. Blair: Distributed Systems: Concepts and Design (5th ed.). Addison-Wesley, 2011
- A. Tanenbaum, M. van Steen: Distributed Systems: Principles and Paradigms (2nd ed.). Prentice-Hall, 2007 (Neuauflage Ende 2016?)
- O. Haase: Kommunikation in verteilten Anwendungen (2. Aufl.). R. Oldenbourg Verlag, 2008
- A. Schill, T. Springer: Verteilte Systeme (2. Aufl.). Springer Vieweg, 2012

Motivation
&
Historie

„Verteiltes System“ – zwei Definitionen

1) A distributed computing system consists of multiple autonomous processors that do not share primary memory, but cooperate by sending messages over a communication network. — *H. Bal*

2) A distributed system is one in which the failure of a computer you didn’t even know existed can render your own computer unusable. — *Leslie Lamport*

- Welche Problemaspekte stecken hinter Lamports Charakterisierung?

„Verteiltes System“

- Physisch verteiltes System
  - Compute-Cluster ... Rechnernetz

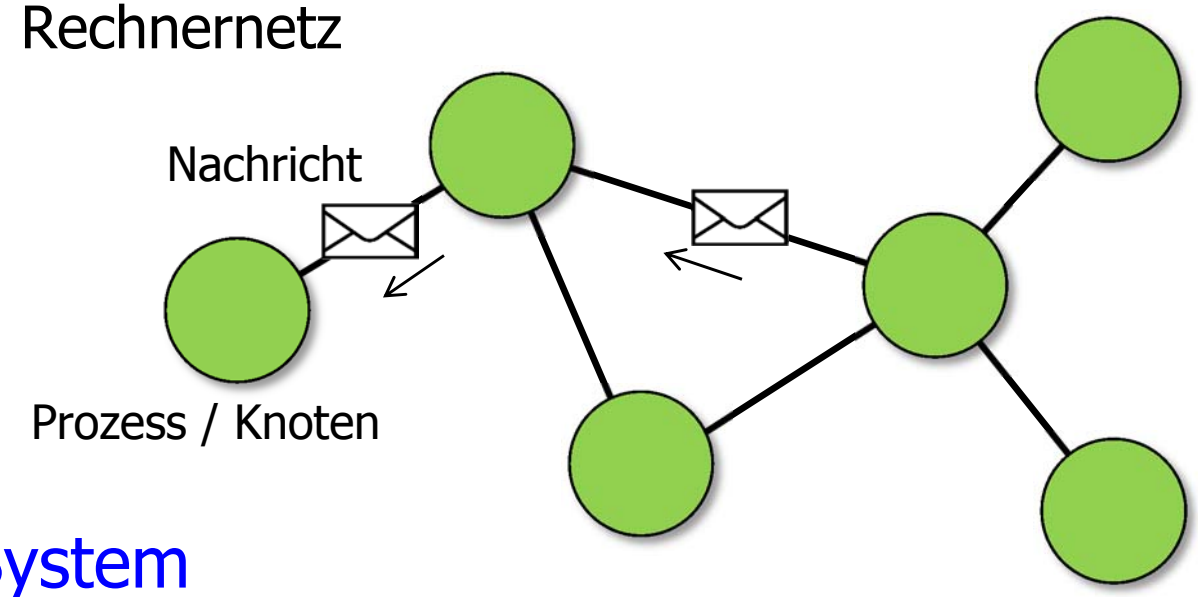

- Logisch verteiltes System
  - Prozesse (Objekte, Agenten)
  - Verteilung des Zustandes (keine globale Sicht)
  - Keine gemeinsame Zeit (globale, genaue Uhr)

Sichten verteilter Systeme (1)

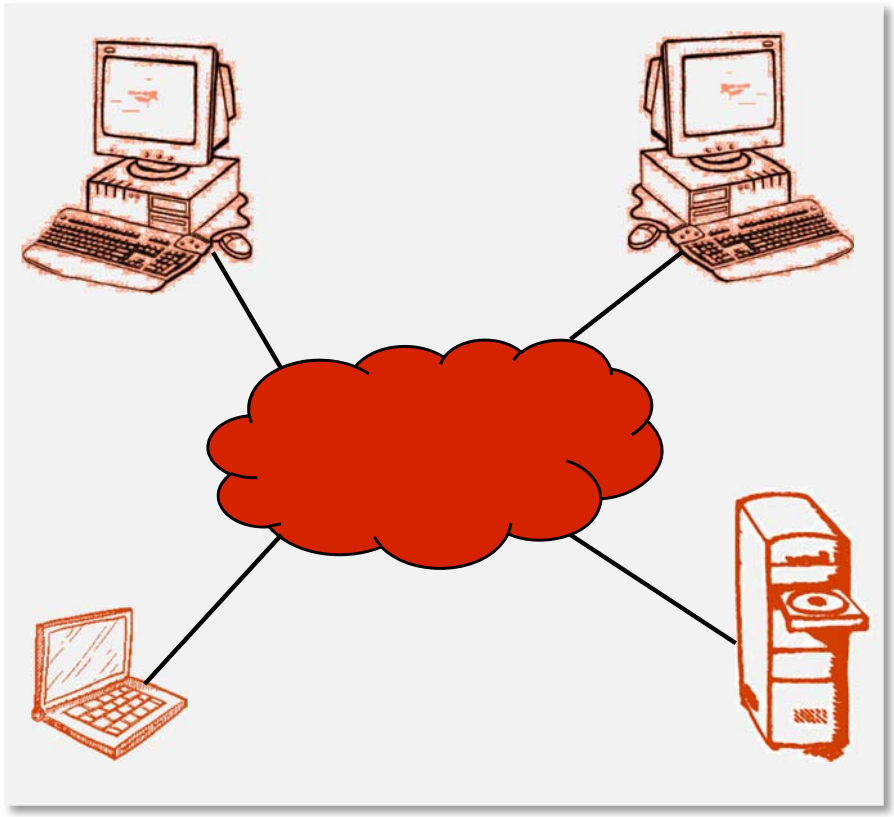

- Computernetz mit "Rechenknoten", z.B.
  - Compute-Cluster
  - Local Area Network
  - Internet
- Relevante Aspekte:
  - Routing, Adressierung,...

Zunehmende Abstraktion 

Sichten verteilter Systeme (2)

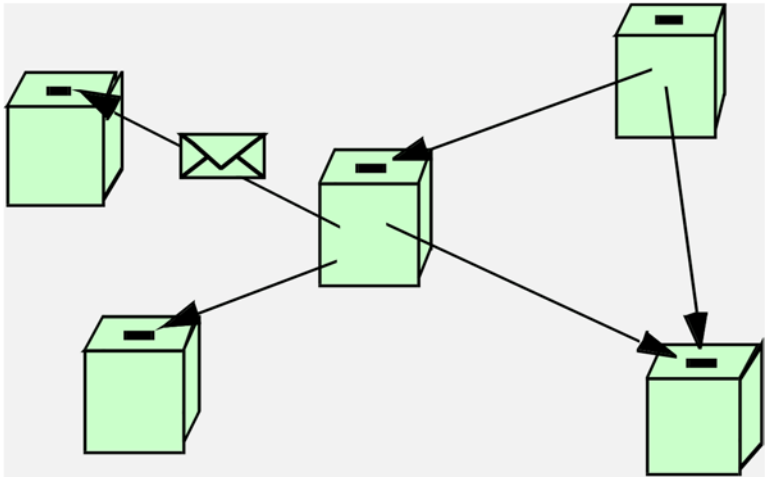

kommunizierende Prozesse,
kooperierende Objekte

- Objekte in Betriebs-systemen, Middleware, Programmiersprachen
- "Programmierersicht"
  - z.B. Client mit API zu Server

Zunehmende Abstraktion 

Sichten verteilter Systeme (3)

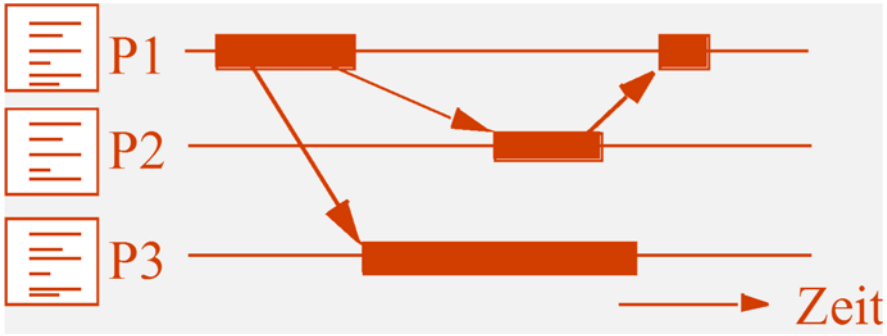

- Algorithmen- und Protokollebene
  - Aktionen, Ereignisfolgen
  - Konsistenz, Korrektheit

- Also: Man kann verteilte Systeme auf verschiedenen Abstraktionsstufen betrachten
- Es sind dabei jeweils unterschiedliche Aspekte relevant und interessant

Die verteilte Welt

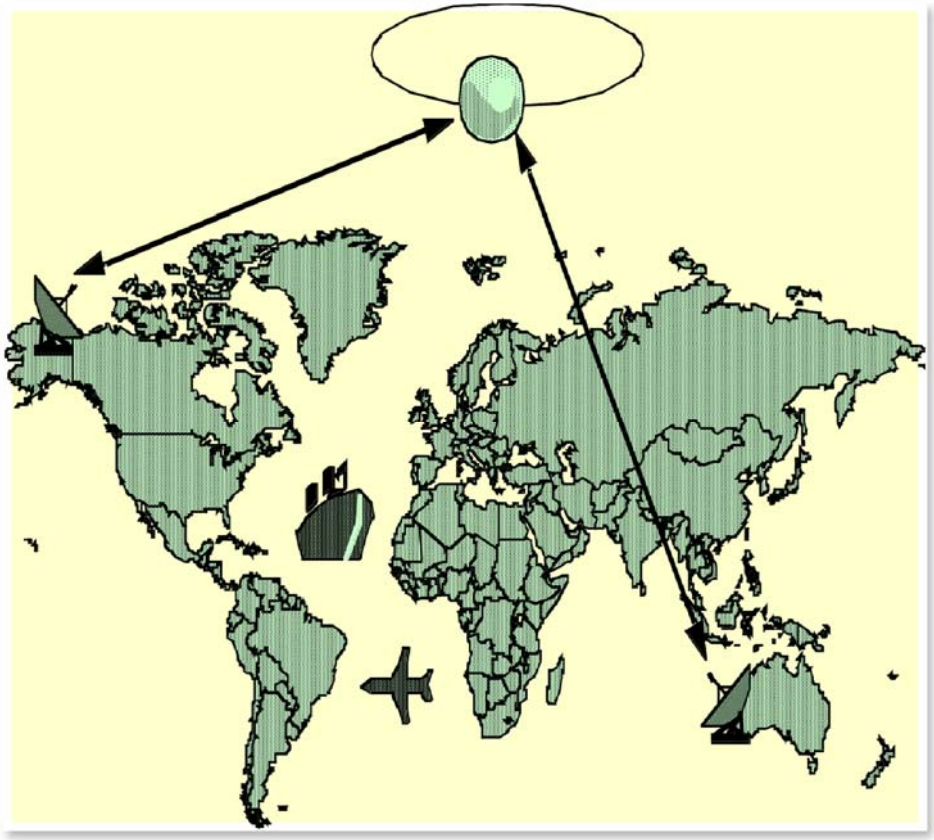

Auch die "reale Welt" ist ein verteiltes System:

- viele gleichzeitige ("parallele") Aktivitäten
- exakte globale Zeit oft nicht gegeben
- keine konsistente Sicht des Gesamtzustandes
- Kooperation durch explizite Kommunikation
- Ursache und Wirkung zeitlich (und räumlich) getrennt

Warum verteilte Systeme?

- Es gibt inhärent geographisch verteilte physische Systeme
  - z.B. Steuerung einer Fabrik, Zweigstellennetz einer Bank (→ Zusammenführen / Verteilen von Information)
- Electronic commerce
  - kooperative Informationsverarbeitung räumlich getrennter Institutionen (z.B. Reisebüros, Kreditkarten,...)
- Mensch-Mensch-Telekommunikation
  - E-Mail, Diskussionsforen, Blogs, digitale soziale Netze, IP-Telefonie,...
- Globalisierung von Diensten
  - Skaleneffekte, Outsourcing,...

Wirtschaftliche Aspekte

- Outsourcing von Diensten, Verlagerung in eine „Cloud", kann günstiger sein als eine lokal-zentralisierte Lösung
- Compute-Cluster manchmal besseres Preis-Leistungs-verhältnis als Supercomputer

Verteilte Systeme als „Verbunde“

- Verteilte Systeme verbinden räumlich (oder logisch) getrennte Komponenten zu einem bestimmten Zweck; die autonomen Komponenten gehen ein Bündnis ein

---

- Systemverbund
  - gemeinsame Nutzung von Betriebsmitteln, Geräten,...
  - einfache inkrementelle Erweiterbarkeit
- Funktionsverbund
  - Kooperation bzgl. Nutzung jeweils spezifischer Geräte- oder Diensteigenschaften
- Lastverbund
  - Zusammenfassung der Kapazitäten
- Datenverbund
  - globale Bereit-stellung von Daten
- Überlebensverbund
  - Redundanz durch Replikation

Historische Entwicklung (1)

- Rechner-zu-Rechner-Kommunikation
  - Zugriff auf entfernte Daten ("Datenfernübertragung", DFÜ)
  - dezentrale Informationsverarbeitung war zunächst ökonomisch nicht sinnvoll (zu teuer, lokal Fachpersonal nötig)
    → Master-Slave-Beziehung (Terminals und "Remote Job Entry")

Häufigkeit des Wortgebrauchs über die Zeit, basierend auf den von Google eingescannten Büchern (Publikationsjahr)

https://books.google.com/ngrams

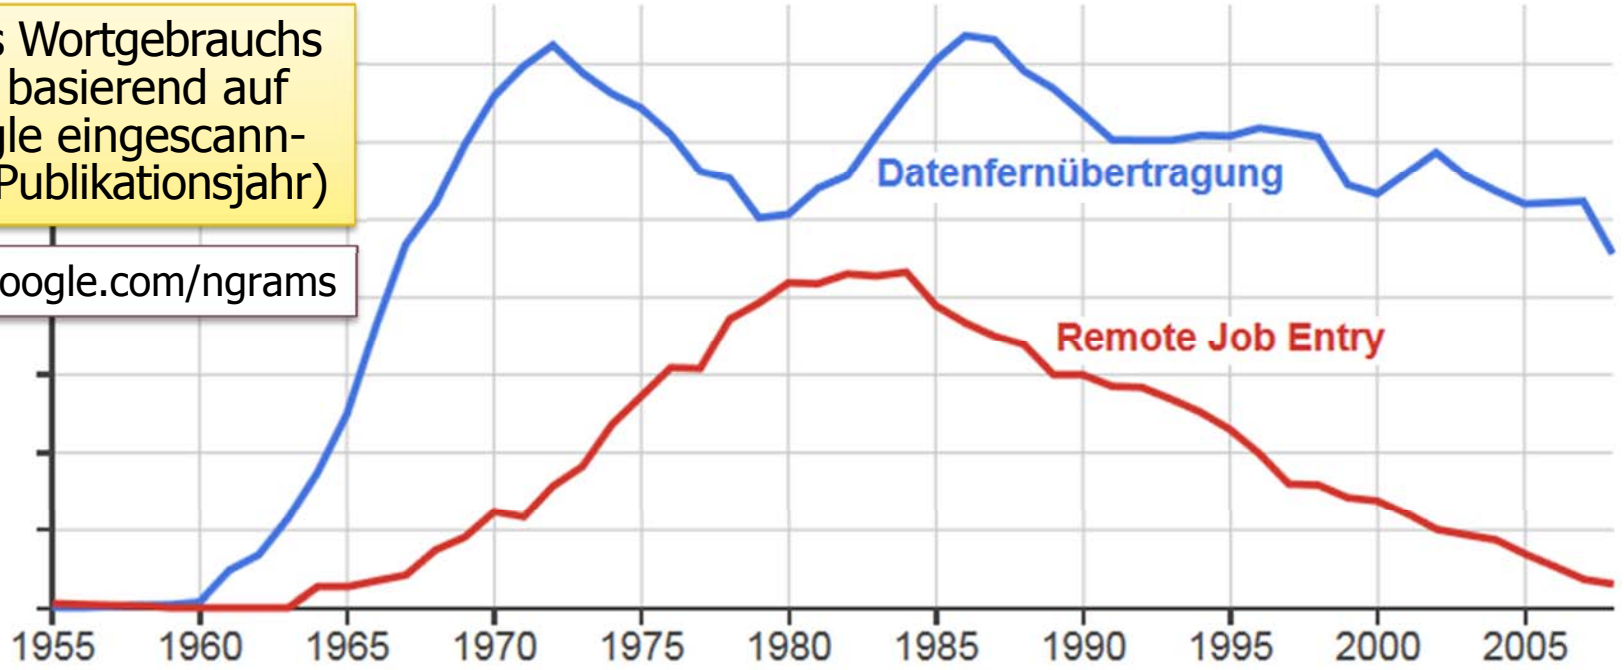

Historische Entwicklung (1)

- Rechner-zu-Rechner-Kommunikation
  - Zugriff auf entfernte Daten (“Datenfernübertragung”, DFÜ)
  - dezentrale Informationsverarbeitung war zunächst ökonomisch nicht sinnvoll (zu teuer, lokal Fachpersonal nötig)
    → Master-Slave-Beziehung (Terminals und “Remote Job Entry”)

- ARPANET (Prototyp des Internet)
  - 1969
  - symmetrische Kooperationsbeziehung (“peer to peer”)
  - file transfer, remote login, E-Mail
  - Internet-Protokollfamilie (TCP/IP,...)

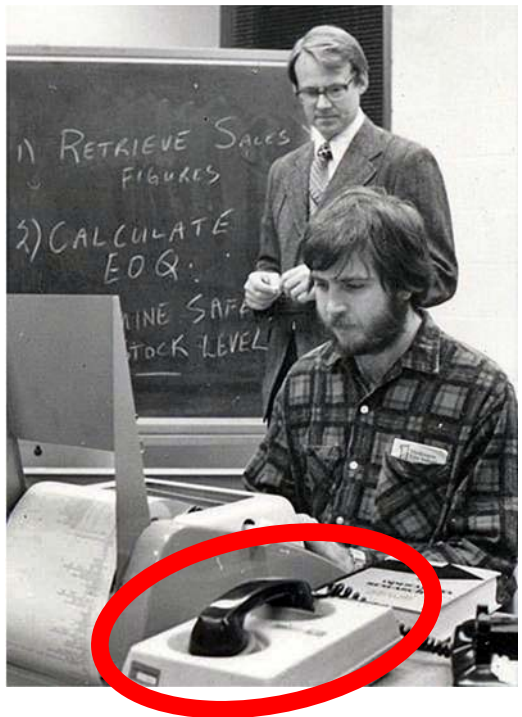

Historische Entwicklung (2)

- Workstation- und PC-Netze *(LAN)*
  - Mehrere bahnbrechende, frühe Ideen bei XEROX-PARC (XEROX Star als erste Workstation, GUI, Desktop-Metapher, 1973: Ethernet, 1976: RPC, 1985: verteilte Dateisysteme,...)
- Kommerzielle Pionierprojekte als Treiber *(WAN)*
  - z.B. Flugreservierungssysteme, Banken, Kreditkarten
- Web / Internet als Plattform
  - für electronic commerce
  - web services
  - neue, darauf aufbauende Dienste
- Mobile Geräte
  - Smartphones etc.; WLAN
- Internet der Dinge

Änderung der Vernetzungsqualität aus historischer Sicht

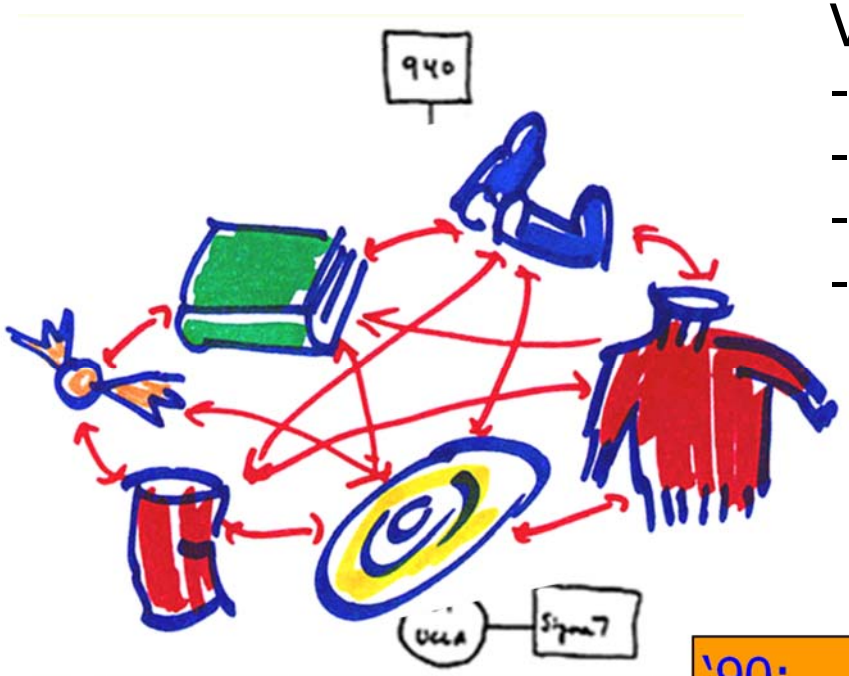

Vernetzung von:
- Computern (ftp)
- Dokumenten (WWW)
- Menschen (soz. Netze)
- Dingen (Internet der Dinge)

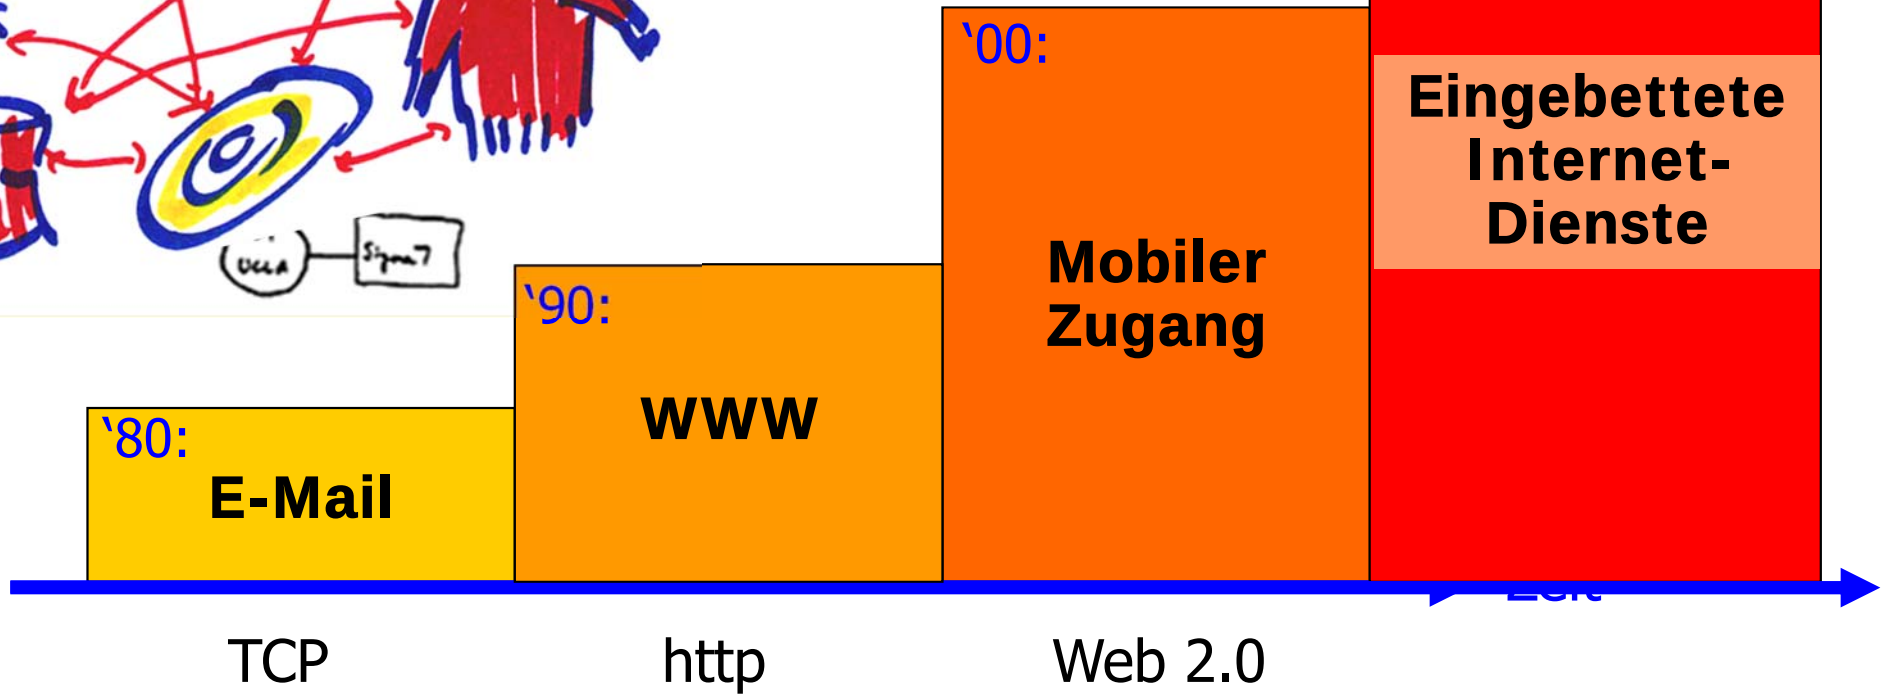

Historie von Konzepten

- Concurrency, Synchronisation
  - war bereits früh ein Thema bei Datenbanken und Betriebssystemen
- Programmiersprachen
  - „kommunizierende" Objekte
- Parallele und verteilte Algorithmen
- Semantik von Kooperation / Kommunikation
  - mathematische Modelle für Verteiltheit (z.B. CCS, Petri-Netze)
- Abstraktionsprinzipien
  - Schichten, Dienstprimitive,...
- Verständnis grundlegender Phänomene der Verteiltheit
  - Konsistenz, Zeit, Zustand,...

Entwicklung "guter" Konzepte, Modelle, Abstraktionen etc. zum Verständnis der Phänomene dauert oft lange (notwendige Ordnung und Sichtung des verfügbaren Gedankenguts)

Diese sind jedoch für eine gute Lösung praktischer Probleme hilfreich, oft sogar entscheidend!

Architekturen

Architekturen verteilter Systeme

- Zu Anfang waren Systeme monolithisch

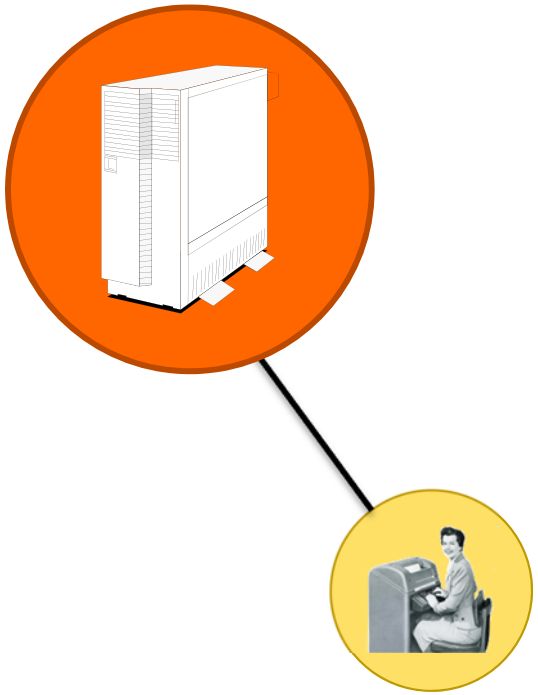

- Nicht verteilt / vernetzt
- Mainframes
- Terminals als angeschlossene „Datensichtgeräte“
  („Datenendgerät“: Fernschreiber
  = „teletype“, abgekürzt „tty“)

Ein Fernschreiber („teletype“)

Teletype, tty

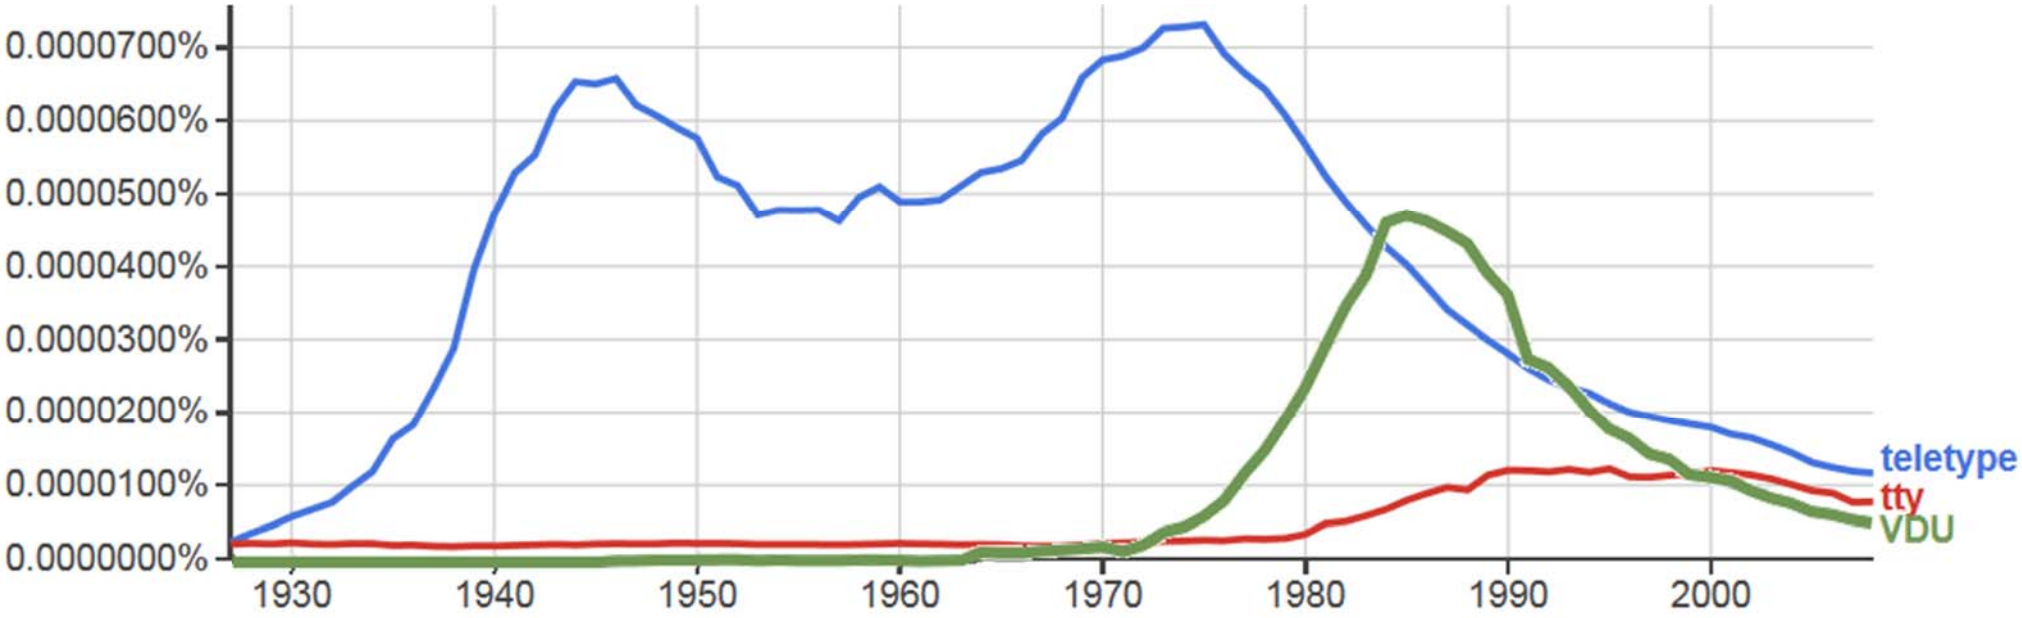

- Die zwei Leben des „teletype“: Telex und Computerterminal
- Ab 1970 abgelöst durch VDU (visual display unit)
- Was löste 15 Jahre später VDUs ab?

VDU ≅ „Datensichtgerät“

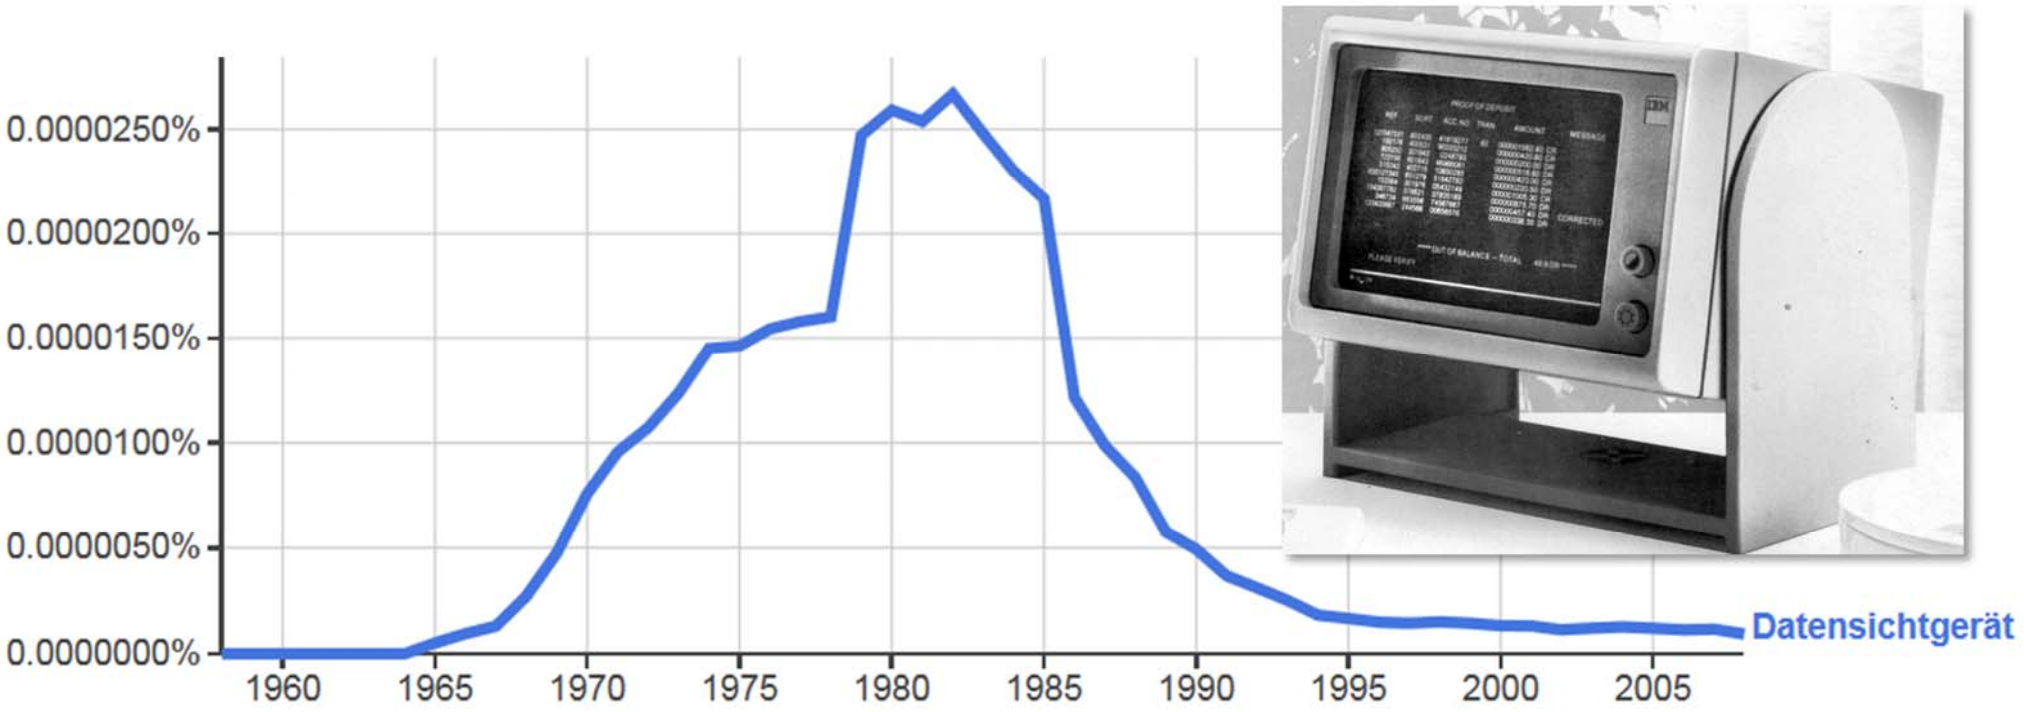

Architekturen verteilter Systeme: Peer-to-Peer

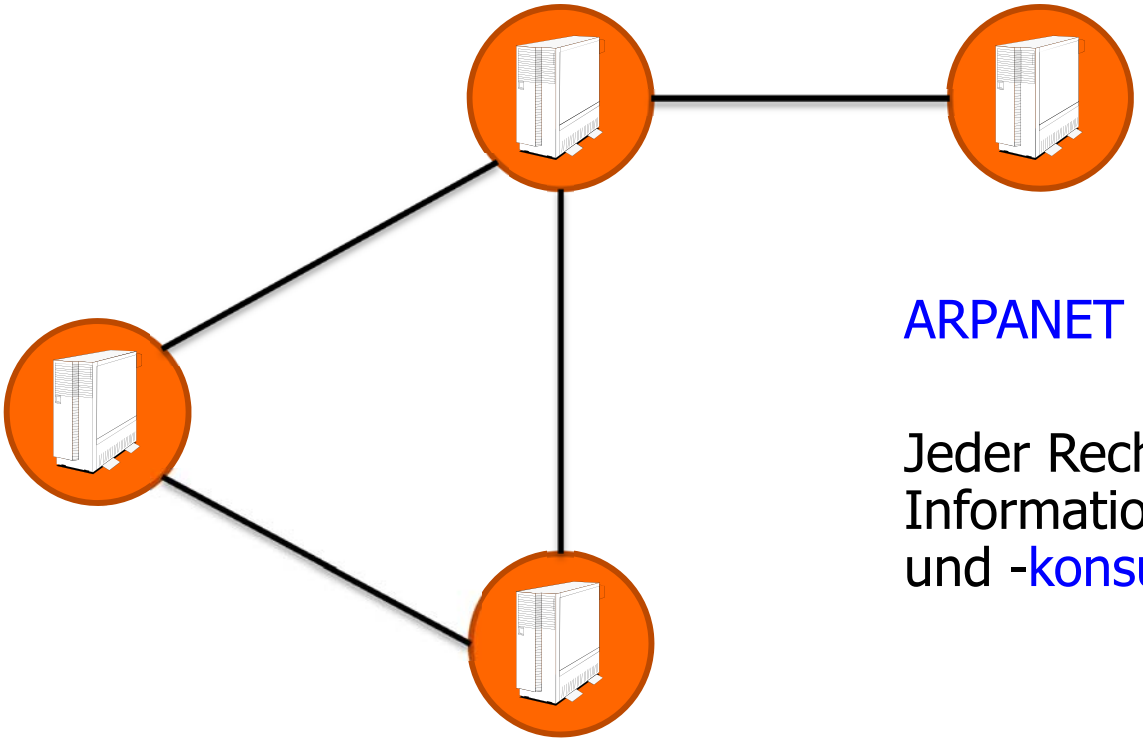

ARPANET 1969

Jeder Rechner ist gleichzeitig Informationsanbieter und -konsument

Architekturen verteilter Systeme: Client-Server

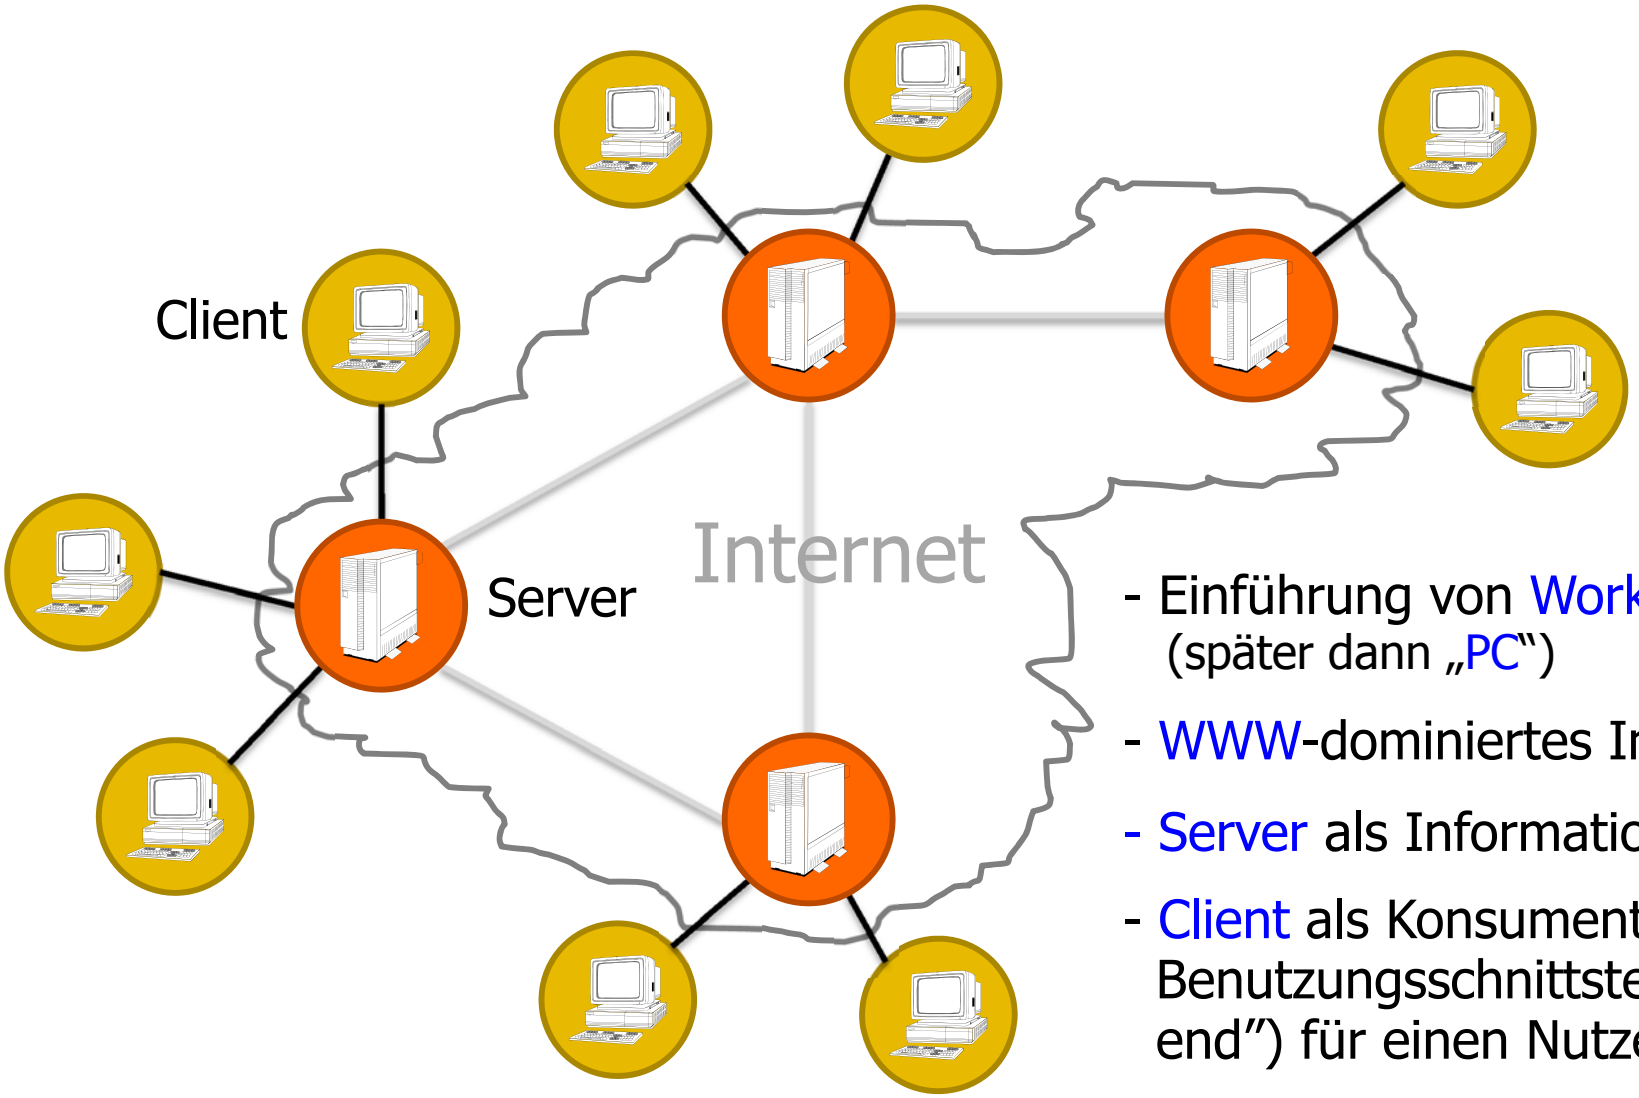

- Einführung von Workstations (später dann „PC“)
- WWW-dominiertes Internet
- Server als Informationsanbieter
- Client als Konsument; gleichzeitig Benutzungsschnittstelle (“front end”) für einen Nutzer

Architekturen verteilter Systeme: Client-Server

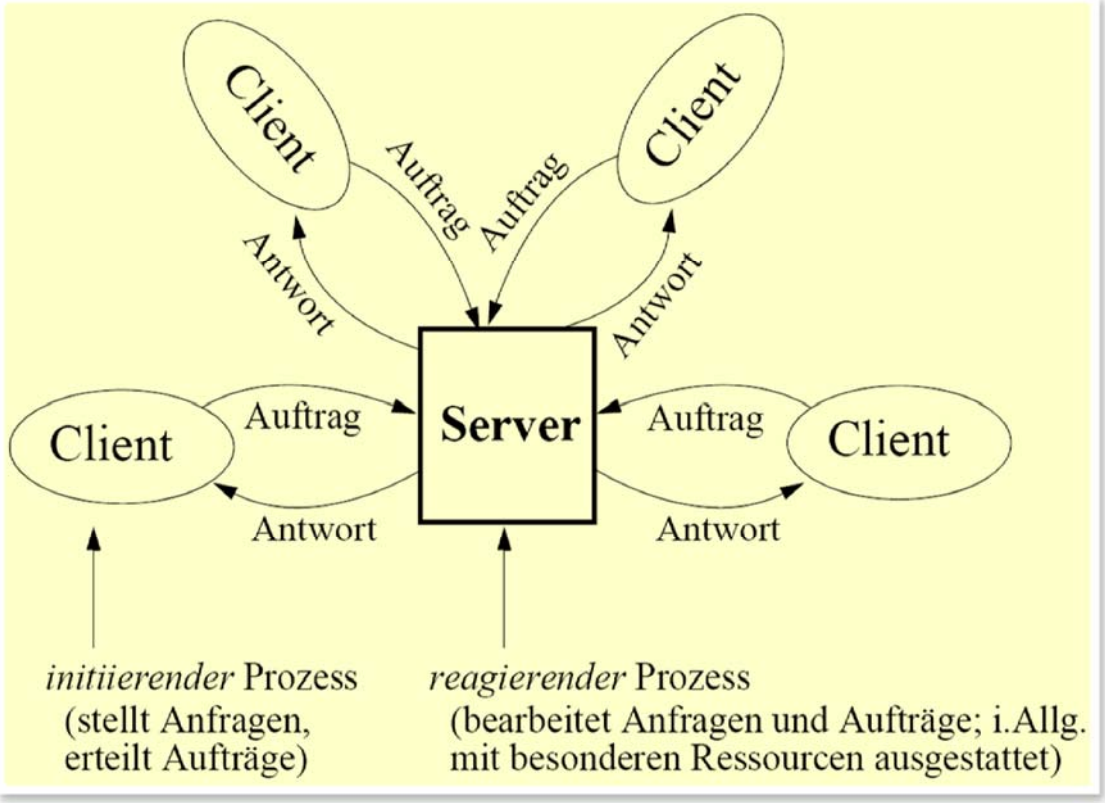

Populär auch wegen des eingängigen Modells

- entspricht Geschäftsvorgängen in unserer Dienstleistungsgesellschaft
- gewohntes Muster → intuitive Struktur, gute Überschaubarkeit

Architekturen verteilter Systeme: Fat- und Thin-Client

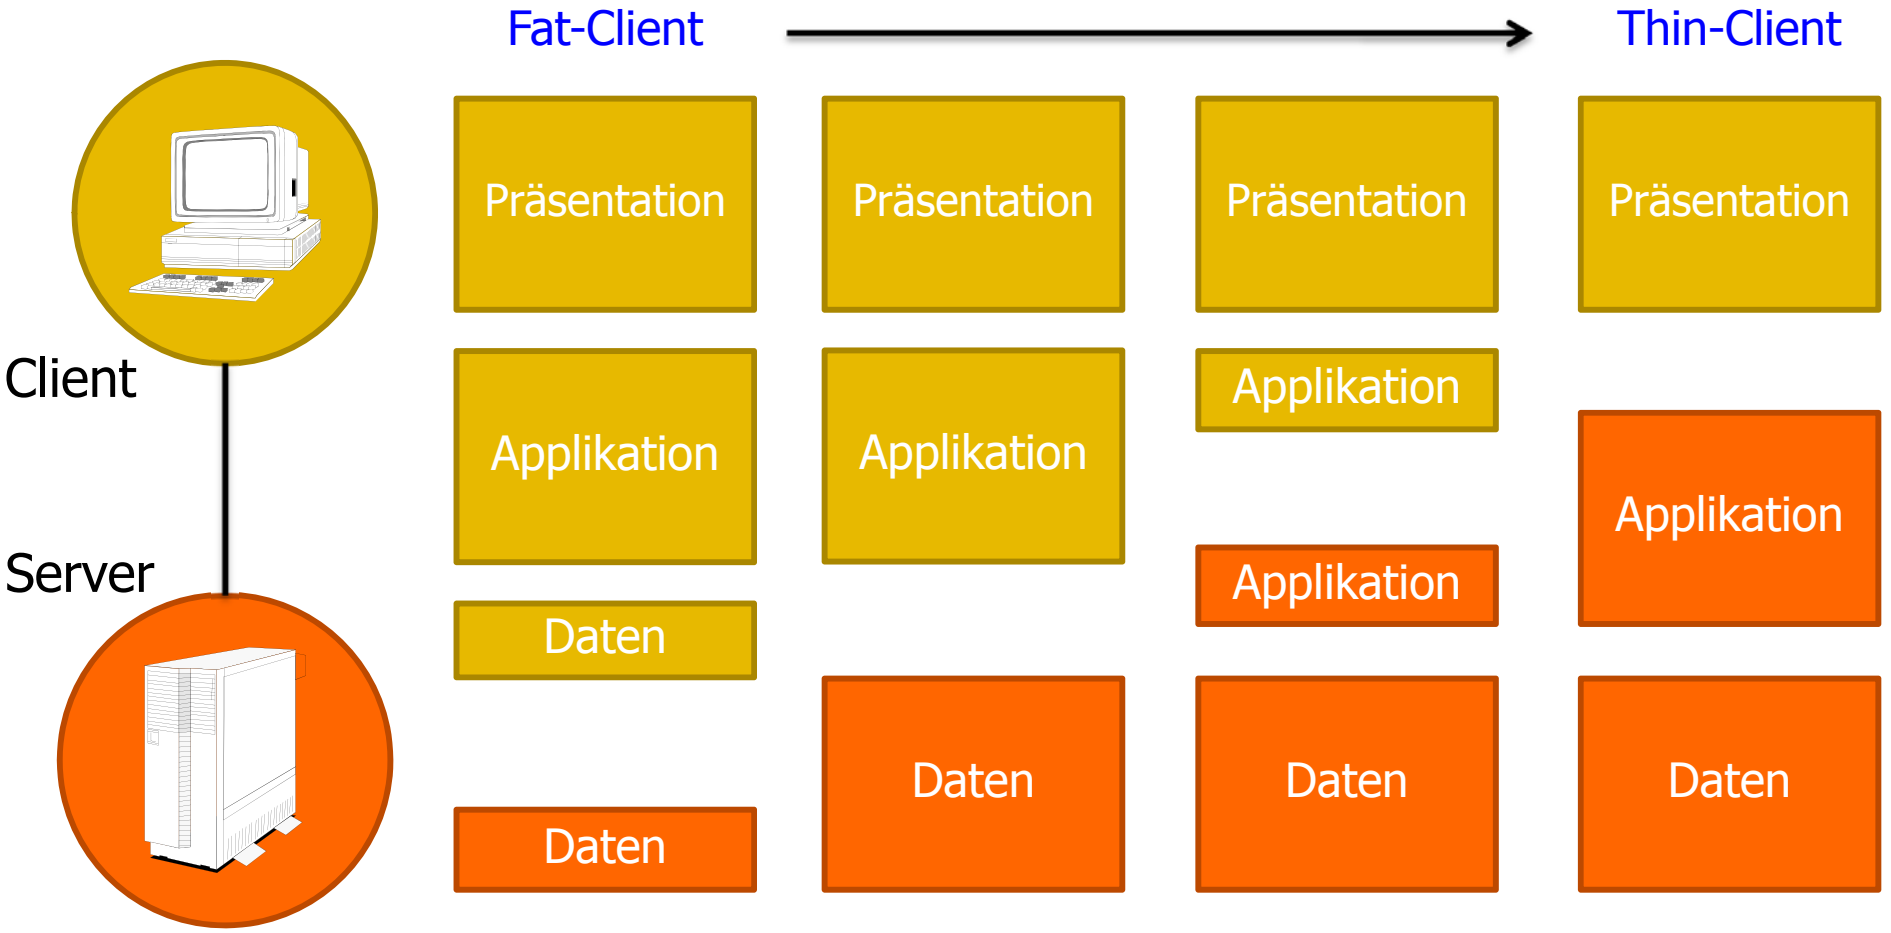

Architekturen verteilter Systeme: 3-Tier

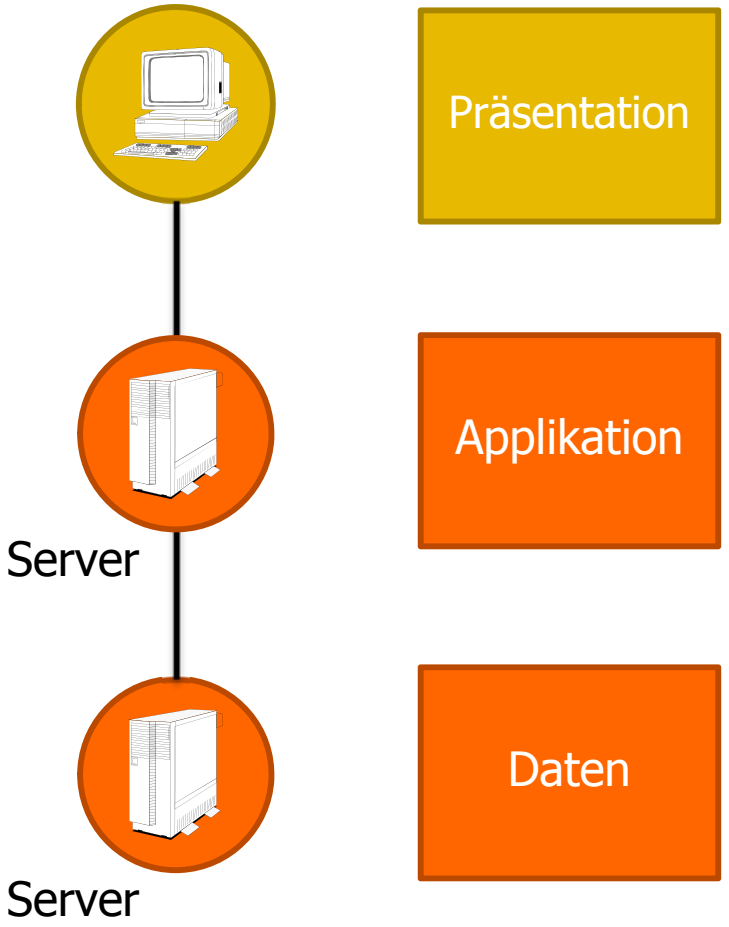

Verarbeitung wird auf mehrere physikalische Einheiten verteilt

- Logische Schichten mit minimierten Abhängigkeiten
- Dedizierte und für den Zweck optimierte Hardware
- Leichtere Wartung
- Einfaches Austauschen

Architekturen verteilter Systeme: Multi-Tier

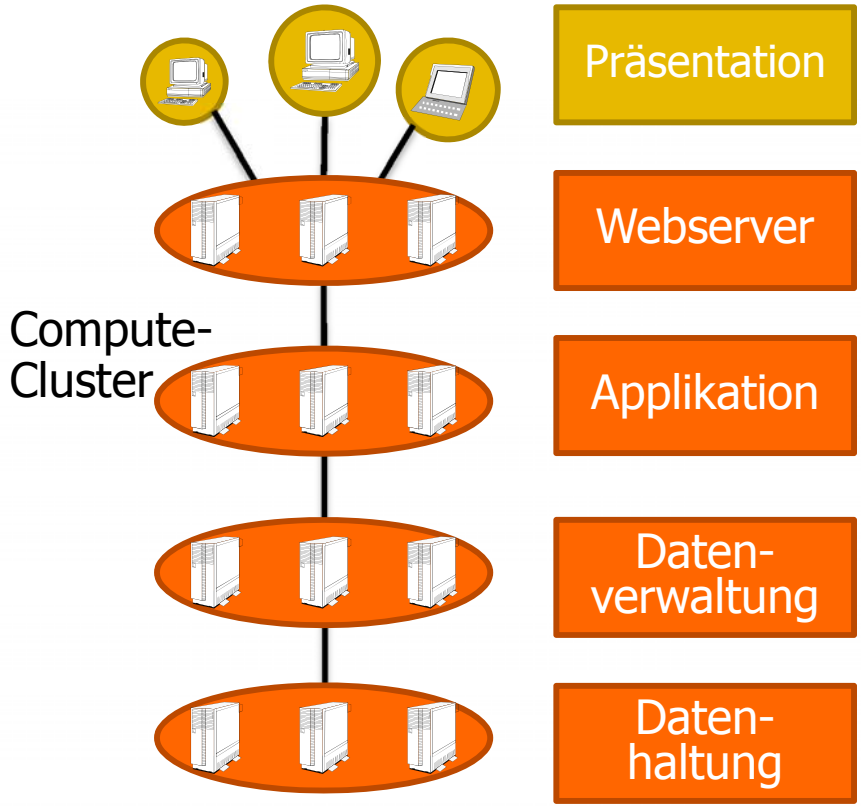

Weitere Schichten sowie mehrere physikalische Einheiten pro Schicht („Compute-Cluster") erhöhen die Skalierbarkeit und Flexibilität

Mehrere Webserver ermöglichen z.B. Lastverteilung

Verteilte Datenbanken in der Datenhaltungsschicht bietet Sicherheit durch Replikation und hohen Durchsatz

Ökonomisch machbar mit zunehmender Verbilligung der Hardware

Architekturen verteilter Systeme: Compute-Cluster

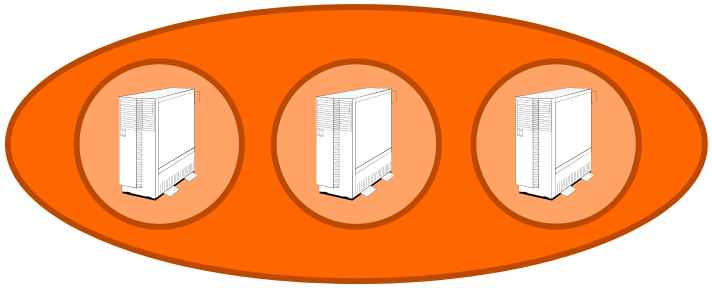

- Vernetzung kompletter Einzelrechner
- Räumlich konzentriert (wenige Meter)
- Sehr schnelles Verbindungsnetz

Es gibt diverse Netztopologien, um die Einzelrechner *(als Knoten in einem Graphen)* miteinander zu verbinden – diese sind unterschiedlich hinsichtlich

- Skalierbarkeit der Topologie
- Routingkomplexität
- Gesamtzahl der Einzelverbindungen
- maximale bzw. durchschnittliche Entfernung zweier Knoten
- Anzahl der Nachbarn eines Knotens
- …

Hat Einfluss auf Kosten und Leistungsfähigkeit eines Systems

Beispiel: Hypercube-Verbindungstopologie

- Würfel der Dimension d
  - Vorteil: einfaches Routing, kurze Weglängen
  - Nachteil: Viele Einzelverbindungen (O(n log n) bei n Knoten)
- Rekursives Konstruktionsprinzip
  - Hypercube der Dimension 0: Einzelrechner
  - Hypercube der Dimension d+1: „*Nimm zwei Würfel der Dimension d und verbinde korrespondierende Ecken*“

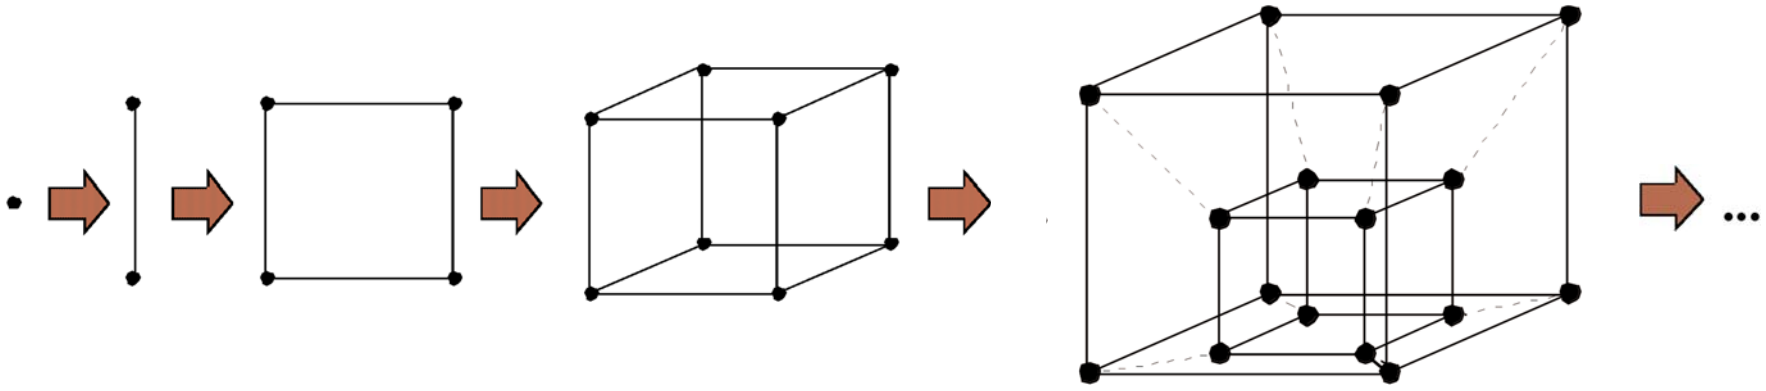

Hypercube-Konstruktion

Hypercube der Dimension d+1: „*Nimm zwei Würfel der Dimension d und verbinde korrespondierende Ecken*“

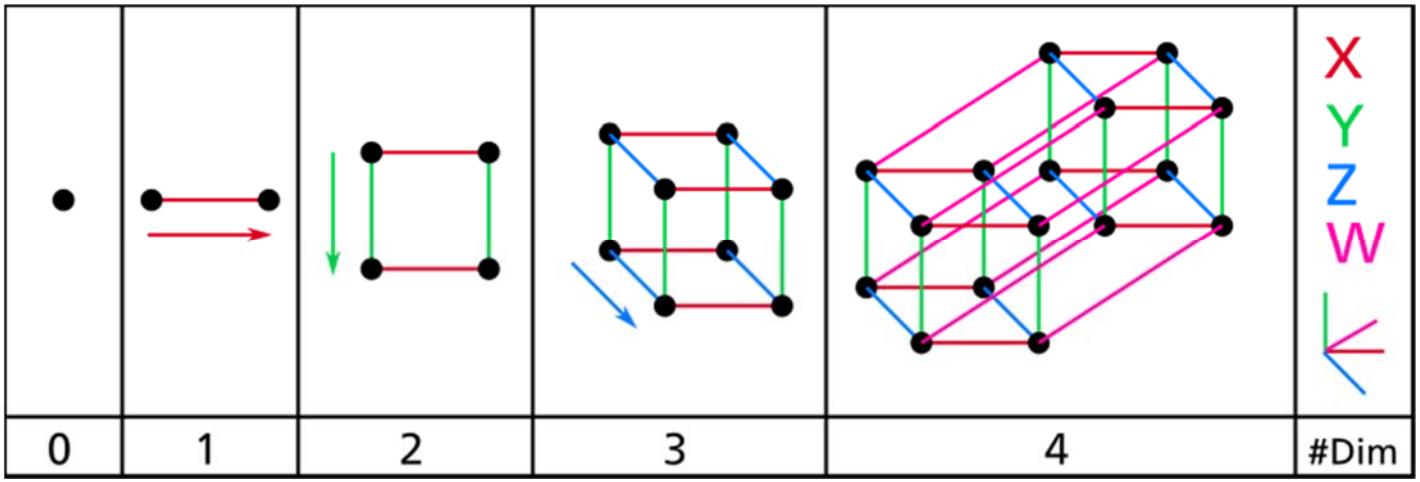

Bildquelle: Wikipedia

The arrows alongside the shapes indicate the direction of extrusion

Hypercube der Dimension 4

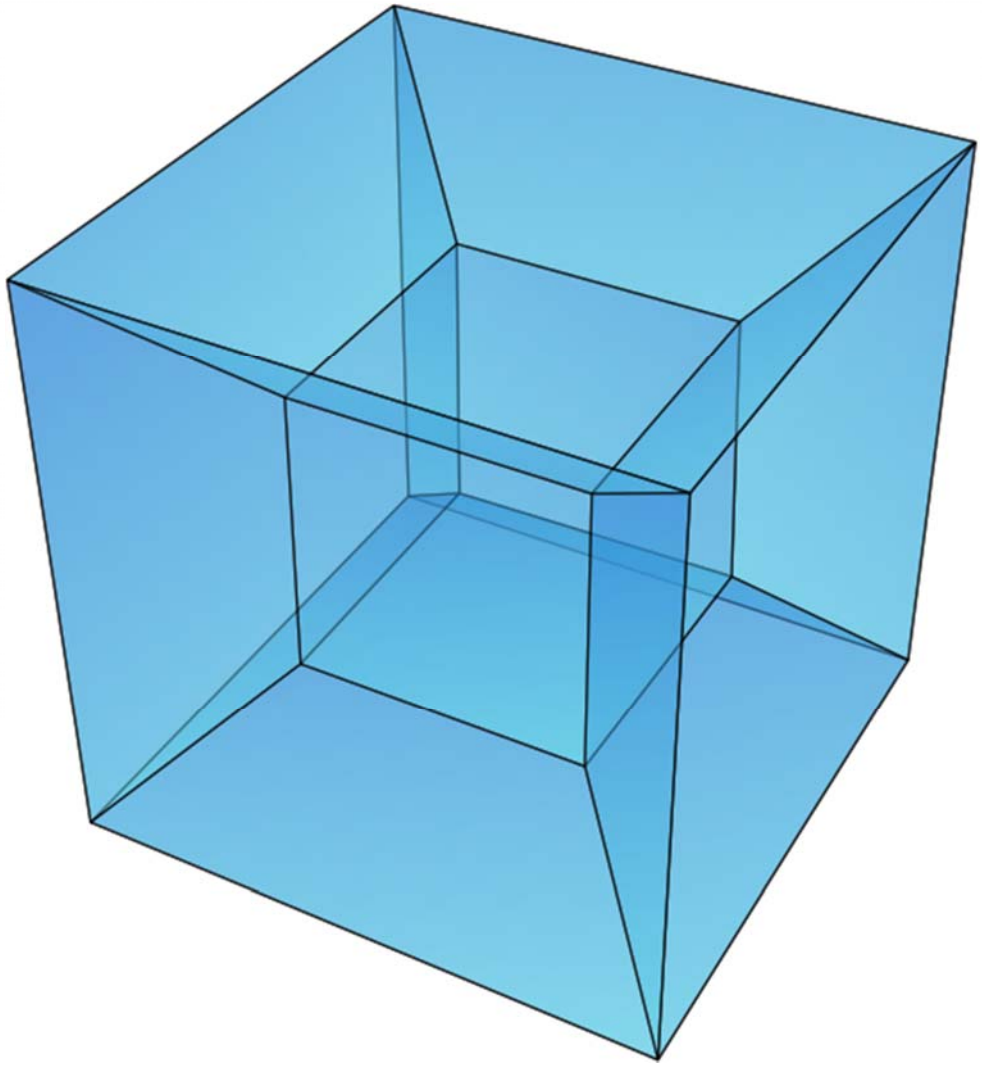

Bildquelle: Wikipedia

Hypercube der Dimension 4

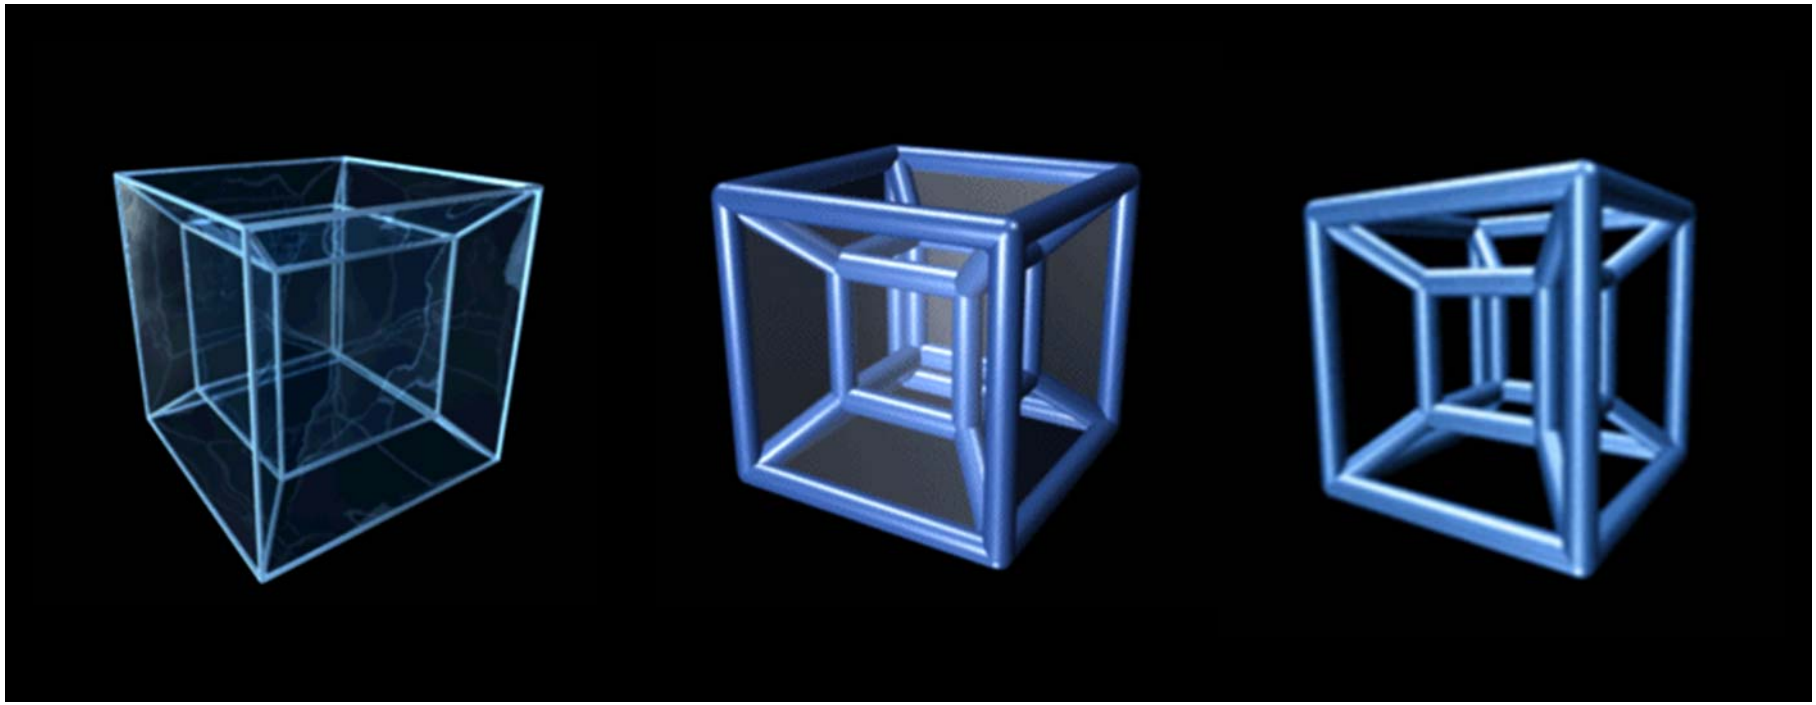

3D-Projektionen rotierender 4D-Hyperwürfel

Bildquellen: Wikipedia

Hypercube der Dimension 4

Richard Medlock: Hyper-Cube #2, Sculpture Key West, 2007, Steel

Routing beim Hypercube

- Knoten systematisch nummerieren (entspr. rekursivem Aufbau)
- Zieladresse bitweise xor mit Absenderadresse
- Wo sich eine "1" findet, in diese Dimension muss gewechselt werden

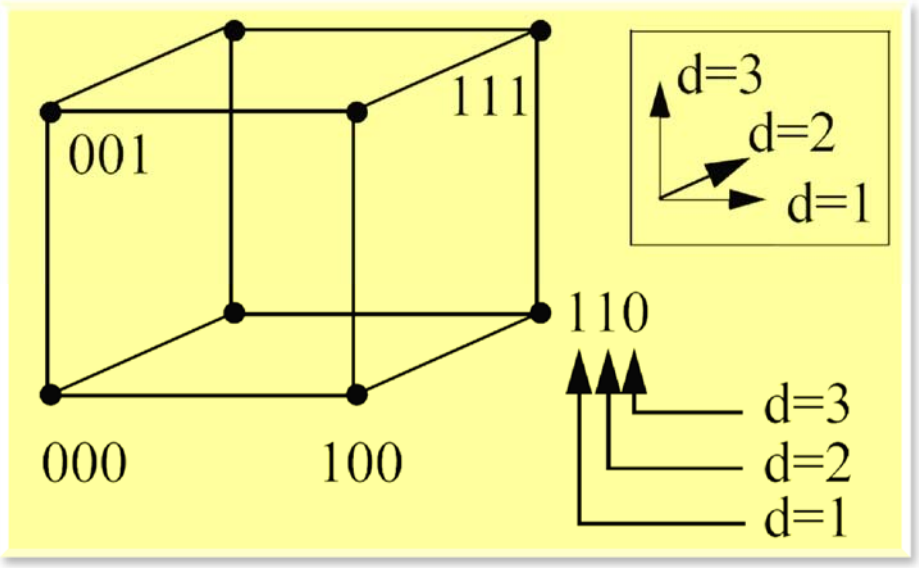

- Maximale Weglänge: d; durchschnittliche Weglänge = d/2
  (Induktionsbeweis als einfache Übung)

Hypercube

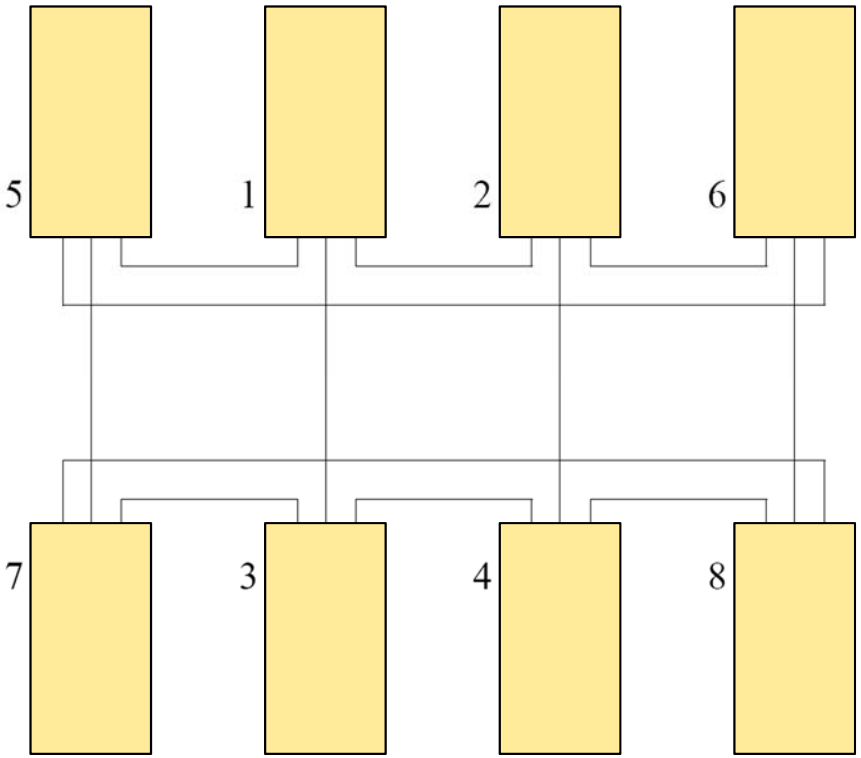

- Dies stellt auch einen Hypercube dar
  - ist nur nicht als Würfel gezeichnet

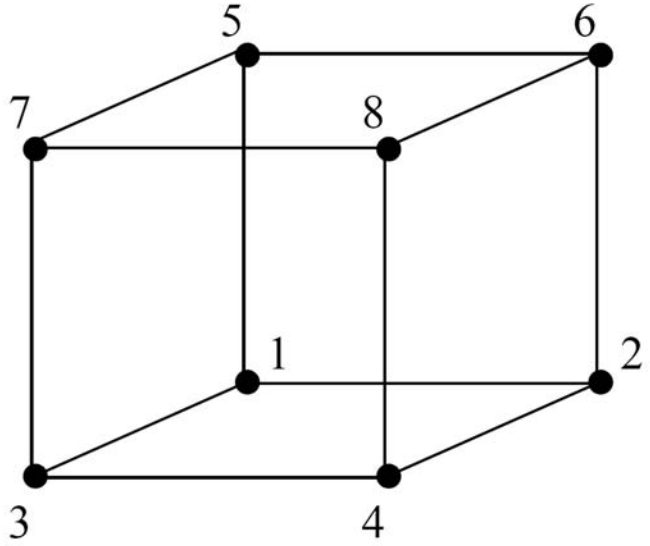

Eine andere Verbindungstopologie: Der d-dimensionale Torus

- Gitter in d Dimensionen mit "wrap-around"

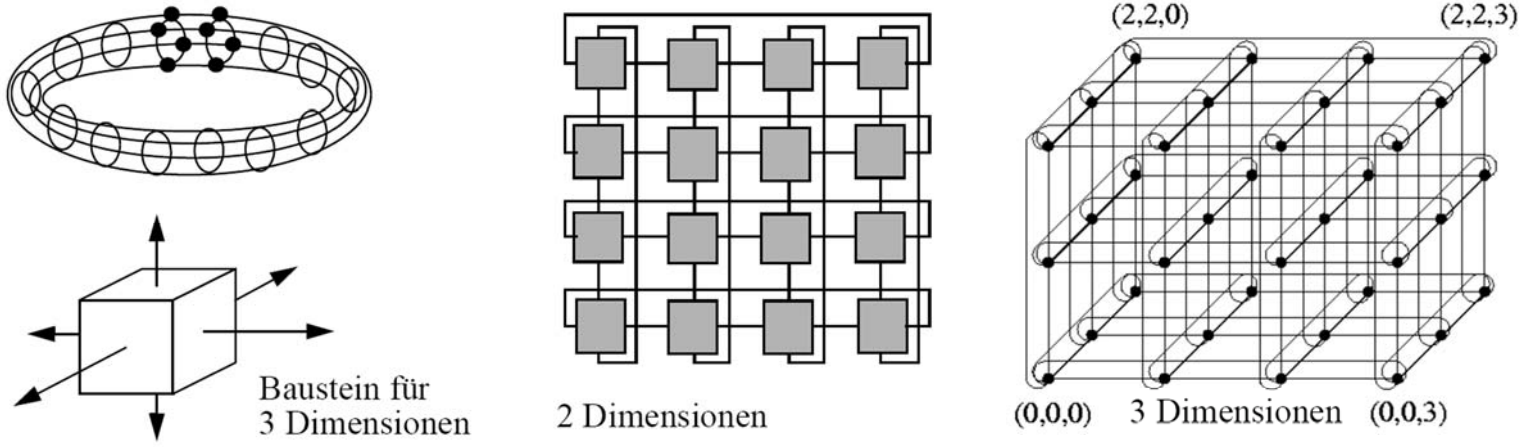

- Rekursives Konstruktionsprinzip: Nimm w_d gleiche Exemplare der Dimension d-1 und verbinde korrespondierende Elemente zu einem Ring
  - Sonderfall einfacher Ring: d = 1
  - Sonderfall Hypercube: d-dimensionaler Torus mit $w_i = 2$ für alle Dimensionen i

Es existieren noch einige andere sinnvolle Verbindungstopologien (auf die wir nicht eingehen)

Parallelrechner ↔ verteiltes System

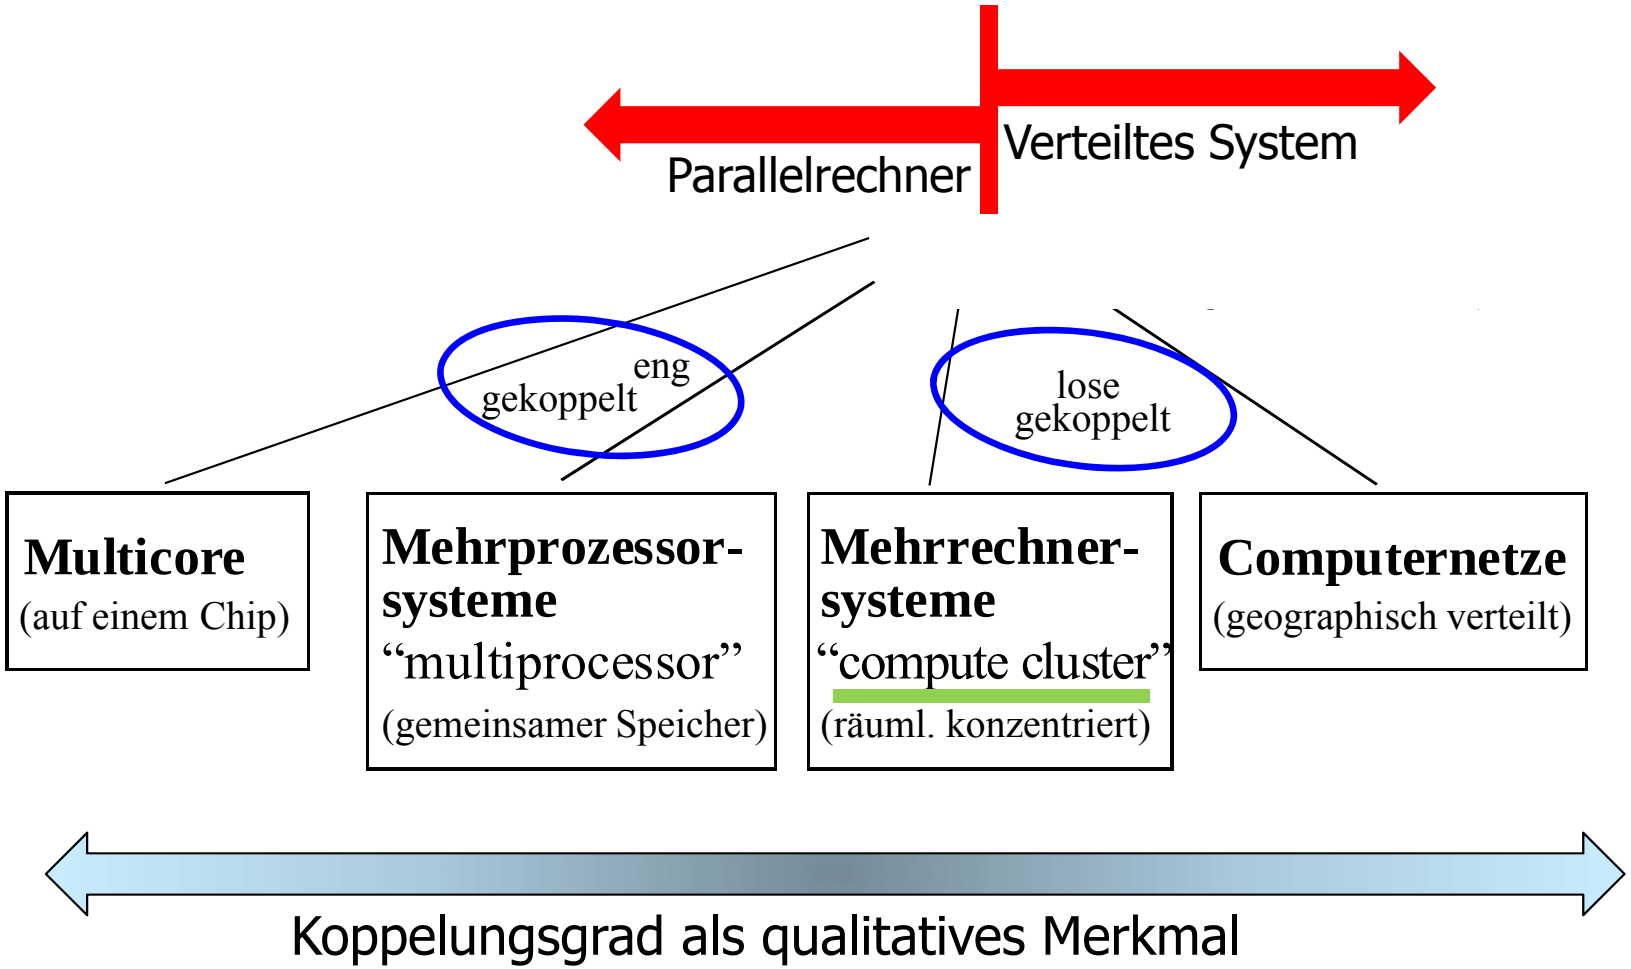

Architekturen verteilter Systeme:
Service-Oriented Architecture (SOA)

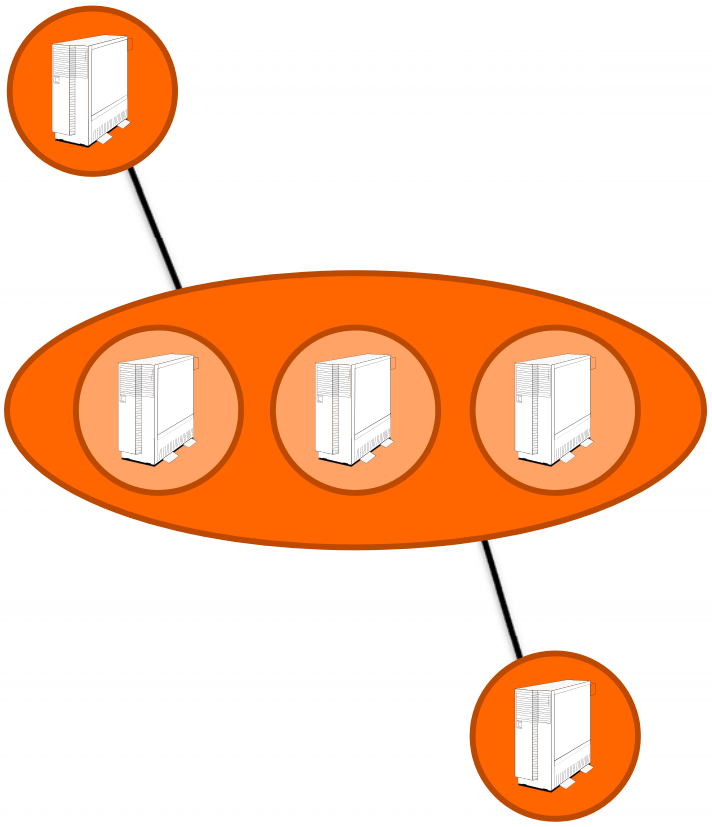

Eine Unterteilung der Applikation in einzelne, unabhängige Abläufe innerhalb eines Geschäftsprozesses erhöht die Flexibilität weiter

Lose Kopplung zwischen Services über Nachrichten und events (statt RPC = Remote Procedure Call)

Services können bei Änderungen der Prozesse einfach neu zusammengestellt werden („development by composition")

Services können auch von externen Anbietern bezogen werden

Oft in Zusammenhang mit Web-Services

Architekturen verteilter Systeme: Cloud-Computing

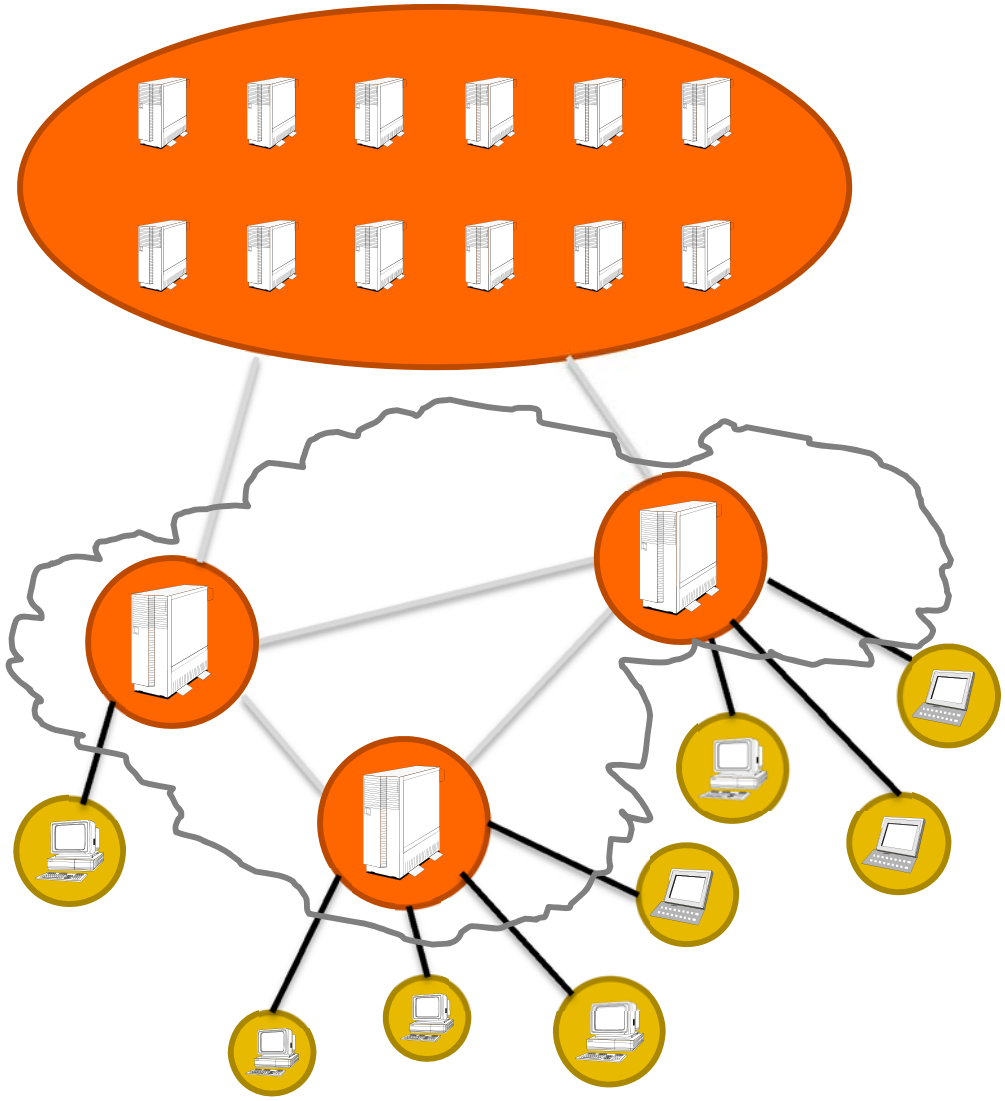

Massive Bündelung der Rechen-leistung an zentraler Stelle

Outsourcen von Applikationen in die Cloud

Internet im Wesentlichen nur noch als Vermittlungsinstanz

Motivierender Trend: Stetige Erhöhung der Bandbreite für Endnutzer

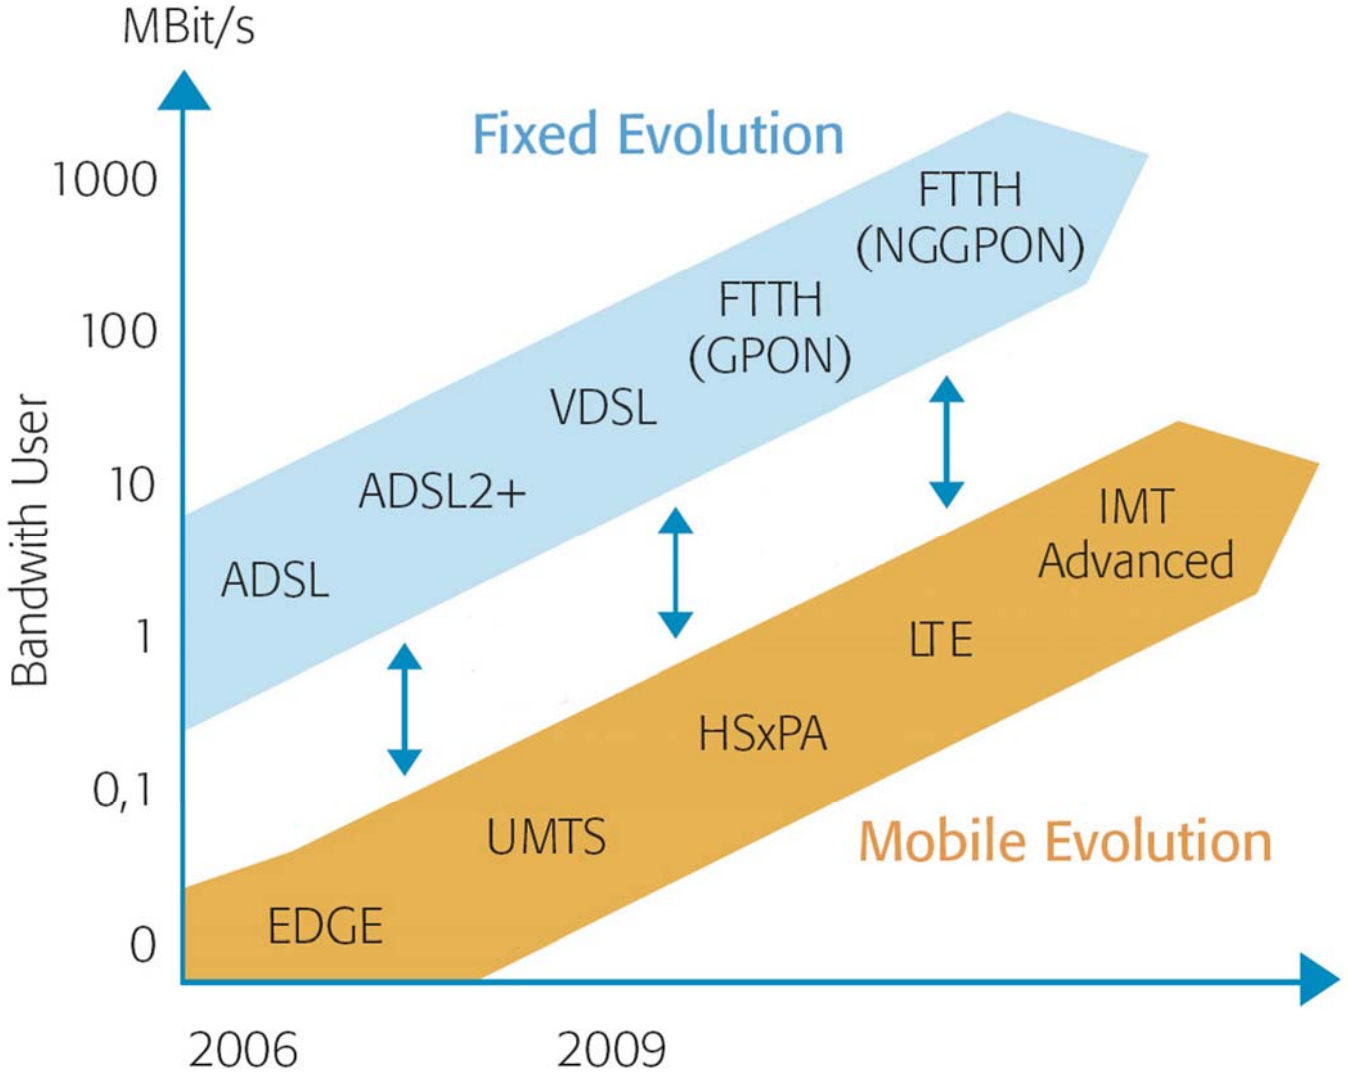

Hochgeschwindigkeit ins Haus

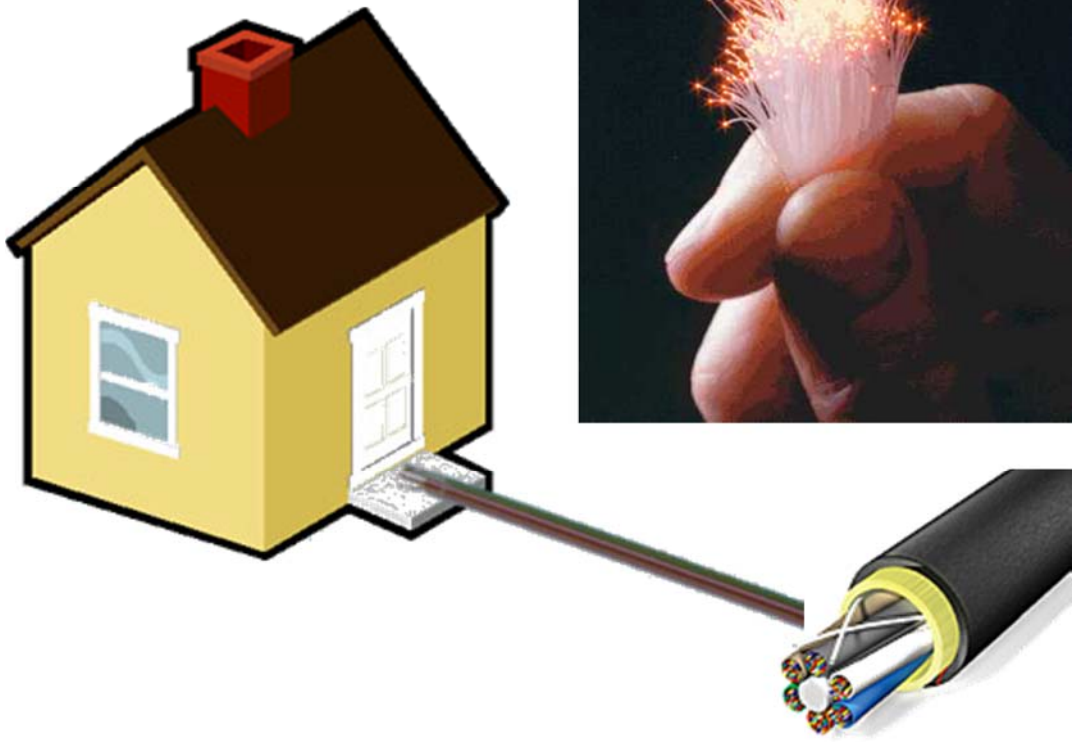

- Konvergenz TV, Telekom-munikation und Internet
- Technologiewechsel → erhebliche Investitionen
  - wirtschaftliche Faktoren und Bedingungen

- Telefondraht → Internet → TV
- TV-Kabel → Telefon → Internet

→ Glasfaser

Hochgeschwindigkeit ins Haus

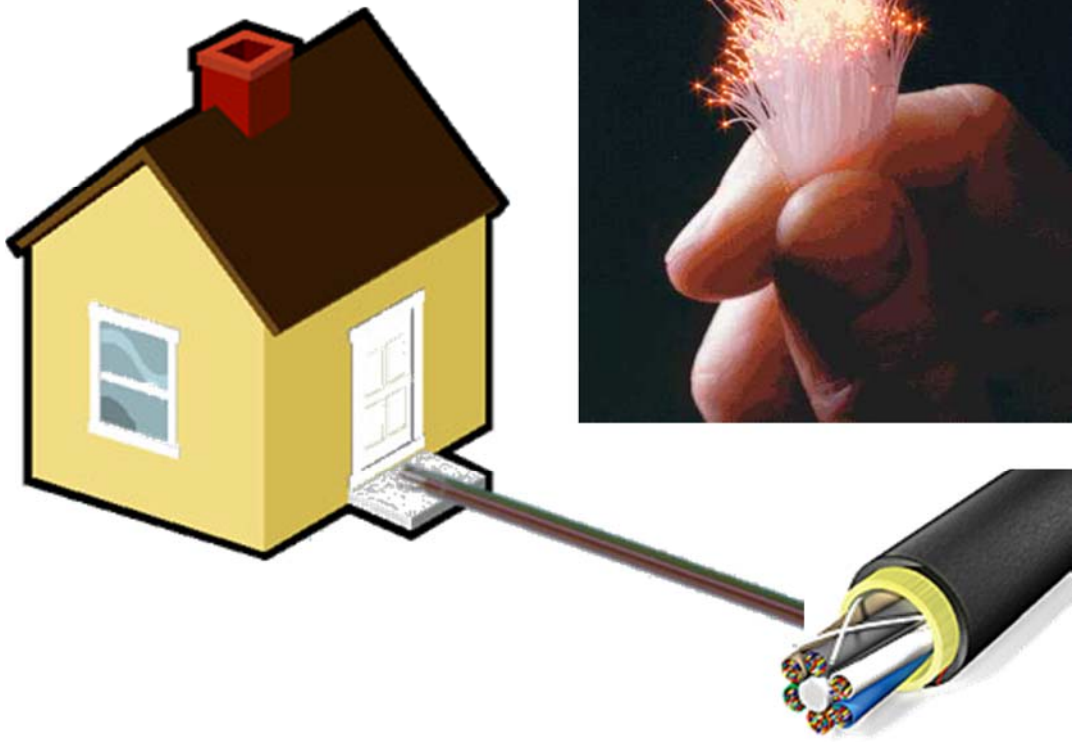

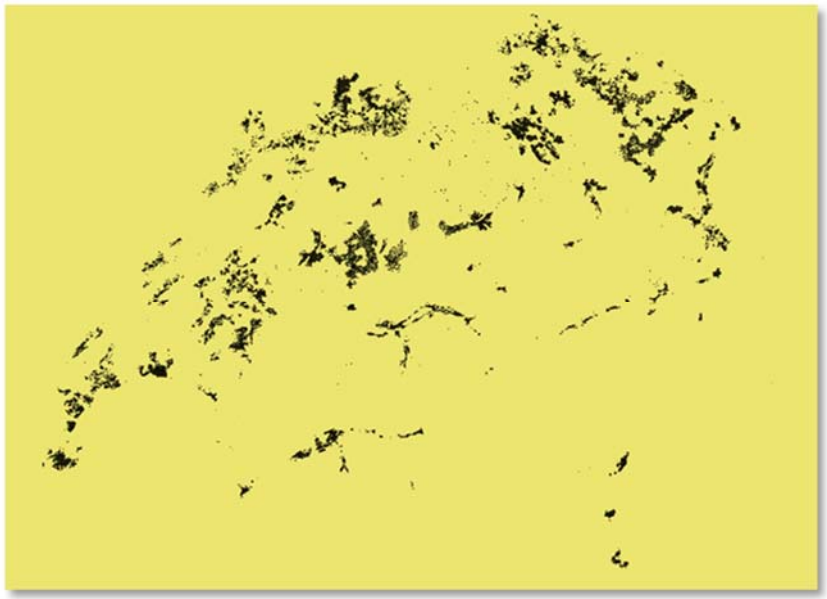

Bildquelle: www.nzz.ch/storytelling/konturen-der-schweiz-die-schweiz-mit-handyantennen-neu-gezeichnet-ld.117913

- Telefondraht → Internet → TV
- TV-Kabel → Telefon → Internet

} → Glasfaser

Cloud-Computing ...für Privatnutzer

Vorteile für Nutzer:

- von überall zugreifbar
- keine Datensicherung
- keine Softwarepflege

Kein PC, sondern billiges Web-Terminal, Smartphone etc.

Wie Wasserleitungen einst den eigenen Brunnen überflüssig machten…

Cloud-Computing

Voraussetzungen?

- Überall Breitband (fest & mobil)
- Netz-Verlässlichkeit (Versorgungssicherheit, Datenschutz,…)
- Wirtschaftlichkeit

Cloud-Computing

Plattformen:

- Wer betreibt sie? Wo?
- Wer verdient daran?
- Wer bestimmt?
- Wer kontrolliert?
- Welche Nationen profitieren davon?

Beispiel: Google-Datenzentren

- Jedes Datenzentrum hat 10 000 – 100 000 Computer
- Kostet über 500 Mio $ (Bau, Infrastruktur, Computer)
- Verbraucht 50 – 100 MW Energie (Strom, Kühlung)
- Neben Google weitere (Amazon, Microsoft, Ebay, Facebook,…)

Google Data Center Groningen

Google Data Center Columbia River

The Dalles, OR, Columbia River

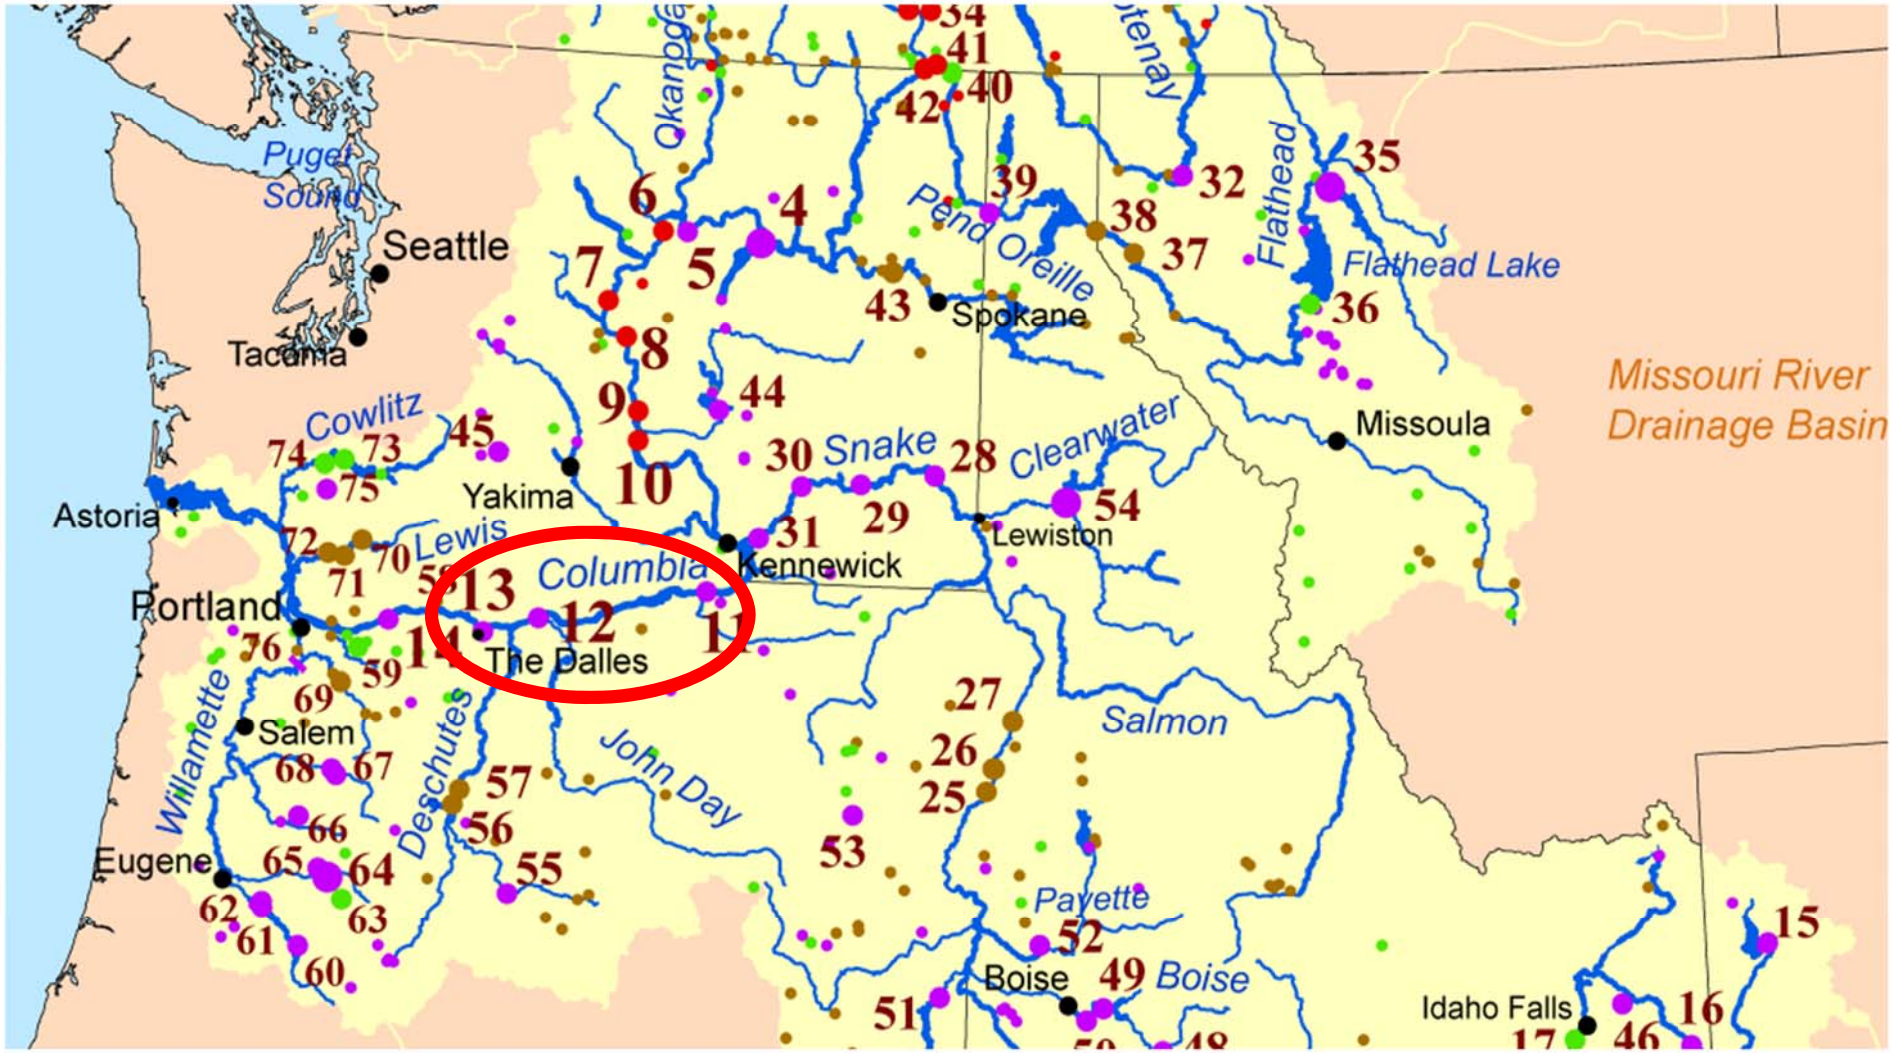

Google Data Center Columbia River

Energiezufuhr : 115 kV / 13.8 kV

Nahes Kraftwerk: Dalles Dam Power Station, Columbia River

The Chronicle, March 1, 2007 –
PUD to seek vote on coal power

Coal will provide most affordable, reliable future power, say supporters of the plan.

As demand for electricity in The Dalles soars, and federal hydropower supplies near their limit, Northern Wasco County PUD plans to ask voters May 15 for permission to buy power from two separate coal-fueled electrical plants soon to be built.

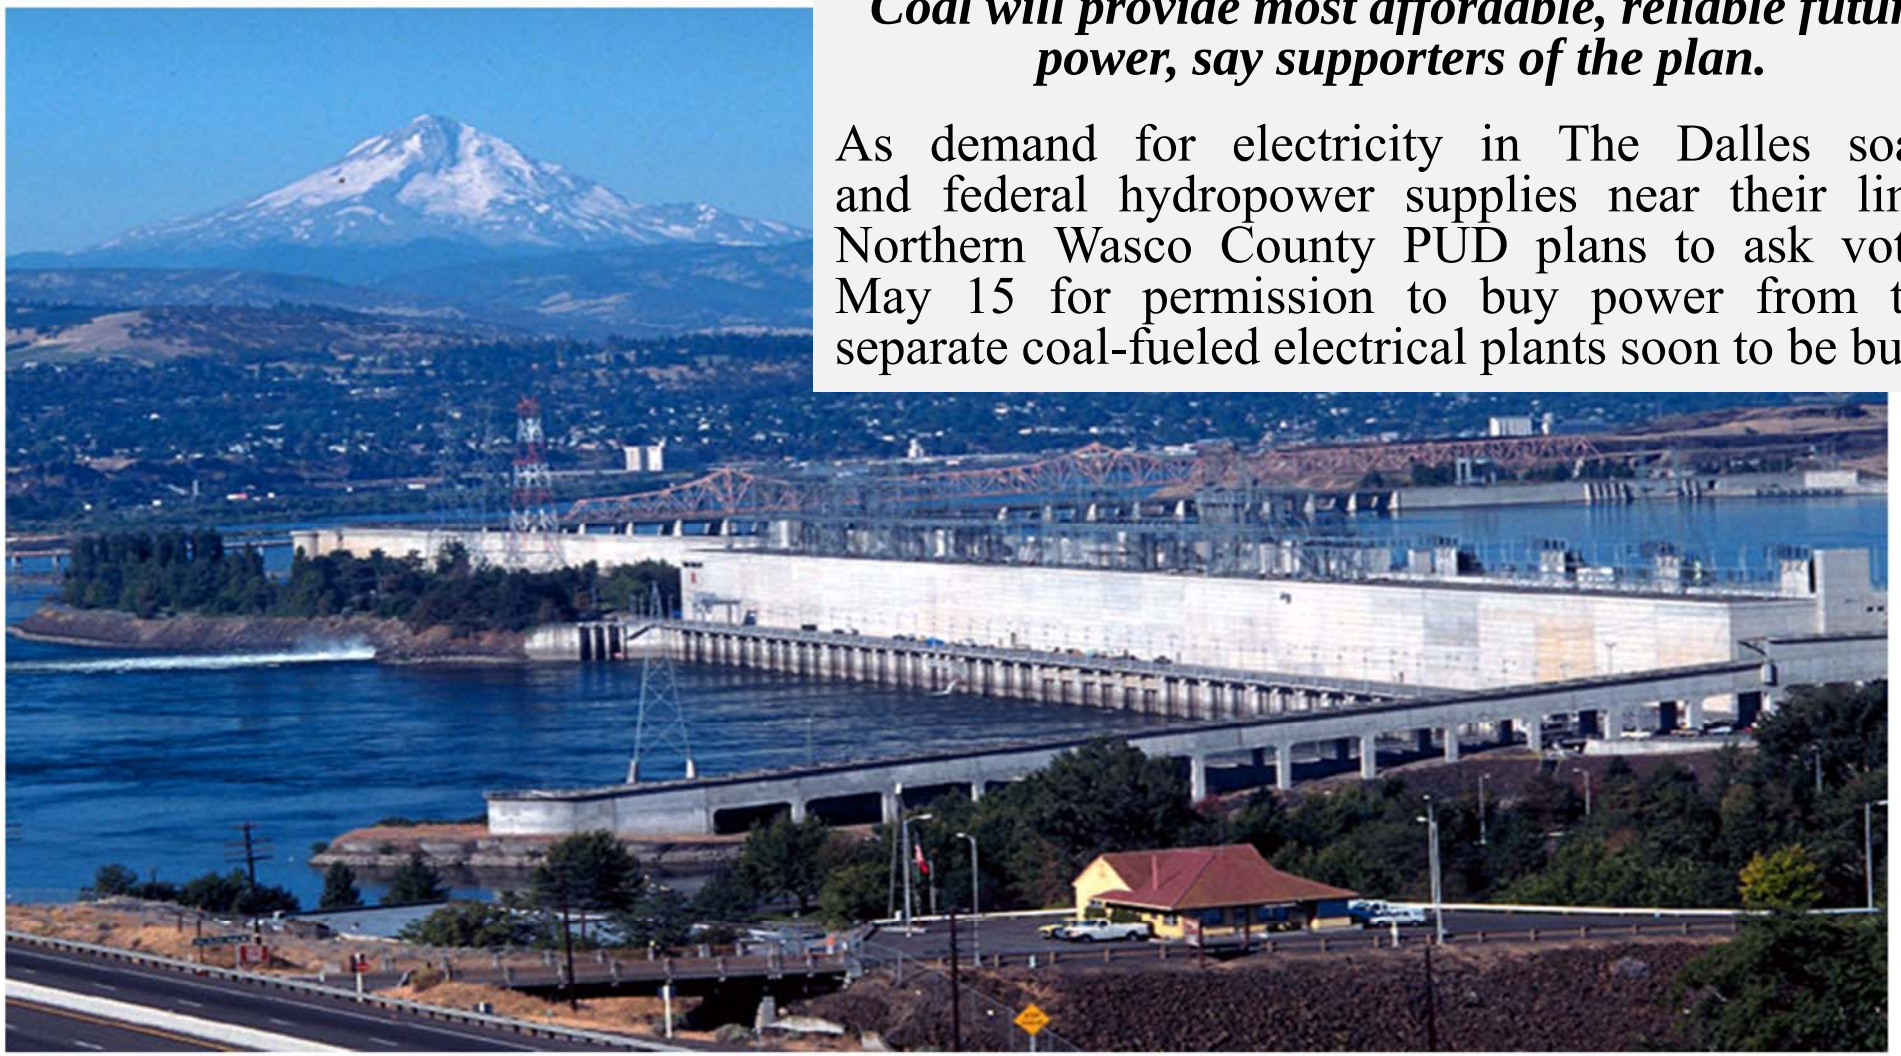

NSA Data Center Bluffdale, Utah

Innenansicht eines Cloud-Zentrums

- Effizient wie Fabriken
  - Produkt: Internet-Dienste
- Kostenvorteil durch Skaleneffekt
  - Faktor 5 – 7 gegenüber traditionellen „kleinen" Rechenzentren
- Angebot nicht benötigter Leistung auf einem Spot-Markt

Das hat sich zu einem wesentlichen Geschäft entwickelt!

Zukünftige Container-Datenzentren

- Hunderte von Containern aus je einigen tausend Compute-Servern
  - mit Anschlüssen für Strom und Kühlung
- Nahe an Kraftwerken
  - Transport von Daten billiger als Strom

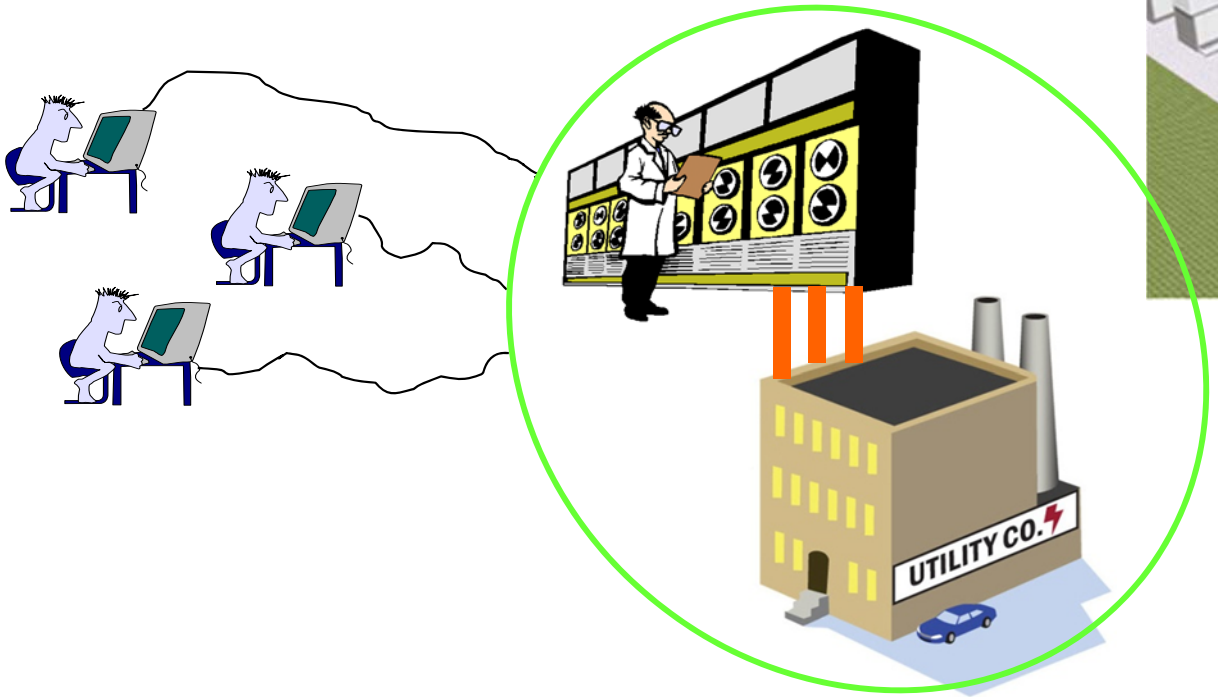

Cloud-Computing für die Industrie und Wirtschaft

- Spontanes Outsourcen von IT inklusive Geschäftsprozesse
  - Datenverarbeitung als Commodity
  - Software und Datenspeicher als Service
- Keine Bindung von Eigenkapital
  - Kosten nach „Verbrauch“
- Elastizität: Sofortiges Hinzufügen weiterer Ressourcen bei Bedarf
  - virtualisierte Hardware

Architekturen verteilter Systeme: Zusammenfassung

- Peer-to-Peer
- Client-Server (Fat-Client vs. Thin Client)
- 3-Tier
- Multi-Tier
- Service-Oriented Architecture (SOA)
- Compute-Cluster
- Cloud-Computing

Charakteristika
&
Phänomene

Charakteristika und Problem-aspekte verteilter Systeme

- Räumliche Separation und Autonomie der Komponenten führen (relativ zu zentralen Systemen) zu neuen Problemen:
  - partielles Fehlverhalten möglich (statt totaler "Absturz")
  - fehlender globaler Zustand und exakt synchronisierte Zeit
  - mögliche Inkonsistenzen (z.B. zwischen Datei und Verzeichnis / Index)
- Typischerweise Heterogenität in Hard- und Software
- Hohe Komplexität
- Sicherheit (Vertraulichkeit, Authentizität, Integrität, Verfügbarkeit,...)
  - notwendiger als in isolierten Einzelsystemen
  - aber schwieriger zu gewährleisten da mehr Angriffspunkte

Gegenmittel?

- Gute Werkzeuge ("Tools") und Methoden
  - z.B. Frameworks und Middleware als Software-Infrastruktur
- Abstraktion als Mittel zur Beherrschung von Komplexität
  - z.B. Schichten (Kapselung, virtuelle Maschinen) oder
  - Modularisierung (z.B. Services)
- Adäquate Modelle, Algorithmen, Konzepte
  - zur Beherrschung der Phänomene rund um die Verteiltheit

- Ziel der Vorlesung
  - Verständnis der grundlegenden Phänomene
  - Kenntnis von geeigneten Konzepte und Methoden

Einige konzeptionelle Probleme und Phänomene verteilter Systeme

1) Schnappschussproblem
2) Phantom-Deadlocks
3) Uhrensynchronisation
4) Kausaltreue Beobachtungen
5) Geheimnisvereinbarung über unsichere Kanäle

Zu Deadlocks siehe auch Vorlesung «Paralleles Programmieren»

Zur Geheimnisvereinbarung siehe auch Vorlesung «Diskrete Mathematik» und «Information Security»

- Dies sind einige einfach zu erläuternde Probleme und Phänomene – es gibt allerdings noch viel mehr und viel komplexere Probleme konzeptioneller wie praktischer Art

  (Manches davon wird allerdings nicht hier, sondern in anderen Vorlesungen, z.B. "Verteilte Algorithmen", eingehender behandelt)

Ein erstes Beispiel: Wie viel Geld ist in Umlauf?

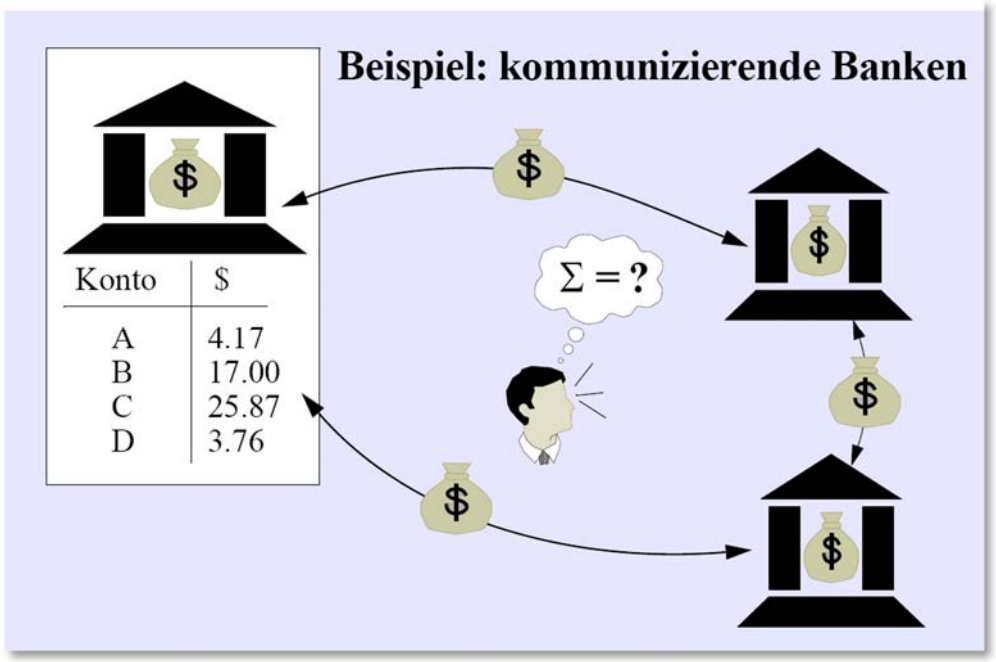

- Hier: konstante Geldmenge
- Ständige Transfers zwischen den Banken
- Niemand hat eine globale Sicht
- Es gibt keine gemeinsame Zeit ("Stichtag")
- Anwendung: z.B. verteilte Datenbank-Sicherungspunkte

➔ Schnappschussproblem

Ein zweites Beispiel: Das Deadlock-Problem

Ein zweites Beispiel: Das Deadlock-Problem

Phantom-Deadlocks

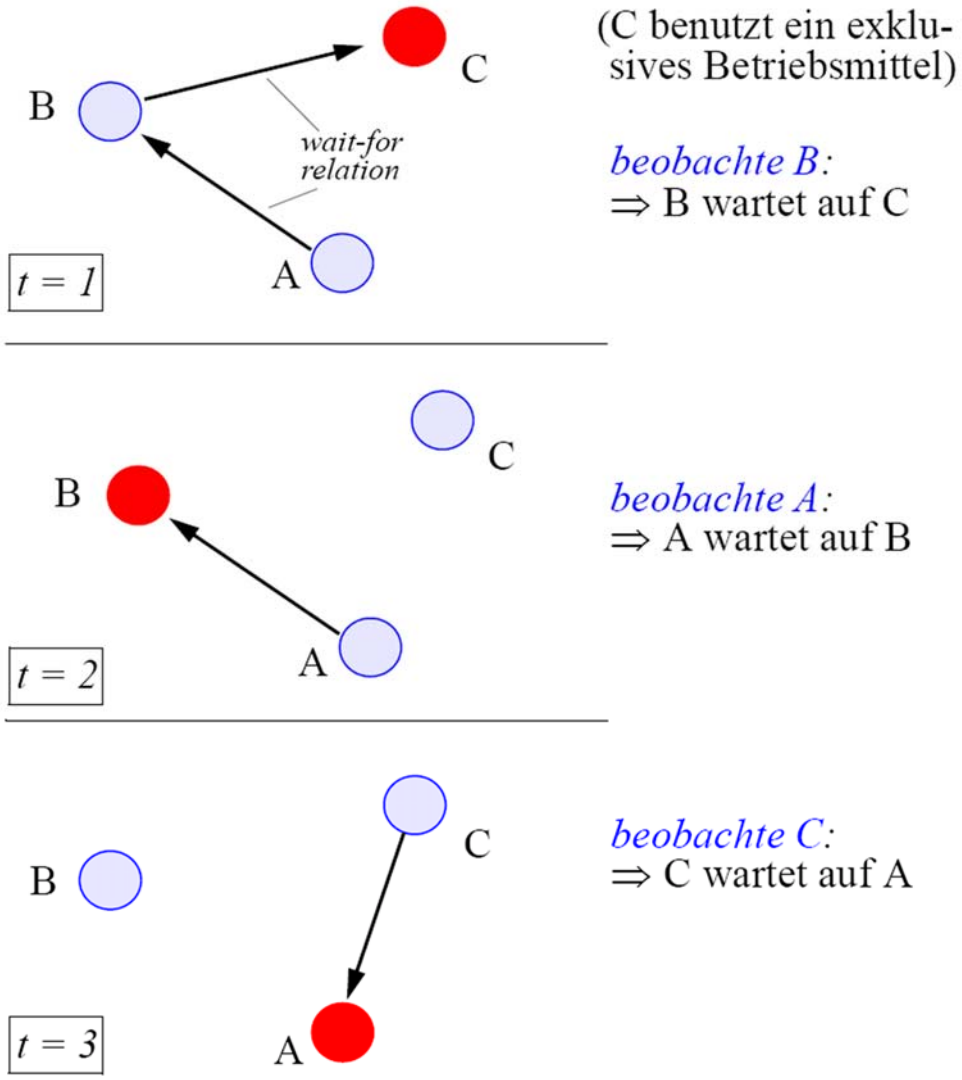

- Aus den Einzelbeobachtungen darf man nicht schliessen:
- A wartet auf B und B wartet auf C und C wartet auf A

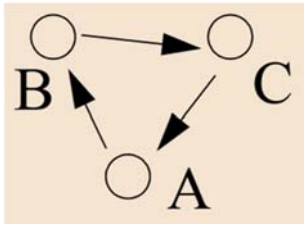

- Diese zyklische Wartebedingung wäre tatsächlich ein Deadlock
- Die Einzelbeobachtungen fanden hier aber zu unterschiedlichen Zeiten statt
- Lösung (nur echte Deadlocks erkennen) ohne Uhren, globale Zeit, Zeitstempel etc.?

Ein drittes Problem: Uhrensynchronisation

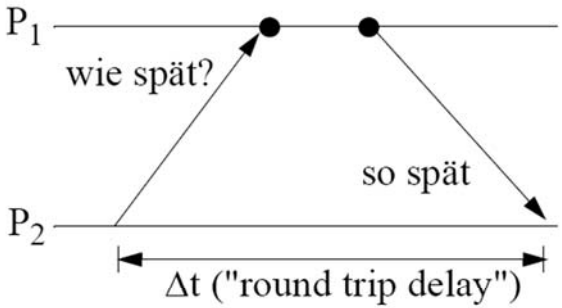

Laufzeit der Nachrichten variabel (und oft verschieden für Hin- und Rückweg)

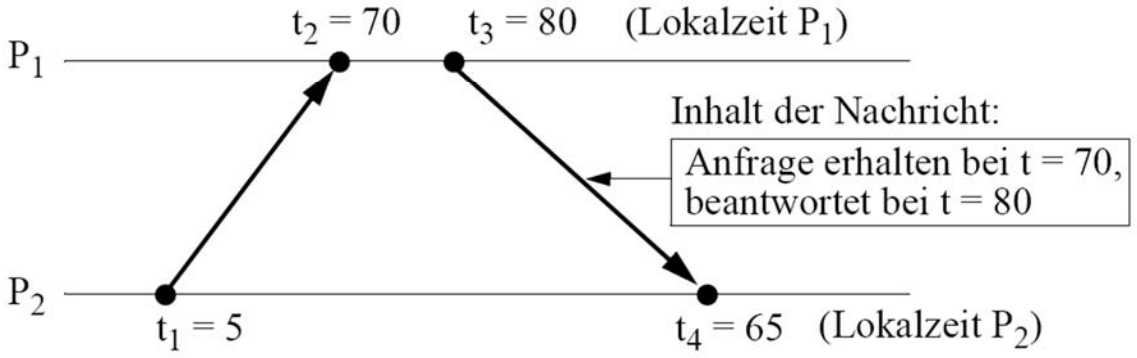

- Uhren gehen nicht unbedingt gleich schnell!
  - Gilt wenigstens "Beschleunigung ≈ 0", d.h. ist konstanter Drift gerechtfertigt?
- Wie kann man den Offset der Uhren ermitteln oder zumindest approximieren?

Ein viertes Problem: (nicht) kausaltreue Beobachtungen

- Gewünscht: Eine Ursache stets vor ihrer (u.U. indirekten) Wirkung beobachten

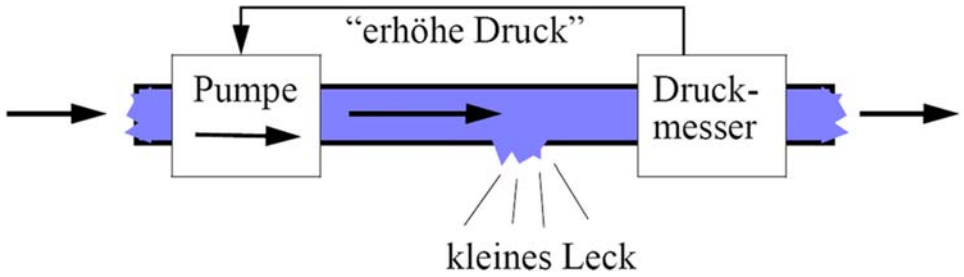

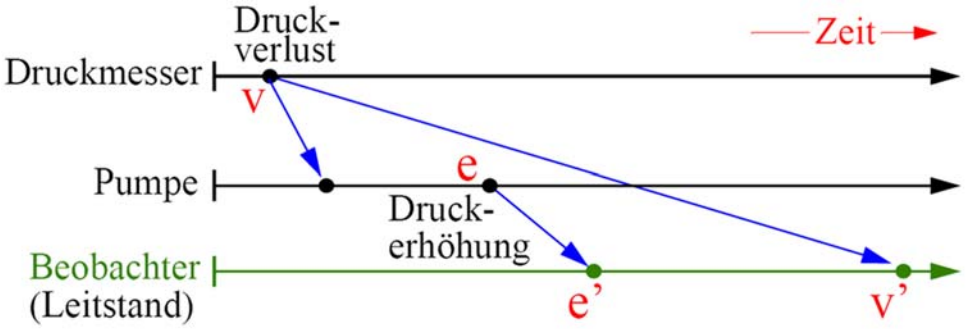

Falsche Schlussfolgerung des Beobachters:

Es erhöhte sich der Druck (aufgrund einer unbegründeten Aktivität der Pumpe), es kam zu einem Leck, was durch den abfallenden Druck angezeigt wird.

Und noch ein letztes Problem: Verteilte Geheimnisvereinbarung

- Problem: A und B wollen sich *über einen unsicheren Kanal* auf ein gemeinsames geheimes Passwort einigen

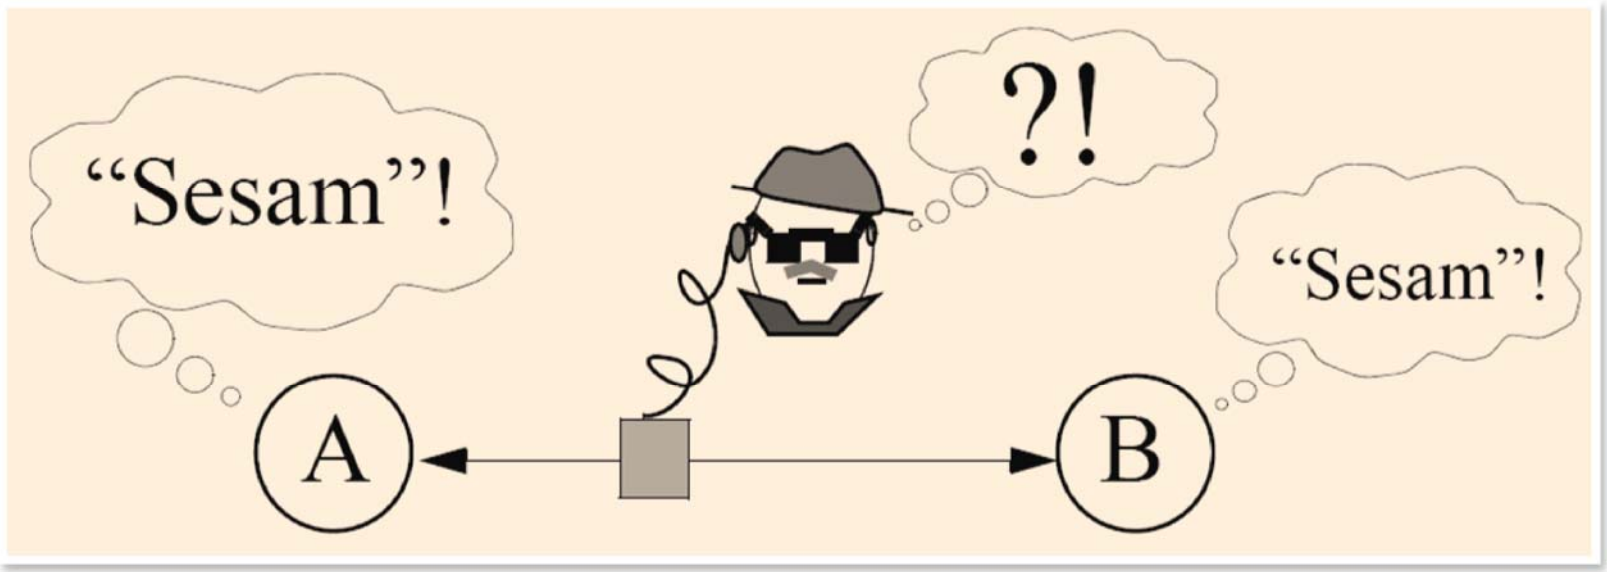

Verteilte Geheimnisvereinbarung (2)

- Idee: Vorhängeschlösser um eine sichere Truhe:

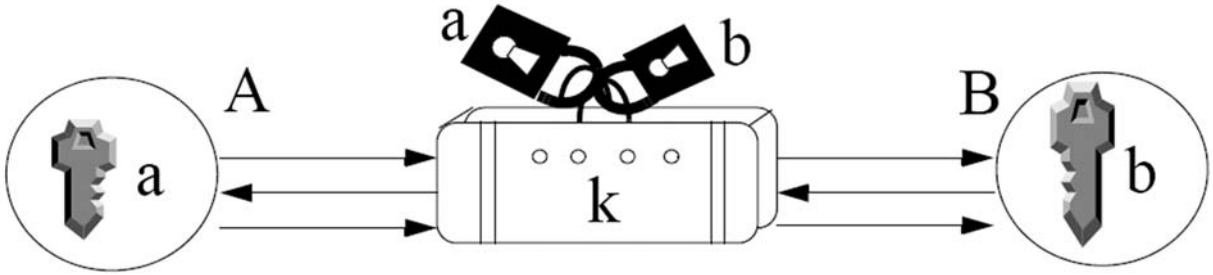

1. A denkt sich Passwort k aus und tut es in die Truhe.
2. A verschliesst die Truhe mit einem Schloss a.
3. A sendet die so verschlossene Truhe an B.
4. B umschliesst das ganze mit seinem Schloss b.
5. B sendet alles doppelt verschlossen an A zurück.
6. A entfernt sein Schloss a.
7. A sendet die mit b verschlossene Truhe wieder an B.
8. B entfernt sein Schloss b.

- Problem: Lässt sich das so softwaretechnisch realisieren?

Kommunikation

– Nachrichten –

Kooperation durch Informationsaustausch

- Prozesse sollen kooperieren, daher untereinander Information austauschen können
  - falls vorhanden, evtl. über einen gemeinsamen globalen Speicher
    (dieser kann physisch existieren oder evtl. nur logisch als „virtual shared memory“)
  - oder alternativ mittels Nachrichten: Daten an entfernte Stelle kopieren

Zur Prozesssynchronisation siehe auch Vorlesung «Paralleles Programmieren»

Im Folgenden steht vor allem der Informationsaustausch via Nachrichten im Vordergrund

Kommunikation

Notwendig, damit Kommunikation klappt, ist jedenfalls:

1. Ein dazwischenliegendes physikalisches Medium
   - z.B. elektrische Signale in Kupferkabeln (oder der „Äther"?)
2. Einheitliche Verhaltensregeln
   - Kommunikationsprotokolle
3. Gemeinsame Sprache und gemeinsame Semantik
   - gleiches Verständnis der Bedeutung von Kommunikationskonstrukten und -regeln

Also trotz Verteiltheit gewisse gemeinsame Aspekte!

Nachrichtenbasierte Kommunikation

Nächste 11 slides: siehe auch Vorlesungen «Networks», «Systems» sowie «Paralleles Programmieren»

- send → receive
- Implizite Synchronisation: Senden vor Empfangen
  - Empfänger erfährt, wie weit der Sender mindestens ist (er ist mindestens bis zum Absenden der Nachricht gekommen)
- Nachrichten sind dynamische Betriebsmittel
  - verursachen Aufwand und müssen verwaltet werden

- Wir schreiben manchmal „**!**" als Kurzform für ein Sendekommando und „**?**" für eine Empfangsanweisung

Auch andere Bezeichnungen, z.B. „Message Oriented Middleware“

Message Passing System

- Organisiert den Nachrichtentransport und verwaltet die dafür notwendigen Ressourcen (wie message queues etc.)
- Bietet Kommunikationsprimitive (als APIs) an
  - z.B. send (...) bzw. receive (...)
  - evtl. auch ganze library verschiedener Kommunikationsdienste (z.B. Multicast etc.) sowie Hilfsdienste zum Zweck der Kooperation
  - verwendbar mit gängigen Programmiersprachen (C, Java,...)

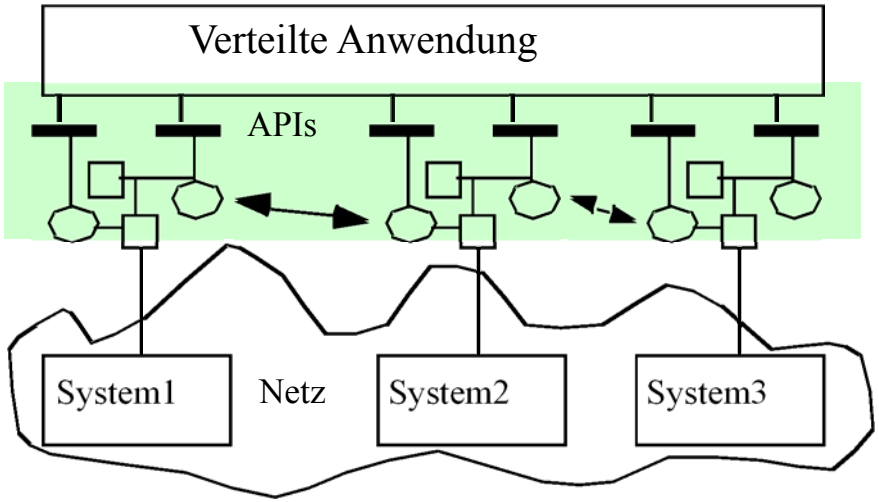

- Besteht aus Hilfsprozessen, Pufferobjekten, ...
- Verbirgt Details des zugrundeliegenden Netzes bzw. Kommunikationssubsystems

Message Passing System (2)

- Implementiert „höhere“ Kommunikationsprotokolle
  - verwendet dazu vorhandene elementarere Netzprotokolle
- Garantiert (je nach „Semantik“) gewisse Eigenschaften
  - z.B. Reihenfolgeerhalt oder Prioritäten von Nachrichten
- Abstrahiert von Implementierungsaspekten
  - z.B. Geräteadressen oder Längenrestriktionen von Nachrichten etc.
- Maskiert gewisse Fehler
  - mit typischen Techniken zur Erhöhung des Zuverlässigkeitsgrades: Timeouts, Quittungen, Sequenznummern, Wiederholungen, Prüfsummen, fehlerkorrigierende Codes,…
- Verbirgt Heterogenität unterschiedlicher Systemplattformen
  - erleichtert damit Portabilität von Anwendungen

Macht dies alles ein für alle Mal für viele unterschiedliche Anwendungen

Ordnungserhalt von Nachrichten: FIFO

- Manchmal werden vom Kommunikationssystem Garantien bzgl. Nachrichtenreihenfolgen gegeben
- Eine solche Garantie stellt z.B. FIFO (First-In-First-Out) dar: Nachrichten zwischen zwei Prozessen (also auf dem Kommunikationskanal zwischen Sender und Empfänger) überholen sich nicht: Empfangsreihenfolge = Sendereihenfolge

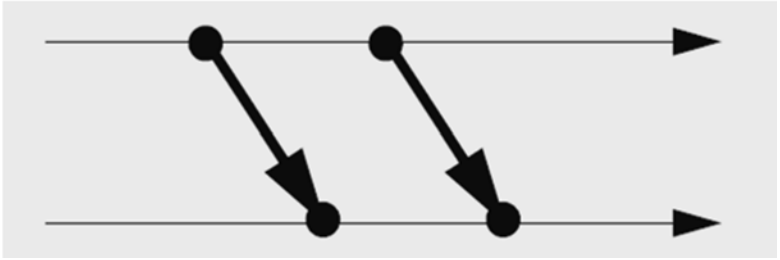

FIFO

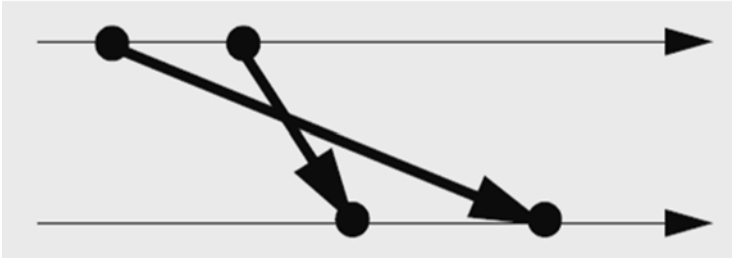

kein FIFO

Ordnungserhalt von Nachrichten: kausale Ordnung

- FIFO verbietet allerdings nicht, dass Nachrichten evtl. (über eine Kette anderer Nachrichten) indirekt überholt werden!

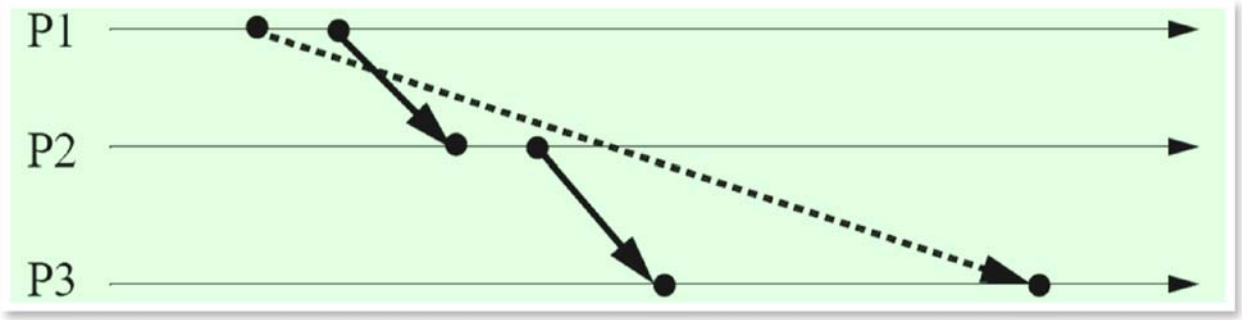

Zwar FIFO, aber nicht kausal geordnet

- Möchte man auch dies haben, so muss die Kommunikation kausal geordnet sein
  - keine Information erreicht Empfänger auf Umwegen schneller als auf direktem Wege („Dreiecksungleichung")
  - entspricht einer „Globalisierung" von FIFO auf mehrere Prozesse
  - Denkübungen: Anwendungszweck? Und wie garantiert (d.h. implementiert) man dies auf einem System ohne Ordnungsgarantie?

Prioritäten von Nachrichten?

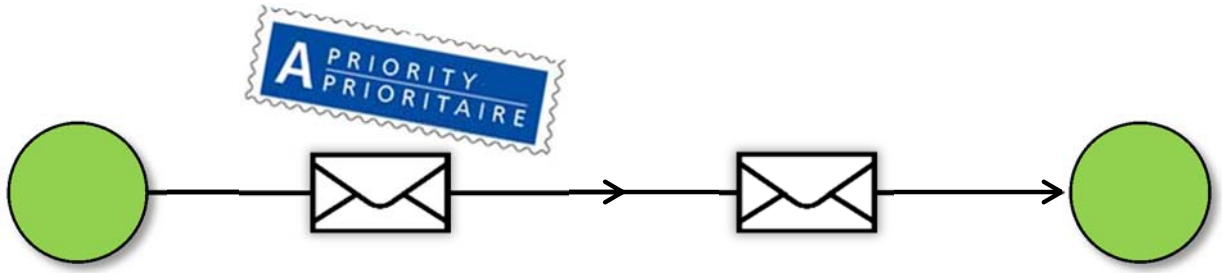

- Achtung: Semantik ist a priori nicht ganz klar:
  - Soll (kann?) das Transportsystem Nachrichten höherer Priorität bevorzugt (=?) befördern?
  - Können (z.B. bei fehlender Pufferkapazität) Nachrichten niedrigerer Priorität überschrieben werden?
  - Wie viele Prioritätsstufen gibt es?
  - Sollen aus einer Mailbox (= Nachrichtenspeicher) immer zuerst Nachrichten mit höherer Priorität geholt werden?

- Ist das fair?
- Netzneutral?
- Und was heisst das überhaupt?

Prioritäten von Nachrichten? (2)

- Mögliche Anwendungen:
  - Unterbrechen / abbrechen laufender Aktionen (→ Interrupt)
  - Aufbrechen von Blockaden
  - Out-of-Band-Signalisierung

  } Durchbrechung der FIFO-Reihenfolge!

Vgl. auch Service-Klassen in Computernetzen: bei Rückstaus bei den Routern soll z.B. interaktiver Datenverkehr bevorzugt werden vor Datei-Download etc.

- Vorsicht bei der Anwendung: Nur bei klarer Semantik verwenden; löst oft ein Problem nicht grundsätzlich!
  - Inwiefern wäre eine (faule) Implementierung, bei der „eilige" Nachrichten (insgeheim) wie normale Nachrichten realisiert werden (oder umgekehrt!), tatsächlich „Betrug" am Anwender?

Fehlermodelle

- Zweck: Klassifikation von Fehlermöglichkeiten; Abstraktion von den tieferliegenden spezifischen Ursachen
- Nachrichtenfehler beim Senden / Übertragen / Empfangen:

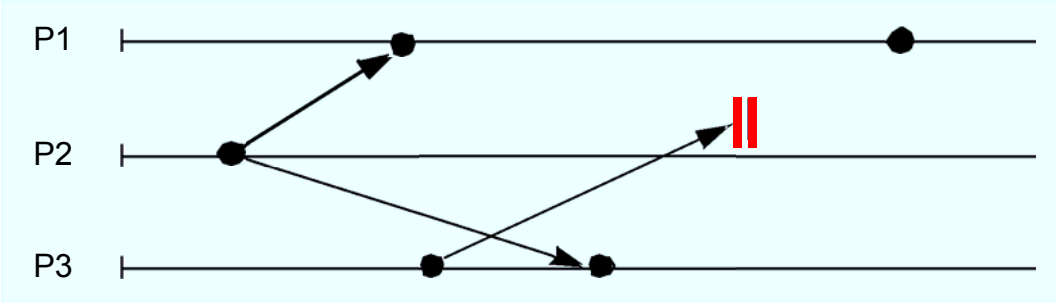

→ verlorene Nachricht

- Crash / Fail-Stop: Ausfall eines Prozessors:

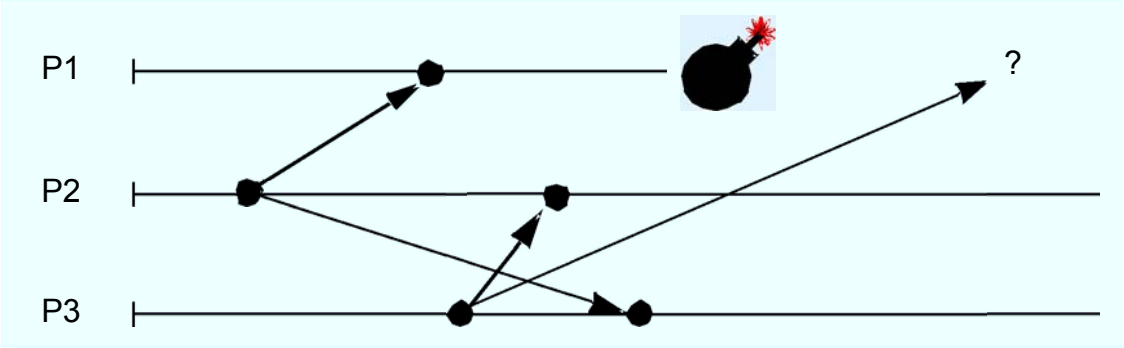

→ Nicht mehr erreichbarer / mitspielender Prozess

Fehlermodelle (2)

- Zeitfehler: Ereignis geschieht zu spät (oder zu früh)
- „Byzantinische" Fehler: Beliebiges Fehlverhalten, z.B.:
  - verfälschte Nachrichteninhalte
  - Prozess, der unsinnige Nachrichten sendet

(solche Fehler lassen sich nur teilweise, z.B. durch Redundanz, erkennen)

- Fehlertolerante Algorithmen bzw. Systeme müssen das „richtige" spezifische Fehlermodell berücksichtigen!
  - adäquate Modellierung der realen Situation / des Einsatzgebietes
  - Algorithmus / Programm / System ist korrekt (oder fehlerhaft) nur relativ zum jeweils betrachteten Fehlermodell

Mitteilungsorientierte Kommunikation

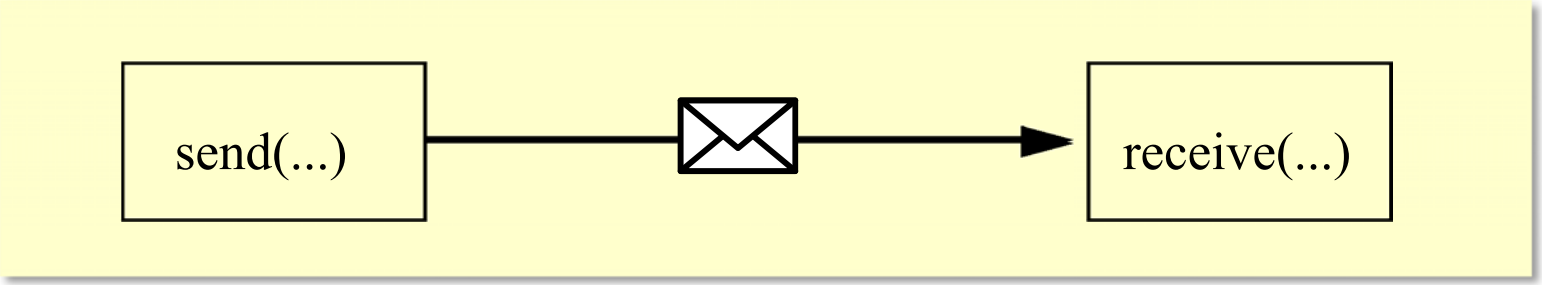

- Einfachste Form der Kommunikation („fire & forget“)
- Unidirektional
- Übermittelte Werte werden der Nachricht typw. als „Ausgabeparameter“ beim send (-API) übergeben

---

- Die Nachricht ist in der Praxis eine gewisse Zeit lang unterwegs, bevor sie beim Empfängerprozess ankommt
- Sendprozess kann nach dem Absenden aber i. Allg. direkt weiterarbeiten (Nachrichtenkanal puffert die Nachricht)

Asynchrone Kommunikation

Auftragsorientierte Kommunikation

Send und receive evtl. zu einem *einzigen* API zusammenfassen

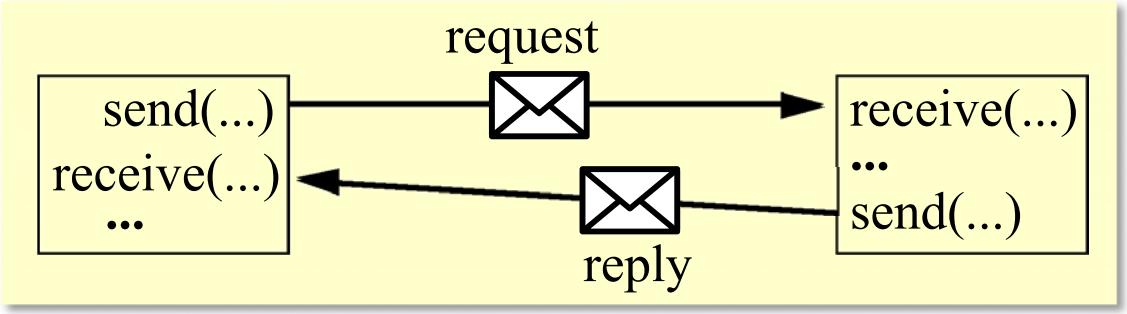

- Bidirektional
- Ergebnis des Auftrags wird als „Antwortnachricht“ zurückgeschickt

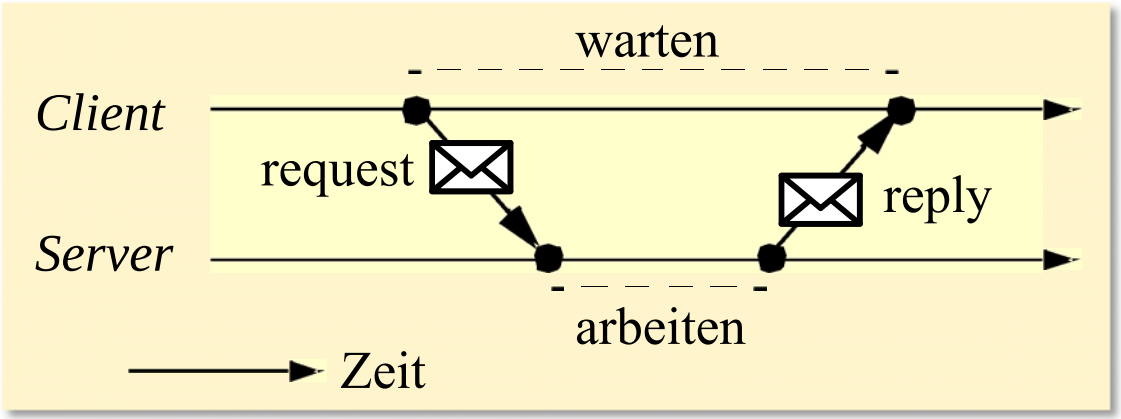

- Auftraggeber („Client“) wartet, bis Antwort eintrifft
  (→ keine Parallelarbeit von Client und Server)

Synchrone Kommunikation?

Kommunikation

synchron

⇔

asynchron

Zu den nächsten 5 slides siehe auch Vorlesung «Networks»

Blockierendes Senden

- Blocking send: Sender ist bis zum Abschluss der Nachrichtentransaktion blockiert

was genau ist das?

  - Sender hat eine Garantie: Nachricht wurde zugestellt / empfangen

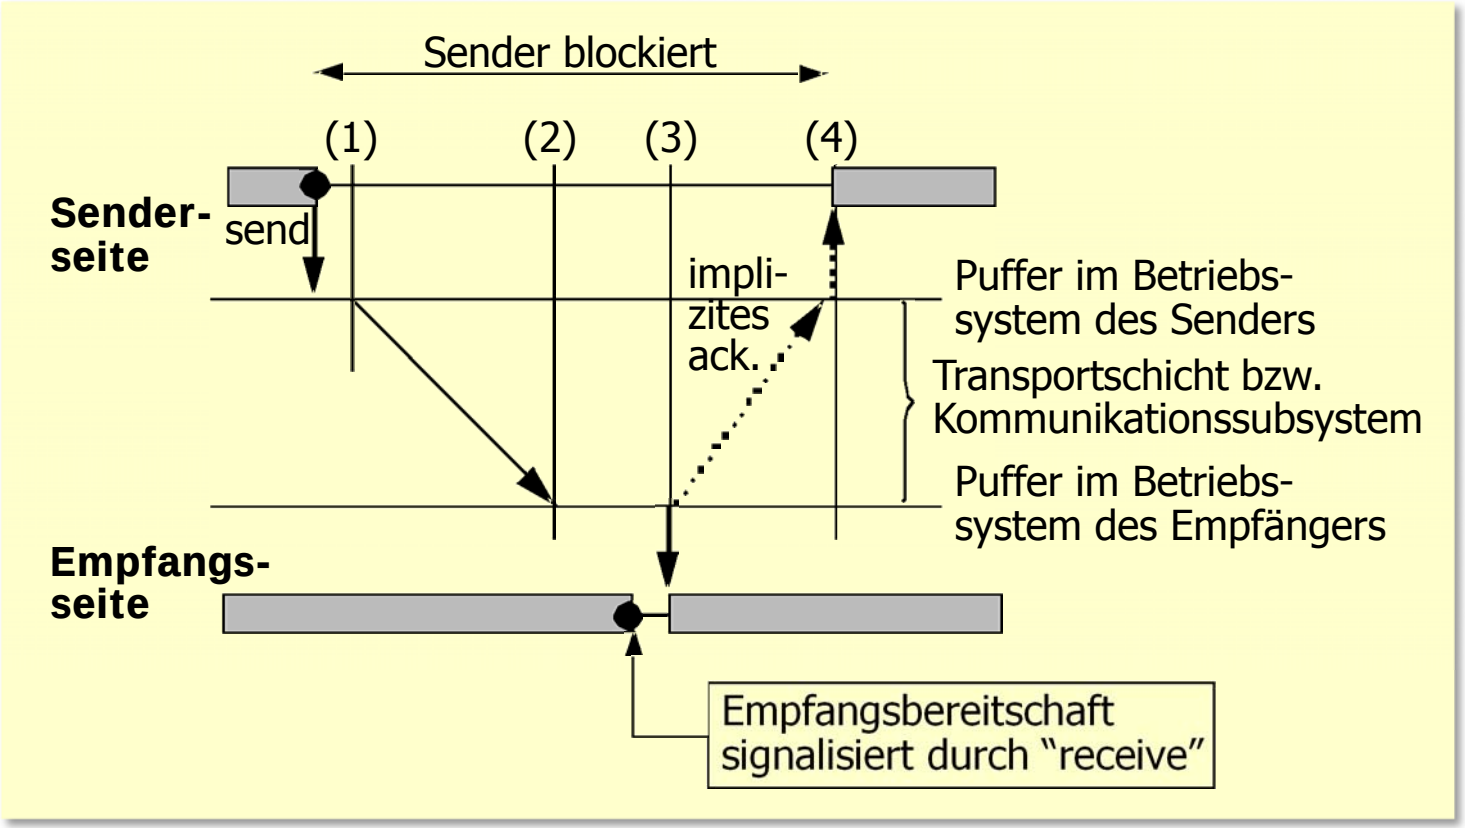

Blockierendes Senden (2)

- Verschiedene Ansichten einer adäquaten Definition von „Abschluss der Transaktion“ aus Sendersicht:

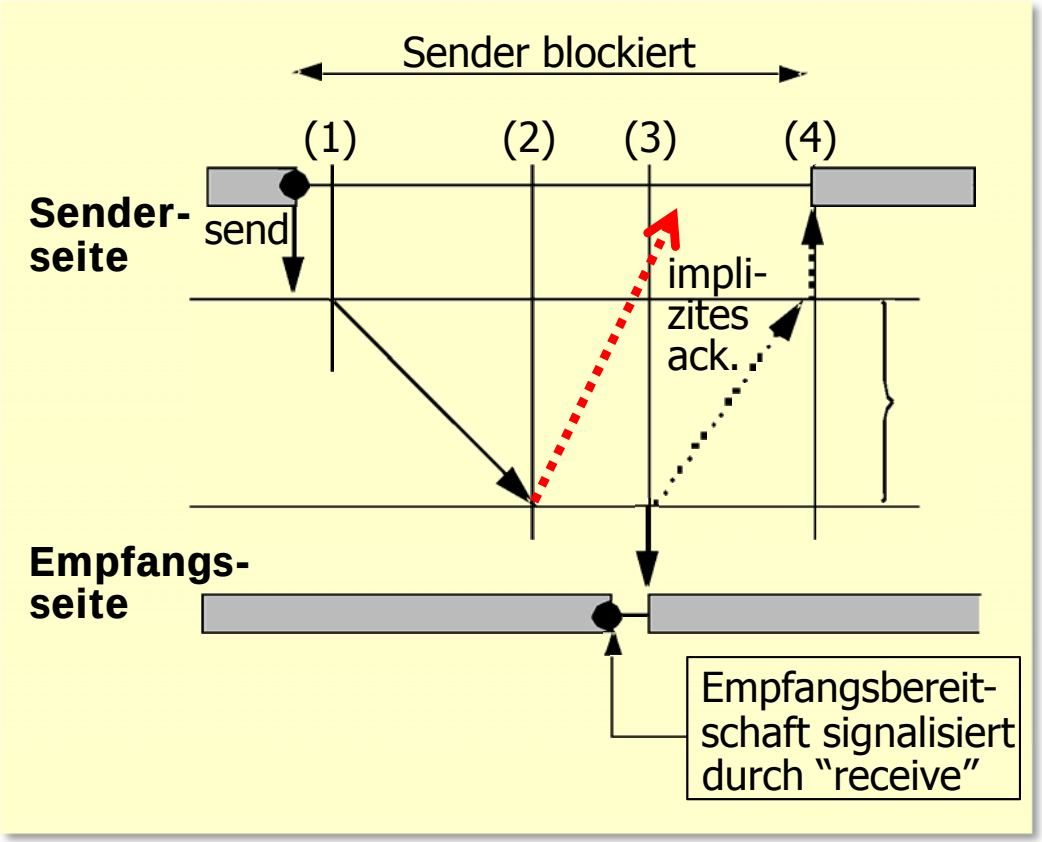

Zeitpunkt 4 (automatische Bestätigung bei (3), dass der Empfänger receive ausgeführt hat) ist die höhere, anwendungsorientierte Sicht.

Falls eine Bestätigung bereits zum Zeitpunkt 2 geschickt wird, erfährt der Sender nur, dass die Nachricht am Zielort zur Verfügung steht und der Sendepuffer wieder frei ist.

(Vorher sollte der Sendepuffer nicht überschrieben werden, weil die Nachricht bei fehlerhafter Übertragung evtl. wiederholt werden muss.)

„gleich“ „zeitig“

Synchrone Kommunikation

- Idealisierung:
  Send und receive geschehen („im Prinzip“) gleichzeitig
- Wodurch ist diese Idealisierung gerechtfertigt?
  (kann man auch mit einer Marssonde synchron kommunizieren?)

Achtung: „synchron“ und „asynchron“ werden in diversen Teilgebieten der Informatik etwas unterschiedlich gebraucht

- z.B. asynchroner Datentransfer (jedes Zeichen in einem Bitstrom individuell behandeln und evtl. mit eigener Zusatzinformation wie Start- / Stoppbit versehen) gegenüber synchronem Datentransfer (ganzen Bitstrom als eine Einheit übertragen; Sender und Empfänger werden längere Zeit synchron getaktet)

Synchrone Kommunikation mit „blocking send“ implementiert

a) „Receiver first“-Fall:

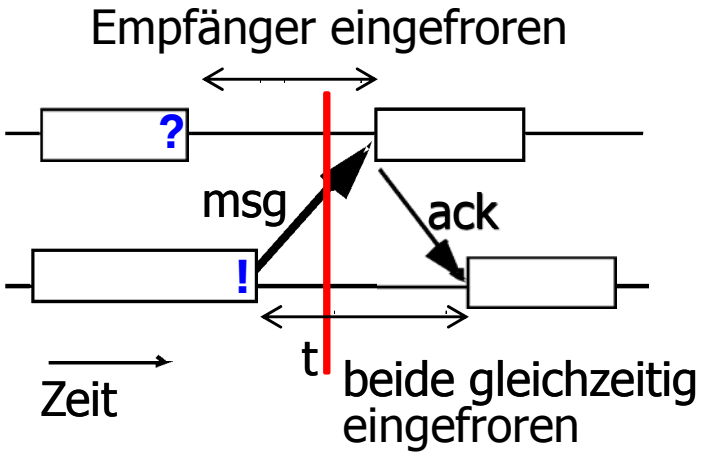

Bemerkung: „receive“ ist i.Allg. immer blockierend (d.h. Empfänger wartet so lange, bis eine Nachricht ankommt)

Idealisierung:
senkrechte Pfeile in den Zeitdiagrammen

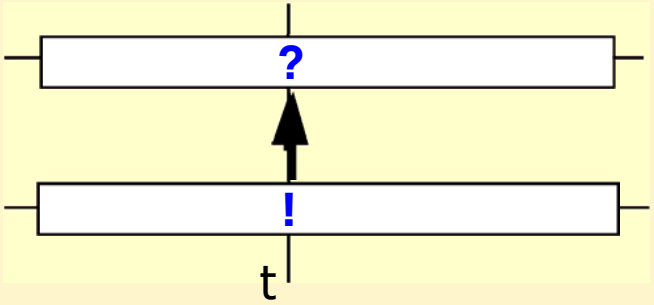

Als wäre die Nachricht zum Zeitpunkt t gleichzeitig gesendet („!“) und empfangen („?“) worden!

Synchrone Kommunikation mit „blocking send“ implementiert (2)

b) „Sender first“-Fall:

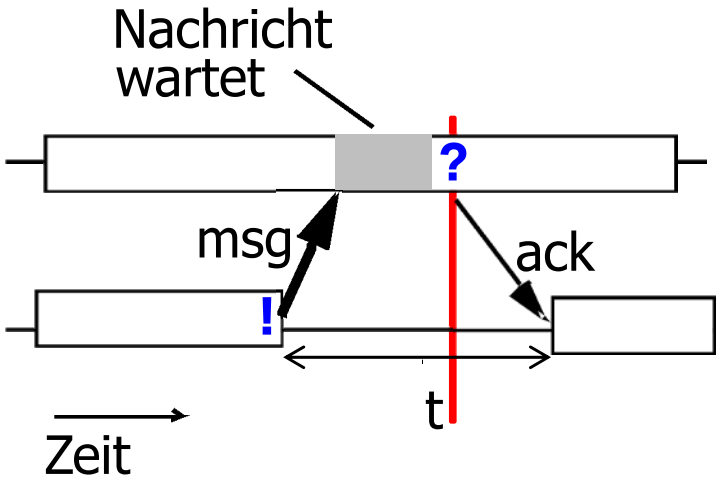

Der Sender ist eingefroren, seine Zeit steht quasi still → es gibt einen gemeinsamen Zeitpunkt t, wo die beiden Kommunikationspartner sich treffen → „Rendezvous“

Idealisierung:
senkrechte Pfeile in den Zeitdiagrammen

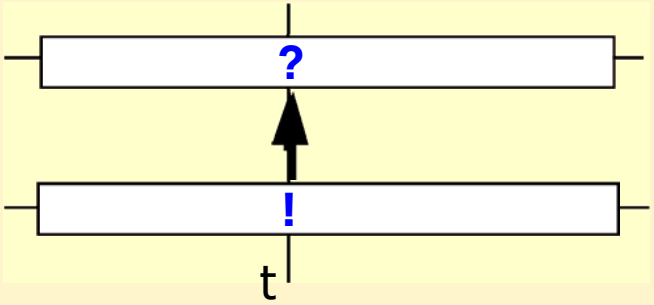

Als wäre die Nachricht zum Zeitpunkt t gleichzeitig gesendet („!“) und empfangen („?“) worden!

Virtuelle Gleichzeitigkeit

- Ein Ablauf, der synchrone Kommunikation benutzt, ist (bei Abstraktion von der Realzeit) durch ein äquivalentes Zeitdiagramm darstellbar, bei dem alle Nachrichtenpfeile senkrecht verlaufen
  - nur stetige Deformation erlaubt („Gummiband-Transformation")

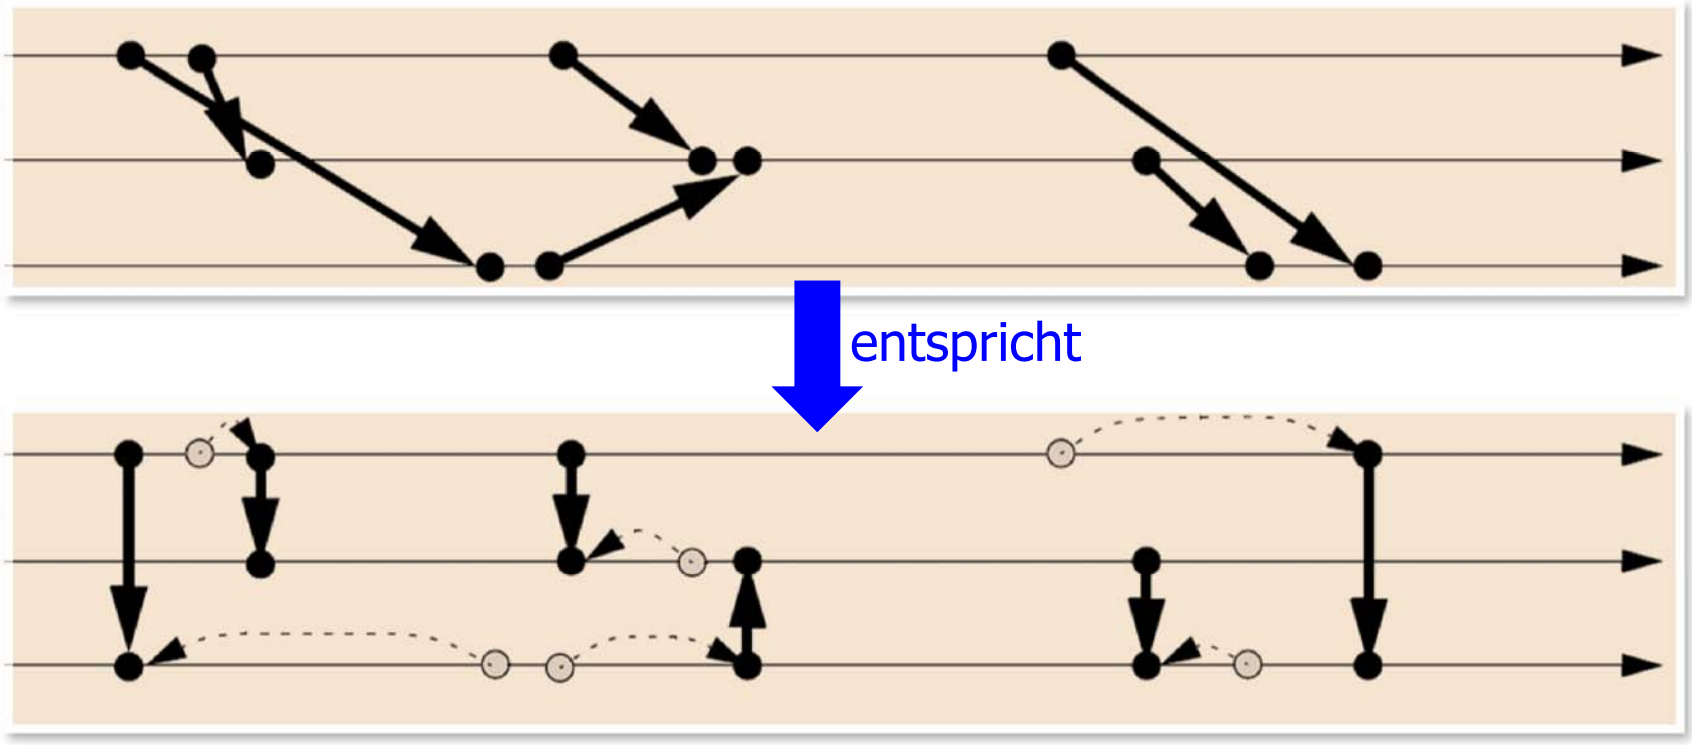

Virtuelle Gleichzeitigkeit?

- Folgendes geht nicht virtuell gleichzeitig (wieso?)

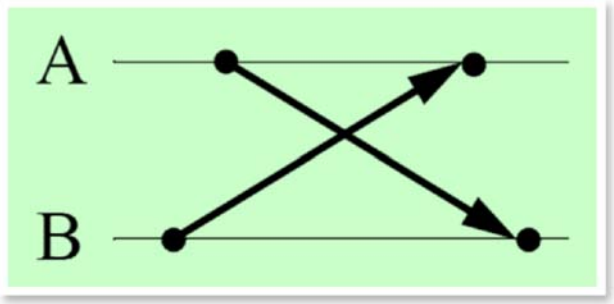

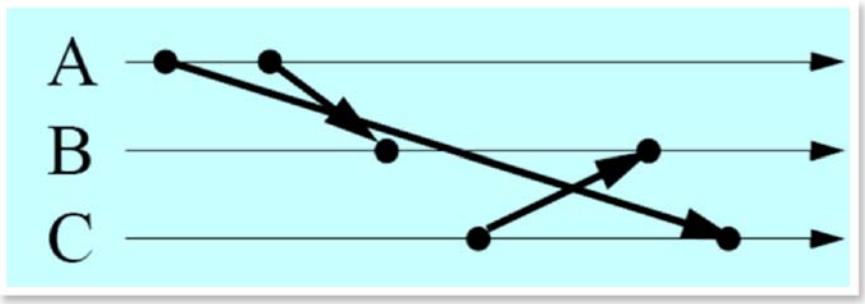

- Aber was geschieht eigentlich, wenn man mit synchronen Kommunikationskonstrukten so programmiert, dass dies provoziert wird?

Mehr dazu (nur) für besonders Interessierte: B. Charron-Bost, F. Mattern, G. Tel: S*ynchronous, Asynchronous and Causally Ordered Communication.* Distributed Computing 9(4), pp. 173-191, www.vs.inf.ethz.ch/publ/

Deadlocks bei synchroner Kommunikation

Zu «Deadlocks» siehe auch Vorlesungen «Networks» und «Parallelles Programmieren»

```
P1:
    send (...) to P2;
    receive...
    ...
```

```
P2:
    send (...) to P1;
    receive...
    ...
```

In beiden Prozessen muss zunächst das send ganz ausgeführt werden, bevor es zu einem receive kommt

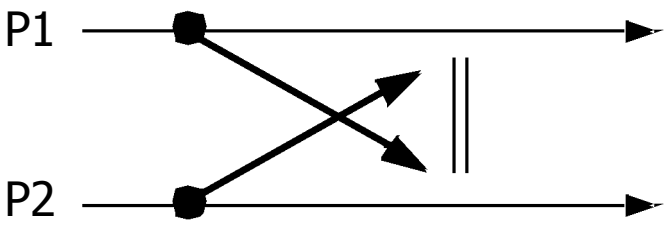

⇒ Kommunikationsdeadlock!

Zyklische Abhängigkeit der Prozesse voneinander: P1 wartet auf P2, und P2 wartet auf P1

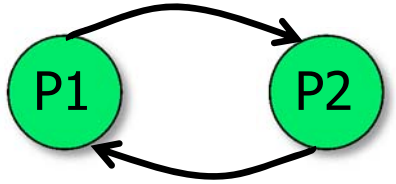

„Wait-for-Graph"

Genauso „dumm": 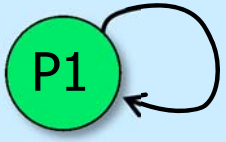


```
P1:
    send (...) to P1;
    receive...
    ...
```

Gleichnishaft entspricht der *synchronen* Kommunikation das Telefonieren, der *asynchronen* Kommunikation der Briefwechsel

Zu den nächsten 5 slides siehe auch Vorlesungen «Net-works», «Systems» sowie «Paralleles Programmieren»

Asynchrone Kommunikation

- No-wait send: Sender ist nur (kurz) bis zur lokalen Ab-lieferung der Nachricht an das Transportsystem blockiert
  - diese kurzzeitige Blockade sollten für die Anwendung transparent sein

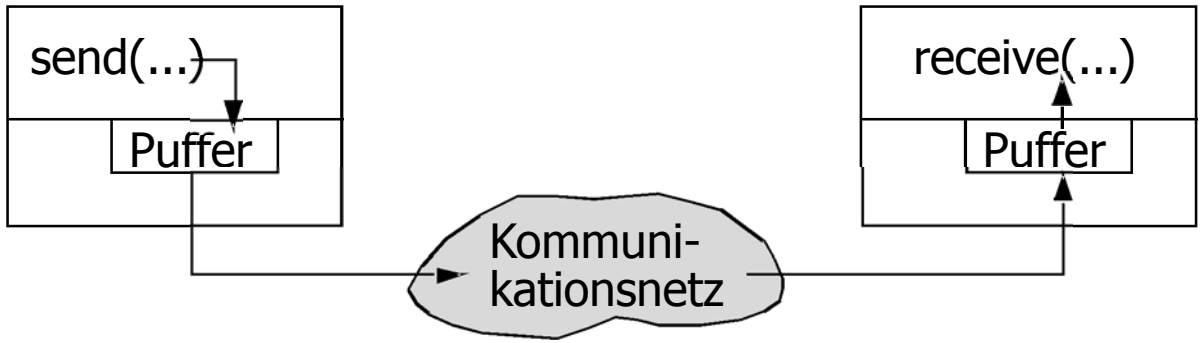

- Jedoch i.Allg. länger blockiert, falls das System momentan keine Ressourcen (z.B. Pufferplatz) für die Nachricht hat
  - Alternative: Den sendenden Prozess dann nicht länger blockieren, sondern mittels „return value" über Misserfolg des send informieren

Asynchrone ↔ synchrone Kommunikation

- Vorteile asynchroner Kommunikation (im Vgl. zur syn. Komm.):
  - sendender Prozess kann weiterarbeiten, noch während die Nachricht übertragen wird
  - stärkere Entkoppelung von Sender / Empfänger
    (Empfänger darf z.B. zum Sendezeitpunkt unerreichbar sein)
  - höherer Grad an Parallelität möglich
  - geringere Gefahr von Kommunikationsdeadlocks
- Nachteile
  - Sender weiss nicht, ob / wann Nachricht angekommen ist
  - Debugging der Anwendung oft schwierig (wieso?)
  - System muss Puffer verwalten

Sendeoperationen in der Praxis

- Es gibt Kommunikationsbibliotheken, deren Dienste von verschiedenen Programmiersprachen (C, Java,...) aus aufgerufen werden können
  - z.B. MPI (Message Passing Interface) } Quasi-Standard; verfügbar auf diversen Plattformen
- Typischer Aufruf einer solchen Send-Operation:

```
status = send(buffer, size, dest, ...)
```

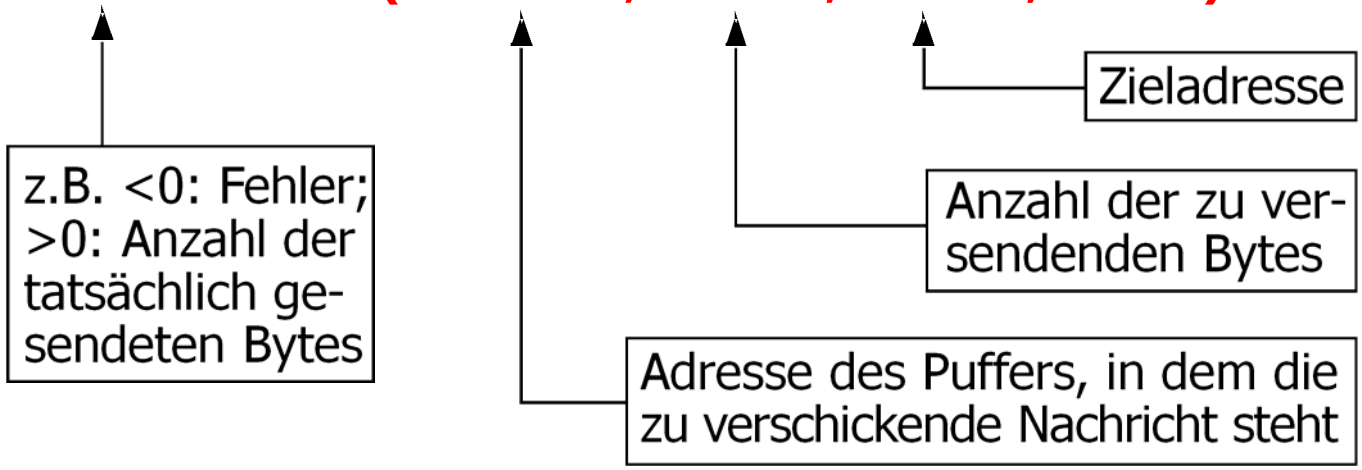

Sendeoperationen in der Praxis (2)

- Derartige Systeme bieten im Allgemeinen mehrere verschiedene Typen von Send-Operation an
  - Zweck: Hohe Effizienz durch möglichst spezifische Operationen
  - Achtung: Spezifische Operation kann in anderen Situationen u.U. eine falsche oder unbeabsichtigte Wirkung haben (z.B. wenn vorausgesetzt wird, dass der Empfänger schon im receive wartet)
  - Vorsicht: Semantik und Kontext der Anwendbarkeit ist oft nur informell beschrieben

Dazu und nachfolgend (synchron vs. blockierend) siehe auch Vorlesung «Paralleles Programmieren»

Synchron $\stackrel{?}{=}$ blockierend

- Kommunikationsbibliotheken machen oft einen Unterschied zwischen synchronem und blockierendem Senden
  - bzw. analog zwischen asynchron und nicht-blockierend

leider etwas verwirrend!

- **Blockierung** ist dann ein rein senderseitiger Aspekt
  - blockierend: Sender wartet, bis die Nachricht lokal vom Kommunikationssystem abgenommen wurde (und der Puffer wieder frei ist)
  - nicht-blockierend: Sender informiert Kommunikationssystem lediglich, wo bzw. dass es eine zu versendende Nachricht gibt (Gefahr des Überschreibens des Puffers bevor dieser frei ist!)
- **Synchron / asynchron** nimmt Bezug auf den Empfänger
  - synchron: Nach Ende der Send-Operation wurde die Nachricht dem Empfänger zugestellt (asynchron: dies ist nicht garantiert)

Nicht-blockierend

- Nicht-blockierende Operationen liefern oft einen „handle“

  `h = send(...)`

  - dieser kann in Test- bzw. Warteoperationen verwendet werden
  - z.B. Test, ob Send-Operation beendet:
    `if msgdone(h)…`
  - oder z.B. warten auf Beendigung der Send-Operation:
    `msgwait(h)`

- Nicht-blockierend ist oft effizienter, aber evtl. unsicherer und komplexer (evtl. Test; warten) als blockierend

Dualität der Kommunikationsmodelle

Zu den nächsten 10 slides (Dualität, Klassifikation, Rendezvous) siehe auch Vorlesungen «Networks», «Systems» sowie «Paralleles Programmieren»

Synchrone Kommunikation lässt sich mit asynchroner Kommunikation nachbilden:

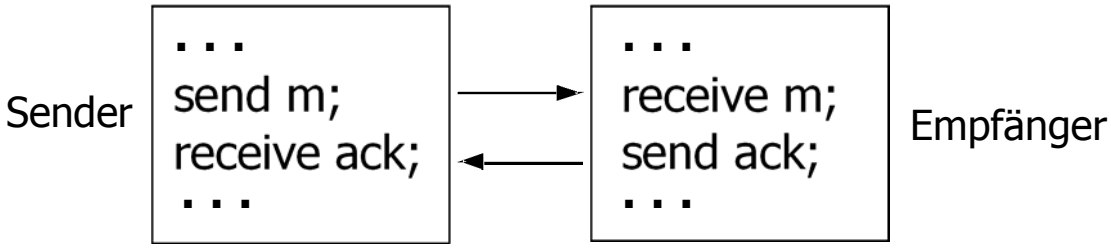

- Warten auf explizites Acknowledgment im Sender direkt nach dem send (receive wird als blockierend vorausgesetzt)
- Explizites Versenden des Acknowledgments durch den Empfänger direkt nach dem receive

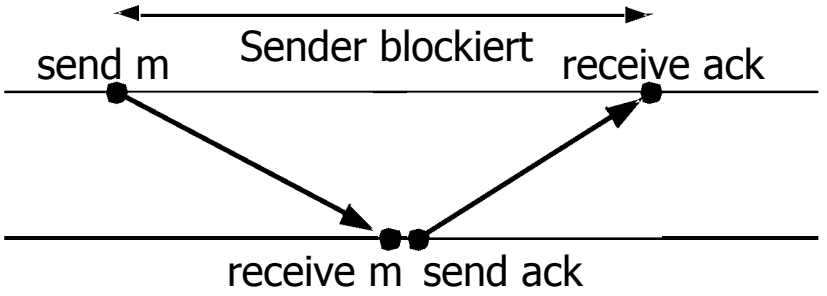

Dualität der Kommunikationsmodelle (2)

Asynchrone Kommunikation mittels synchroner:

Idee: Zusätzlichen Prozess vorsehen, der für die Zwischenpufferung aller Nachrichten sorgt

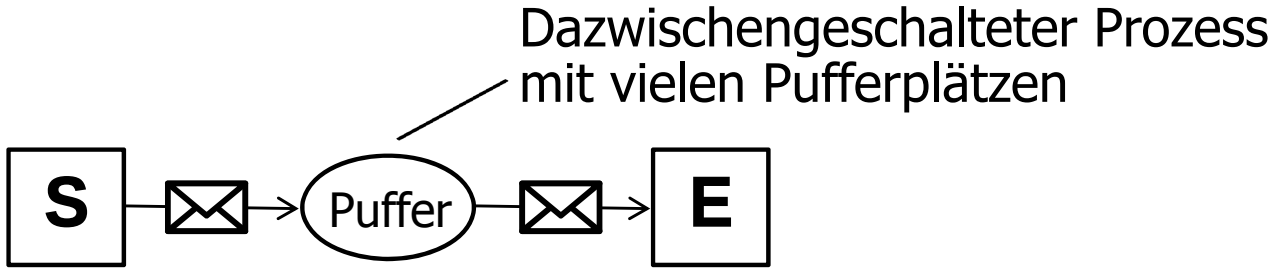

→ Entkoppelung von Sender und Empfänger

Realisierung von Pufferprozessen bei synchroner Kommunikation?

```
.....
receive  - warte, bis Sender S etwas schickt; dann:
Nachricht im lokalen Speicher ablegen
?
send     - warte, bis Empfänger E bereit ist
.....
```

- Dilemma: Was tut der Pufferprozess nach dem Ablegen der Nachricht in seinem lokalen Speicher?
  - wieder im receive auf den Sender warten, *oder*
  - in einem (blocking) send auf den Empfänger warten?
- Entweder Sender S oder Empfänger E könnte so unnötigerweise blockiert werden!

Bemerkung: Puffer der Gösse 1 lassen sich so realisieren → Kaskadierung im Prinzip möglich („Pufferpipeline“)

1. Lösung: Puffer als Server!

- E schickt „seinem" Puffer einen „request" (und muss dazu die Adresse des Puffers kennen)
- Puffer schickt E keine Antwort, wenn er leer ist
- Empfänger E wird nur dann verzögert, wenn Puffer leer
- Für Sender S ändert sich nichts

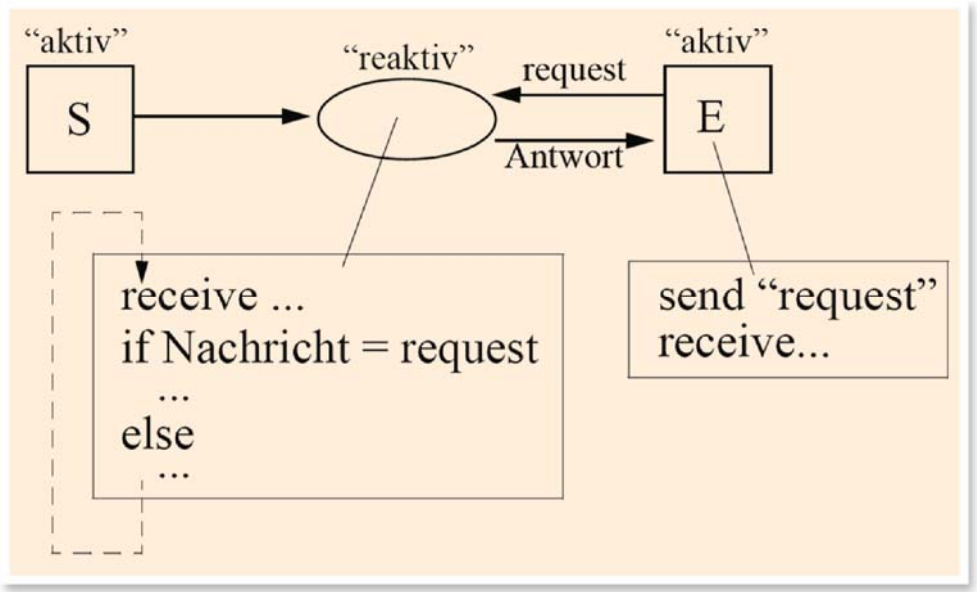

- Was tun bei vollem Puffer?
  → Dann sollte der Puffer keine Nachricht von S (wohl aber von E!) annehmen (Denkübung: wie programmiert man das?)

2. Lösung: Puffer als Multithread-Objekt

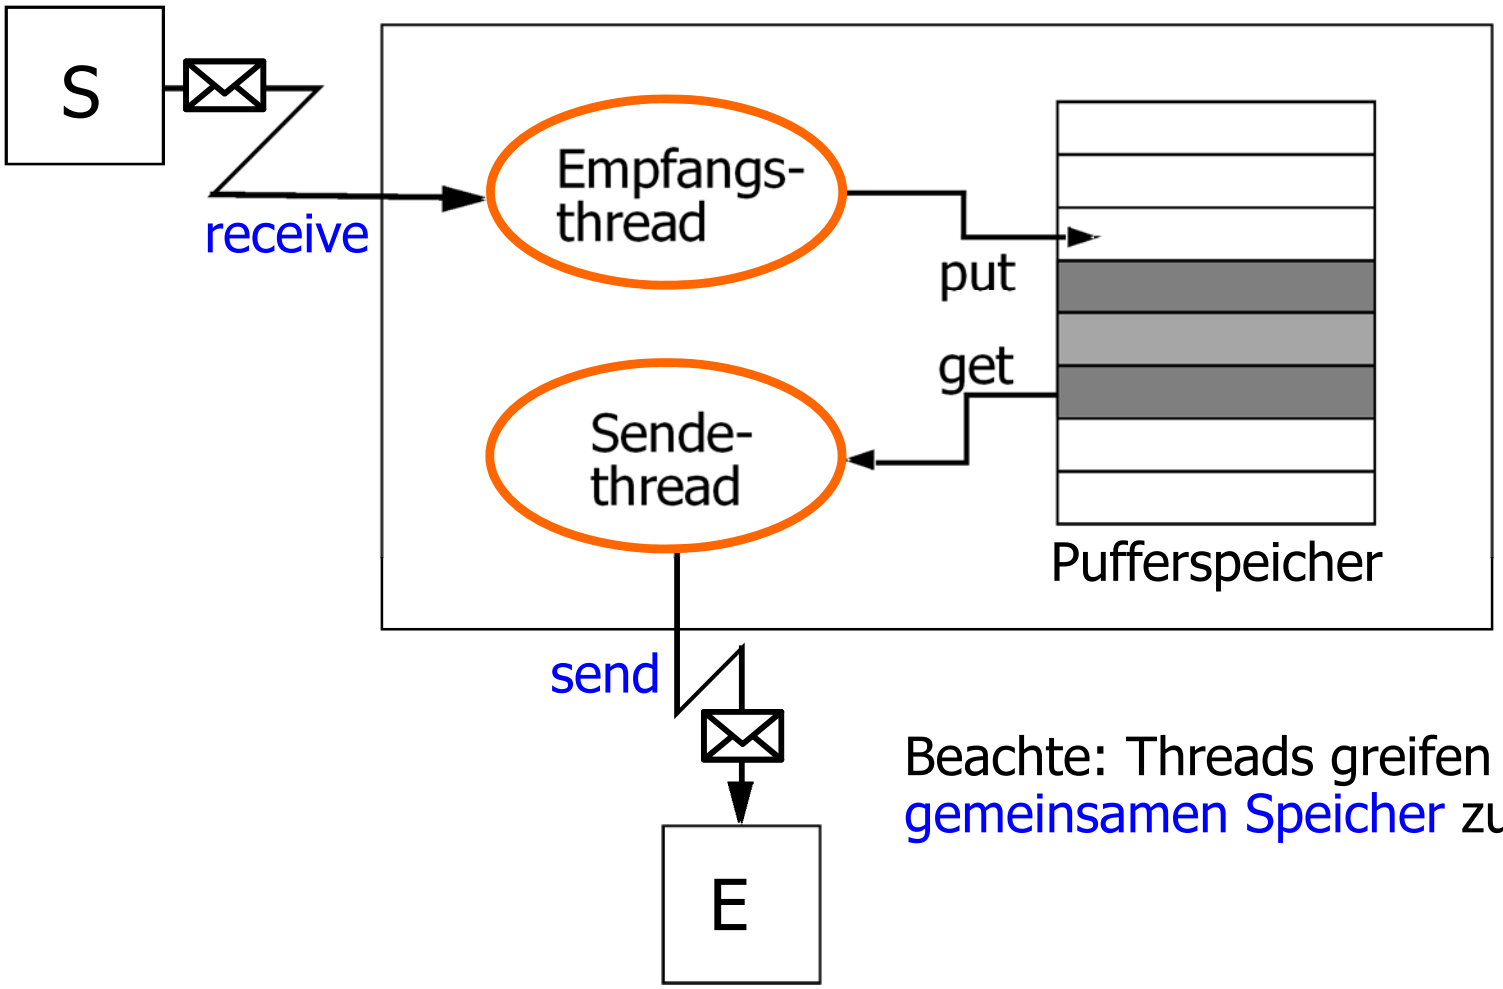

Beachte: Threads greifen auf gemeinsamen Speicher zu

Puffer als Multithread-Objekt (2)

- Empfangsthread ist (fast) immer empfangsbereit
  - nur kurzzeitig anderweitig beschäftigt (put in lokalen Pufferspeicher)
  - evtl. nicht empfangsbereit, wenn lokaler Pufferspeicher voll
- Sendethread ist (fast) immer sendebereit
- Pufferspeicher ist i.Allg. zyklisch organisiert (→ FIFO)
- Pufferspeicher liegt im gemeinsamen Adressraum

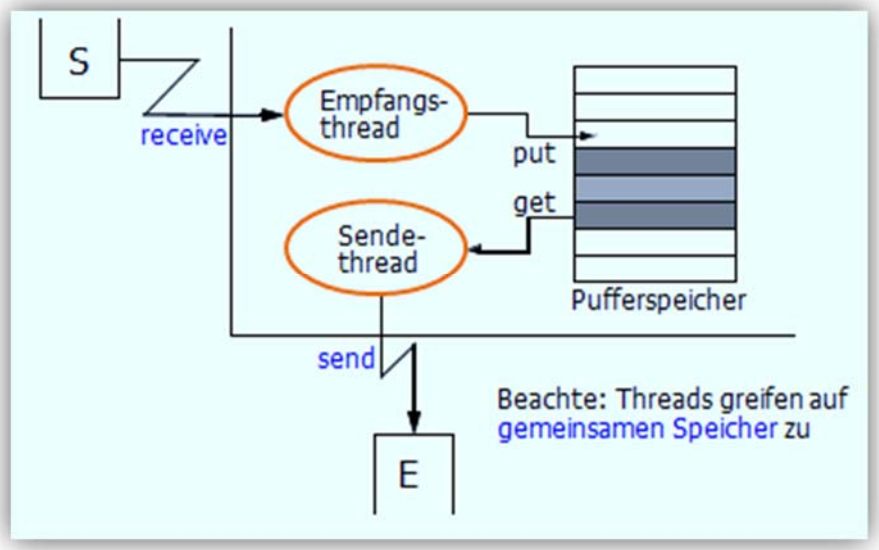

- ⇒ Synchronisation der beiden Threads notwendig!
  - Konzepte des parallelen Programmierens (atomare Aktionen etc.)

Hauptklassifikation von Kommunikationsmechanismen

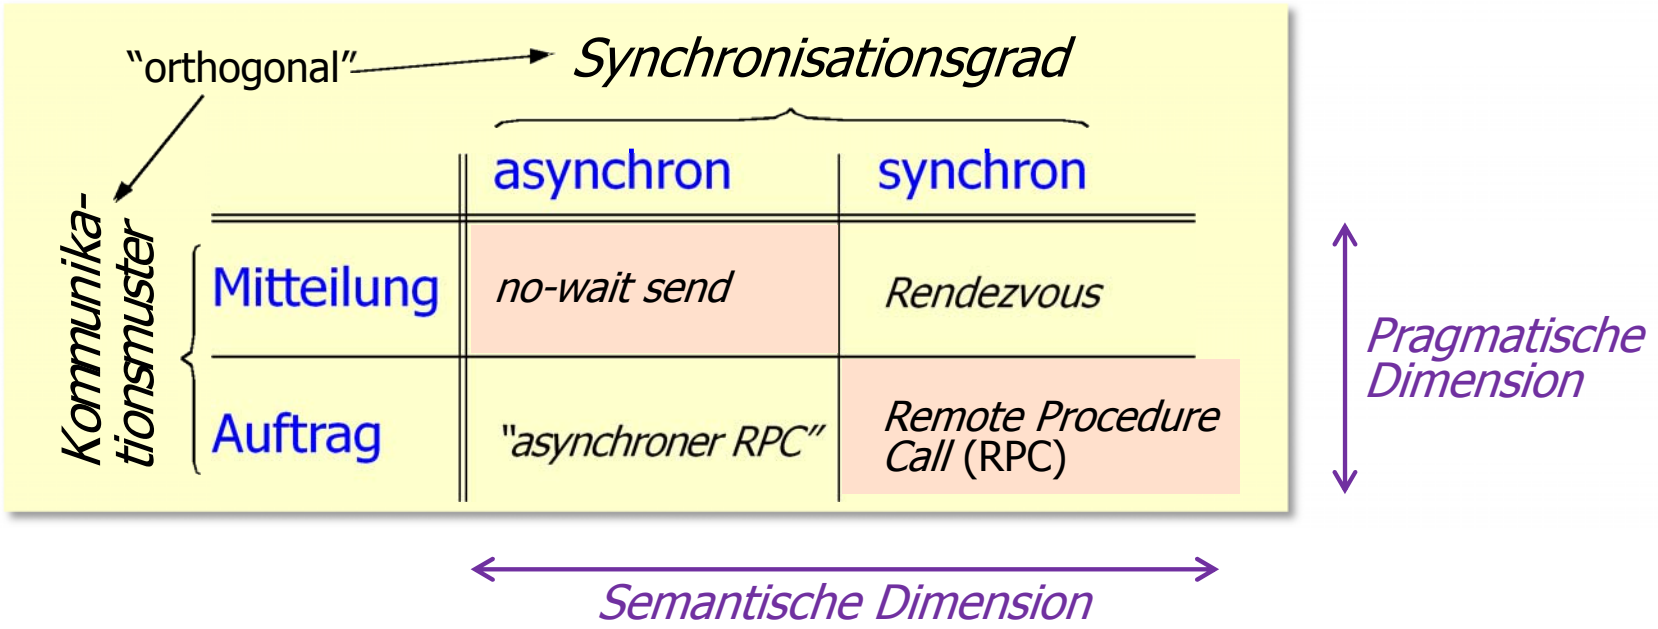

- Häufigste Kombination:
  Mitteilung asynchron, Auftrag hingegen synchron

- Wir schauen uns nun der Reihe nach die 4 Kombinationen an →

No-Wait Send

- Asynchron-mitteilungsorientierte Kommunikation

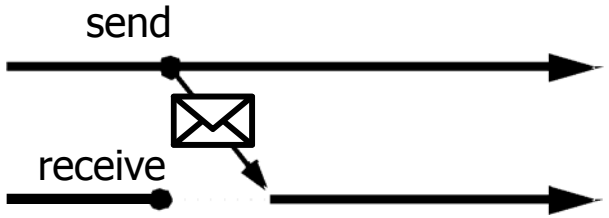

- Vorteile
  - weitgehende zeitliche Entkopplung von Sender und Empfänger
  - einfache, effiziente Implementierung (bei kurzen Nachrichten)
- Nachteile
  - keine Erfolgsgarantie für den Sender
  - Notwendigkeit der Zwischenpufferung (Kopieraufwand, Speicher-verwaltung,...) im Unterschied etwa zur synchronen Kommunikation
  - Gefahr des „Überrennens" des Empfängers bei zu häufigen Nachrichten → Flusssteuerung („flow control") notwendig

Rendezvous-Protokolle

- Synchron-mitteilungsorientierte Kommunikation

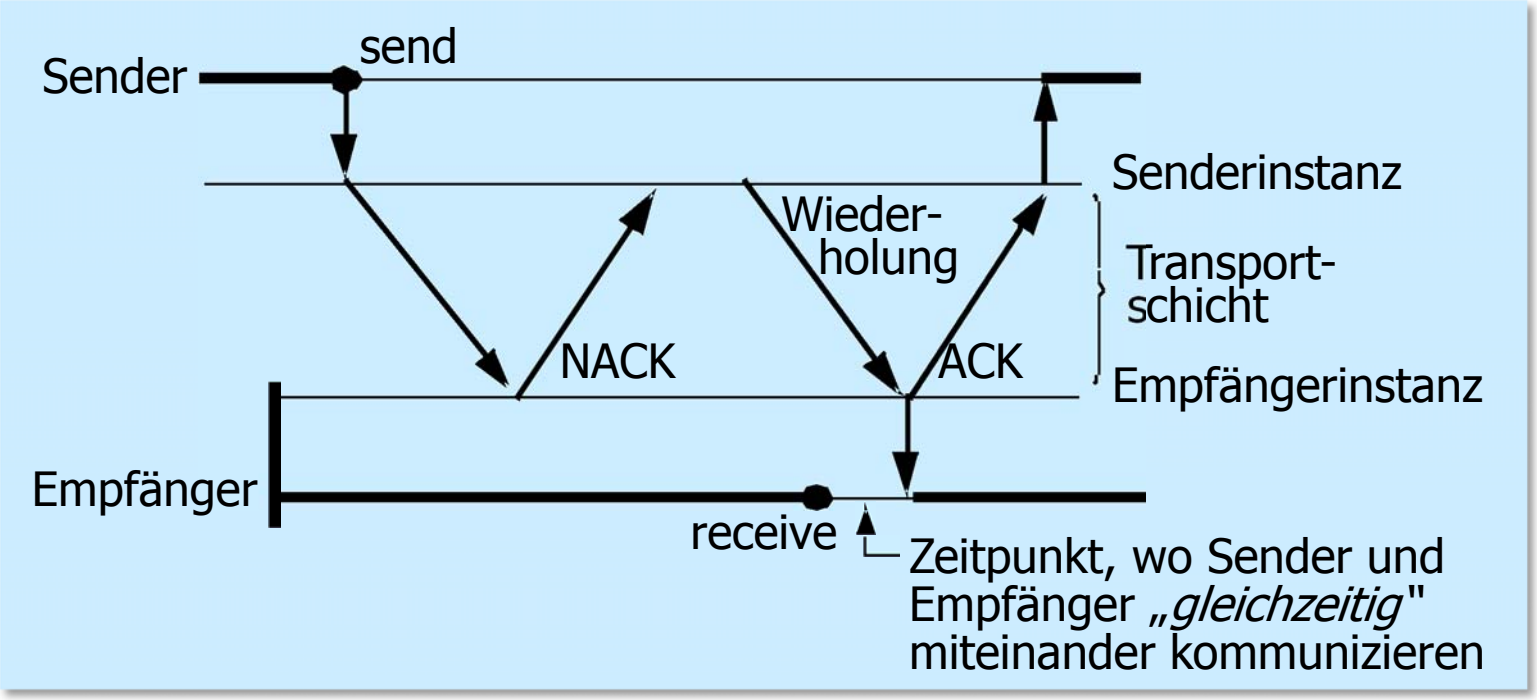

- Hier beispielhaft „Sender-first-Szenario“:
  Sender wartet als Erster („Receiver-first-Szenario“ analog)

Rendezvous-Protokolle (2)

- Rendezvous: Der erste wartet auf den anderen („Synchronisationspunkt“)
- Mit NACK / ACK (vgl. Bild) sind wenig Puffer nötig → aber aufwändiges Protokoll („busy waiting“)
  - Alternative 1: Statt NACK („negative ACK“): Nachricht auf Empfängerseite puffern (Nachteil: Platzbedarf für Puffer)
  - Alternative 2: Statt laufendem Wiederholungsversuch: Empfängerinstanz meldet sich bei Senderinstanz, sobald Empfänger bereit
- Insbesondere bei langen Nachrichten sinnvoll: Vorherige Anfrage, ob bei der Empfängerinstanz genügend Pufferplatz vorhanden ist, bzw. ob Empfänger bereits Synchronisationspunkt erreicht hat

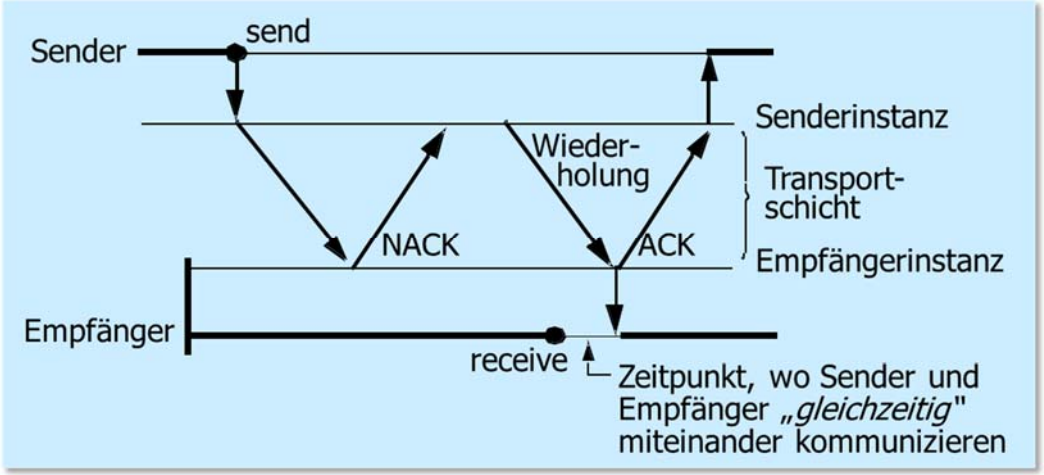

Hauptklassifikation von Kommunikationsmechanismen

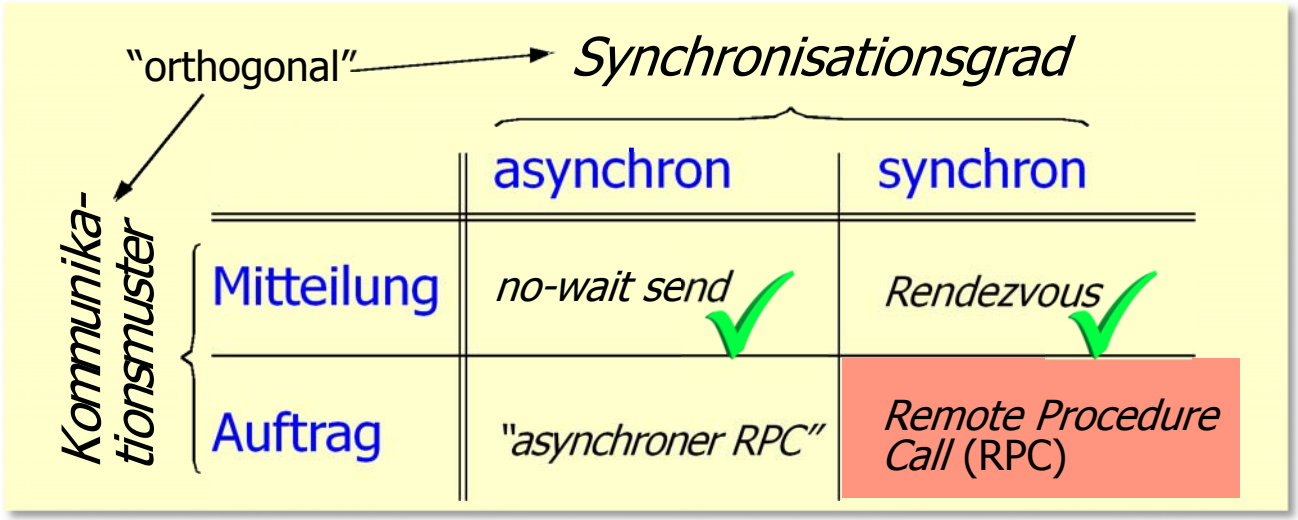

Kommunikation

– RPC –

Remote Procedure Call (RPC)

- Aufruf einer „entfernten Prozedur“
- Synchron-auftragsorientiertiertes Prinzip

Keine Parallelität zwischen Client und Server

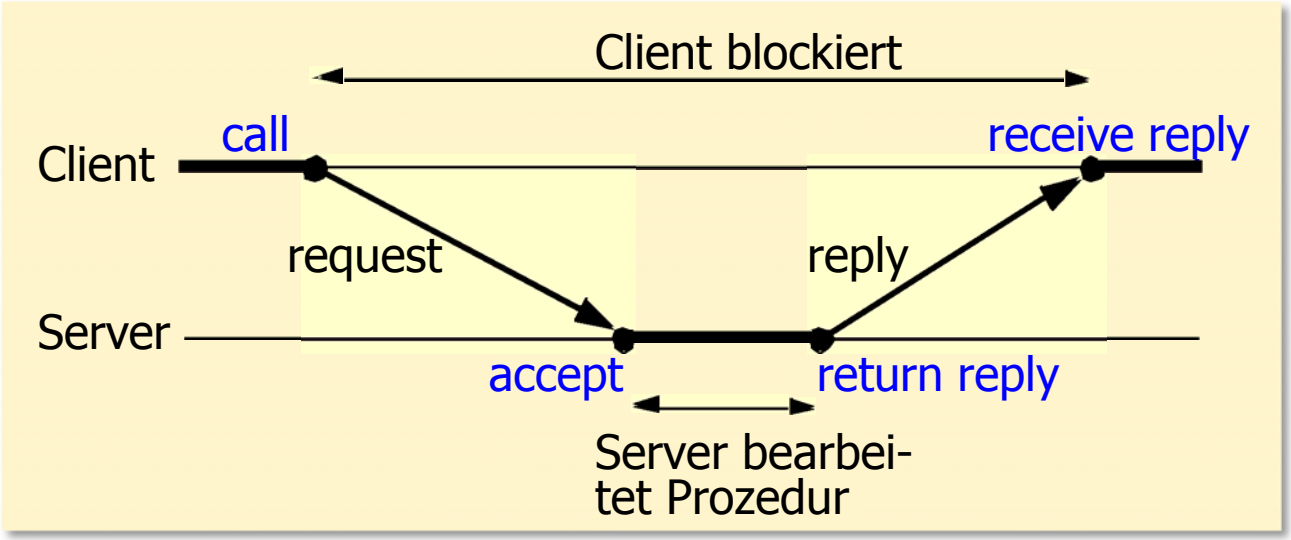

accept, return reply, receive reply etc. werden „unsichtbar“ durch Compiler bzw. Laufzeit-system erledigt

- Bezeichnung bei verteilten objektorientierten Systemen: „Remote Method Invocation“ (RMI), z.B. Java RMI

RPC: Pragmatik

- Soll dem klassischen Prozeduraufruf möglichst gleichen
  - klare Semantik für Anwender (Auftrag als „Unterprogramm“)
- Einfaches Programmieren
  - kein Erstellen von Nachrichten, kein Quittieren etc. auf Anwendungsebene
  - Syntax analog zu traditionellem lokalen Prozeduraufruf
  - Analoge Verwendung lokaler / entfernter Prozeduren
  - Typsicherheit (Datentypprüfung auf Client- und Serverseite möglich)
- Implementierungsproblem: „Verteilungstransparenz“
  - Verteiltheit so gut wie möglich verbergen

RPC: Implementierung

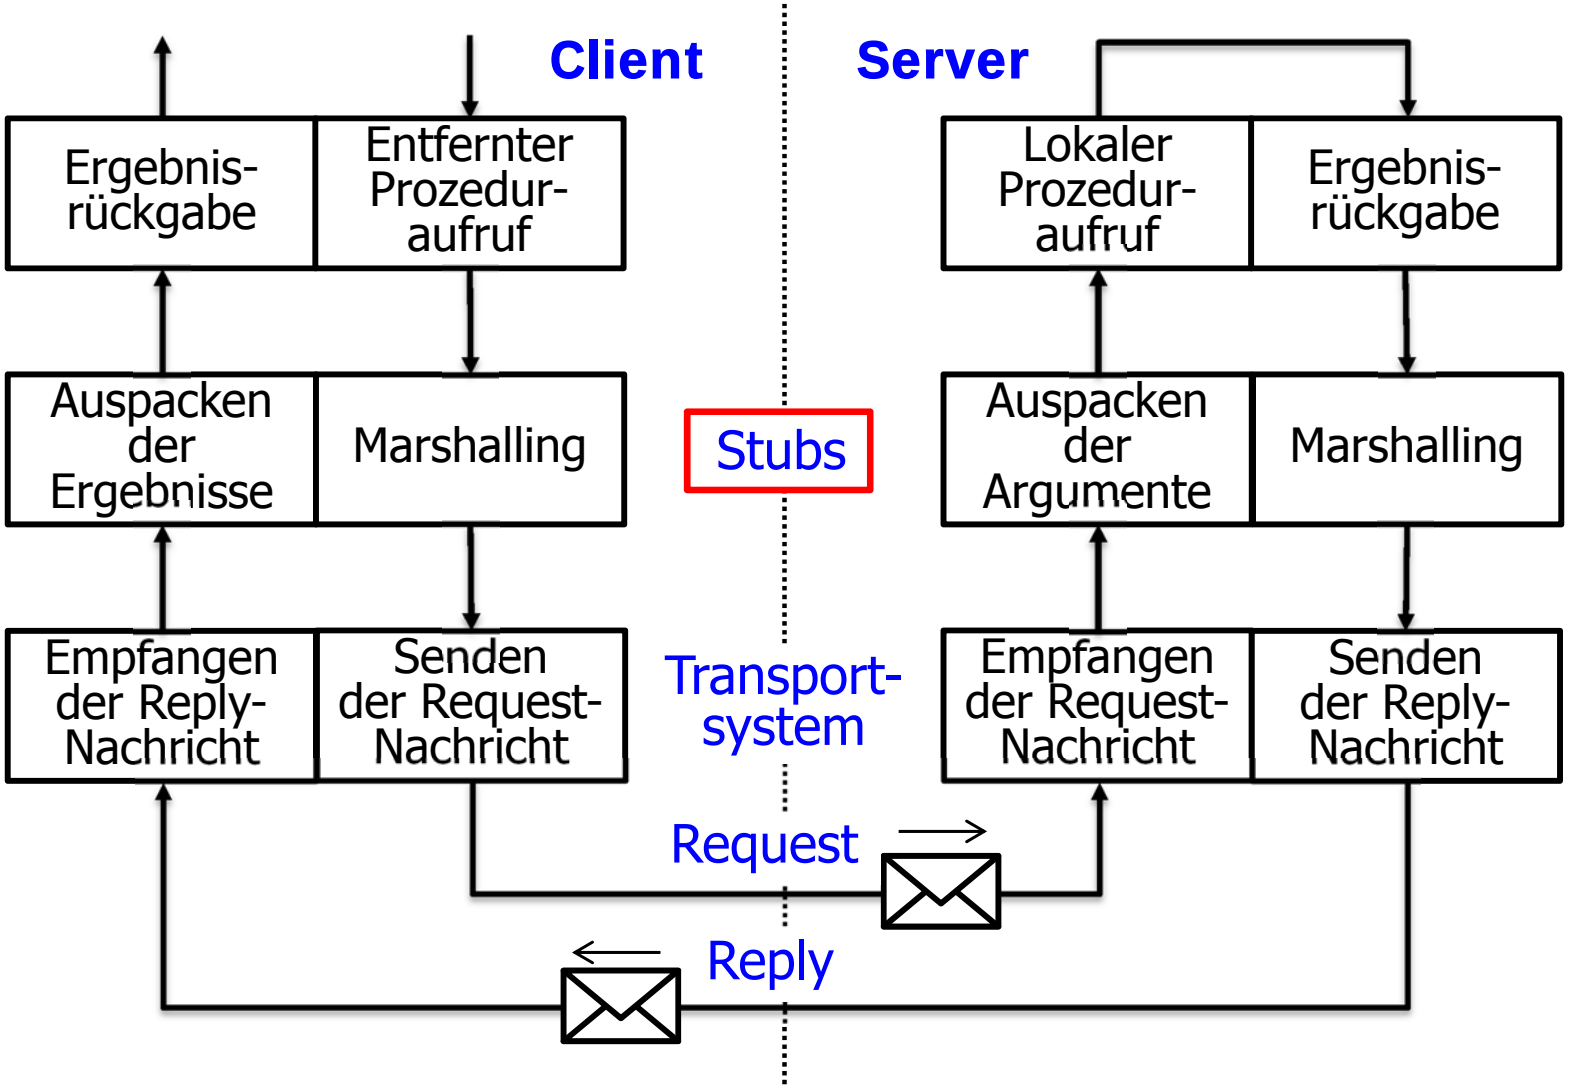

RPC: Stubs

- Stub = Stummel, Stumpf

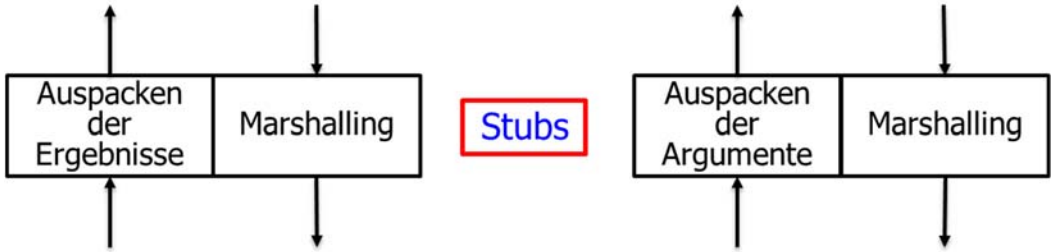

Client:

```
xxx ;
call S.X(out: a ; in: b);
xxx ;
```

Ersetzt durch ein längeres Programmstück (*Client-Stub*), welches u.a.:

- Parameter a in eine Nachricht packt
- Nachricht an Server S versendet
- Timeout für die Antwort setzt
- Antwort entgegennimmt (oder evtl. exception bei timeout auslöst)
- Ergebnisparameter b mit den Werten der Antwortnachricht setzt

RPC: Stubs (2)

- Wirken als „proxy“
  - lokale Stellvertreter des entfernten Gegenübers

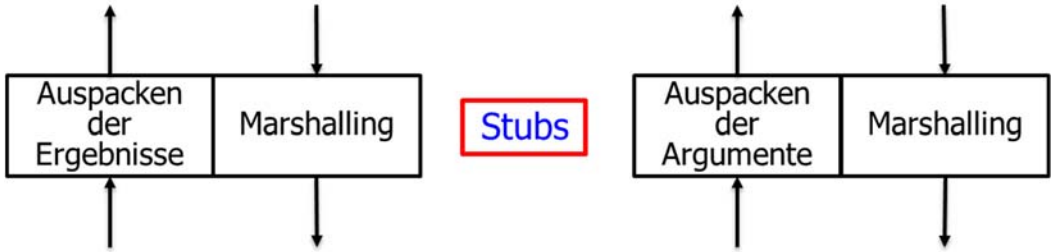

- Simulieren einen lokalen Aufruf
- Sorgen für Zusammenbau und Entpacken von Nachrichten
- Konvertieren Datenrepräsentationen
  - bei heterogenen Umgebungen
- Können oft weitgehend automatisch generiert werden
  - z.B. aus dem Client- oder Server-Code sowie evtl. einer Schnittstellenbeschreibung
- Steuern das Übertragungsprotokoll
  - z.B. zur Behebung von Übertragungsfehlern

Kommunikation mit Proxies

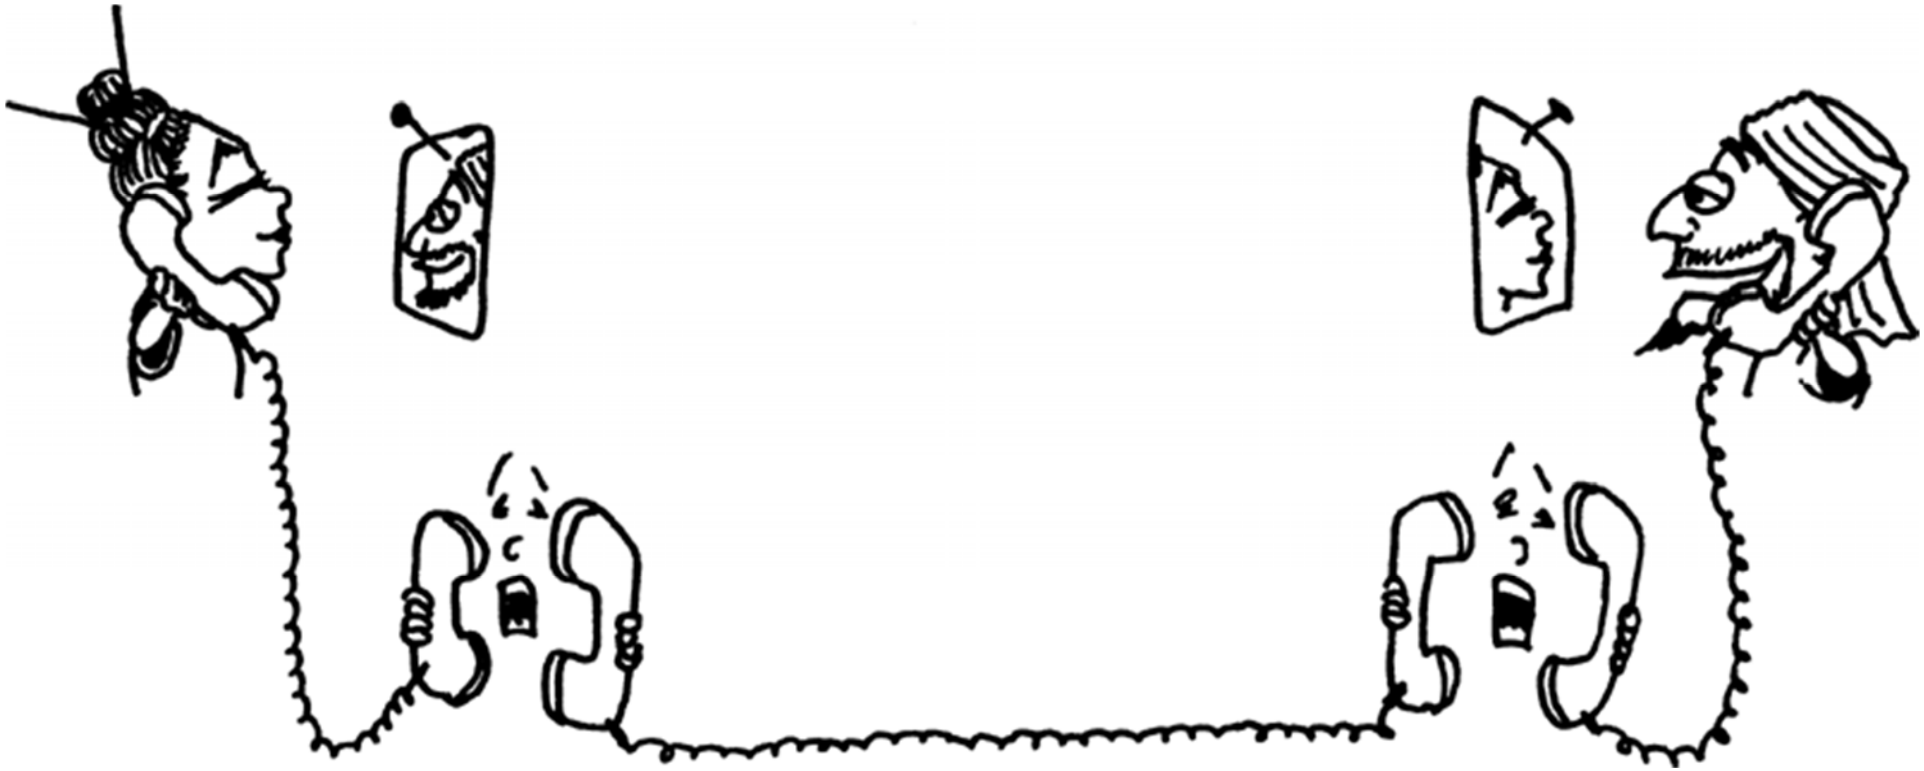

(Aus dem Buch: „Java ist auch eine Insel“)

RPC: Kompatibilität von Datenformaten und -strukturen?

- Problem: Parameter komplexer Datentypen wie
  - Records, Strukturen
  - Objekte
  - Referenzen, Zeiger
  - Zeigergeflechte

  } sollen Adressen über Rechner- / Adressraumgrenzen erlaubt sein?
  - sollen Referenzen symbolisch, relativ,... interpretiert werden?
  - wie wird Typkompatibilität sichergestellt?

- Problem: RPCs werden oft in heterogenen Umgebungen eingesetzt mit unterschiedlicher Repräsentation, z.B. von
  - Strings (Längenfeld ↔ '\0' als Endekennung)
  - Character (ASCII ↔ Unicode)
  - Arrays (zeilen- ↔ spaltenweise)
  - Zahlen (niedrigstes Bit vorne oder hinten)

RPC: Marshalling

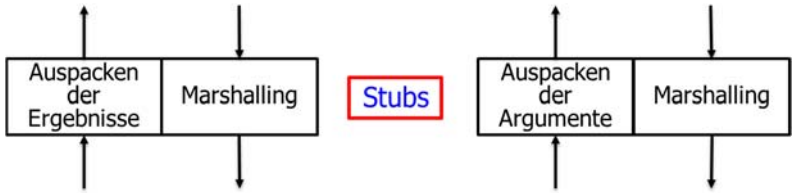

Marshalling: Zusammenstellen der Nachricht aus den aktuellen Prozedurparametern

- evtl. dabei geeignete „standardisierte" Codierung (komplexer) Datenstrukturen
- Glätten („flattening") komplexer (evtl. verzeigerter) Datenstrukturen zu einer Sequenz von Basistypen (evtl. mit Strukturinformation)
- umgekehrte Transformation wird gelegentlich als „unmarshalling" bezeichnet

RPC: Datenkonversion

1) Umwandlung in eine gemeinsame Standardrepräsentation

- z.B. XML bei Web-Applikationen

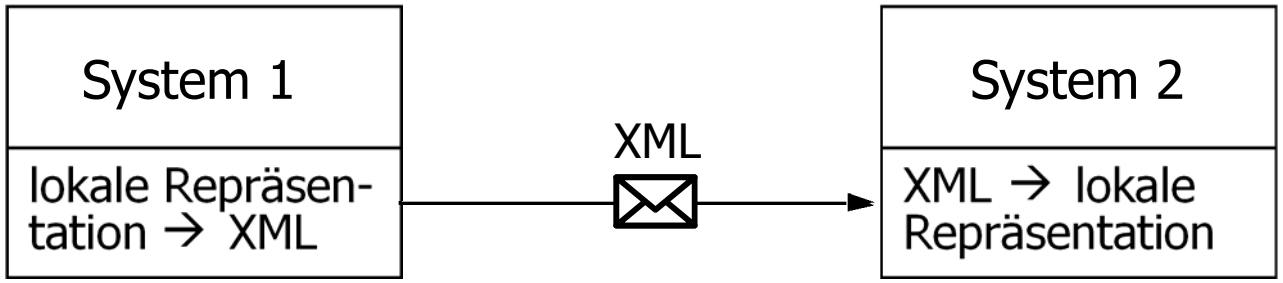

- Beachte: Jeweils zwei Konvertierungen erforderlich; für jeden Datentyp jeweils Kodierungs- und Dekodierungsroutinen vorsehen

RPC: Datenkonversion (2)

2) Oder sendeseitig lokale Datenrepräsentation verwenden und dies in der Nachricht vermerken
   - „Receiver makes it right“
   - Vorteil: bei gleichen Systemumgebungen / Computertypen ist keine (doppelte) Umwandlung nötig
   - Empfänger muss aber die Senderrepräsentation kennen und mit ihr umgehen können

Generell: Datenkonversion ist überflüssig, wenn sich alle Kommunikationspartner von vornherein an einen gemeinsamen Standard halten

RPC: Transparenzproblematik

- RPCs sollten so weit wie möglich lokalen Prozedur-aufrufen (als bekanntes Programmierparadigma) gleichen, es gibt aber einige inhärente Unterschiede
  - z.B. bei Nichterreichbarkeit oder Absturz des Servers; RPCs dauern auch länger als lokale Prozeduraufrufe
- Beachte auch: Client-/Serverprozesse haben evtl. unterschiedliche Lebenszyklen
  - Server könnte z.B. noch nicht oder nicht mehr oder in einer „falschen" (z.B. veralteten) Version existieren
  - Anwender oder Programmierer eines Clients hat typischerweise keine Kontrolle über den Server

RPC: Leistungstransparenz?

- RPC i.Allg. wesentlich langsamer als lokaler Prozeduraufruf
- Kommunikationsbandbreite ist bei umfangreichen Datenmengen relevant
- Oft ungewisse, variable Verzögerungen

Effizienzzanalyse eines RPC-Protokolls

(zitiert nach A. Tanenbaum)

Null-RPC (Nutznachricht der Länge 0, keine Auftragsbearbeitung)

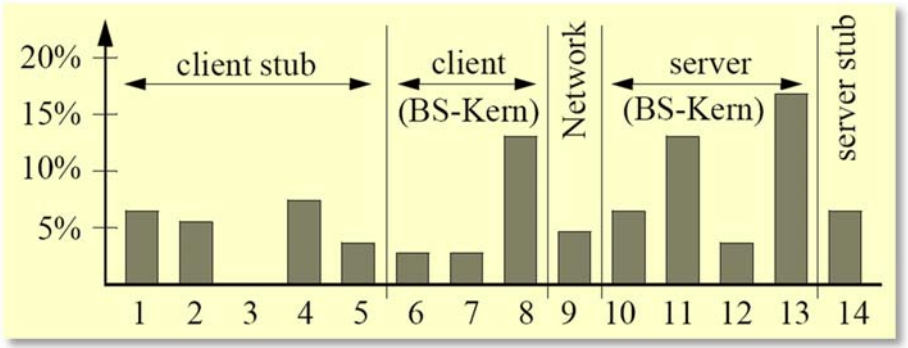

1440 Byte-Nutznachricht (ebenfalls keine Auftragsbearbeitung)

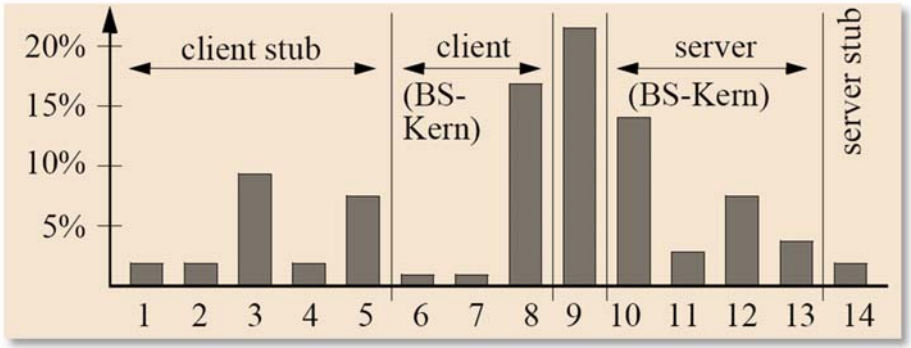

1. Call stub
2. Get message buffer
3. Marshal parameters
4. Fill in headers
5. Compute UDP checksum
6. Trap to kernel
7. Queue packet for transmission
8. Move packet to controller over the bus
9. Network transmission time
10. Get packet from controller
11. Interrupt service routine
12. Compute UDP checksum
13. Context switch to user space
14. Server stub code

- Eigentliche Übertragung (9) kostet relativ wenig
- Rechenoverhead (Prüfsummen, Header etc.) ist nicht vernachlässigbar
- Bei kurzen Nachrichten ist Kontextwechsel zwischen Anwendung und Betriebssystem relevant (6, 13)
- Mehrfaches Kopieren kostet viel

Antwortnachricht ist ähnlich aufwändig

RPC: Ortstransparenz?

- Meist muss Server („Zielort“) bei Adressierung explizit genannt werden
- Getrennte Adressräume von Client und Server
  - keine Kommunikation über globale Variablen möglich
  - → typischerweise keine Pointer / Referenzparameter als Parameter möglich

RPC: Fehlertransparenz?

- Es gibt mehr Fehlerfälle
  - beim klassischen Prozeduraufruf gilt: Client = Server → „alles oder nichts“
  - hier: partielle („einseitige“) Systemausfälle typisch (Server-Absturz, Client-Absturz)

⇒ Fehlerproblematik ist also „kompliziert“!

- Nachrichtenverlust
  - ununterscheidbar von zu langsamer Nachricht!
- Client und Server haben zumindest zwischenzeitlich eine unterschiedliche Sicht des Zustands der „RPC-Transaktion“
  - crash kann im „ungünstigsten Moment“ des RPC-Protokolls erfolgen

Typische RPC-Fehlerursachen

Wir besprechen nachfolgend 4 typische Fehlerursachen:

1. Verlorene Request-Nachricht
2. Verlorene Reply-Nachricht
3. Server-Crash
4. Client-Crash

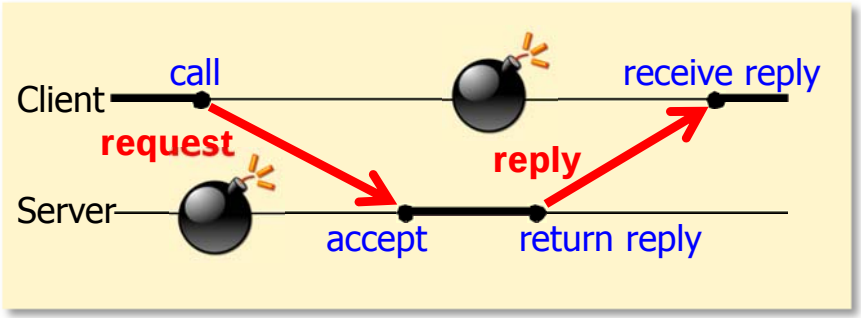

Grundprobleme:

- Client / Server haben temporär eine inkonsistente Sicht
- Timeout beim Client kann verschiedene Ursachen haben (verlorener Request, verlorenes Reply, langsamer Request bzw. Reply, langsamer Server, abgestürzter Server,...) → Fehlermaskierung schwierig

Verlorene Request-Nachricht

- Gegenmassnahme:
  Nach Timeout (= kein Reply) die Request-Nachricht erneut senden

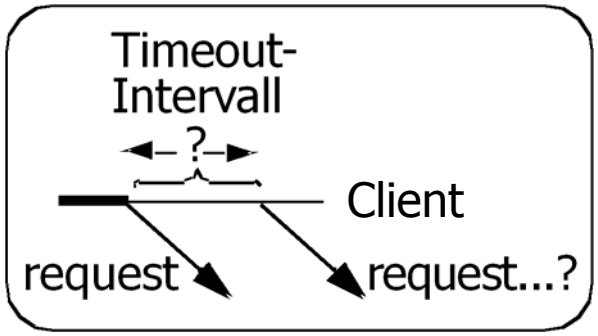

- Probleme:
  - Wie viele Wiederholungsversuche maximal?
  - Wie gross soll der Timeout sein?
  - Was, wenn die Request-Nachricht gar nicht verloren war, sondern Nachricht oder Server untypisch langsam?

Verlorene Request-Nachricht (2)

- Probleme, wenn Nachricht tatsächlich gar nicht verloren:
  - Doppelte Request-Nachricht!
    (Gefährlich bei serverseitig nicht-idempotenten Operationen!)
  - Server sollte solche Duplikate erkennen (Denkübung: Benötigt er dafür einen Zustand? Genügt es, wenn der Client Duplikate als solche kennzeichnet? Genügen Sequenznummern? Zeitmarken?)
  - Würde das Quittieren der Request-Nachricht etwas bringen?

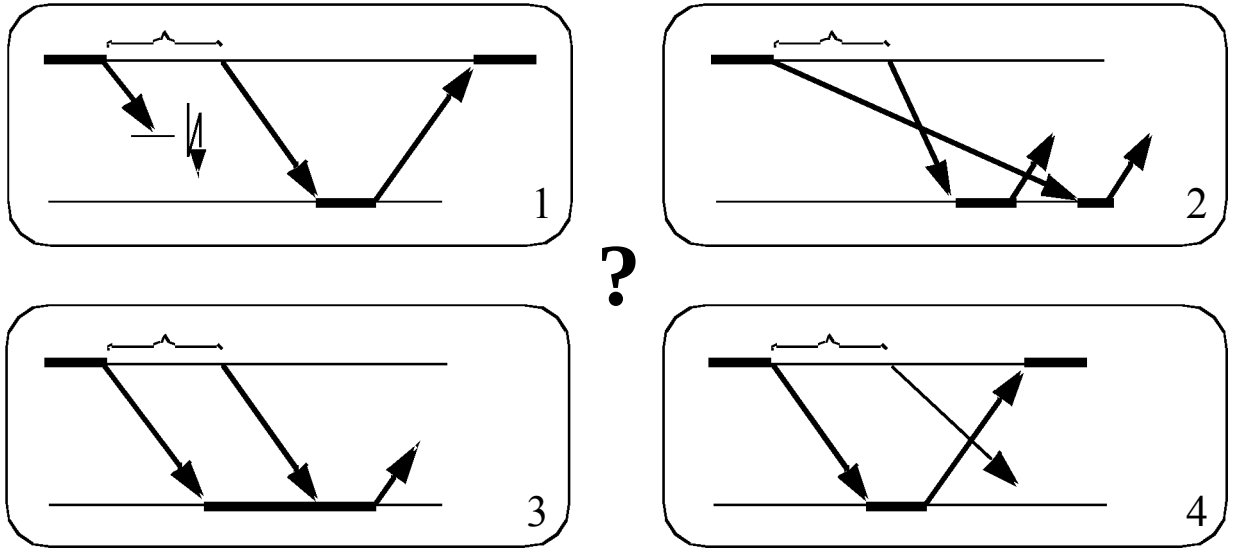

Bei automatischer Wiederholung von Request-Nachrichten ist eine Vielzahl möglicher Fälle zu unterscheiden

Verlorene Reply-Nachricht

- Gegenmassnahme 1:
  analog zu verlorener Request-Nachricht
  - also: Anfrage bei Timeout wiederholen

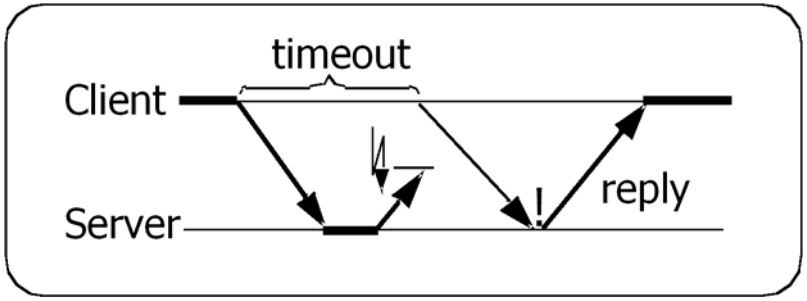

- Probleme:
  - vielleicht ging aber tatsächlich der Request verloren?
  - oder der Server war nur langsam und arbeitet noch?
  - ist aus Sicht des Clients nicht unterscheidbar!

Verlorene Reply-Nachricht (2)

- Gegenmassnahme 2:
  Server hält eine „Historie" versendeter Replies
  - falls Server Request-Duplikate erkennt und den Auftrag bereits ausgeführt hat: letztes Reply erneut senden, ohne die Prozedur nochmal auszuführen
  - pro Client muss nur das neueste Reply gespeichert werden
- Bei vielen Clients u.U. dennoch Speicherplatzprobleme:
  → Historie nach „einiger" Zeit löschen bzw. kürzen
  - und wenn man ein gelöschtes Reply später dennoch braucht?
  - ist in diesem Zusammenhang ein ack eines Reply sinnvoll?

Server-Crash

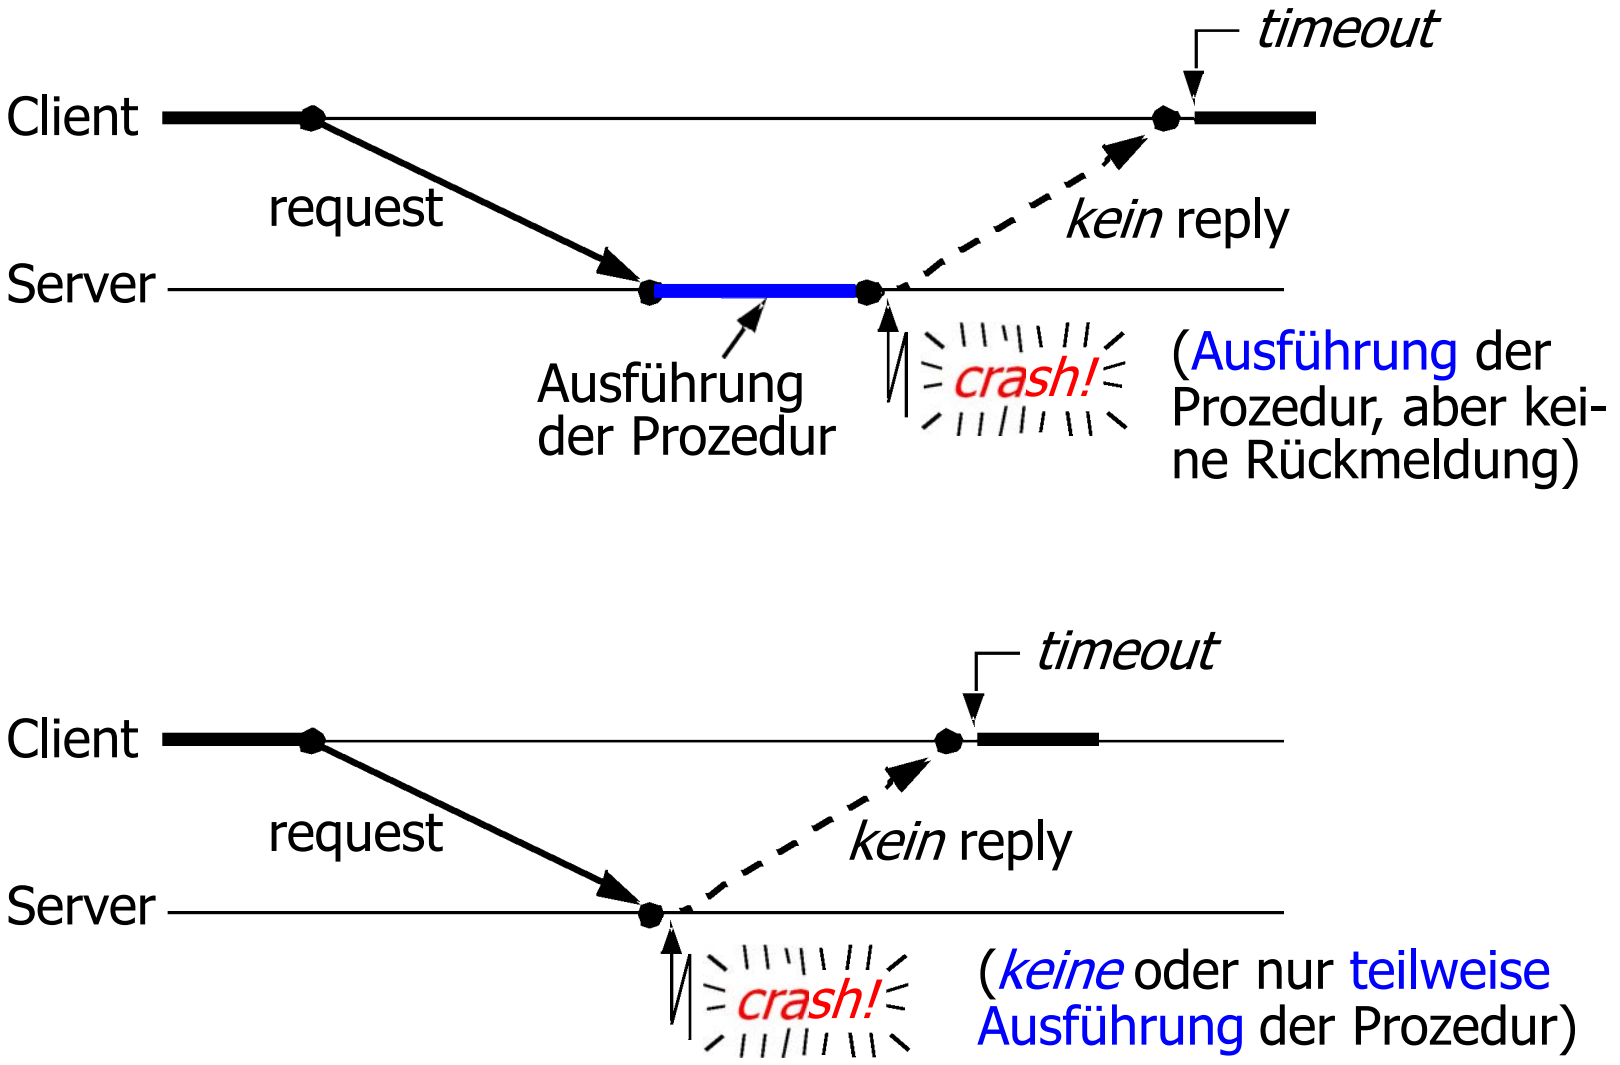

Server-Crash (2)

- Probleme: Wie soll der Client obige Fälle unterscheiden?
  - ebenso: Unterschied zu verlorenem request bzw. reply?
  - Sinn und Erfolg konkreter Gegenmassnahmen hängt u.U. davon ab!
  - Client meint evtl. zu Unrecht, dass ein Auftrag nicht ausgeführt wurde (→ falsche Sicht des Zustandes!)
- Evtl. Probleme nach einem Server-Restart
  - z.B. „Locks", die noch bestehen (Gegenmassnahmen?) bzw. allgemein: „verschmutzter" Zustand durch frühere Inkarnation
  - typischerweise ungenügend Information, um in alte Transaktionszustände problemlos wieder einzusteigen

Client-Crash

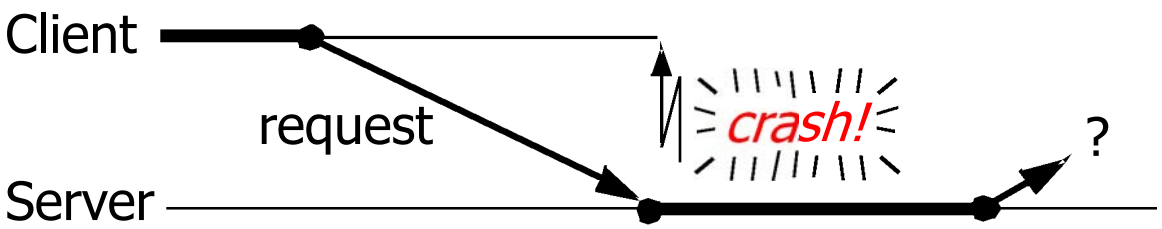

- Beziehungsweise einem Crash analoges Problem: Client mittlerweile nicht mehr am reply interessiert

- Reply des Servers wird nicht abgenommen
  - Server wartet z.B. vergeblich auf eine Bestätigung (wie unterscheidet der Server dies von langsamen Clients oder langsamen Nachrichten?)
  - blockiert i.Allg. Ressourcen beim Server!

Client-Crash (2)

- Problem: „Orphans“ (Waisenkinder) beim Server
  - Prozesse, deren Auftraggeber nicht mehr existiert
- Nach Restart könnte ein Client versuchen, Orphans zu terminieren (z.B. durch Benachrichtigung der Server)
  - Orphans könnten aber bereits andere RPCs abgesetzt haben, weitere Prozesse gegründet haben,...
- Pessimistischer Ansatz: Server fragt bei laufenden Aufträgen von Zeit zu Zeit und vor wichtigen Operationen beim Client zurück (ob dieser noch existiert)
- „Sehr“ alte Prozesse, die für einen Auftrag gegründet wurden, werden als Orphans angesehen und terminiert

RPC-Fehlersemantik-Klassen

- Operationale Sichtweise:
  - Wie wird nach einem Timeout auf (vermeintlich?) nicht eintreffende Nachrichten, wiederholte Requests, gecrashte Prozesse reagiert?

---

1. Maybe-Semantik:
   - Keine Wiederholung von Requests
   - Einfach und effizient
   - Keinerlei Erfolgsgarantien → nur ausnahmsweise anwendbar
   - Mögliche Anwendungsklasse: z.B. Auskunftsdienste (Anwendung kann es evtl. später noch einmal probieren, wenn keine Antwort kommt)

RPC-Fehlersemantik-Klassen (2)

2. At-least-once-Semantik:
   - Automatische Wiederholung (evtl. mehrfach) von Requests
   - Keine Duplikatserkennung (zustandsloses Protokoll auf Serverseite)
   - Akzeptabel bei idempotenten Operationen (z.B. Lesen einer Datei)

1) und 2) werden etwas euphemistisch oft als „best effort" bezeichnet

---

„Better than best effort"

3. At-most-once-Semantik:
   - Erkennen von Duplikaten (Sequenznummern, log-Datei etc.)
   - Keine wiederholte Ausführung der Prozedur, sondern evtl. erneutes Senden des (gemerkten) Reply
   - Geeignet auch für nicht-idempotente Operationen

RPC-Fehlersemantik-Klassen (3)

- Maybe → at-least-once → at-most-once → ...
  ist zunehmend aufwändiger zu realisieren

Ist „exactly-once“ machbar?

- Man begnügt sich daher, falls es die Anwendung erlaubt, oft mit einer billigeren aber weniger perfekten Fehlersemantik
- Motto: so billig wie möglich, so „perfekt“ wie nötig

Asynchroner RPC

- Andere Bezeichnung: „Remote Service Invocation“
- Auftragsorientiert, d.h. also: Antwortverpflichtung

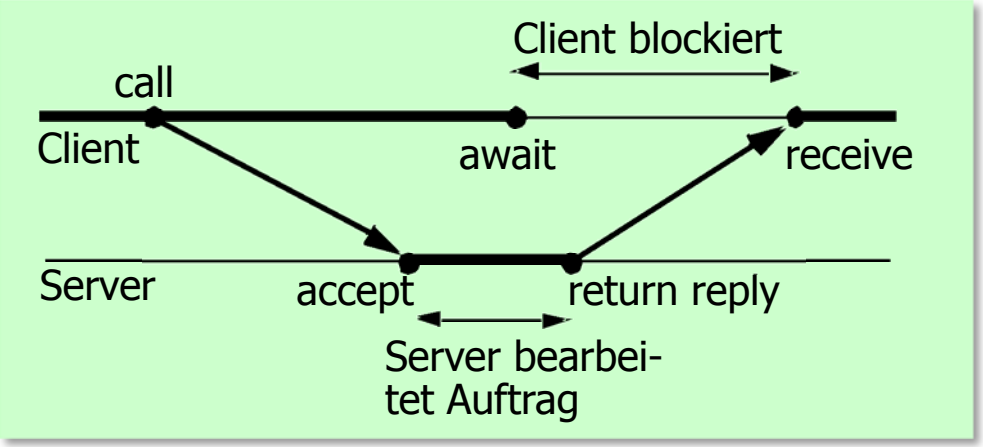

- Parallelverarbeitung von Client und Server möglich, solange Client noch nicht auf Resultat angewiesen

Asynchroner RPC: Zuordnung Auftrag/Ergebnisempfang

- Unterschiedliche Ausprägung auf Sprachebene möglich
  - „await" könnte z.B. einen bei „call" zurückgelieferten „handle" als Parameter erhalten, also z.B.: `Y = call X(…); … await(Y);`

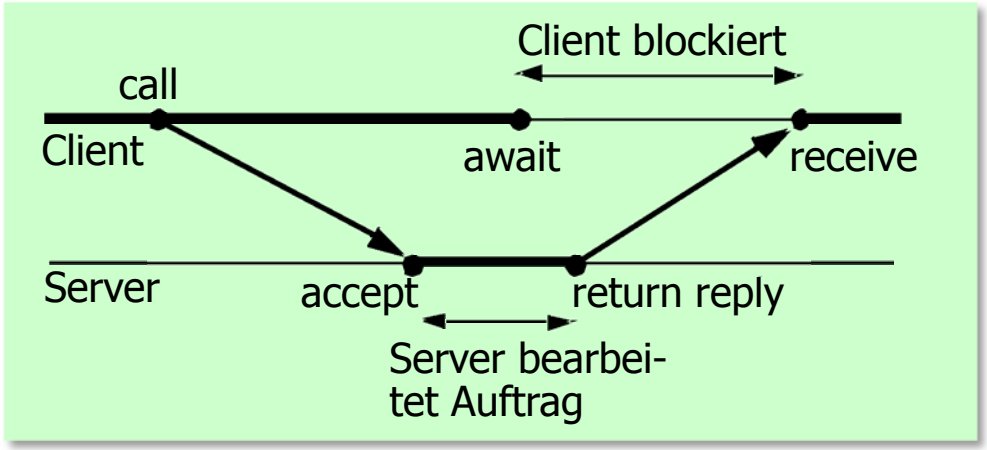

  - evtl. könnte die Antwort auch asynchron in einem eigens dafür vorgesehenen Anweisungsblock empfangen werden (vgl. Interrupt- oder Exception-Routine)

Asynchroner RPC: Future-Variable

- Spracheinbettung evtl. auch durch „Future-Variablen“
- Future-Variable = „handle“ auf das in anderem Thread parallel berechnetes Funktionsergebnis
- Programm blockiert nur dann, wenn der Wert der Future-Variablen bei ihrer Nutzung noch nicht feststeht
- Beispiel (Scala):

```
...
val x = future(callRPC())
... // continue local computation
println(x()) // await x iff necessary
```

Weiteres zu RPCs in der Praxis

Wir besprechen nachfolgend 4 ergänzende Aspekte:

1. Rückrufe
2. Context-Handles
3. Broadcast bzw. Multicast
4. Sicherheit

Rückrufe („call back RPC“)

- Temporärer Rollentausch
  von Client und Server
  - um eventuell bei langen Aktionen Zwischenresultate zurückzumelden
  - um eventuell weitere Daten vom Client anzufordern
- Client muss Rückrufadresse beim call übergeben

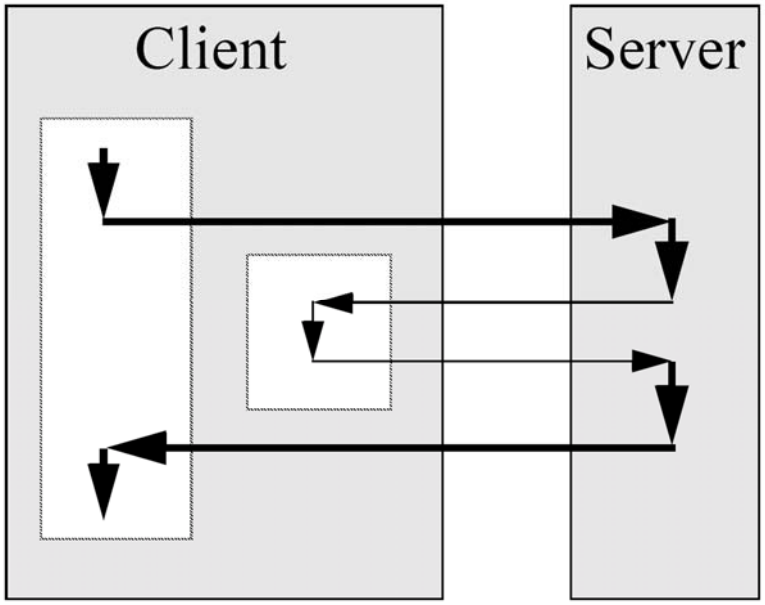

Context-Handles

- Struktur mit Kontextinformation zur Verwaltung von Zustandsinformation über mehrere Aufrufe hinweg
  - vgl. „cookies“: kleine Textdatei, die ein Web-Server einem Browser (= Client) schickt und die im Browser gespeichert wird
- Context-Handles werden vom Server dynamisch erzeugt und an den Client (bei „reply“) zurückgegeben
- Client kann diese beim nächsten Aufruf (unverändert) wieder mitsenden
  - Server „erinnert“ sich so an den Kontext
- Vorteil: Server selbst arbeitet „zustandslos“

Broadcast / Multicast

- Request wird „gleichzeitig“ an mehrere Server geschickt
  - Multicast: an eine Teilmenge
  - Broadcast: an „alle“

- RPC ist beendet mit der ersten empfangenen Antwort oder Client hat die Möglichkeit, nach einer Antwort auf eine weitere Antwort zu warten

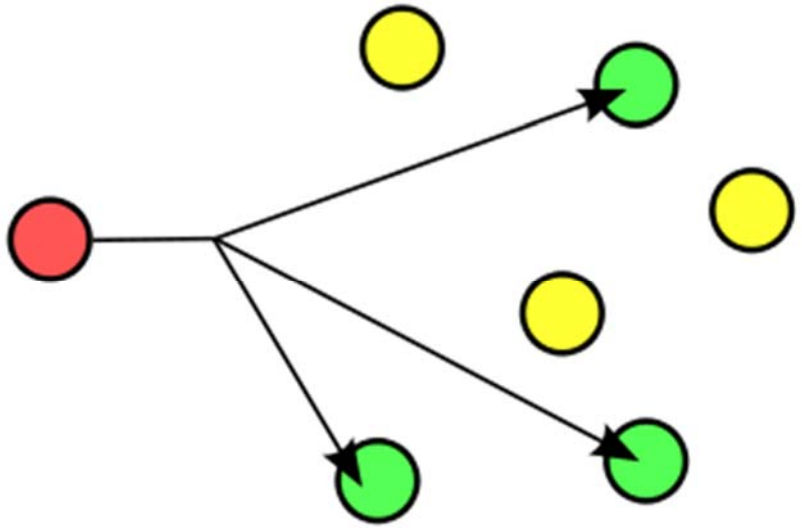

Sicherheit

- Oft gibt es wählbare Sicherheitsstufen, z.B.:
  - Authentifizierung bei Aufbau der Verbindung (“binding”)
  - Authentifizierung pro RPC-Aufruf oder pro Nachricht
  - Ende-zu-Ende-Verschlüsselung der zugrundeliegenden Nachrichten
  - Schutz gegen Verfälschung
    (digitale Signatur, verschlüsselte Prüfsumme etc.)

Beispiel „Secure RPC“
(als Teil des „SUN RPC“)

- Client und Server vereinbaren (geheim) einen Session-Key K
  - wird zum Verschlüsseln der Nachrichten genutzt
- Jeder Request enthält einen mit K kodierten Zeitstempel
- Erster Request enthält zusätzlich verschlüsselt eine Zeitfenstergrösse W als zeitliches Toleranzintervall sowie (ebenfalls verschlüsselt) W-1
  - „zufälliges“ Generieren einer ersten Nachricht ist so nahezu unmöglich
  - replay (bei kleinem W) ist ebenfalls erfolglos
  - W ist verschlüsselt, auch um Angreifern keine Information über die Fenstergrösse zu geben
- Server akzeptiert einen Request nur, wenn:
  - Zeitstempel grösser als letzter Zeitstempel und
  - Zeitstempel innerhalb des Zeitfensters
- Zur Authentifizierung enthält die Antwort des Servers (verschlüsselt!) den letzten erhaltenen Zeitstempel-1

Kommunikation

– Weitere Konzepte –

Mehr zu allgemeinen Kommunikationsprinzipien

Im Folgenden:

- Port-Konzept
- Kommunikationskanäle
- Ereigniskanäle
- Timeouts bei der Kommunikation

Das Port-Konzept

- Port = adressierbarer Kommunikationsendpunkt, der die interne Struktur eines Nachrichtenempfängers abkapselt
- Ein Prozess kann mehrere (evtl. typisierte) Ports haben

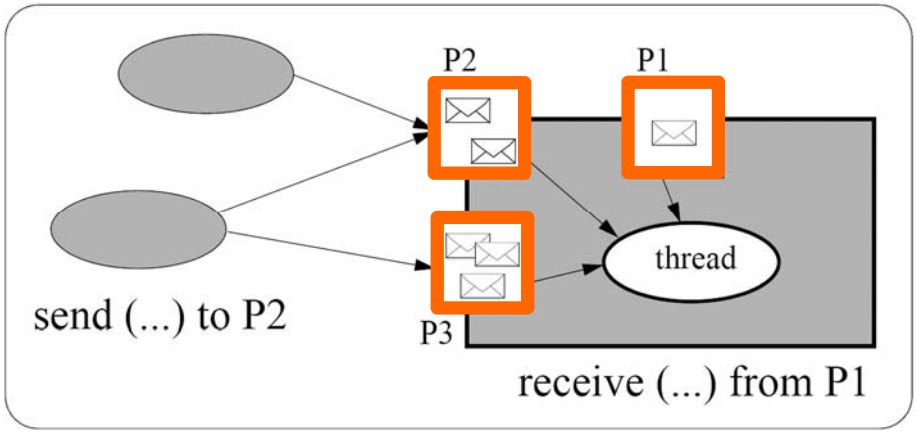

Diverse Varianten des Konzepts:

- Ports mit Stauräumen („message queues") für Nachrichten
- Möglichkeit, Ports dynamisch zu gründen oder auch zu schliessen und zu öffnen

- Neben solchen Eingangsports („In-Port") sind auch Ausgangsports („Out-Port") möglich
  - ein Prozess sendet dann an einen „seiner" Ausgangsports, nicht direkt an den Eingangsport eines Empfängers (→ „Kanäle", nächste Seite)

Kommunikationskanäle

- (Logische) Kanäle, z.B. eingerichtet mit Ports als Endpunkte
  - dazu je einen In- und Out-Port miteinander verbinden

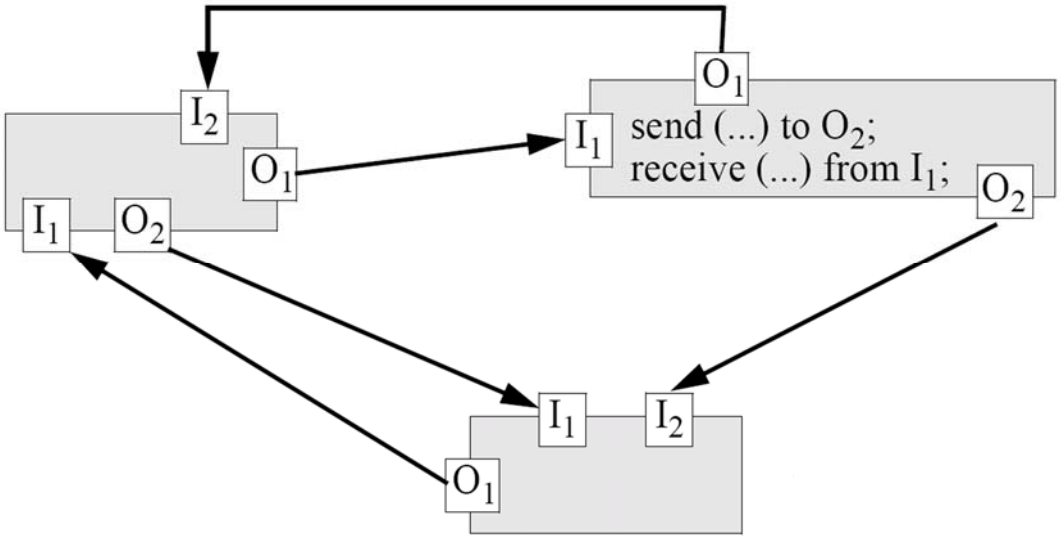

- Alternativ: Kanäle benennen und etwas *auf den Kanal senden* bzw. von ihm lesen
- Evtl. Broadcast-Kanäle: Nachricht geht an alle angeschlossenen Empfänger

- Flexibilität durch Umkonfiguration der Verbindungsstruktur
  - eigentlicher Adressat wird den Prozessen verborgen („abstrahiert“)
  - daher sind die Prozesse selbst von einer Umkonfiguration nicht betroffen

Ereigniskanäle / „Softwarebus“

- Kooperierende autonome Software-Komponenten
  - nicht notwendigerweise geographisch weit verteilt
  - mit i.Allg. getrennten Lebenszyklen
  - anonym: kennen nicht die Identität der anderen
  - Auslösen von „Ereignissen“ durch Sender
  - Reagieren auf Ereignisse beim Empfänger

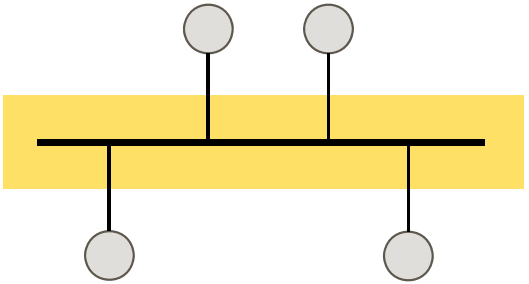

- Ereigniskanal als „Softwarebus“
  - agiert als Zwischeninstanz und verknüpft die Komponenten
  - registriert Interessenten (vgl. lookup service)
  - Dispatching eingehender Ereignisse
  - evtl. Puffern, Filtern, Umlenken von Ereignissen

Ereigniskanäle (2)

- Probleme
  - Ereignisse können „jederzeit“ ausgelöst werden, werden von Empfängern aber i.Allg. nicht jederzeit entgegengenommen (→ Pufferung?)
  - falls Komponenten nicht lokal, sondern geographisch verteilt sind → „übliche“ Probleme nachrichtenbasierter Kommunikation: Verzögerungen, evtl. verlorene Ereignisse, falsche Reihenfolge,…
- Beispiele
  - Microsoft-Komponentenarchitektur (.NET etc.)
  - „Distributed Events“ bei JavaBeans und Jini (event generator bzw. remote event listener)

Zeitüberwachter Nachrichtenempfang

- Idee: Receive soll max. eine gewisse Zeit lang blockieren
  - z.B. über Rückgabewert abfragen, ob Kommunikation erfolgreich war oder aber der Timeout zugeschlagen hat
- Im Timeout-Fall geeignete Recovery-Mass-nahmen treffen oder Exception auslösen
  - adäquate Wahl des Timeout-Werts oft schwierig

- Verwendung bei:
  - Echtzeitprogrammierung
  - Aufheben von Blockaden im Fehlerfall (z.B. bei abgestürztem Kommunikationspartner)
- Timeout analog auch beim blockierendem Senden sinnvoll

Zeitüberwachter Nachrichtenempfang (2)

- Sprachliche Einbindung z.B. so:

```
receive ... delay t
    {...}
  else
    {...}
end
```

Wird nach mindestens t Zeiteinheiten ausgeführt, wenn bis dahin noch keine Nachricht empfangen

- Beachte: Es wird mindestens so lange auf Kommunikation gewartet – danach kann im Prinzip (wie immer!) noch beliebig viel Zeit bis zur Fortsetzung des Ablaufs verstreichen
- Was könnte „delay 0" bedeuten? Ist das sinnvoll?

Client / Server

Client-Server-Architektur

Ist bekannt

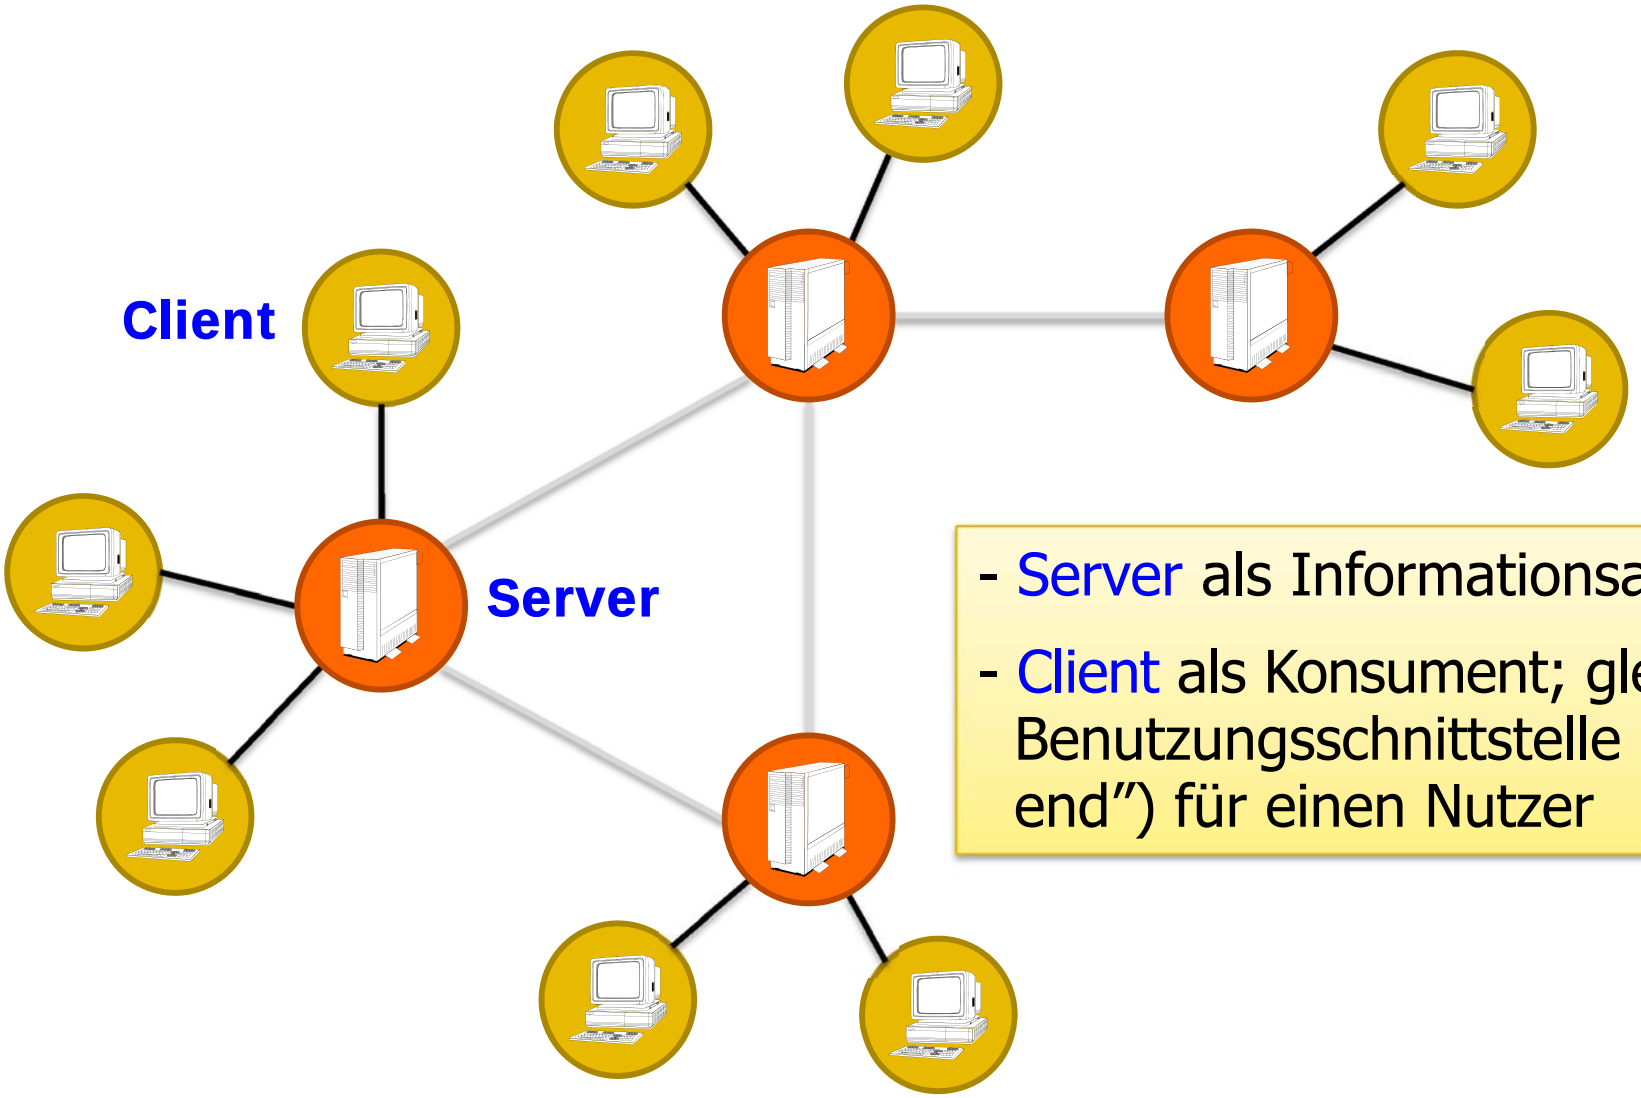

- Server als Informationsanbieter
- Client als Konsument; gleichzeitig Benutzungsschnittstelle (“front end”) für einen Nutzer

Gleichzeitige Server-Aufträge

- Problem: Oft viele „gleichzeitige“ Aufträge

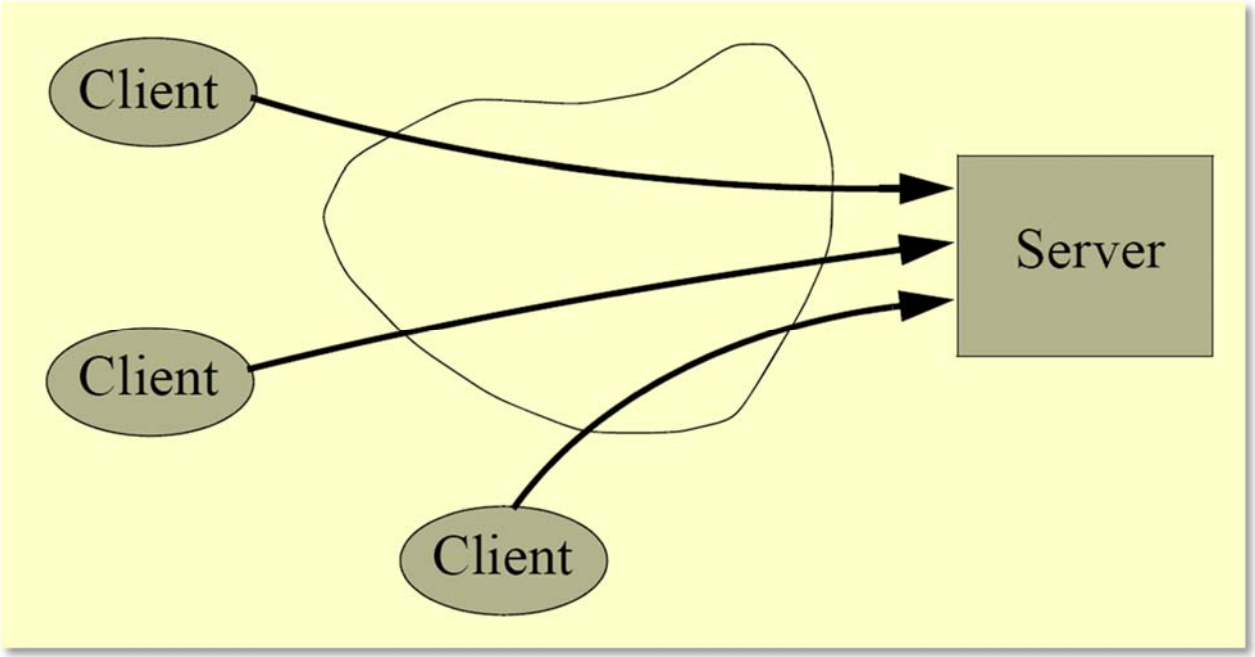

- Diverse Realisierungsmöglichkeiten →

Iterativer Server („single threaded“)

- Iterative Server bearbeiten nur einen einzigen Auftrag pro Zeit
  - eintreffende Anfragen während der Auftragsbearbeitung: in Warteschlange puffern, abweisen oder schlichtweg ignorieren
  - einfach zu realisieren
  - bei trivialen Diensten mit kurzer Bearbeitungszeit oft sinnvoll, ansonsten konkurrente Server

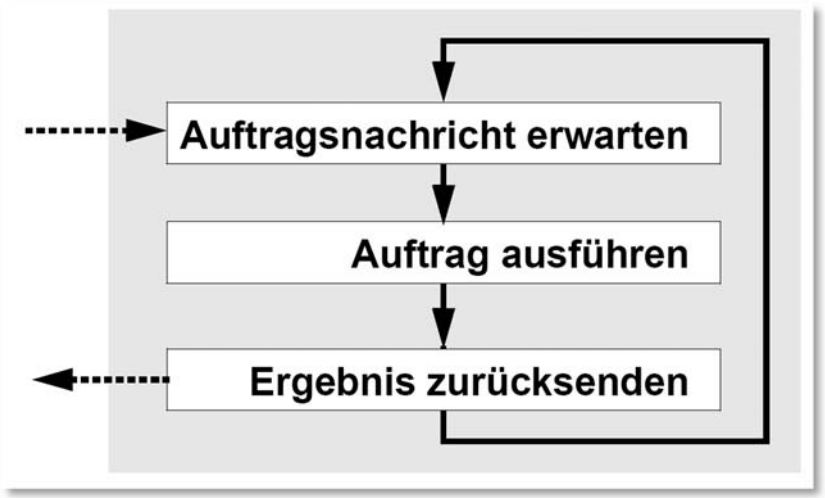

Konkurrente Server

- (Quasi-)gleichzeitige Bearbeitung mehrerer Aufträge
  - sinnvoll (d.h. effizienter für Clients) bei längeren Aufträgen

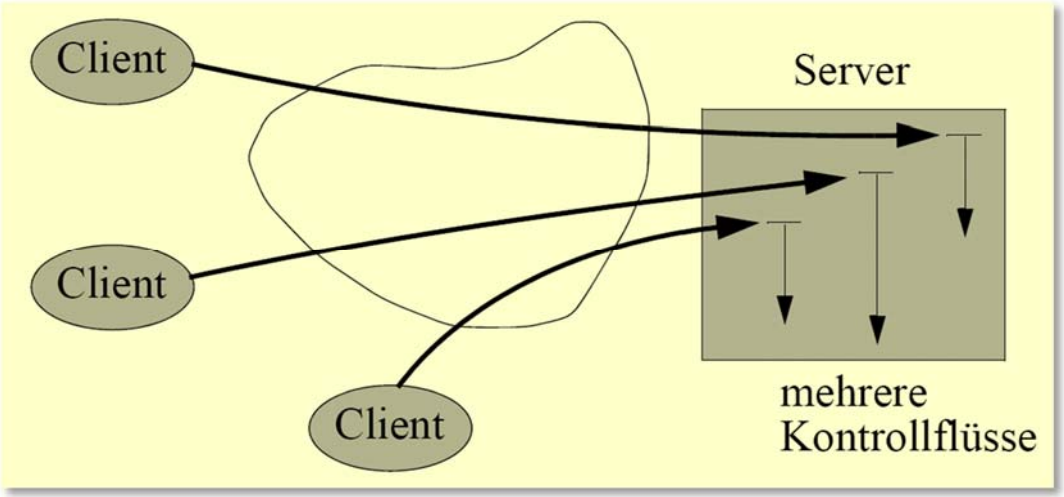

Verschiedene Realisierungen

- Verbund mehrerer Server-Maschinen (Cluster, Cloud)
- mehrere Prozessoren bzw. Multicore-Prozessoren
- dynamische (oder vorgegründete Prozesse / Threads)

- Beachte: Auch bei Monoprozessor-Systemen ist Timesharing sinnvoll: Nutzung erzwungener Wartezeiten während einer Auftragsbearbeitung für Aufträge anderer Klienten; kürzere mittlere Antwortzeiten bei Jobmix aus langen und kurzen Aufträgen

Konkurrente Server mit dynamischen Handler-Prozessen

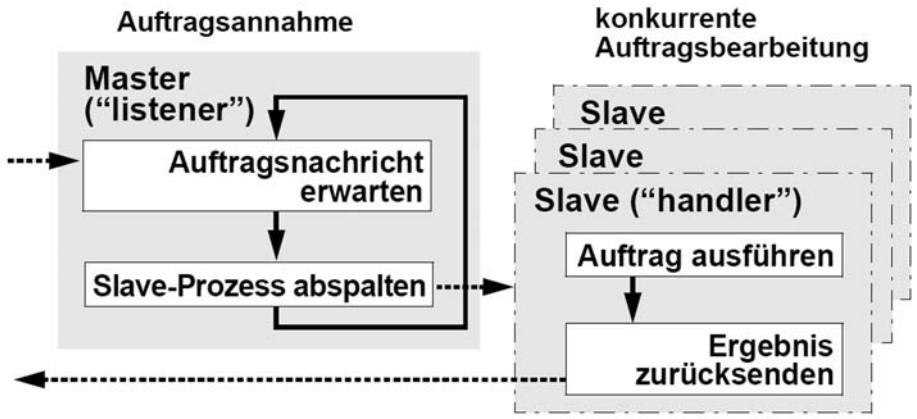

Für jeden Auftrag gründet der Master („Dispatcher") einen neuen Slave-Prozess und wartet dann auf einen neuen Auftrag

Alternative: „Process preallocation": Feste Anzahl statischer Slave-Prozesse (evtl. effizienter, da Wegfall der Erzeugungskosten)

- Neu gegründeter Slave („handler") übernimmt den Auftrag
- Client kommuniziert dann direkt mit dem Slave
- Slaves sind typischerweise Leichtgewichtsprozesse („threads")
- Slaves terminieren i.Allg. nach Beendigung des Auftrags
- Die Anzahl gleichzeitiger Slaves sollte begrenzt werden

Master/Slave

Subject: Identification of equipment sold to LA County
Date: Tue, 18 Nov 2003 14:21:16 -0800
From: "Los Angeles County"

The County of Los Angeles actively promotes and is committed to ensure a work environment that is free from any discriminatory influence be it actual or perceived. As such, it is the County's expectation that our manufacturers, suppliers and contractors make a concentrated effort to ensure that any equipment, supplies or services that are provided to County departments do not possess or portray an image that may be construed as offensive or defamatory in nature.

One such recent example included the manufacturer's labeling of equipment where the words "Master/Slave" appeared to identify the primary and secondary sources. Based on the cultural diversity and sensitivity of Los Angeles County, this is not an acceptable identification label.

We would request that each manufacturer, supplier and contractor review, identify and remove/change any identification or labeling of equipment or components thereof that could be interpreted as discriminatory or offensive in nature before such equipment is sold or otherwise provided to any County department.

Thank you in advance for your cooperation and assistance.

Joe Sandoval, Division Manager
Purchasing and Contract Services
Internal Services Department
County of Los Angeles

Multithreading beim Client-Server-Konzept

- Server-Threads: quasiparallele Bearbeitung von Aufträgen
  - Server bleibt ständig empfangsbereit

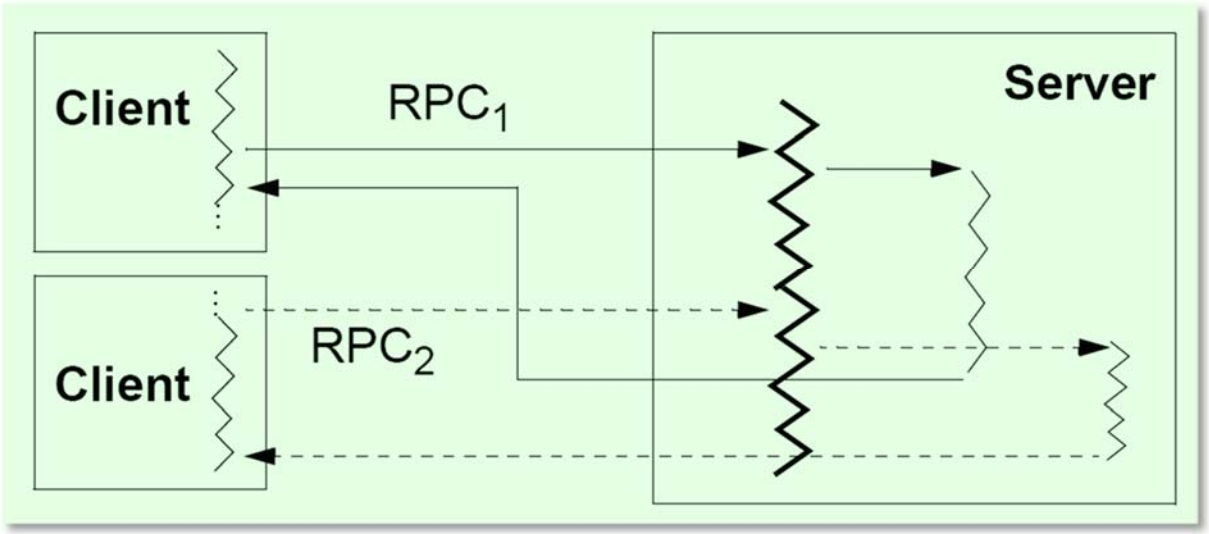

- Client-Threads: Möglichkeit zum „asynchronen RPC"
  - Hauptkontrollfluss delegiert RPCs an nebenläufige Threads
  - keine Blockade durch Aufrufe im Hauptkontrollfluss
  - echte Parallelität von Client (Hauptkontrollfluss) und Server

Zustandsändernde / -invariante Aufträge

- Verändern Aufträge den Zustand des Servers?
  - typische zustandsinvariante Aufträge: Anfrage bei Auskunftsdienst (z.B. Namensdienst oder Zeitservice)
  - typische zustandsändernde Aufträge: Schreiben bei Datei-Server
- Idempotente Aufträge
  - Wiederholung eines Auftrags führt zum gleichen Effekt
  - Beispiel: „Schreibe in Position 317 von Datei XYZ den Wert W“ (ist aber nicht zustandsinvariant!)
  - Gegenbeispiel: „Schreibe ans Ende der Datei XYZ den Wert W“
  - Gegenbeispiel: „Wie spät ist es?“ (ist aber zustandsinvariant!)
- Bei Idempotenz oder Zustandsinvarianz kann bei fehlgeschlagenem Auftrag (timeout beim Client) dieser problemlos erneut abgesetzt werden (→ einfache Fehlertoleranz)

Zustandslose („stateless“) / zustandsbehaftete („statefull“) Server

- Hält der Server Zustandsinformation über Aufträge hinweg?
  - z.B. (Protokoll)zustand des Clients
  - z.B. Information über frühere damit zusammenhängende Aufträge
- Beispiel: Datei-Server

```
open(“XYZ”);
read;
read;
close;
```

In klassischen Systemen hält sich das Betriebssystem Zustandsinformation, z.B. über die Position des Dateizeigers geöffneter Dateien

- Bei zustandslosen Servern entfällt open/close; jeder Auftrag muss vollständig beschrieben sein (Position des Dateizeigers etc.)
  - zustandsbehaftete Server sind daher i.Allg. effizienter
  - Dateisperren bei zustandslosen Servern nicht so einfach möglich
- Zustandsbehaftete Server können wiederholte Aufträge erkennen (z.B. Speichern von Sequenznummern) → Idempotenz
- Crash eines Servers: Weniger Probleme im zustandslosen Fall

Sind Web-Server zustandslos?

- Beim HTTP-Zugriffsprotokoll wird über den Auftrag hinweg keine Zustandsinformation gehalten
  - jeder link, den man anklickt, löst eine neue „Transaktion" aus
- Stellt z.B. ein Problem bei Shopping-Anwendungen dar
  - oft gewünscht: Transaktionen über mehrere Klicks hinweg
  - Wiedererkennen von Kunden (beim nächsten Klick oder auch Tage später)
  - erforderlich z.B. für die Realisierung virtueller „Warenkörbe" von Kunden

Wiedererkennung von Kunden?

- „URL rewriting“ und dynamische Web-Seiten
  - der Einstiegsseite eine eindeutige Identität anheften, wenn der Kunde diese erstmalig aufruft
  - diese Identität jedem link auf der Seite anheften und mit zurückübertragen
- „Cookie“ als Context-Handle
  - kleine Textdatei, die ein Server einem Browser (= Client) schickt und die im Browser gespeichert wird
  - der Server kann das Cookie später wieder lesen und damit den Kunden bzw. die Transaktion wiedererkennen
- Evtl. auch Wiedererkennung über IP-Adresse
  - aber oft Probleme bei dynamischen IP-Adressen, Proxies etc.

Lookup-Service

- Problem: Wie finden sich Client und Server?
  - haben i.Allg. verschiedene Lebenszyklen → kein gemeinsames Übersetzen / statisches Binden (fehlende gemeinsame Umgebung)
  - → Lookup-Service (LUS) oder „Registry" fungiert als „Service-Broker"

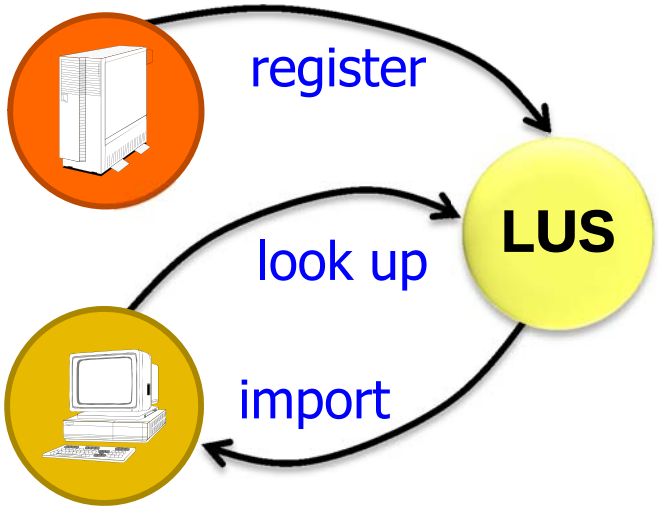

- Server macht seinen Service (z.B. RPC-Routine) dem LUS bekannt
  - register: API (RPC-Schnittstelle) „exportieren" (Name, Parameter, Typen,...)
  - evtl. später auch wieder abmelden
- Client erfragt beim LUS die Adresse eines geeigneten Servers
  - Angabe des gewünschten Typs von Service beim look up oder discovery
  - „importieren" der RPC-Schnittstelle

Lookup-Service (2)

- Vorteile („Mehrwert"): im Prinzip kann LUS
  - mehrere Server für den gleichen Service registrieren (→ Fehlertoleranz; Lastausgleich)
  - Autorisierung etc. überprüfen
  - durch Polling der Server die Verfügbarkeit eines Services testen
  - verschiedene Versionen eines Dienstes verwalten

- Probleme:
  - look up kostet Ausführungszeit (gegenüber statischem Binden)
  - zentraler LUS ist ein potentieller Engpass / „single point of failure" (evtl. LUS geeignet replizieren / verteilen)
  - wie lernen Client oder Server die Adresse des „richtigen" oder „zuständigen" LUS kennen?
    - z.B. feste („well-know") Adresse oder Broadcast in lokaler Umgebung

Middleware, Web Services

Middleware-Entwicklung, die Jini und Web Services historisch voranging

1. RPC-Bibliotheken (z.B. von SUN für UNIX)
   - Unterstützung des Client-Server-Paradigmas
   - einfache Schnittstellenbeschreibungssprache, Stubgeneratoren
   - erste Sicherheitskonzepte: Authentifizierung, Autorisierung, Verschlüsselung
2. Client-Server-Verteilungsplattformen (z.B. DCE)
   - Verzeichnisdienst, globaler Namensraum, globales Dateisystem
   - Programmierunterstützung u.a. für Multithreading und Synchronisation
3. Objektbasierte Verteilungsplattformen (z.B. CORBA)
   - Kooperation zwischen verteilten Objekten
   - objektorientierte Schnittstellenbeschreibungssprache
   - „Object Request Broker" als Vermittlungsinstanz

CORBA

- Common Object Request Broker Architecture
  - ORB (Object Request Broker) als Vermittlungsinfrastruktur (Weiterleitung von Methodenaufrufen etc.)
  - IDL (Interface Description Language) mit Stub-Generatoren
  - Systemfunktionen und Basisdienste in Form von Object Services (z.B. Semaphore, Persistierung)

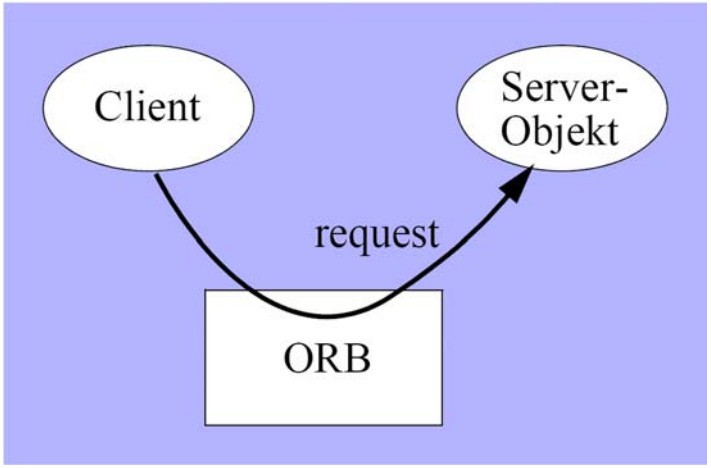

Methodenaufruf unterschiedlicher Semantik:

synchron (mit Rückgabewerten; analog zu RPC)

verzögert synchron (Aufrufer wartet nicht auf das Ergebnis, sondern holt es sich später ab)

one way (asynchron: Aufrufer wartet nicht; keine Ergebnisrückgabe)

CORBA

- Ab ca. 2000 entstand der Wunsch nach einer wesentlichen Erweiterung der CORBA-Funktionalität aufgrund
  - neuer Anforderungen durch grosse E-Commerce-Anwendungen
  - Ausbreitung des WWW
  - Aufkommen von Java
  - Aufkommen mobiler Geräte

Lehrreich diesbezüglich: Michi Henning: *The rise and fall of CORBA. Commun. ACM, Vol. 51, No. 8 (Aug. 2008), 52-57*

- Allerdings geriet die CORBA-Weiterentwicklung ins Stocken
  - zu weitreichende Anforderungen → komplex / ineffizient
  - man versuchte, es jedem Recht zu machen (widersprüchliche Interessen, barocke Konstrukte durch Kompromisse)
  - kommerzielle Implementierungen der Erweiterungen nur zögerlich
  - fehlende Unterstützung durch Microsoft (→ eigene Architektur: DCOM und .NET) aufkommende
  - Konkurrenzsysteme (z.B. Web Services), die z.T. direkter und besser an die neuen Anforderungen angepasst waren

Web Services als Beispiel für das Client-Server-Modell

- Problem: Internet ist zu heterogen für eine einheitliche Programmiersprache oder RPC-Laufzeitumgebung
  - „Lösung“: Web Services als offener, plattform- bzw. sprach-unabhängiger Standard, bei dem nur die Schnittstellen definiert werden und von diversen Plattformen implementiert werden können

---

- HTTP fungiert als Transportschicht
- SOAP als plattformunabhängige Protokollspezifikation
  (ursprünglich: „Simple Object Access Protocol“)
- UDDI als Lookup-Service
  („Universal Description, Discovery and Integration“)
- WSDL als standardisierte Service-Beschreibung
  („Web Services Description Language“)

Alternativ zu HTTP: UDP oder SMTP, z.B. für Mitteilungen ohne Antwort oder wenn Resultatberechnung länger als typischer HTTP-Timeout dauert

Web Services als Beispiel für das Client-Server-Modell

- Problem: Internet ist zu heterogen für eine einheitliche Programmiersprache oder RPC-Laufzeitumgebung
  - „Lösung“: Web Services als offener, plattform- bzw. sprach-unabhängiger Standard, bei dem nur die Schnittstellen definiert werden und von diversen Plattformen implementiert werden können

---

XML (Extensible Markup Language):

- Auszeichnungssprache zur Darstellung hierarchisch strukturierter Daten in Form von Textdaten (z.B. ASCII, UTF-8)
- Unterstrukturen mit Start- (<Tag-Name>) und End-Tag (</Tag-Name>) oder einem Empty-Element-Tag (<*Tag-Name* />)
- Attribute bei einem Tag (Attribut-Name= "Attribut-Wert") für Zusatzinformationen

```
<books>
  <book>
    <author>Karl May</author>
    <title>Winnetou</title>
    <ISBN>3-7802-0170-4</ISBN>
    <price format="EUR"/>
  </book>
  <pubinfo>
    <publisher>
      KM-Verlag
    </publisher>
    <town>Bamberg</town>
  </pubinfo>
</books>
```

Web Services

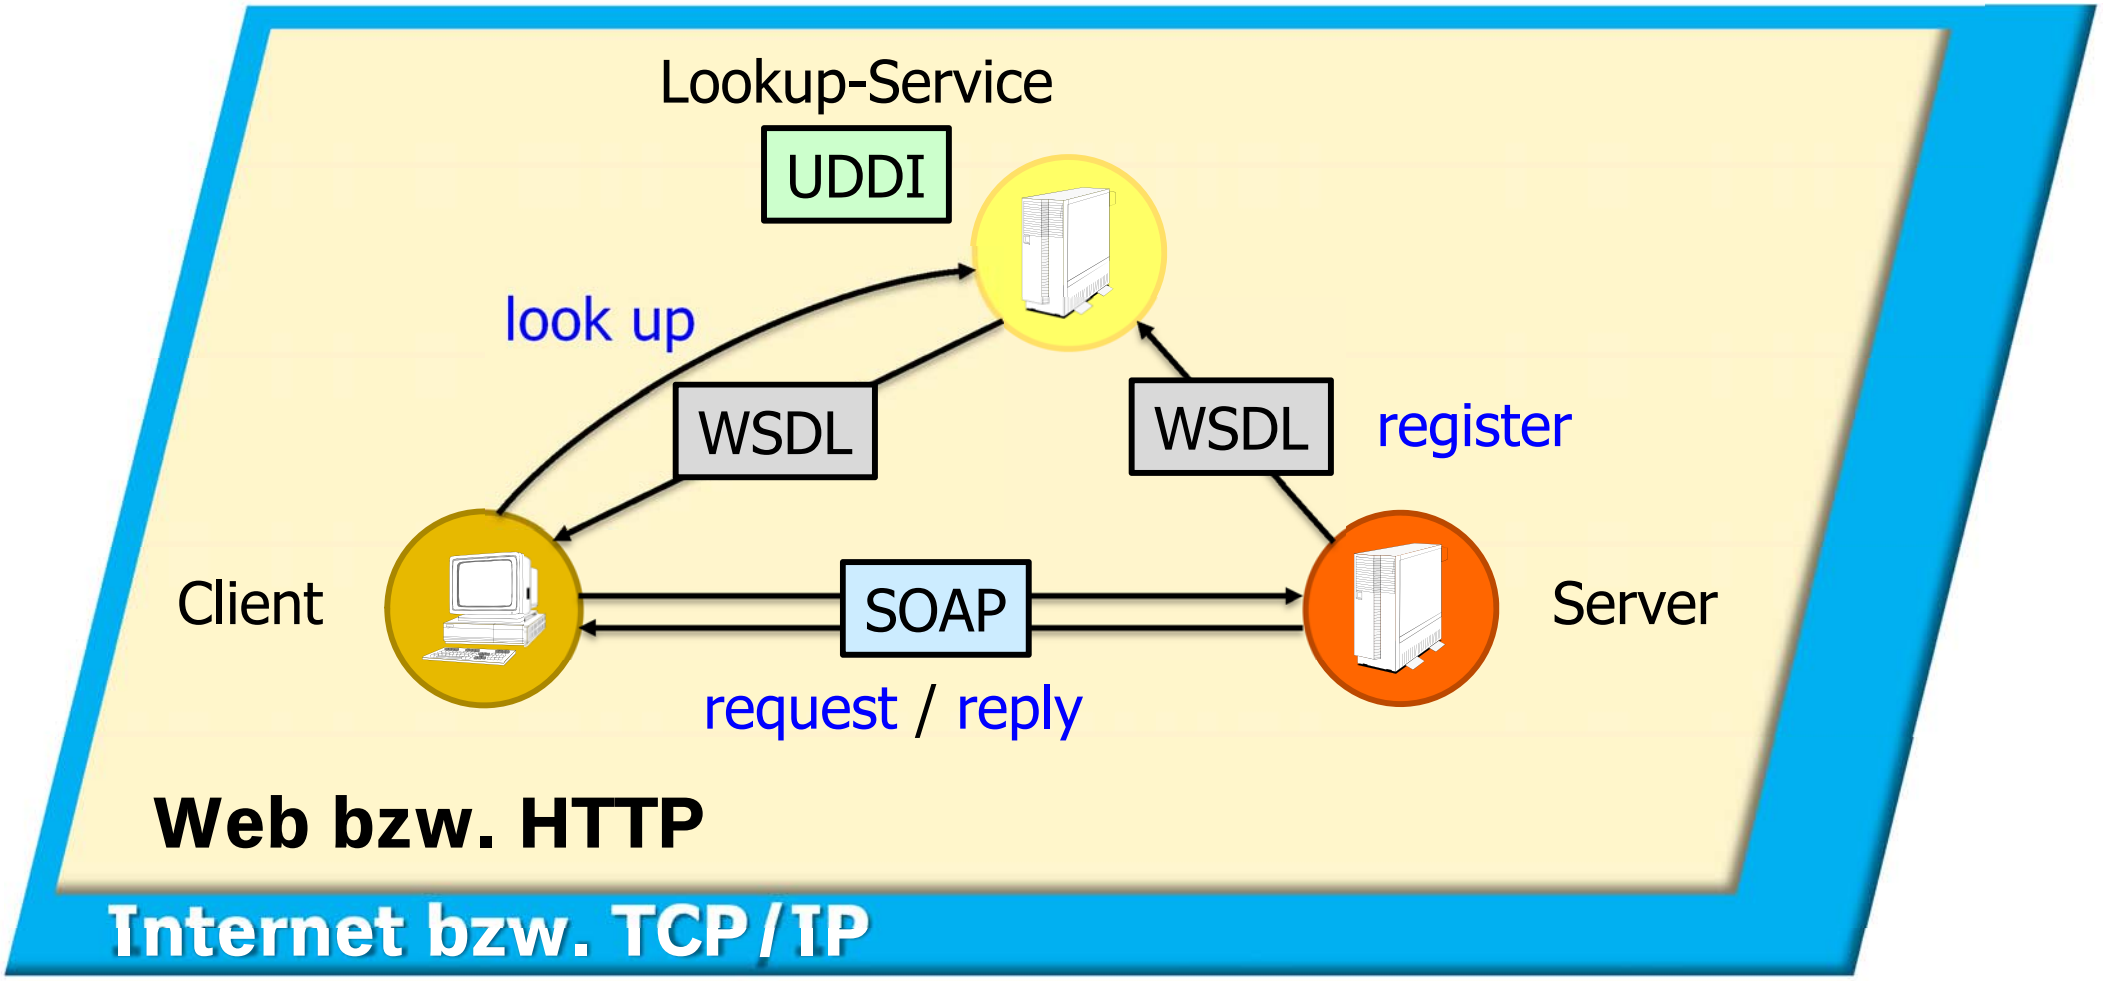

Web Services

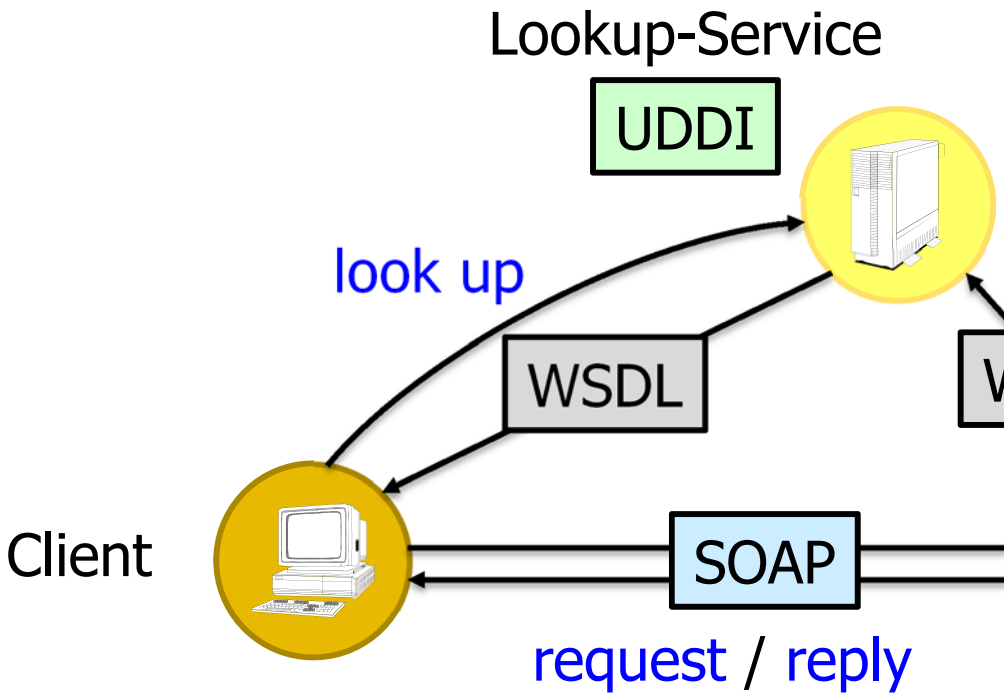

WSDL description

- **types, messages**
  (welche Nachrichten gibt es)
- **portType**
  (wie aufrufen→Signaturen)
- **binding**
  (welches Protokoll, z.B. HTTP)
- **service**
  (wo Service aufrufen)

SOAP envelope

- **Header (optional)**
- **Body**
  - **Element (req./reply)**
    Argumente/Ergebnis

Jeweils XML-Dokumente

WSDL: types

WSDL description

- **types, messages**
  (welche Nachrichten gibt es)
- **portType**
  (wie aufrufen→Signaturen)
- **binding**
  (welches Protokoll, z.B. HTTP)
- **service**
  (wo Service aufrufen)

types

XML-Schema zur Typenbeschreibung

- Definition von Typen (bzw. deren Namen) als XML-„element“
- Meistens als Verweis auf einen „complexType“, der aus „elements“ der Basistypen (int, float,…) besteht
- Das Schema definiert auch einen Namens-raum, der als URI angegeben wird
- Schema oft in externe .xsd-Datei ausgelagert

→ **nächste 2 slides**

WSDL-Namensräume

- ExampleWebServices.wsdl

```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>
<definitions
  name="ExampleWebServices"
  targetNamespace="http://example.org/VS/WebServices/"
  xmlns:tns="http://example.org/VS/WebServices/"
  xmlns="http://schemas.xmlsoap.org/wsdl/"
  xmlns:xsd="http://www.w3.org/2001/XMLSchema"
  xmlns:wsam="http://www.w3.org/2007/05/addressing/metadata"
  xmlns:soap="http://schemas.xmlsoap.org/wsdl/soap">

  <types>
    <xsd:schema>
      <xsd:import
        namespace="http://example.org/VS/WebServices/"
        schemaLocation="ExampleSchema.xsd"/>
    </xsd:schema>
  </types>
...
```

Namensraum der hier beschriebenen Web Services

Definiert Präfix „tns:“, um den targetNamespace anzusprechen

Weitere Präfixe für Namensräume, aus denen Tags benötigt werden

Importiert die Typendefinitionen

nächste slide

WSDL-Namensräume

- ExampleSchema.xsd

```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>
<xs:schema
  version="1.0"
  targetNamespace="http://example.org/VS/WebServices/"
  xmlns:tns="http://example.org/VS/WebServices/"
  xmlns:xs="http://www.w3.org/2001/XMLSchema">

<!-- Elementdefinitionen -->

</xs:schema>
```

nächste slide

Hier gleicher Namensraum wie Services

Definiert Präfix „tns:", um den targetNamespace einfacher anzusprechen

Lässt „xs:" auf den allgemeinen XML-Schema-Namensraum zeigen (vgl. „xsd" im WSDL Dokument)

WSDL-Beispiel: types

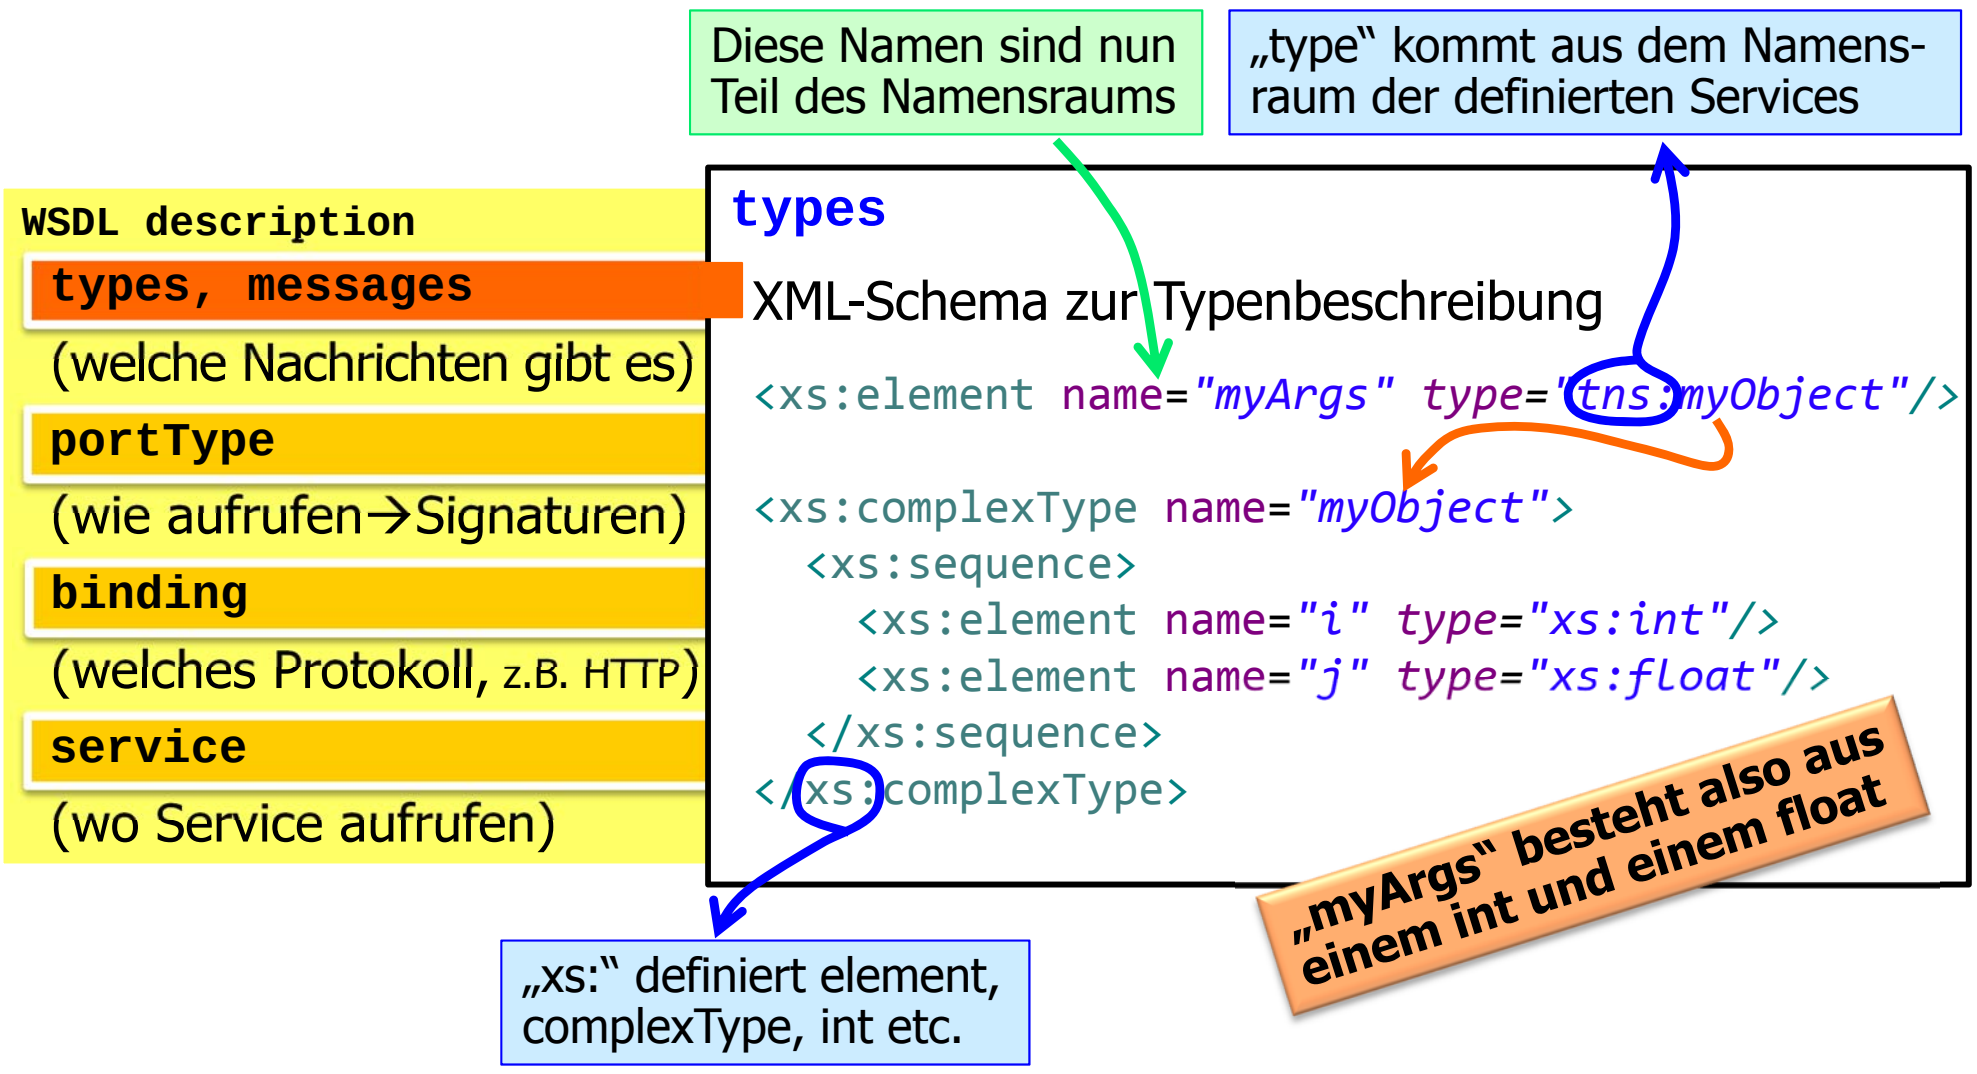

WSDL: messages

WSDL description

types, messages

(welche Nachrichten gibt es)

portType

(wie aufrufen→Signaturen)

binding

(welches Protokoll, z.B. HTTP)

service

(wo Service aufrufen)

messages

- Abstrakte Definition der Nachrichten, mit denen ein Dienst angesprochen wird oder antwortet (können unter „bindings" für spezielle Protokolle konkretisiert werden)
- Daten können in mehrere Teile („part") gruppiert werden, die jeweils einem „type element" entsprechen
- Je ein Eintrag pro Nachrichtendefinition

WSDL-Beispiel: messages

WSDL description

- **types, messages**
  (welche Nachrichten gibt es)
- **portType**
  (wie aufrufen→Signaturen)
- **binding**
  (welches Protokoll, z.B. HTTP)
- **service**
  (wo Service aufrufen)

messages

```
<message name="myRequest">
  <part name="parameters"
        element="tns:myArgs"/>
  <part name="optionalParameters"
        element="tns:myOpt"/>
</message>

<message name="myResponse">
  <part name="result" element="tns:myRet"/>
</message>
```

„myArgs" wurde oben definiert

„message" kann aus null oder mehr „parts" bestehen

„myRequest" hat also einen int und einen float als Parameter

WSDL: portType

WSDL description

types, messages

(welche Nachrichten gibt es)

portType

(wie aufrufen→Signaturen)

binding

(welches Protokoll, z.B. HTTP)

service

(wo Service aufrufen)

portType

- Definition der einzelnen Service Methoden
- Jede Methode entspricht einer „operation"
  - hat typischerweise eine „input"-Nachricht und eine „output"-Nachricht
  - zusätzlich können Fehlerbenachrich-tigungen angegeben werden („fault")
- Methoden können auch unidirektional sein, (z.B. nur „output" für Benachrichtigungen)

WSDL-Beispiel: portType

WSDL description

types, messages

(welche Nachrichten gibt es)

portType

(wie aufrufen→Signaturen)

binding

(welches Protokoll, z.B. HTTP)

service

(wo Service aufrufen)

portType

```
<portType name="groupOfServices">
  <operation name="myMethod">
    <input message="tns:myRequest"/>
    <output message="tns:myResponse"/>
    <fault message="tns:someFault"/>
  </operation>
</portType>
```

Hier könnten weitere „operation" stehen

„myMethod" wird also mit einem int und einem float aufgerufen

WSDL: binding

WSDL description

- **types, messages**
  (welche Nachrichten gibt es)
- **portType**
  (wie aufrufen→Signaturen)
- **binding**
  (welches Protokoll, z.B. HTTP)
- **service**
  (wo Service aufrufen)

binding

- Bindet „portType" an ein Protokoll (z.B. HTTP)
- Es kann mehrere „binding"-Einträge für verschiedene Protokolle geben
  (Tools unterstützen oft nur einen Eintrag)
- (Im Normalfall genügen die Informationen aus „message" und „portType" für die Abbildung der Nachrichten auf ein konkretes Format, d.h. „binding" enthält kaum Information; Abbildung kann für Spezialfälle genau definiert werden)

WSDL-Beispiel: binding

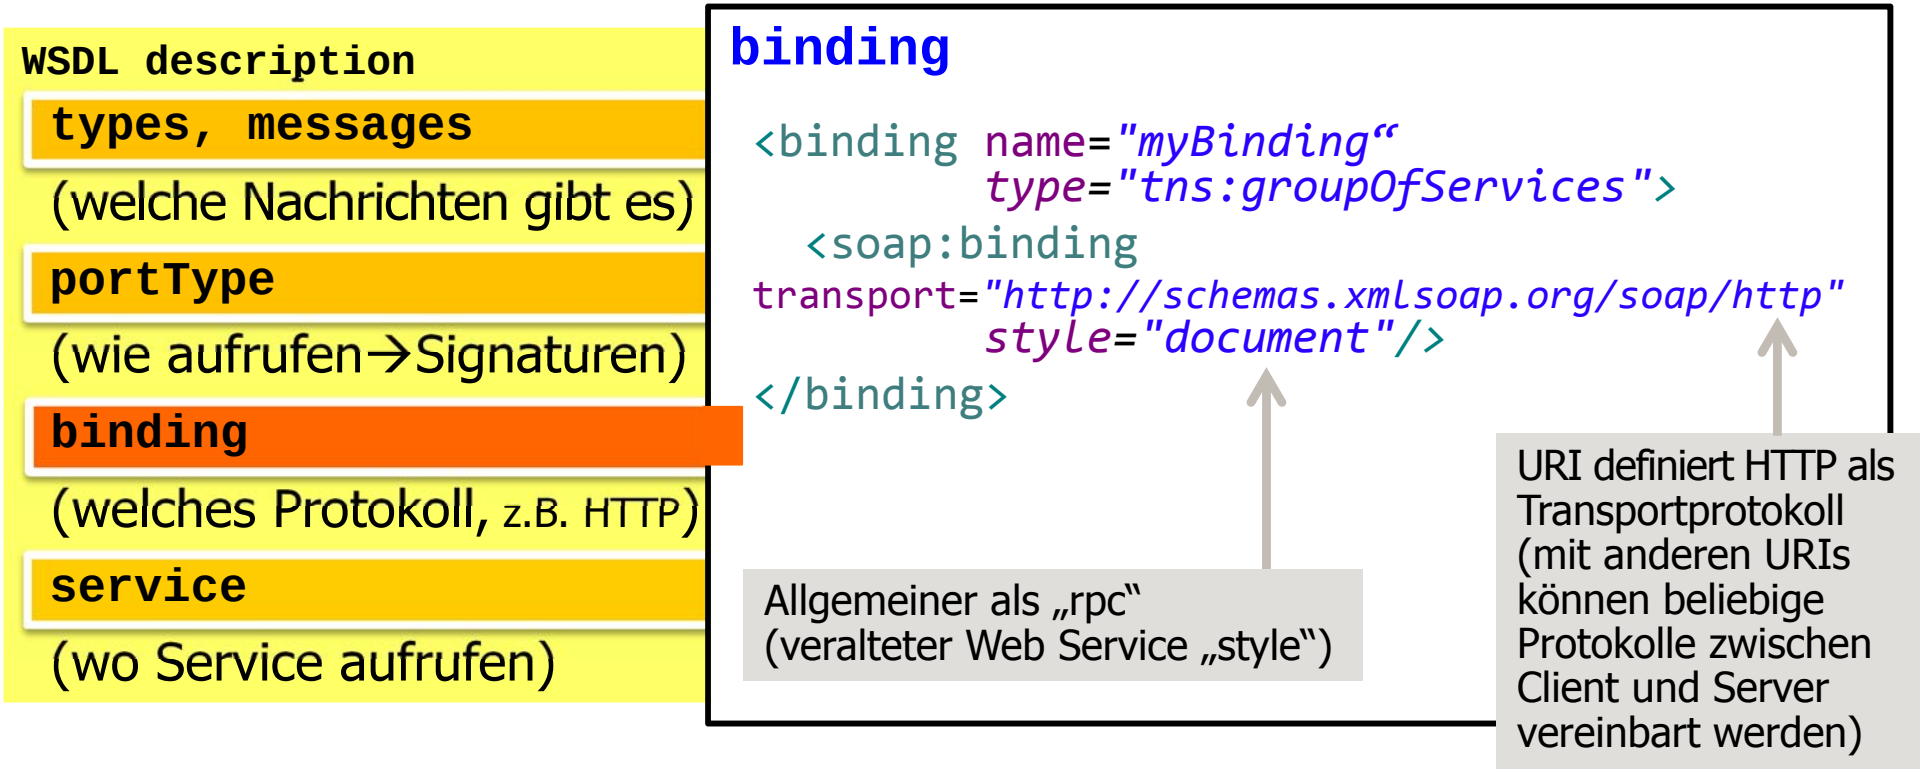

WSDL: service

WSDL description

types, messages

(welche Nachrichten gibt es)

portType

(wie aufrufen→Signaturen)

binding

(welches Protokoll, z.B. HTTP)

service

(wo Service aufrufen)

service

- Gibt Adresse des Web Services an (via „port" → „binding" → „portType")
- Ein Web Service kann mehrere „ports" haben (ist wieder nicht von allen Tools unterstützt)

```
<service name="myWebService">
  <port binding="tns:myBinding">
    <soap:address
 location="http://example.org/VS/service"/>
  </port>
</service>
```

Nochmal: Web Services

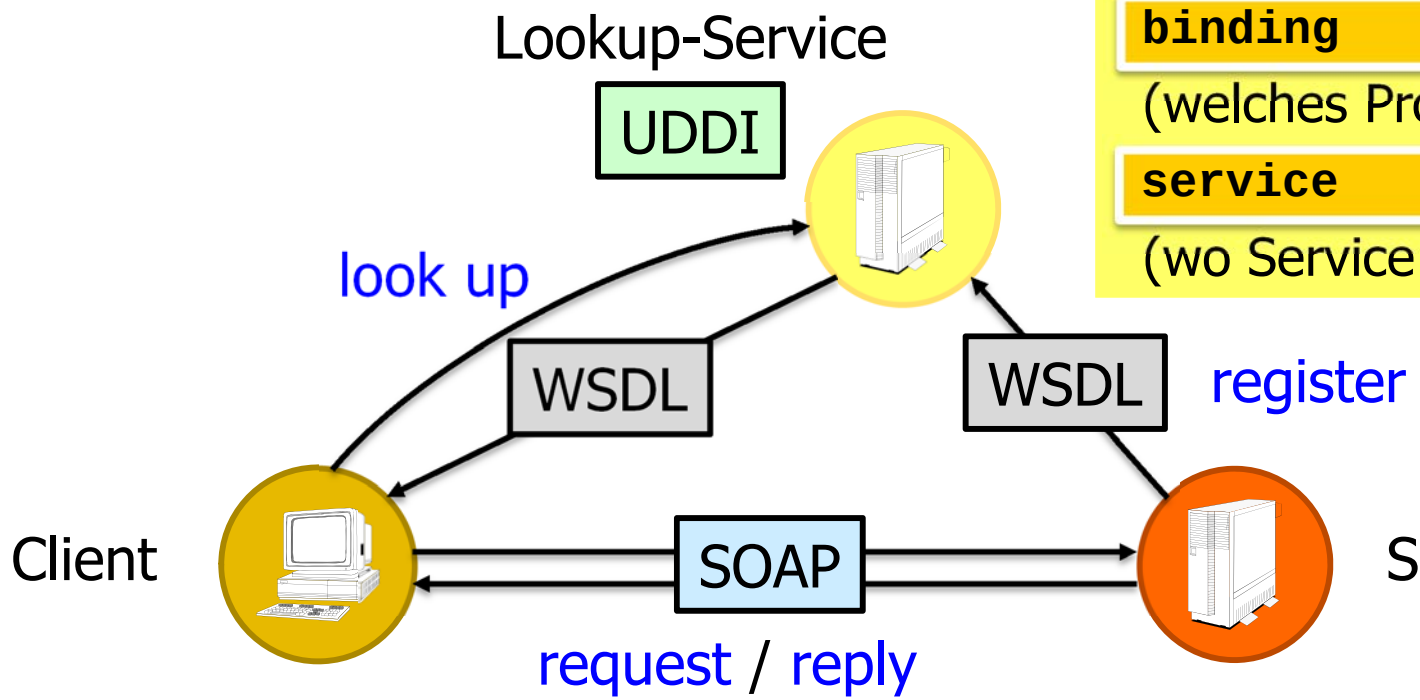

WSDL description

- **types, messages**
  (welche Nachrichten gibt es)
- **portType**
  (wie aufrufen→Signaturen)
- **binding**
  (welches Protokoll, z.B. HTTP)
- **service**
  (wo Service aufrufen)

SOAP envelope

- **Header (optional)**
- **Body**
  - **Element (req./reply)**
    Argumente/Ergebnis

Jeweils XML-Dokumente

SOAP: envelope

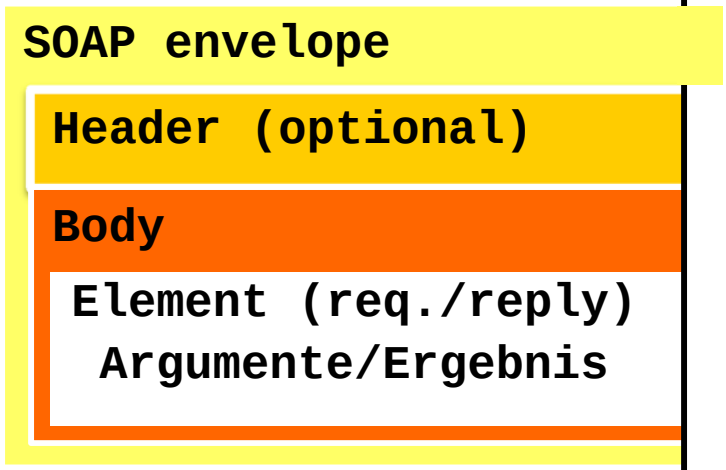

Envelope

Erforderliche Attribute:

- Charakteristischer Namensraum (der das Dokument als SOAP-Nachricht definiert)
- „encodingStyle" gibt Kodierungsregeln für die SOAP-Serialisierung an

Enthaltene Teilstrukturen:

- Header (optional)
- Body (erforderlich)

SOAP: header

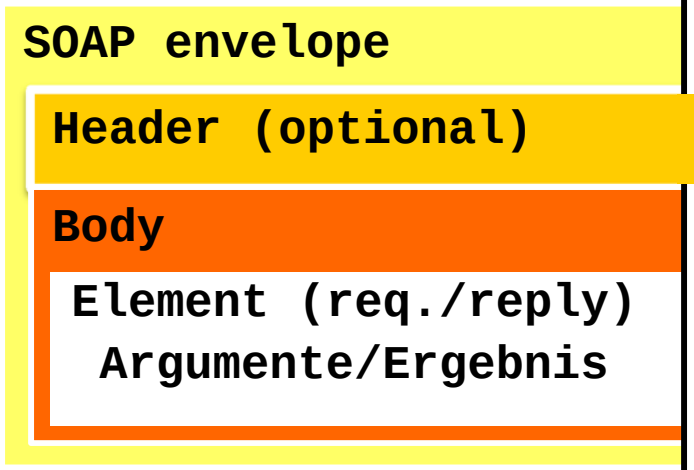

Header

Der SOAP-Header ist optional

Durch ihn könnten zusätzliche Informationen über den Transaktionskontext, z.B. bezüglich Authentifizierung oder Bezahlung, angegeben werden. Diese sind in zusätzlichen WS-* Spezifikationen definiert (z.B. OASIS-Standard)

SOAP: body

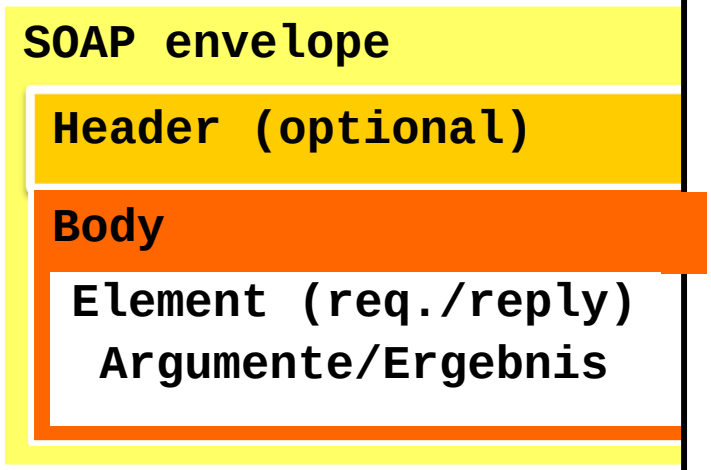

Body

SOAP-Nutzlast:

- Enthält die (mit WSDL bzgl. ihrer Struktur definierte) „message" mit ihren Elementen
- Es wird der Namensraum der WSDL-Spezifikation angegeben, womit die dort definierten Tags verwendet werden können

SOAP-Beispiel: Request

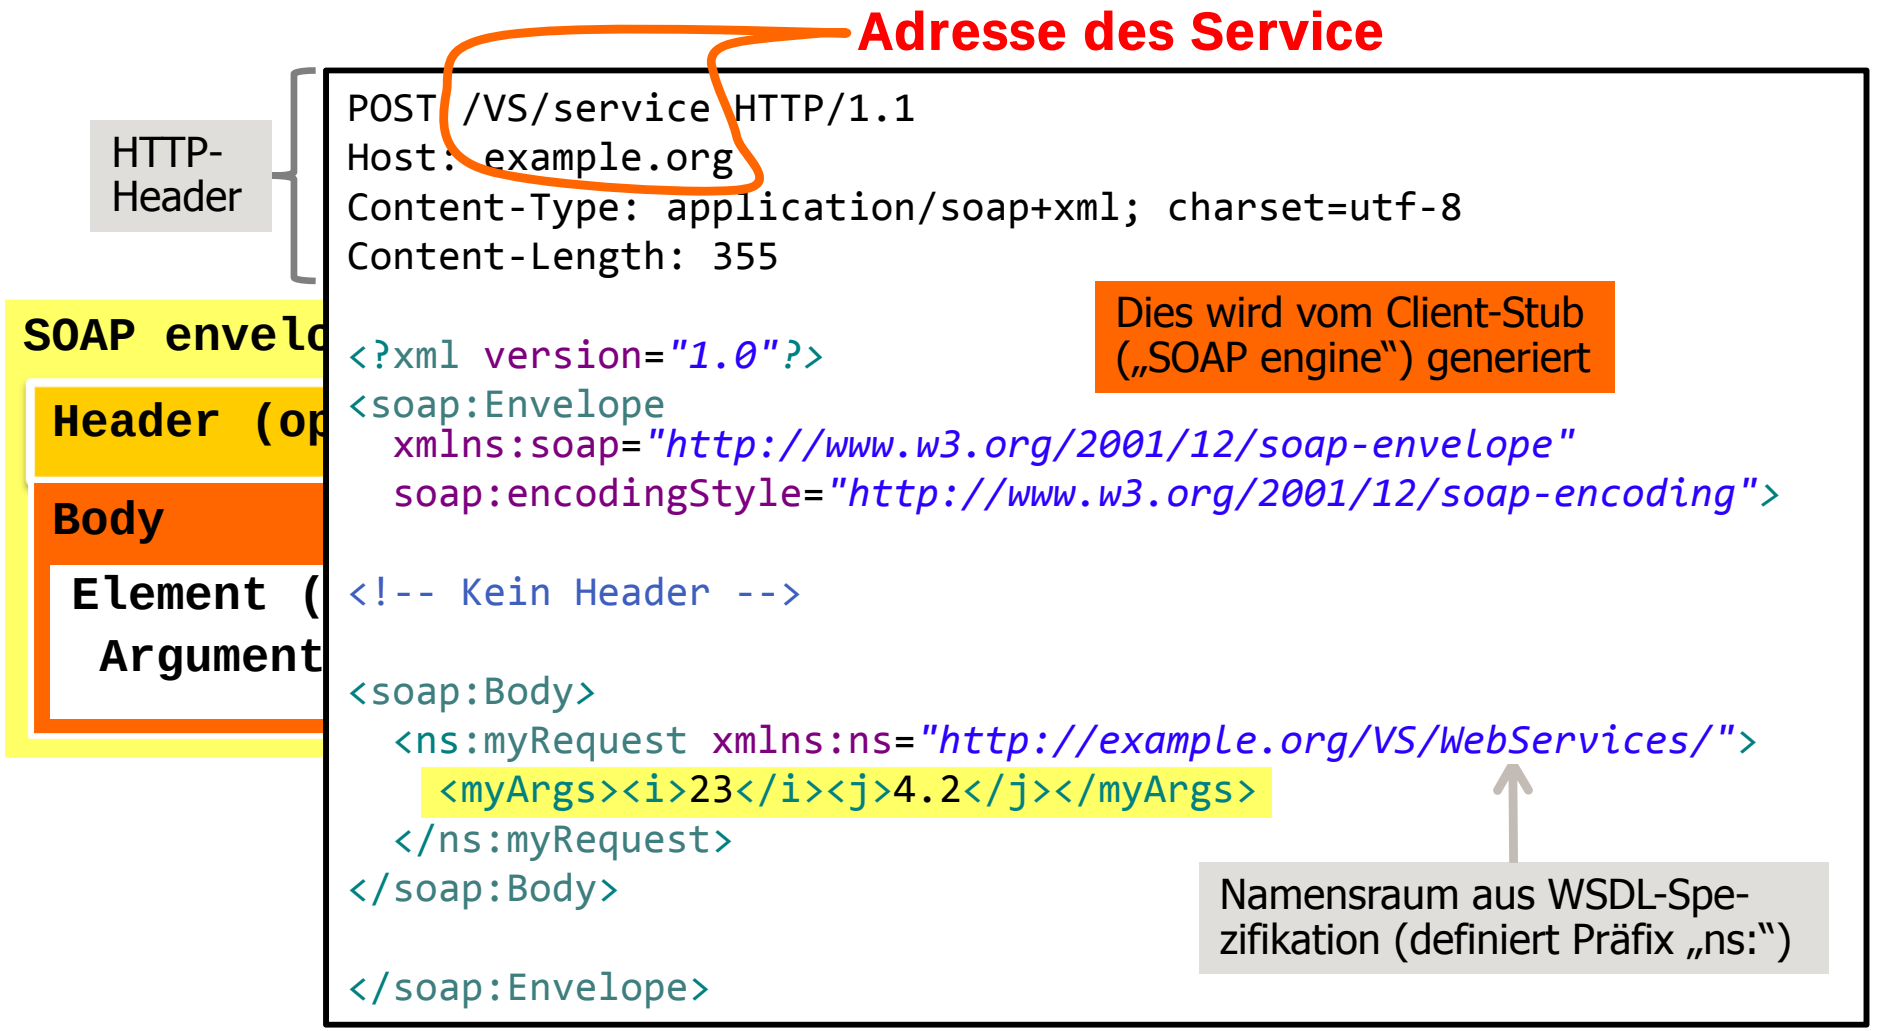

SOAP-Beispiel: Response

HTTP-Header

SOAP envelo

Header (op

Body

Element (

Argument

```
HTTP/1.1 200 OK
Content-Type: application/soap+xml; charset=utf-8
Content-Length: 340

<?xml version="1.0"?>
<soap:Envelope
  xmlns:soap="http://www.w3.org/2001/12/soap-envelope"
  soap:encodingStyle="http://www.w3.org/2001/12/soap-encoding">

<!-- Kein Header -->

<soap:Body>
  <ns:myResponse xmlns:ns="http://example.org/VS/WebServices/">
    <myRet>27.2</myRet>
  </ns:myResponse>
</soap:Body>

</soap:Envelope>
```

Nochmal: Web Services

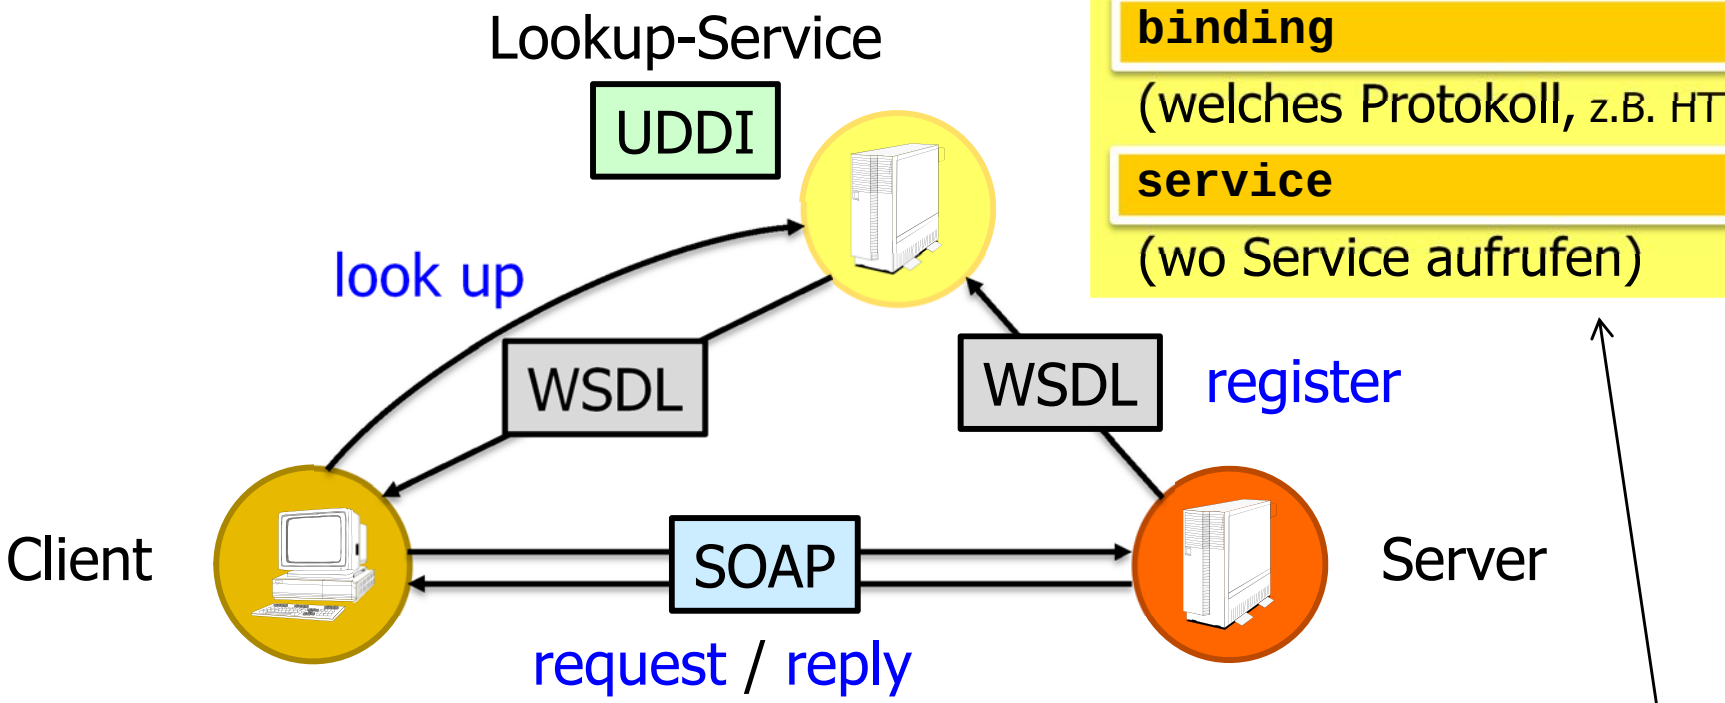

WSDL description

- **types, messages**
  (welche Nachrichten gibt es)
- **portType**
  (wie aufrufen→Signaturen)
- **binding**
  (welches Protokoll, z.B. HTTP)
- **service**
  (wo Service aufrufen)

SOAP envelope

- **Header (optional)**
- **Body**
  - **Element (req./reply)**
    Argumente/Ergebnis

Jeweils XML-Dokumente

Web Service Stubs

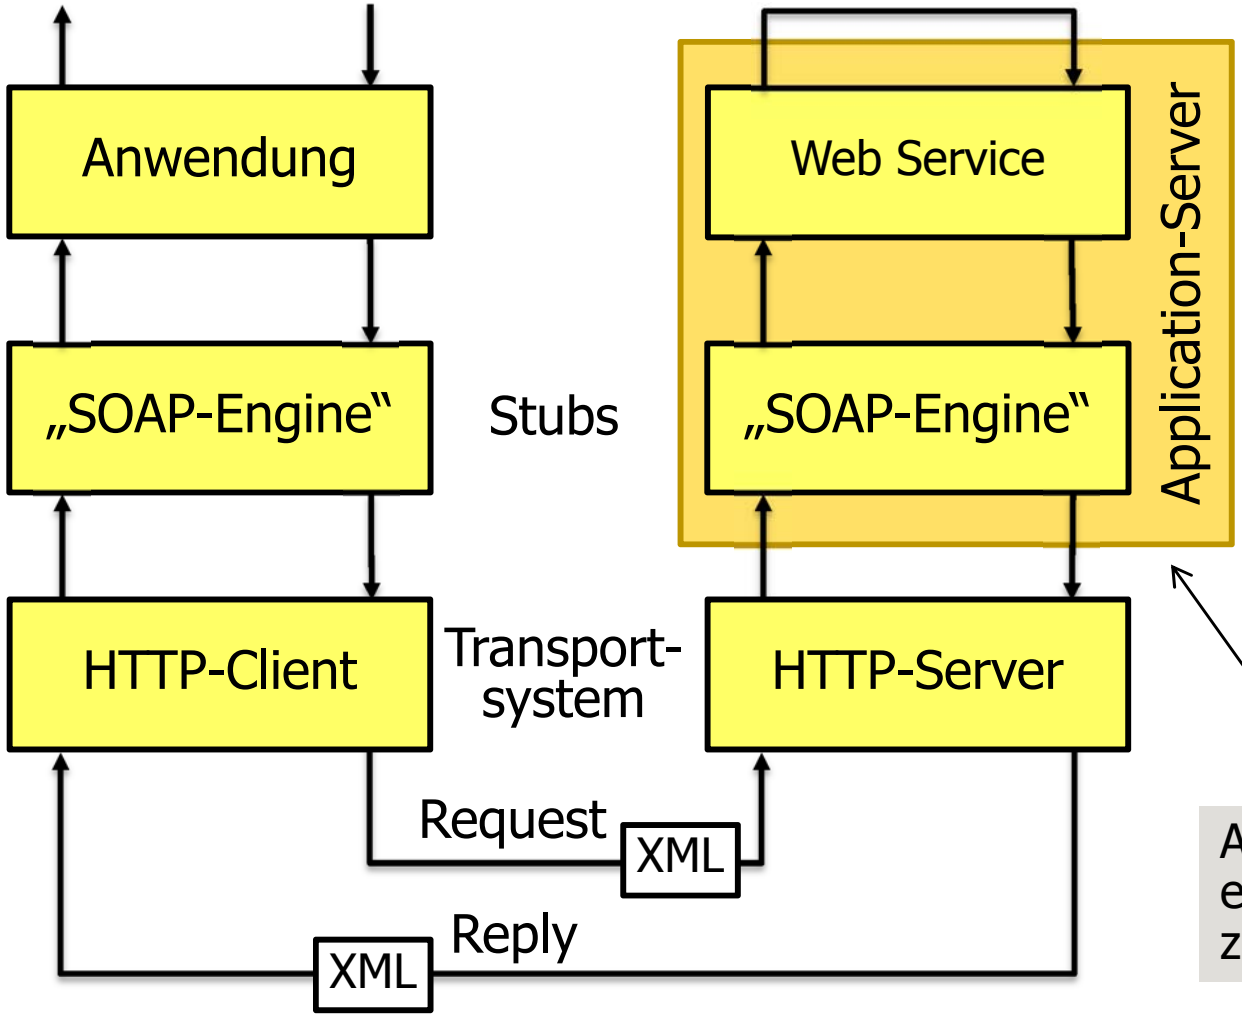

- Server-Stubs werden oft aus einer Web Service-Implementierung generiert
  (bottom up / „code first")
- ...oder automatisch aus einer WSDL-Beschreibung des Interfaces
  (top down / „contract first")
- Client-Stubs können ebenfalls aus WSDL generiert werden

Application-Server haben oft einen integrierten HTTP-Server, z.B. „Apache Tomcat", „Jetty"

vgl. frühere Folie „RPC: Implementierung"

Entwicklung von Web Service-Komponenten mit Java-IDE

- JAX-WS: Java API for XML Web Services
  (Beispiel: NetBeans-Entwicklungsumgebung)

SimpleService.java ×

Source | Design

```
1  /*
2   * To change this template, choose Tools | Templates
3   * and open the template in the editor.
4   */
5  package ch.simple.service;
6
7  import javax.jws.WebService;
8  import javax.jws.WebMethod;
9  import javax.jws.WebParam;
10
11 /**
12  * JAX-WS Example
13  * "add" Web Service taking two Integers as input and returning an Integer
14  */
15 @WebService(serviceName = "SimpleService")
16 public class SimpleService {
17
18     /**
19      * Web service operation
20      */
21     @WebMethod(operationName = "add")
22     public int add(@WebParam(name = "i") int i, @WebParam(name = "j") int j) {
23         return (i + j);
24     }
25 }
26
```

Erweiterung von einfachen Java-Objekten zu Web Services per Java Annotations (bottom up)

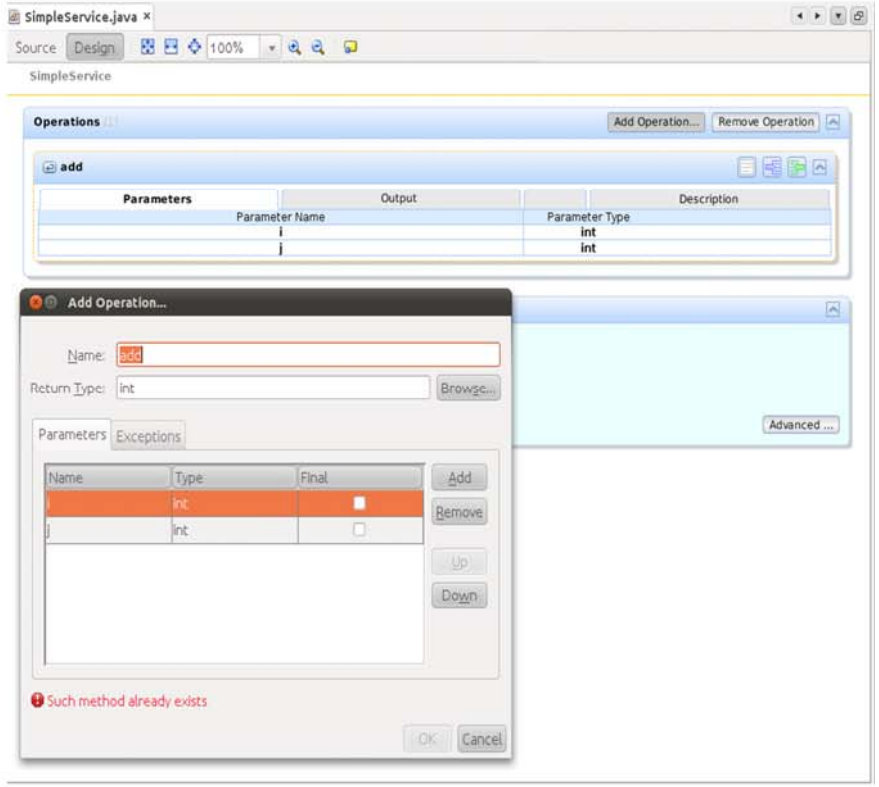

Zusammenfassung

- Web Services spezifizieren die Schnittstellen und erlauben viele Konfigurationsmöglichkeiten
- Eine Grosszahl an Zusatzspezifikationen („WS-*“) deckt viele geschäftsrelevante Anforderungen ab (vorteilhaft wenn Dienste für Banken oder Krankenhäuser zertifiziert werden müssen)
- Relativ grosser Overhead für Aufrufe
- Konfigurationsmöglichkeiten machen WS-* sehr komplex und nur mit Werkzeugen beherrschbar
- Globaler UDDI-Service hat sich aus kommerziellen Gründen nicht durchsetzen können
- Erforderliche Code-Generierung und Softwareupdates bei Änderungen skalieren nicht für offene Webanwendungen

REST

Ressourcen-orientierte Architektur (ROA)

- Funktionalität wird nicht durch Services („SOA"), sondern durch (Web-) Ressourcen angeboten
- Ressource? Bezugsobjekt eines Uniform Resource Identifiers
  - RFC 1630 „URL" (1994) — Implizit: „Etwas, das adressiert werden kann"
  - RFC 2396 „URI" (1998)

> *A resource can be anything that has identity. Familiar examples include an electronic document, an image, a service (e.g., "today's weather report for Los Angeles"), and a collection of other resources. Not all resources are network "retrievable"; e.g., human beings, corporations, and bound books in a library can also be considered resources…*

  - RFC 3986 „URI" (2005)

> *…Likewise, abstract concepts can be resources, such as the operators and operands of a mathematical equation, the types of a relationship…*

(Web-) Ressourcen

Warenkörbe/Repositories

Web-Dienste

Statische Websites

RSS Feeds

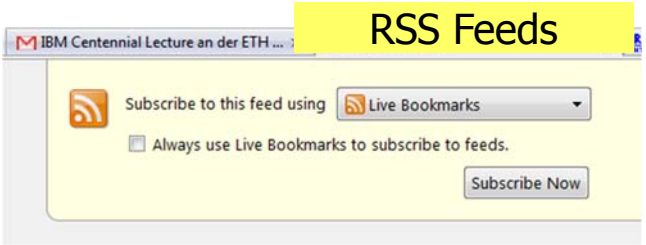

Physische Dinge

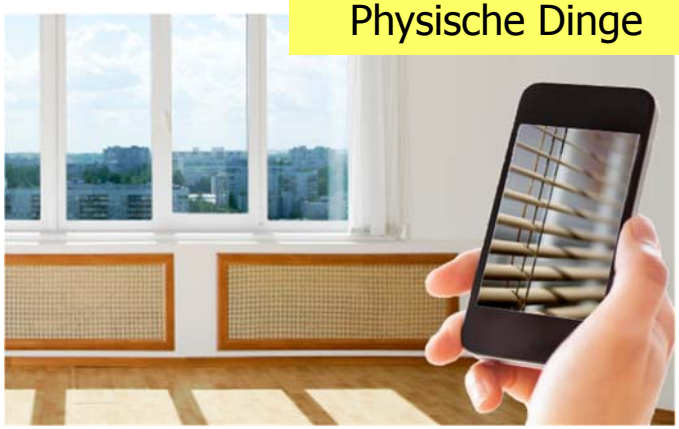

Foren

Repräsentation – Beispiel „Buch“

- Nachfolgend wird der Begriff „Repräsentation“ (einer Web-Ressource) verwendet
  - wir erläutern den Begriff an einem gleichnishaften Beispiel

---

- Das Buch als abstraktes Konzept
  - es gibt verschiedene Ausgaben, Exemplare etc.
  - identifiziert per ISBN: *ISBN-13: 978-3780200075*
  - oder URI: *urn:isbn:978-3780200075*
- Was wir kaufen oder ausleihen ist eine Repräsentation des Buches
  - z.B. Hardcover, PDF, E-Book,…
  - auch ein Bild des Covers kann eine Repräsentation sein
  - oder ein maschinenlesbares XML-Dokument für das Bibliothekssystem

REST

- REST (als idealisierte Architektur des Web) steht für
  - Representational: Nicht Ressourcen, sondern deren Repräsentationen werden übertragen
  - State Transfer: Über diese erhält man Zugriff auf den Zustand von Ressourcen, kann diesen lokal ändern und wieder zurück an die Ressource übertragen
- Menge an Prinzipien („REST constraints“)
- Motivation und Entwicklung
  - Erfolg des World Wide Webs in technischer Hinsicht (z.B. bzgl. Skalierbarkeit) beruht auf Eigenschaften der zugrundeliegenden Protokolle und Mechanismen
  - Ableitung eines Architekturstils für verteilte Systeme allgemein, um die Möglichkeiten, die das Web (bzw. HTTP) bietet, bestmöglich auszunutzen

REST Prinzipien (1)

- Client-Server
  - REST-System besteht aus Komponenten, die entweder einen Client-Konnektor, Server-Konnektor oder beides haben können

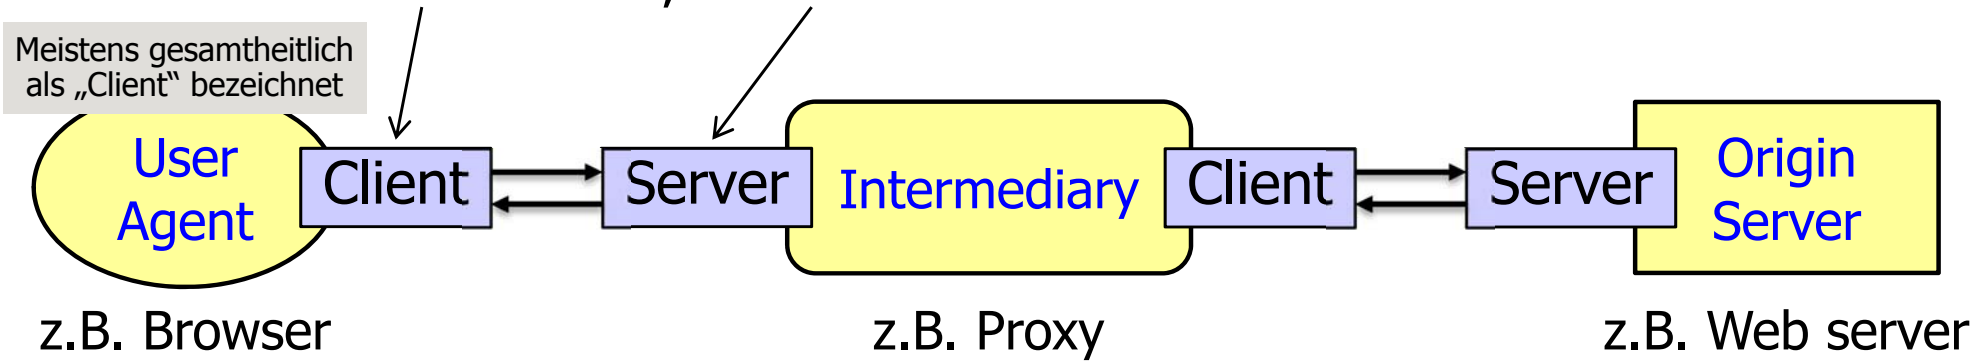

  - User Agent hat die Initiative und erstellt Requests
  - Intermediary leitet Requests (ggf. mit Übersetzung) weiter
  - Origin Server hat die Hoheit über Ressourcen

REST Prinzipien (2)

- Zustandslosigkeit
  - Request muss alle Informationen zur Bearbeitung enthalten
  - d.h. der Kontext wird nur beim Client und nicht beim Server gehalten
  - entschärft Crash-Problematik und Orphans
  - verbessert Skalierbarkeit und Beobachtbarkeit
  - Ermöglicht Caching durch Wiederverwendbarkeit von Antworten

vgl. Formular bei Behörde, welches von jedem Beamten bearbeitet werden kann

- Caching
  - Antworten müssen Metadaten zur Gültigkeitsdauer enthalten (z.B. HTTP „Cache-Control" Header-Field)
  - Clients und Intermediarys können Antworten speichern und weitere Requests lokal bzw. direkt beantworten

REST Prinzipien (3)

- Einheitliche Schnittstellen
  - Adressierung immer durch URIs
  - einheitliche Aufrufe (z.B. GET, POST, PUT, DELETE bei HTTP)
  - Standard-Repräsentationsformate (z.B. Internet Media Types)
  - Ressourcen können mehrere Formate anbieten, aus denen der Client wählen kann (z.B. HTML, XML, JSON, …)
- Geschichtetes System
  - Clients sehen nicht, wie System hinter dem Server aussieht
  - Intermediaries können an beliebiger Stelle eingefügt werden (z.B. Proxies, Load-Balancers, Gateways für Legacy-Systeme)
- Code bei Bedarf
  - Server kann Logik an Client auslagern (z.B. JavaScript)

Keine anwendungsspezifischen Typen und Operationen wie bei Service-orientierten Architekturen

Eigenschaften von REST

- Skalierbarkeit
  - Zustandslosigkeit erlaubt effiziente Server und Lastverteilung
  - Caching reduziert Kommunikation und somit Systemlast
- Anpassungsfähigkeit
  - Einheitliche Schnittstellen entkoppeln Client und Server
  - Schichtung erlaubt nachträgliche Topologieänderungen
  - Code bei Bedarf erlaubt das Nachrüsten von Clients im Betrieb
- Beobachtbarkeit und Zuverlässigkeit
  - Requests mit allen Informationen sind leicht nachverfolgbar
  - Einheitliche Schnittschnellen, Caching und Anpassungsfähigkeit ermöglichen hohe Zuverlässigkeit (z.B. auch durch Redundanz)

Entwicklung von REST-Komponenten mit Java-IDE

- JAX-RS: Java API for RESTful Web Services (Beispiel: Eclipse)

ShoppingCartResource.java

```
import javax.ws.rs.GET;
import javax.ws.rs.POST;
import javax.ws.rs.Path;
import javax.ws.rs.PathParam;
import javax.ws.rs.Produces;
import javax.ws.rs.QueryParam;
import javax.ws.rs.core.Response;

@Path("/cart/{cartID}")
public class ShoppingCartResource {

    @GET @Produces("text/html")
    public Response getCartContent(
            @PathParam("cartID") String cartID) {

        return Response.ok("Books in your cart: ...").build();
    }

    @POST @Consumes("application/json") @Produces("text/html")
    public Response addBookToCart(
            @PathParam("cartID") String cartID,
            @QueryParam("bookID") String bookID) {

        return Response.created(c.bookURIInCart).build();
    }
}
```

Erweiterung von einfachen Java-Objekten zu Ressourcen per Java Annotations

@Path: Pfad zur Ressource

Definition der verwendeten Media Types (@Consumes und @Produces)

Extraktion von Parametern aus dem Request mittels:

@PathParam: z.B. *{cartID}*

@QueryParam: z.B *?bookID=123*

REST-Anwendungsmodell

- „Hypermedia as the Engine of Application State“
  - Client kennt ausschliesslich die Basis-URI des Dienstes sowie die Repräsentationsformate, die verwendet werden
  - Server leitet durch die Anwendungszustände durch Bekanntgabe von Wahlmöglichkeiten (hyperlinks, forms)

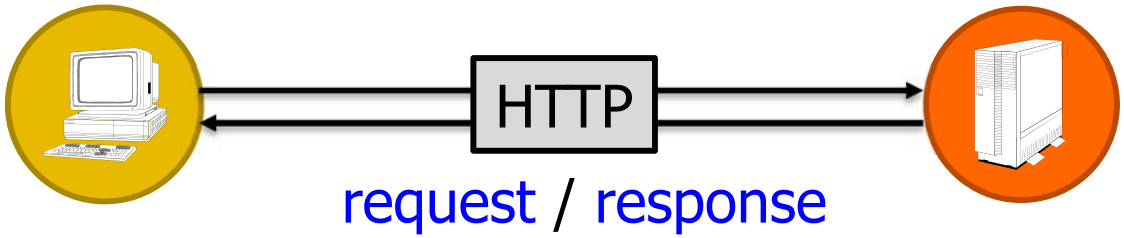

- Der Anwendungszustand besteht aus zwei Komponenten
  - Ressourcenzustand beim Origin Server (kann auch statisch sein)
  - Client-Zustand (ursprünglich „application state“ genannt, da Ressourcen meist statisch waren)

REST: Zustandsspeicherung

- Ressourcenzustand
  - Klassisch die Sammlung an statischen Dokumenten auf dem Server
  - Bei dynamischen Anwendungen oft nur die relevanten Werte; der Rest der Repräsentationen wird von der (statischen) Anwendungslogik oft mithilfe von Templates generiert
- Client-Zustand
  - Bezeichnet den aktuellen Schritt oder Kontext in der Anwendung, z.B. die aktuell gerenderte Repräsentation, sowie deren Historie
  - Bookmarks ergeben Sinn: vollständige URI und Client weiss, in welchem Kontext Bookmark angelegt wird
  - Back button im Browser ergibt Sinn: er führt zu einem früheren Zustand (mit im Client gecachten Repräsentationen)

REST: Zustandsspeicherung

- Zustandslosigkeit (der Kommunikation) heisst, Ressourcen- und Client-Zustand sind strikt getrennt
  - Der Client hinterlegt keine Informationen beim Server, die für Folgerequests gelten sollen (vgl. Sessions z.B. bei FTP oder SSH)
  - Der Server hat keinen direkten Einfluss auf den Client-Zustand; er kann nur indirekt durch die Bekanntgabe von Auswahlmöglichkeiten durch eine Anwendung leiten, Entscheidung liegt aber vollständig beim Client
- Nur so sind Client und Server entkoppelt, so dass die Vorteile von REST zum Ausdruck kommen

Beispiel:

Client

(ein Mensch an einem Browser)

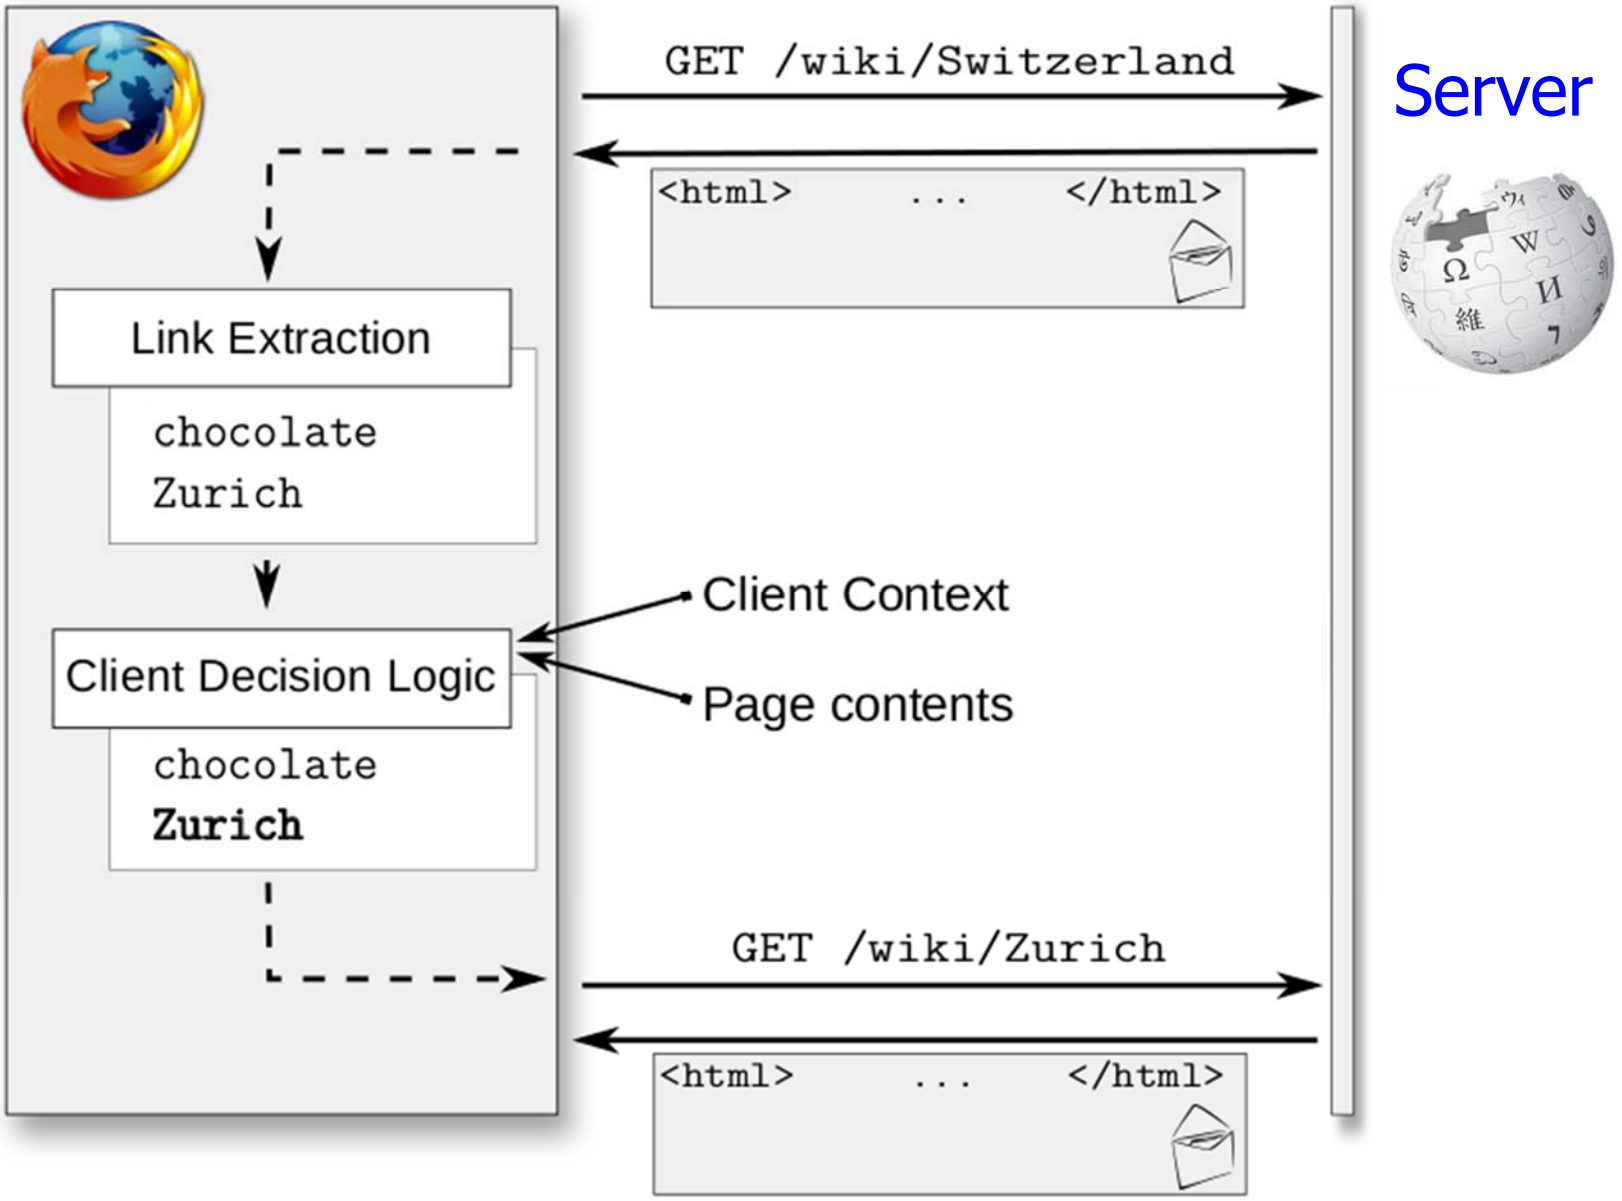

REST: Widersprüchliche Praxis

- Bei vielen Implementierungen wird der Client-Zustand auch auf dem Server gehalten oder von ihm direkt verändert
  - „URL Rewriting“ kodiert spezielle Informationen (z.B. eine Client-spezifische Session-ID) in die Requests
  - Vom Server definierte „Cookies“ müssen vom Client mitgesendet werden und verändern die Interpretation des Requests
- Dann funktioniert eine Kopie einer URI (bookmark) später meistens nicht, weil dem Server der Kontext dazu fehlt
  - auch back button im Browser ist problematisch: führt zu einer früheren Zustandskopie, ohne dass der Server dies mitbekommt – Client meint fälschlicherweise, in einem gewissen Zustand zu sein, der tatsächliche Zustand wird aber auf dem Server gehalten
- Widerspricht den REST-Prinzipien

Beispiel: Bankanwendung mit REST

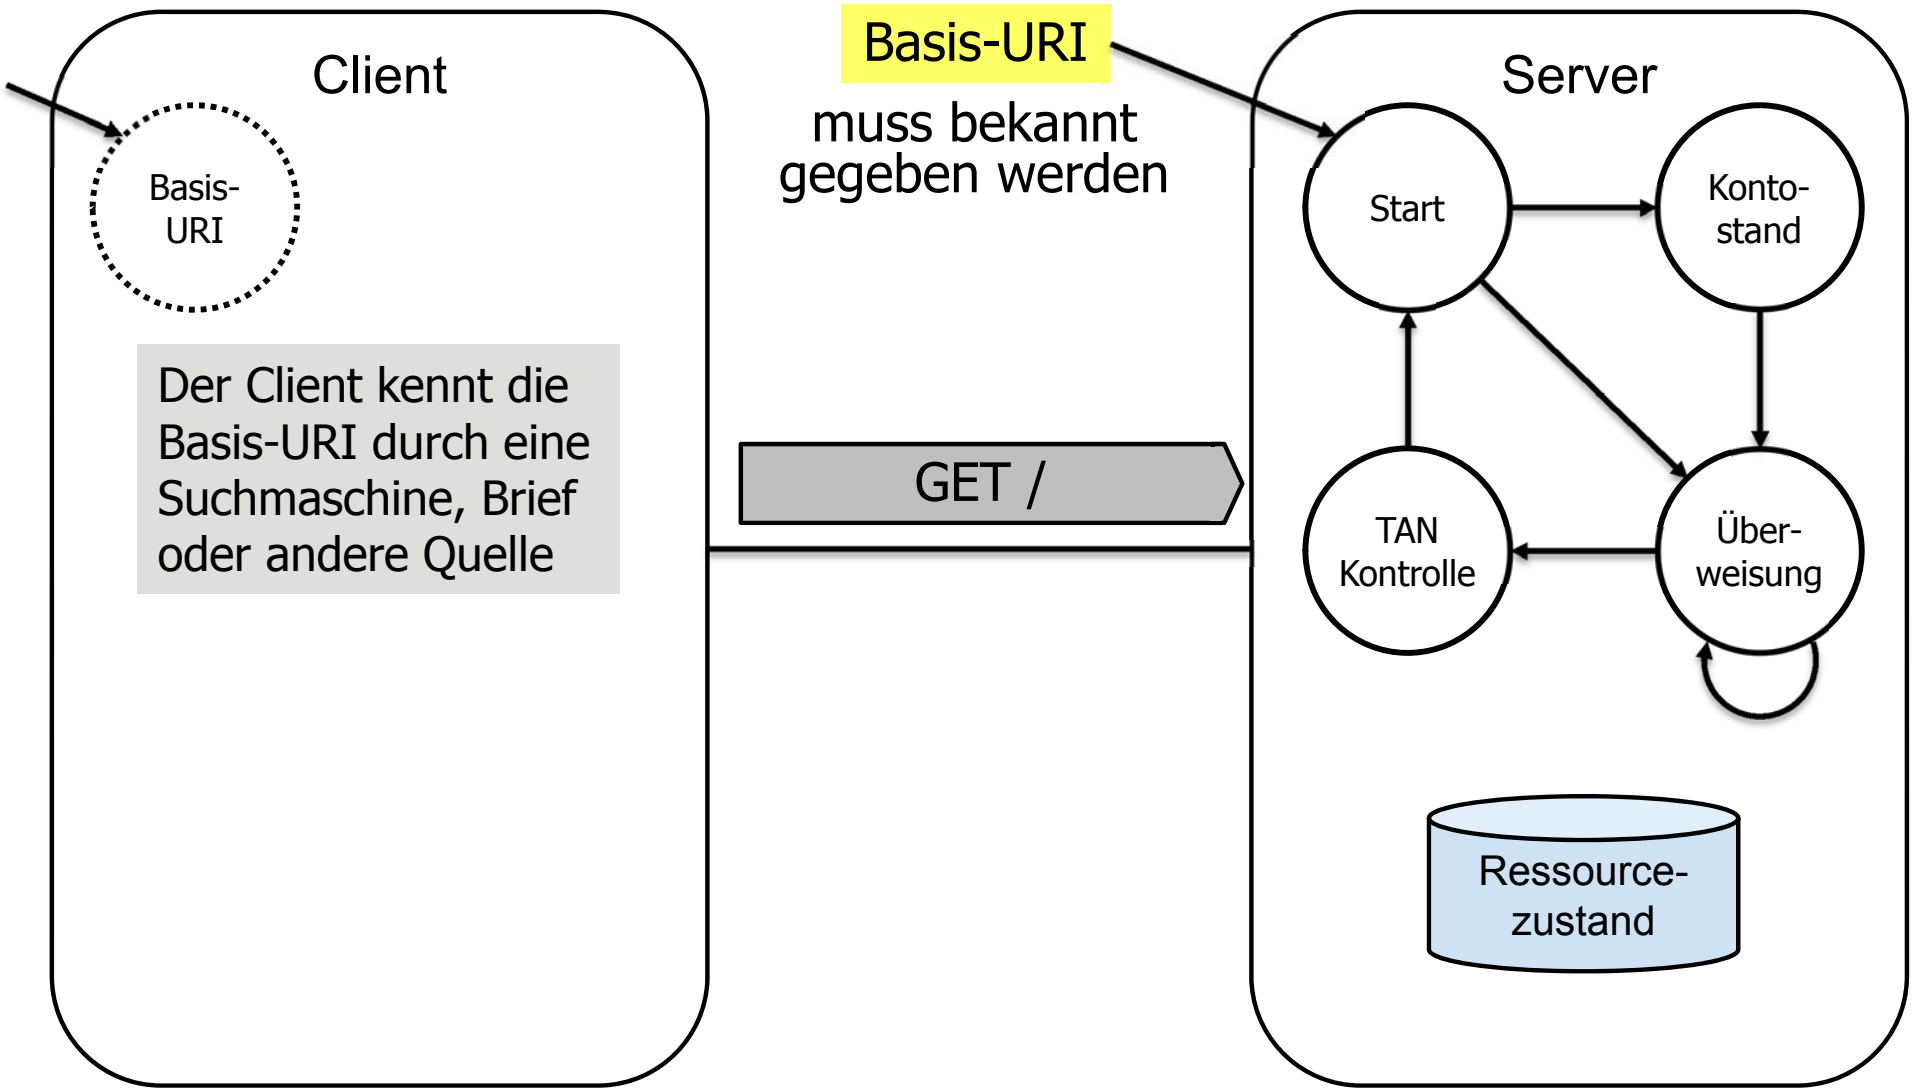

Beispiel: Bankanwendung mit REST

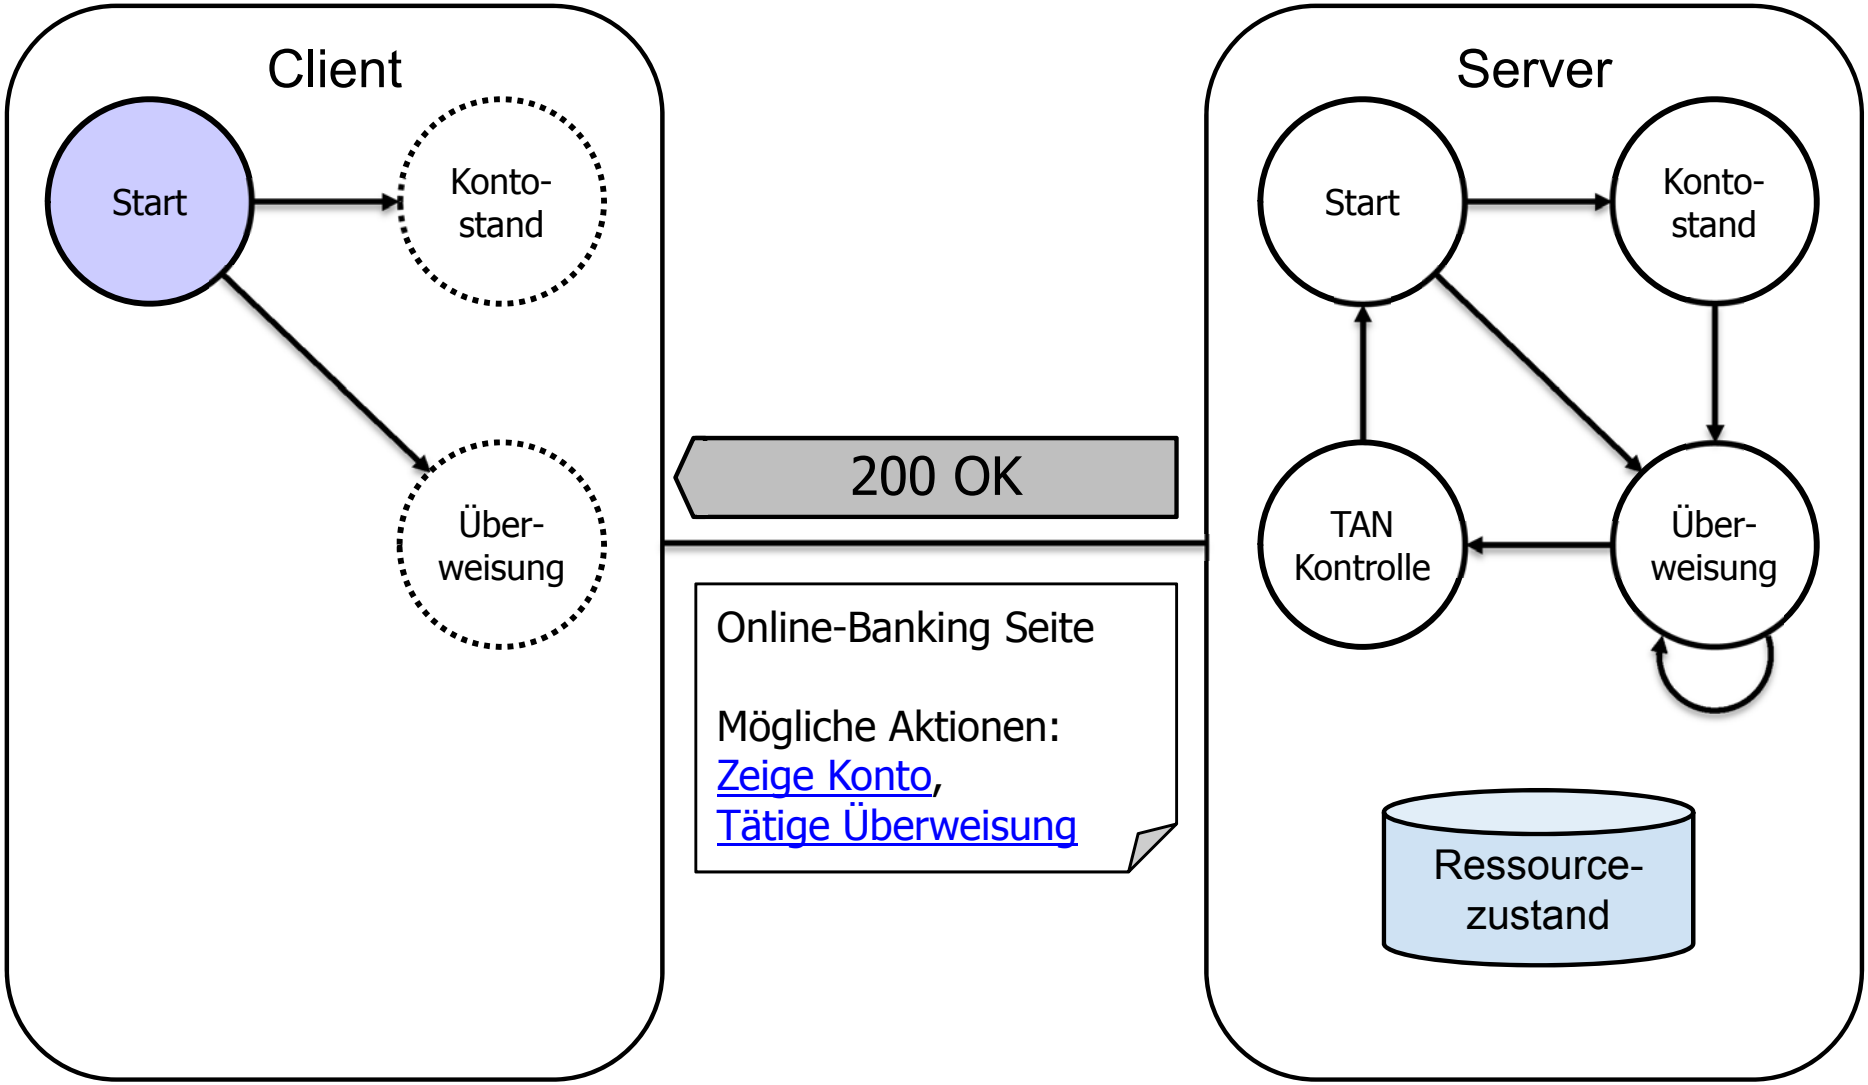

Beispiel: Bankanwendung mit REST

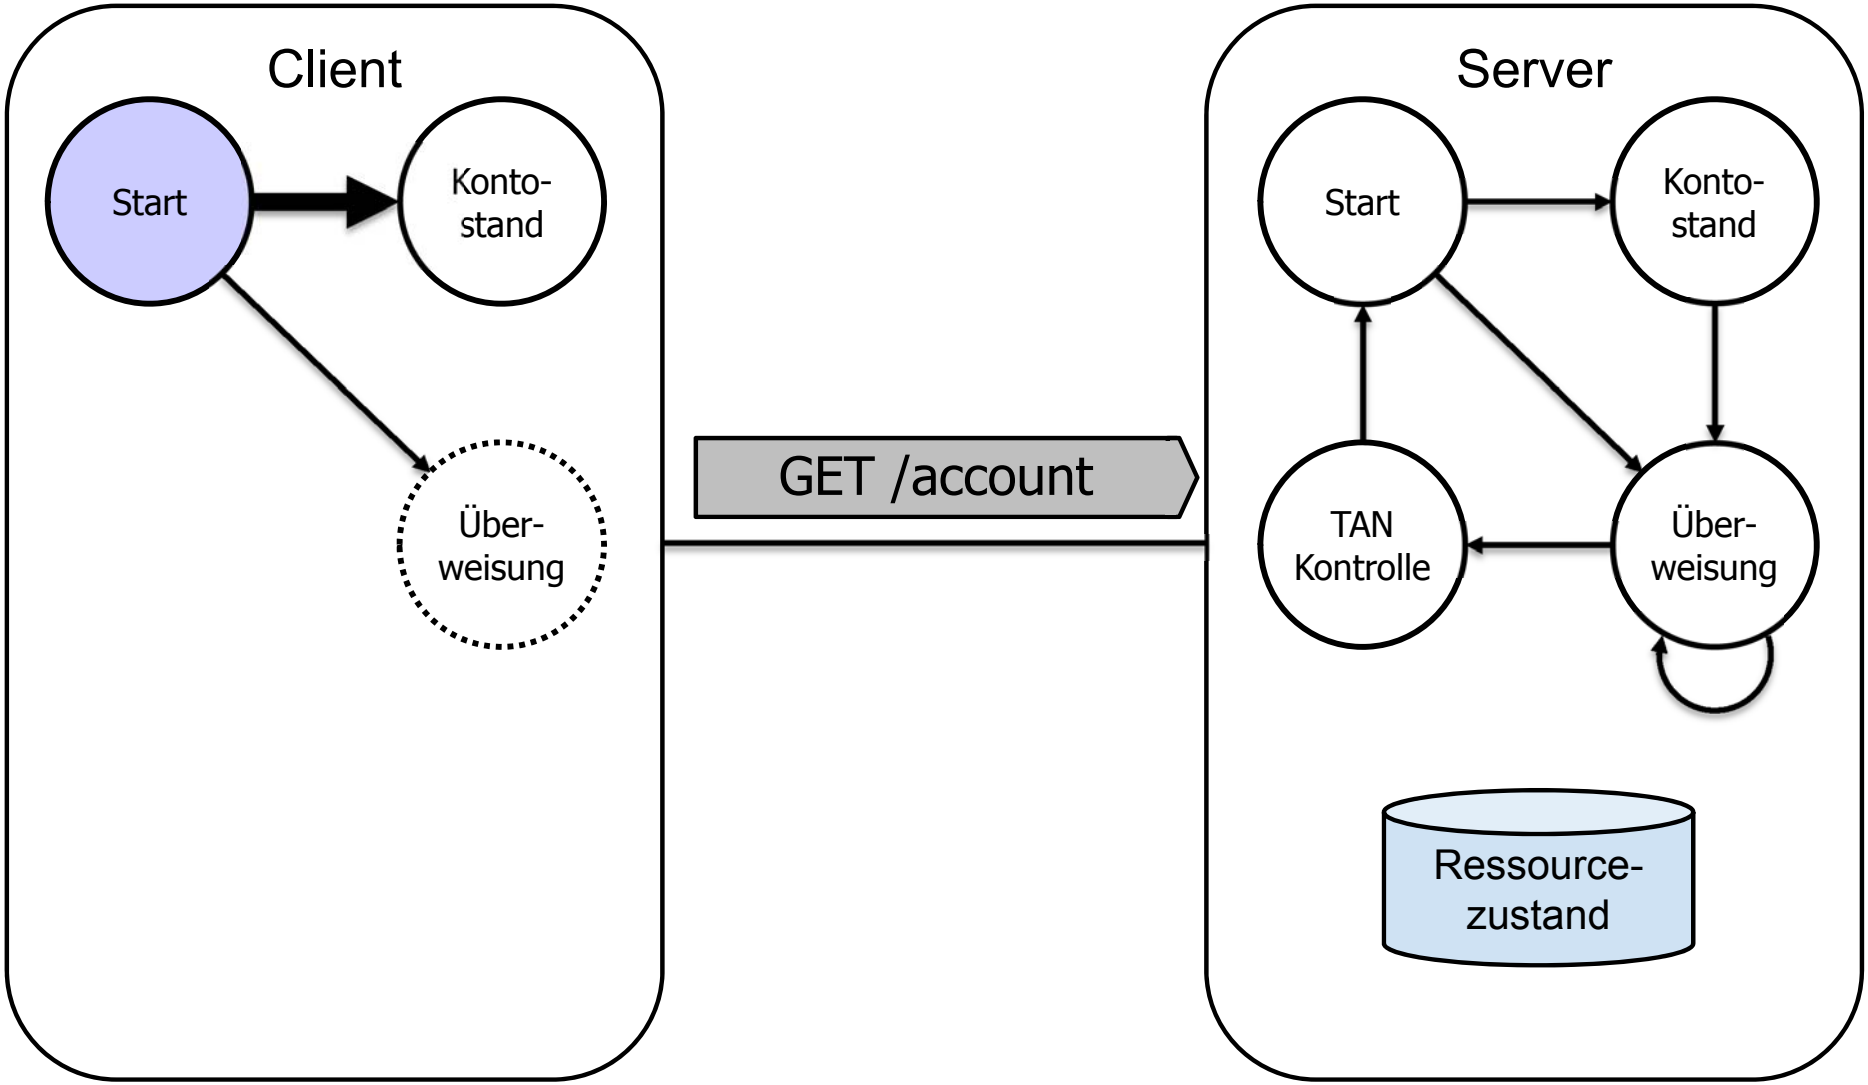

Beispiel: Bankanwendung mit REST

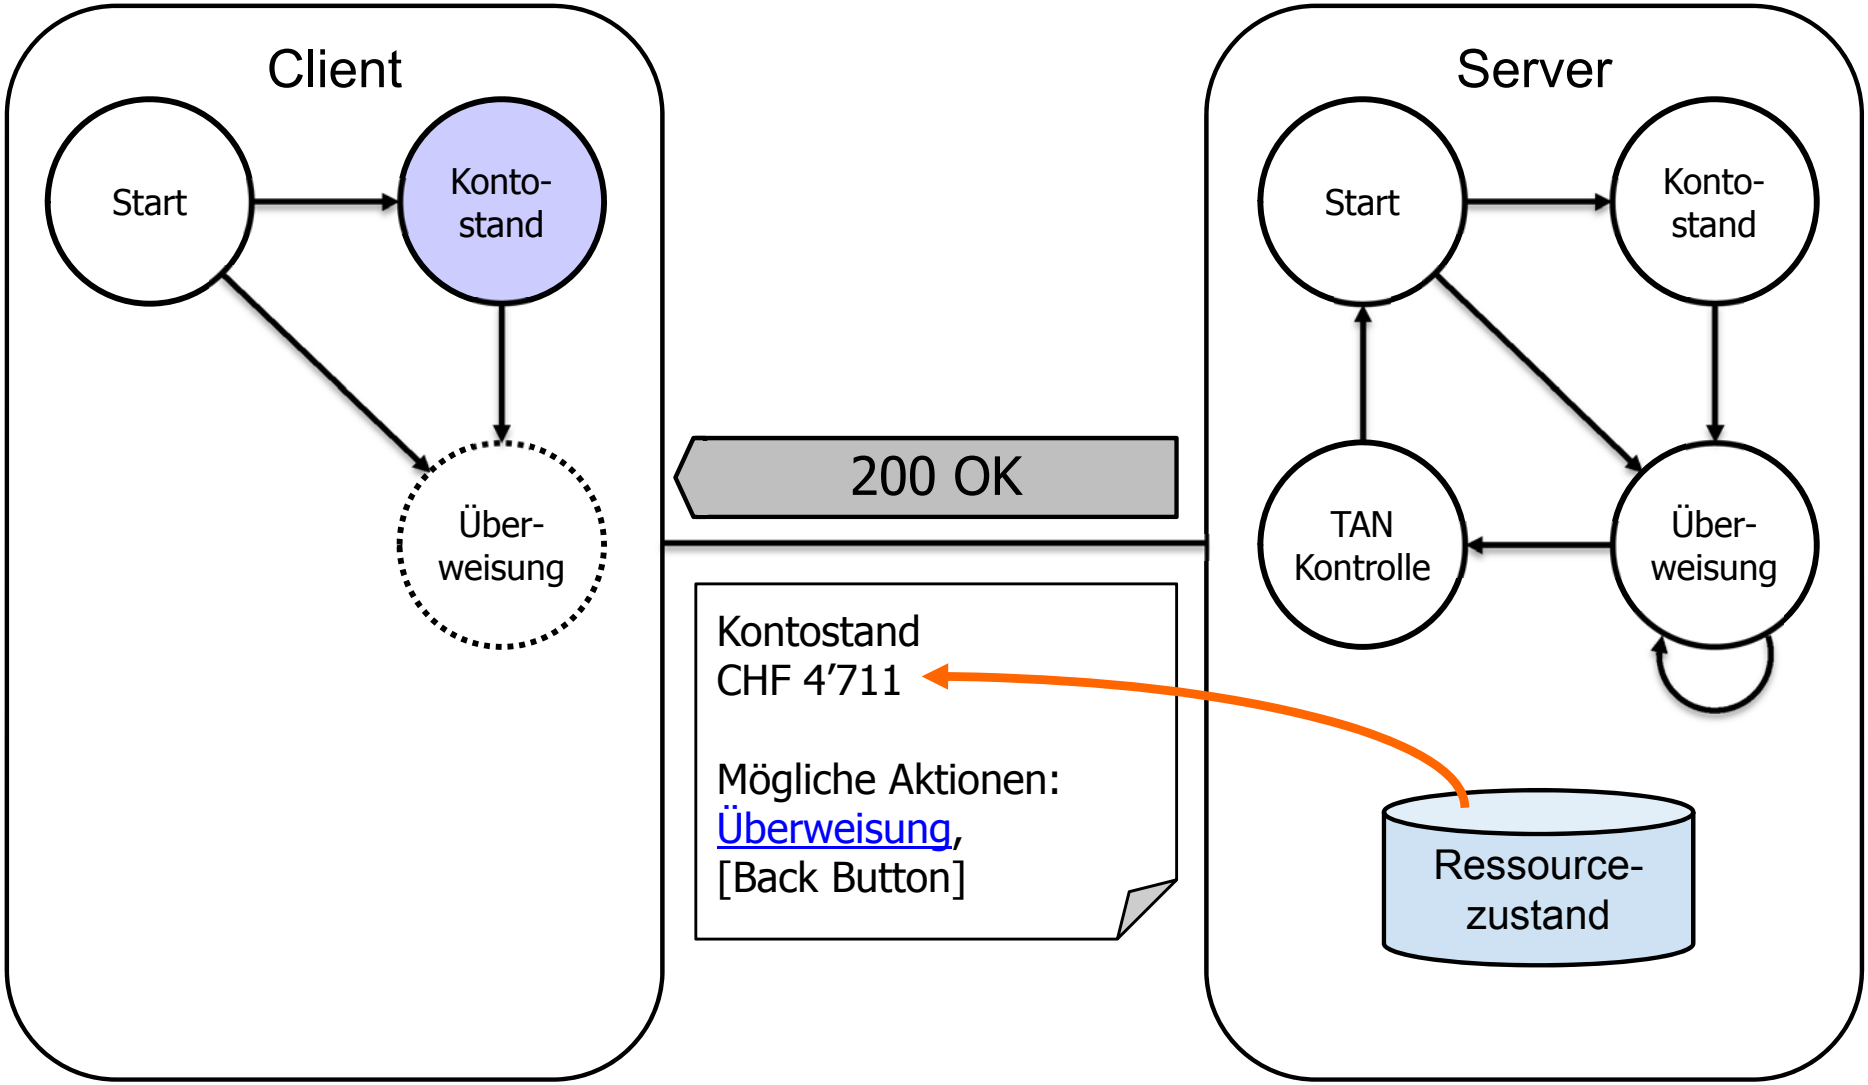

Beispiel: Bankanwendung mit REST

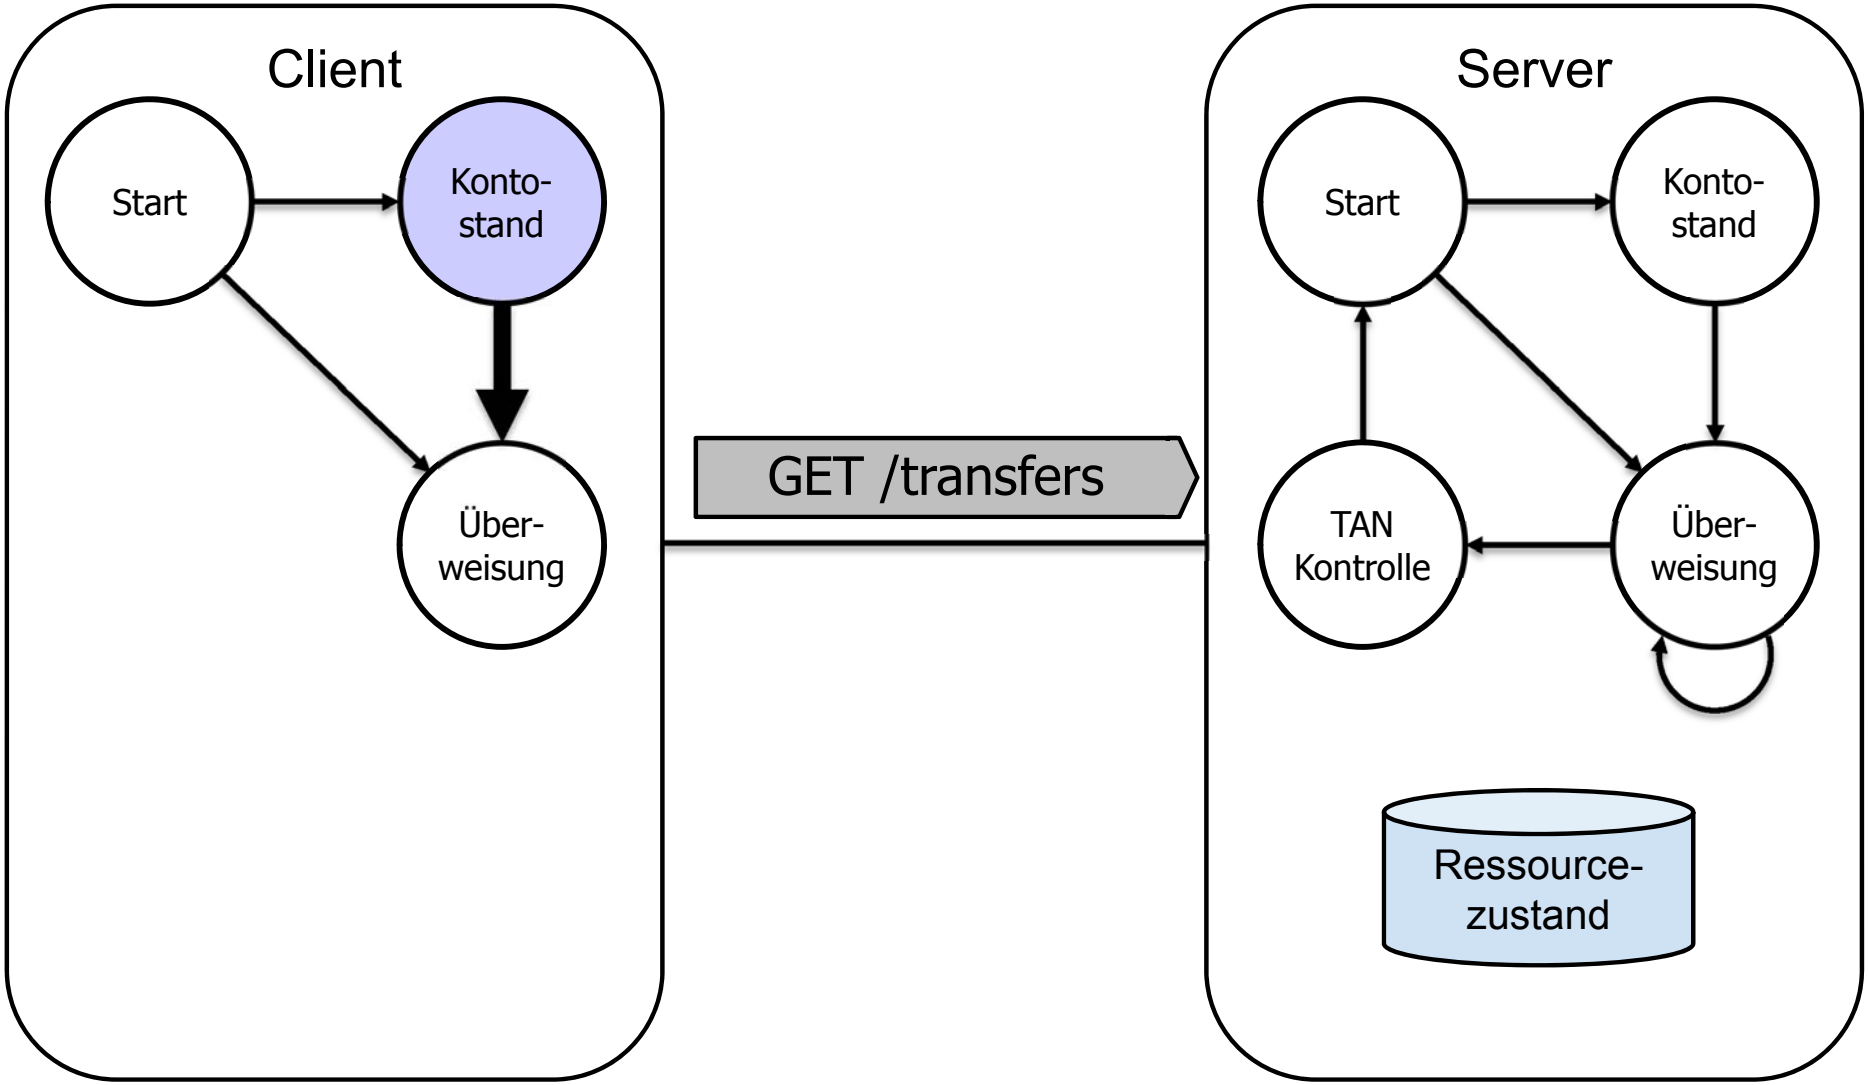

Beispiel: Bankanwendung mit REST

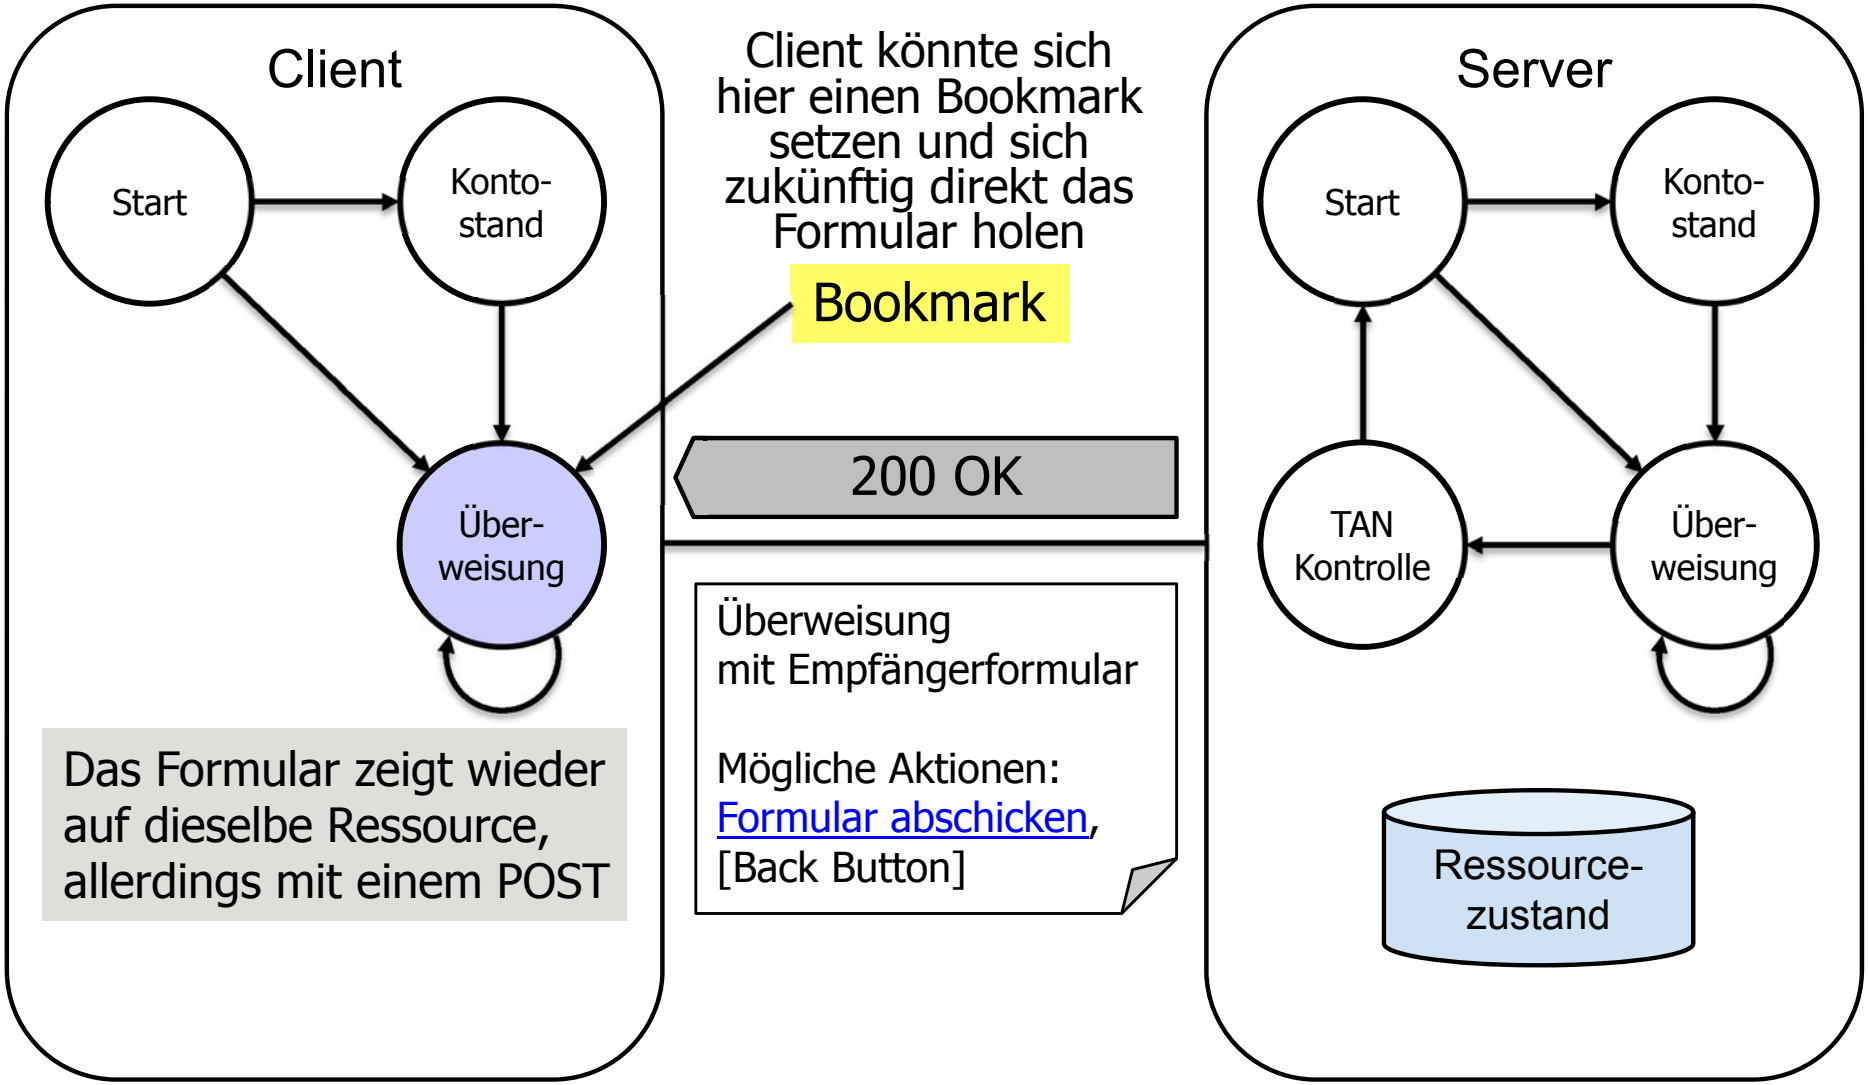

Beispiel: Bankanwendung mit REST

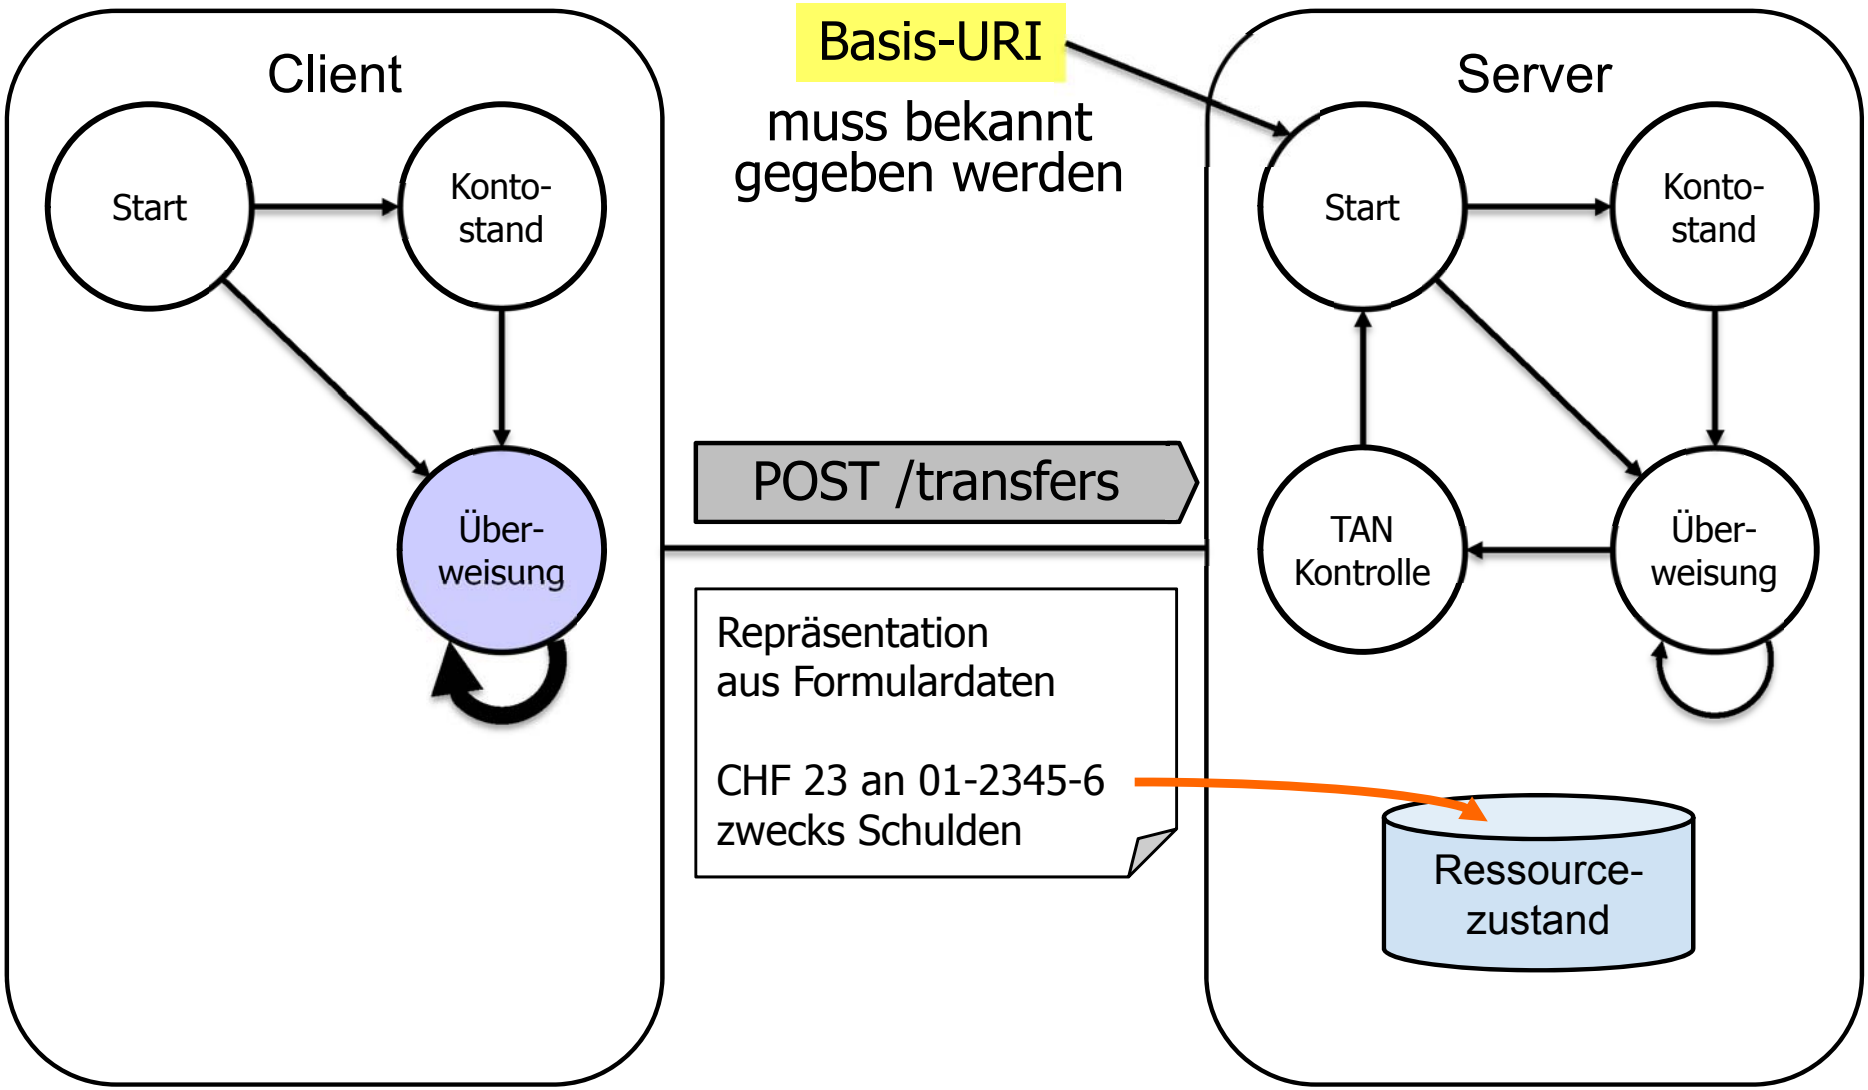

Beispiel: Bankanwendung mit REST

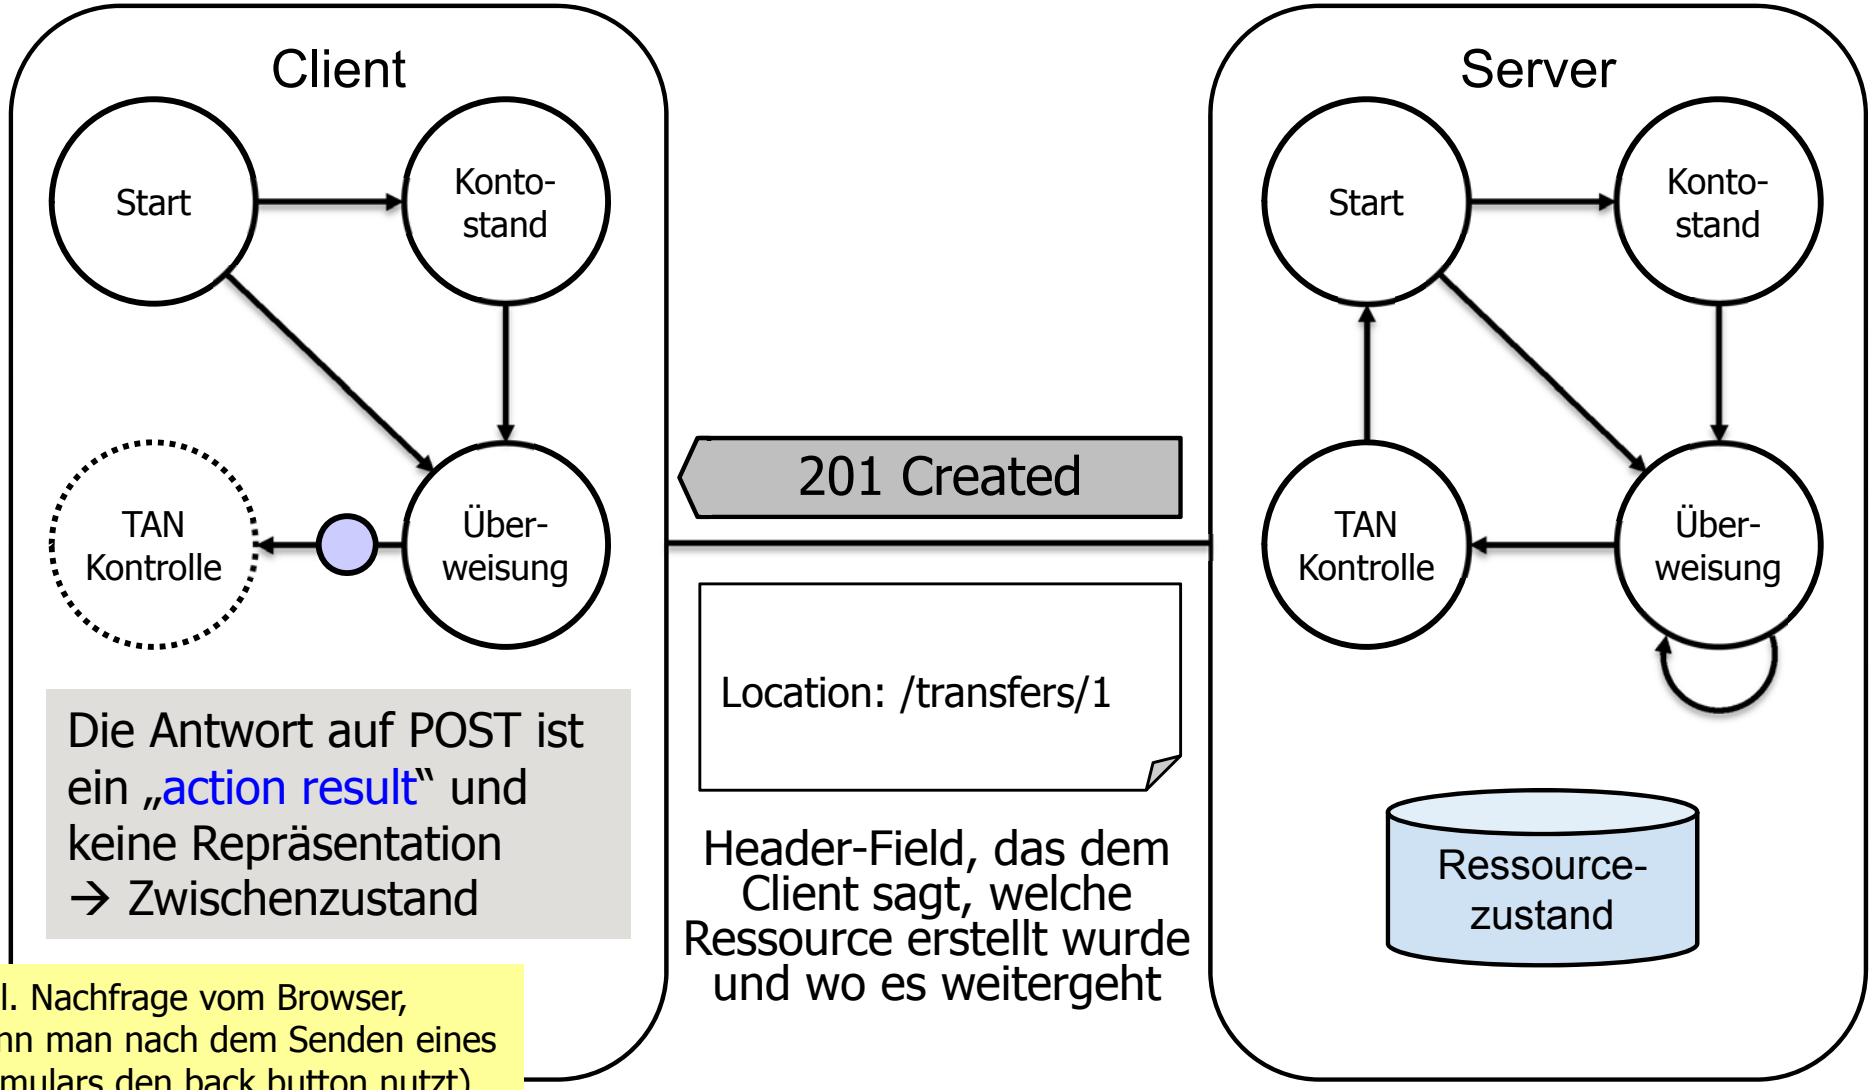

Beispiel: Bankanwendung mit REST

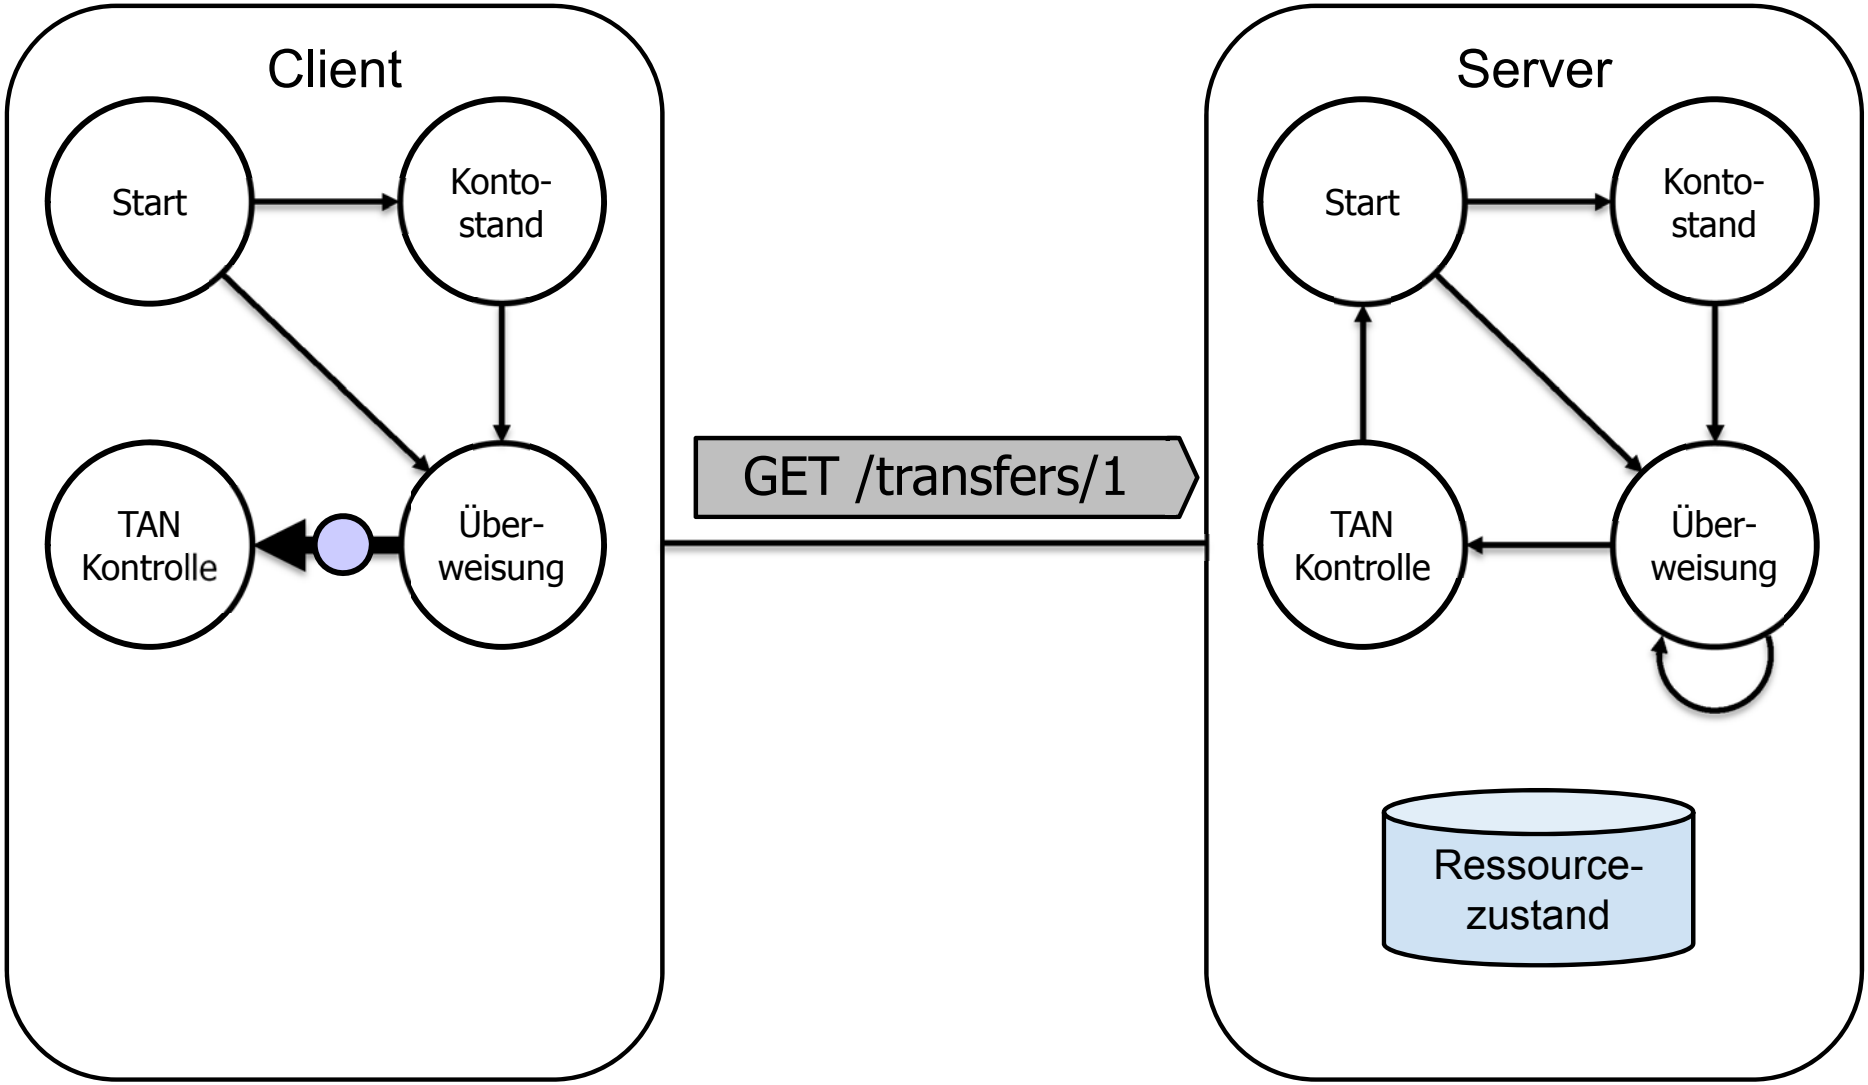

Beispiel: Bankanwendung mit REST

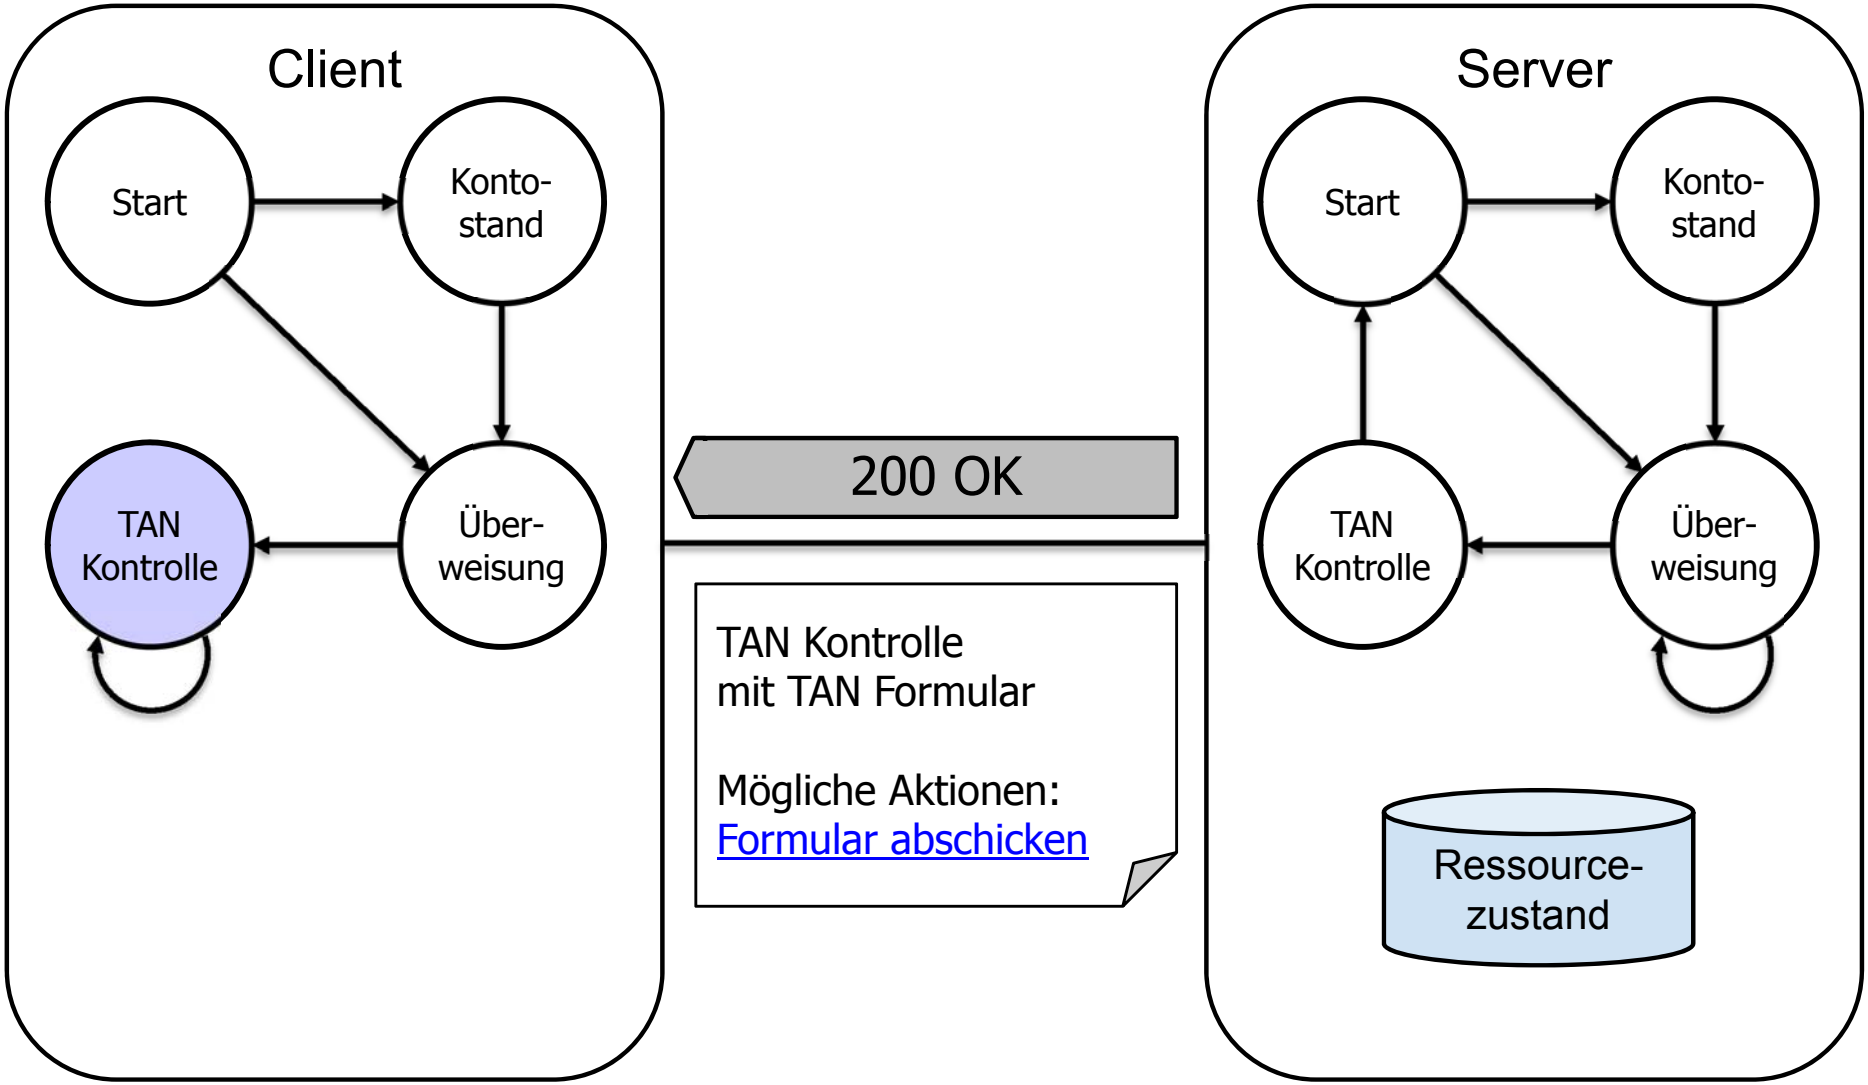

Beispiel: Bankanwendung mit REST

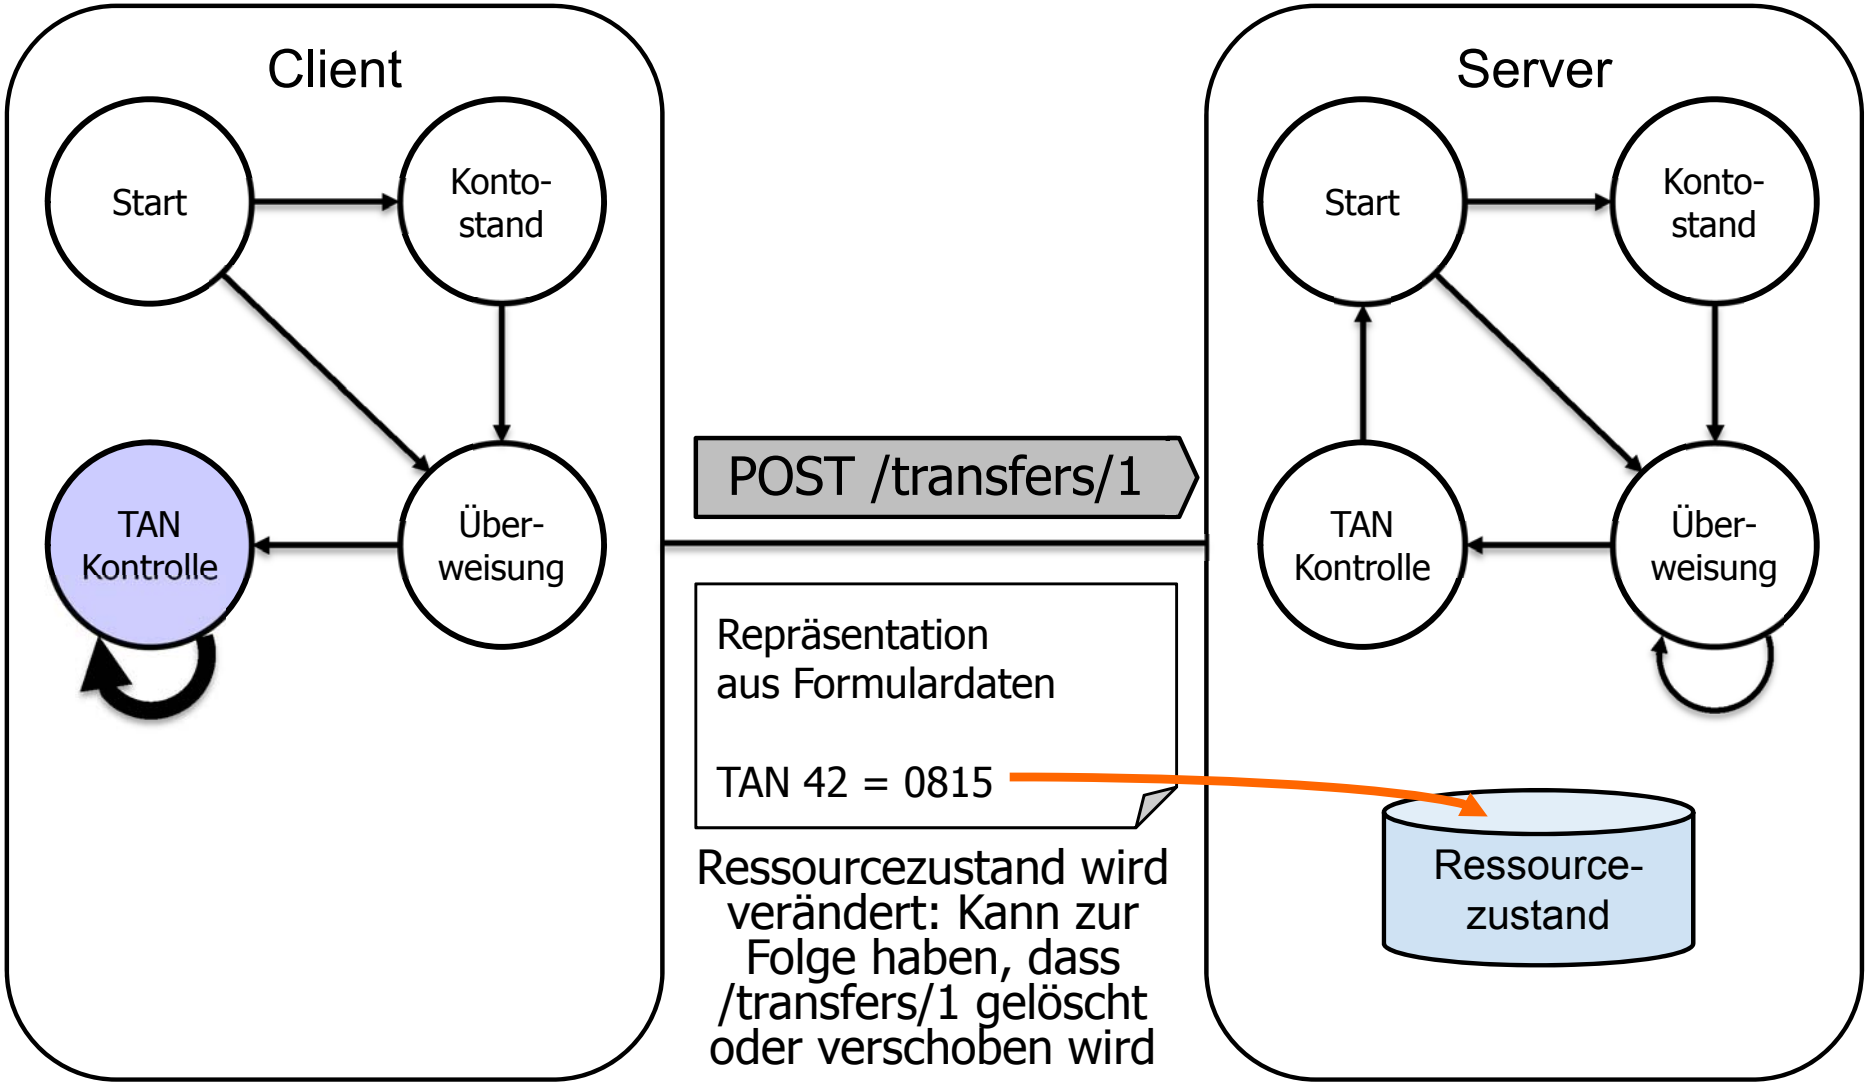

Beispiel: Bankanwendung mit REST

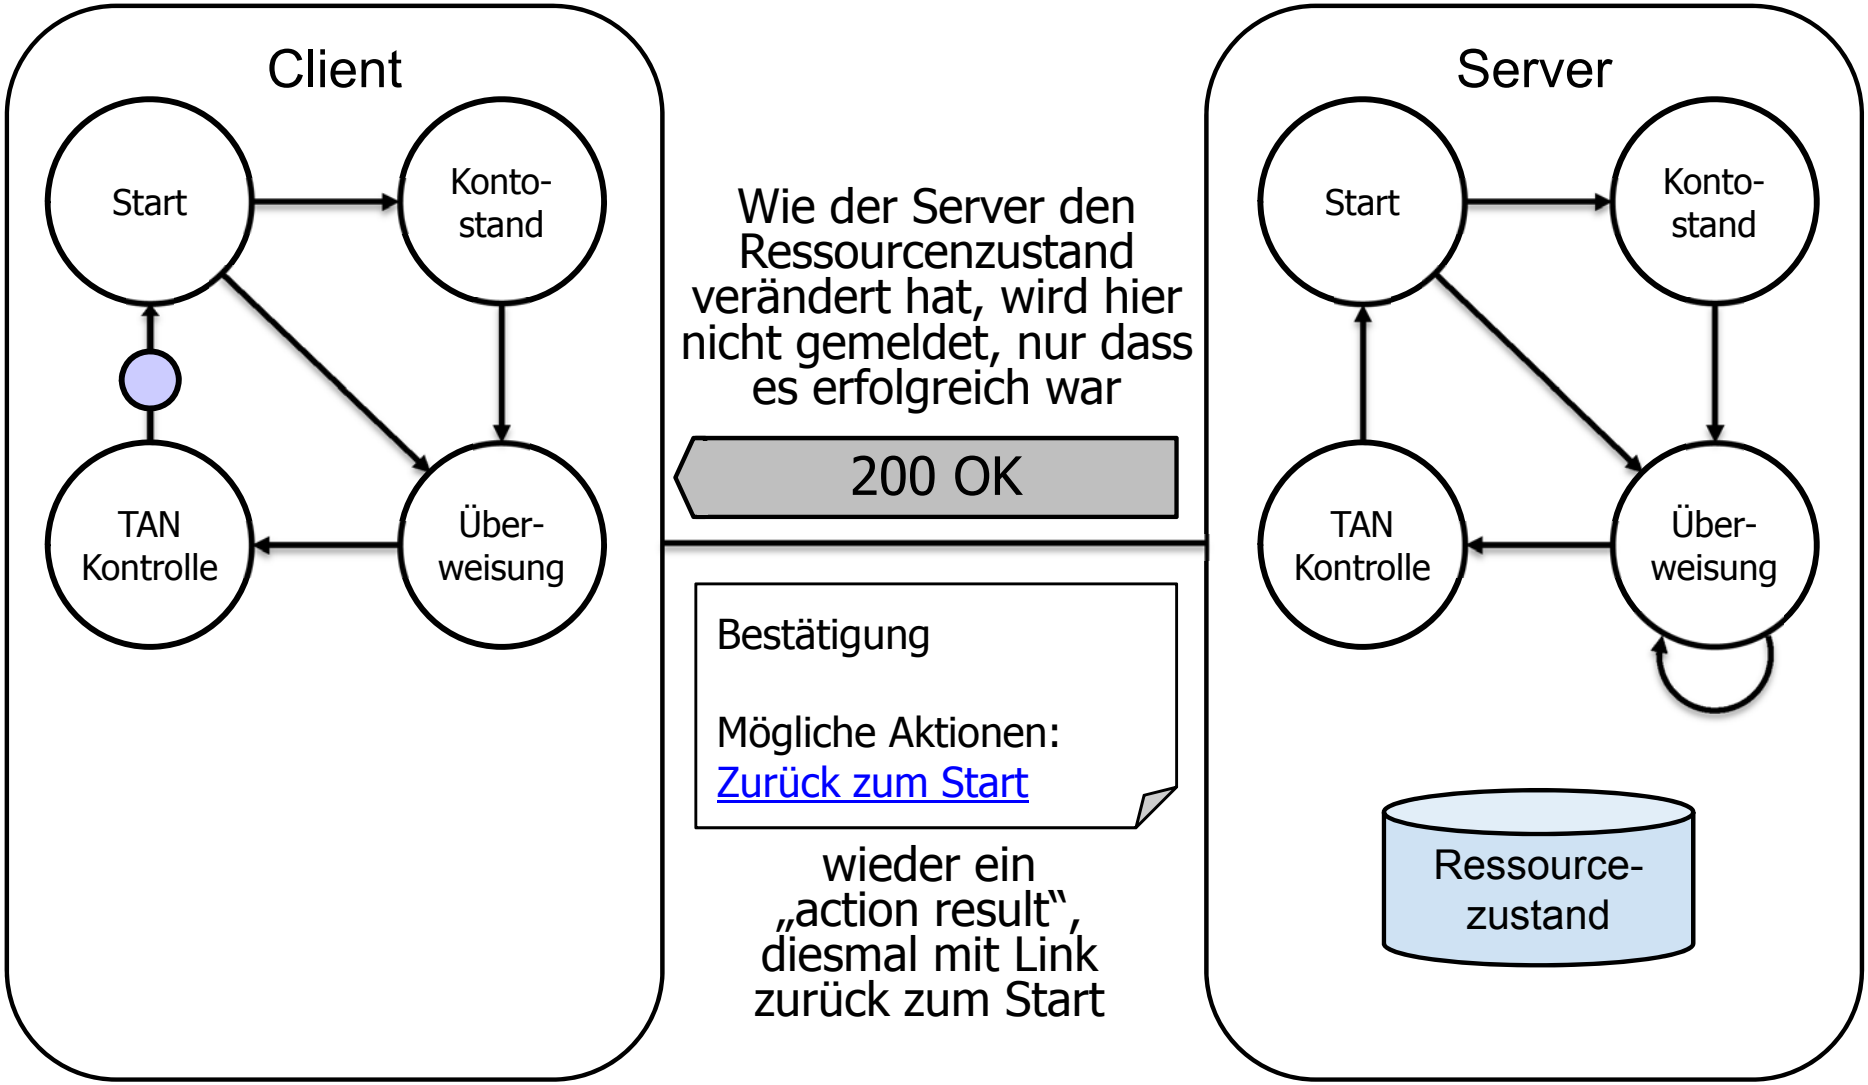

Beispiel: Bankanwendung mit REST

- Der Client hat die Anwendung sukzessive durch die Bekanntgabe von Links erlernt
- Der Server kann die Anwendungslogik unabhängig vom Client verändern → beim nächsten Mal werden einfach andere Links übertragen, die z.B. den Ablauf verändern oder zu neuen Ressourcen führen
- Bookmarks funktionieren dann ggf. nicht mehr
  - Server antwortet mit 404 Not Found
  - Client muss (oder besser: kann) wieder mit Basis-URI beginnen, um die Änderungen zu erfahren

Maschine statt Mensch hinter Client?
Siehe z.B. http://www.hydra-cg.com/
Community Group bei der W3C

Jini

Jini

- Platform ("middleware") for dynamic, cooperative, spontaneously networked systems
  - facilitates implementation of distributed applications

Jini serves as an example for a number of similar platforms (UPnP, Bluetooth SDP, SLP, HAVi, Salutation, e-speak, HP Chai,...)

Jini

- Platform ("middleware") for dynamic, cooperative, spontaneously networked systems
  - facilitates implementation of distributed applications

- framework of APIs with useful functions / services
- helper services (discovery, lookup,...)
- suite of standard protocols and conventions

Jini

- Platform ("middleware") for dynamic, cooperative, spontaneously networked systems
  - facilitates implementation of distributed applications

  - services, devices, ... find each other automatically ("plug and play")
  - dynamically added / removed components
  - changing communication relationships
  - mobility

Jini

- Platform ("middleware") for dynamic, cooperative, spontaneously networked systems
  - facilitates implementation of distributed applications
- Based on Java
  - uses RMI (Remote Method Invocation)
  - code shipping
  - requires JVM / bytecode everywhere
- Service-oriented
  - (almost) everything is considered a service

Service Paradigm

- Almost everything relevant is a service
- Jini's run-time infrastructure offers mechanisms for adding, removing, finding, and using services
- Services are defined by interfaces and provide their functionality via their interfaces
  - services are characterized by their type and their attributes (e.g., "600 dpi", "version 21.1")
- Services (and service users) may "spontaneously" form a so-called federation

Jini: Global Architecture

- Lookup Service (LUS)
  - main registry entity and brokerage service for services and clients
  - maintains information about available services
- Services
  - specified by Java interfaces
  - register together with proxy objects and attributes at the LUS
- Clients
  - know the Java interfaces of the services, but not their implementation
  - find services via the LUS
  - use services via proxy objects

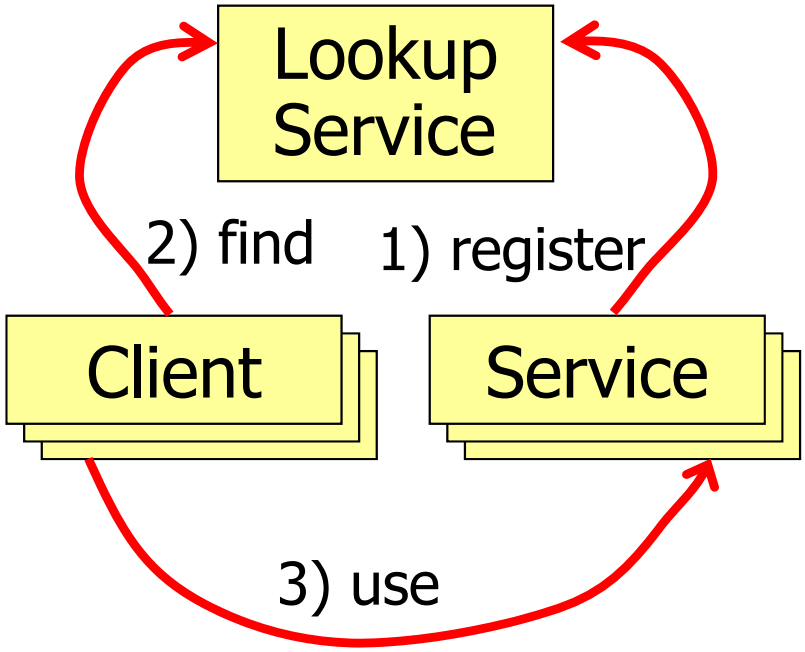

Network Centric

- Jini is based on the network paradigm
  - network = hardware and software infrastructure
- View is "network to which devices are connected to", not "devices that get networked"
  - network always exists, devices and services are transient
- Jini supports dynamic networks and adaptive systems
  - adding and removing components or communication relations should only minimally affect other components

Spontaneous Networking

- Objects in an open, distributed, dynamic world find each other and form a transitory community
  - cooperation, service usage, …
- Typical scenario: client wakes up (device is switched on, plugged in, …) and asks for services in its vicinity
- Finding each other and establishing a connection should be fast, easy, and automatic

Some Fallacies of Common Distributed Computing Systems

- The "classical" idealistic view...
  - the network is reliable
  - latency is zero
  - bandwidth is infinite
  - the network is secure
  - the topology is stable
  - there is a single administrator
- ...isn't true in practice
  - Jini acknowledges and addresses some of these issues

Bird's-Eye View on Jini as a Middleware Infrastructure

- Jini consists of a number of APIs
- Is an extension to the Java platform dealing with distributed computing
- Is an abstraction layer between the application and the underlying infra-structure (network, OS)

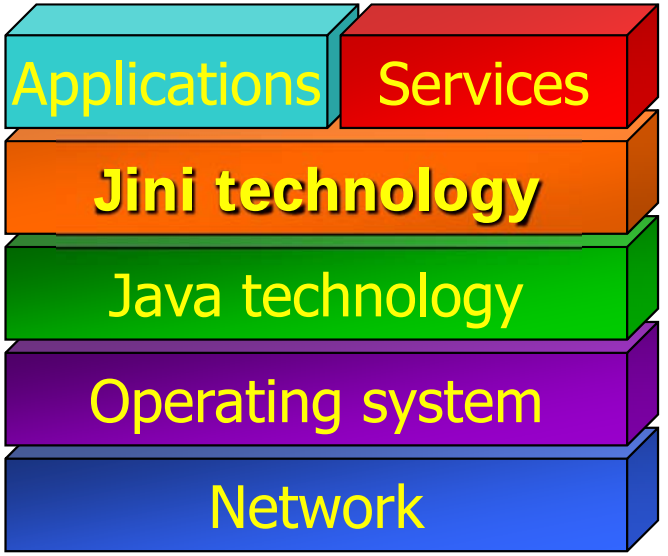

Jini's Use of Java

- Jini requires JVM (as bytecode interpreter)
  - homogeneity in a heterogeneous world

run protocols for discovery and join; have a JVM

- Devices that are not "Jini-enabled" have to be managed by a Jini-enabled software proxy (somewhere in the net)

Main Components of the Jini Infrastructure

- Lookup service (LUS)
  - as repository / naming service / trader
- Protocols
  - discovery & join, lookup of services
  - based on TCP/UDP/IP
- Service proxy objects
  - transferred from service to clients (via LUS)
  - represent the service locally at the client

Lookup Service

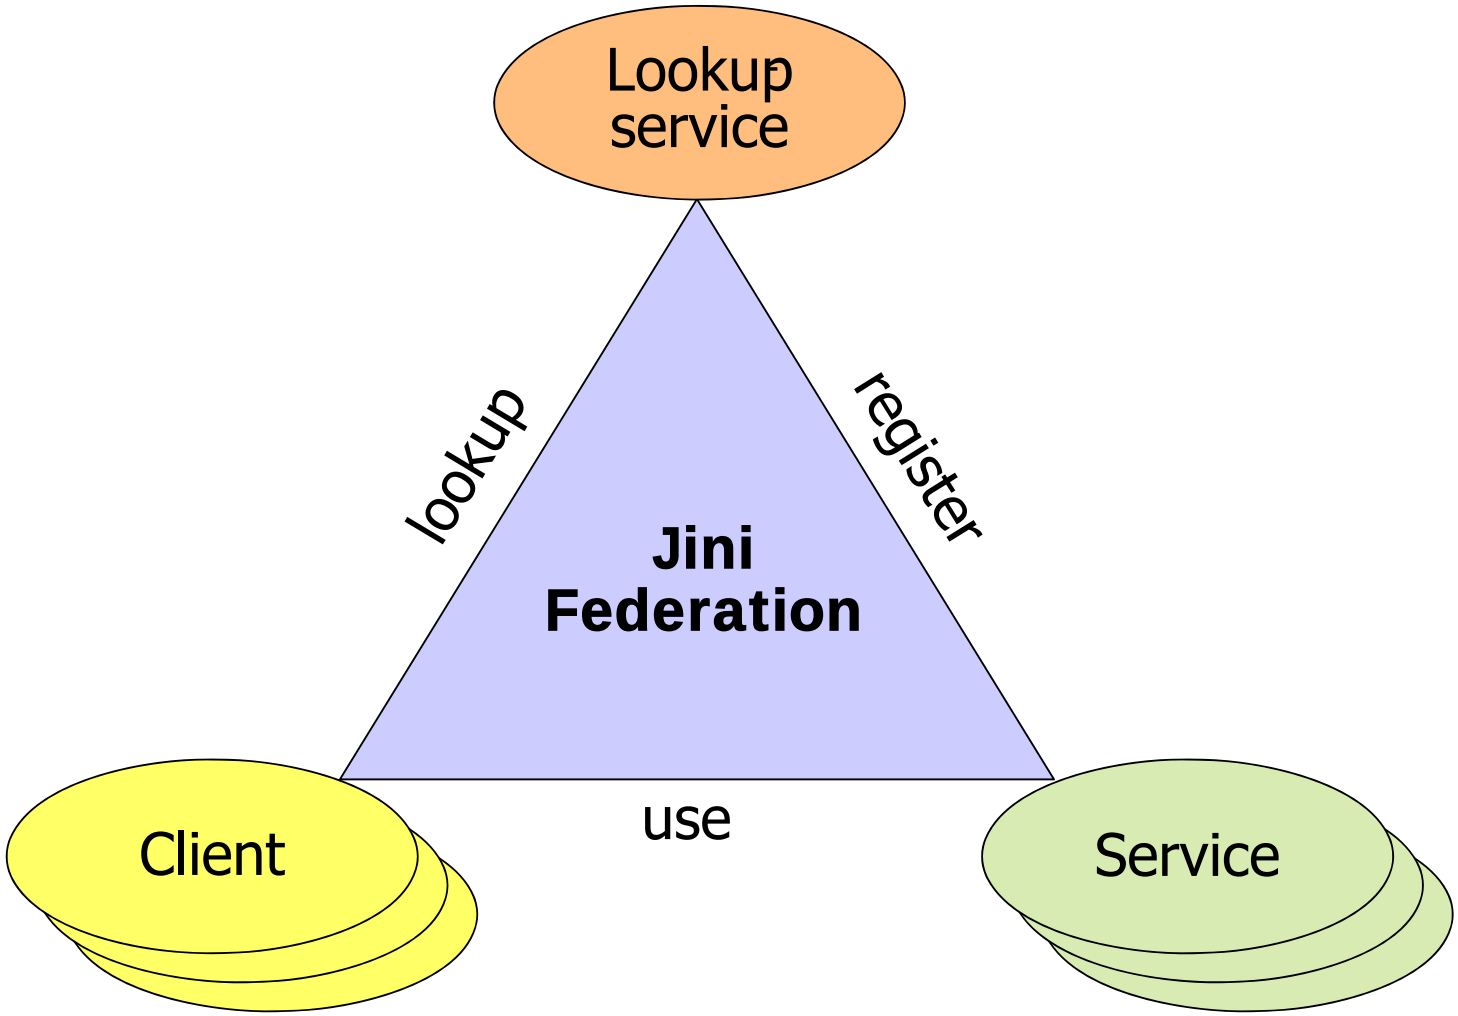

Example

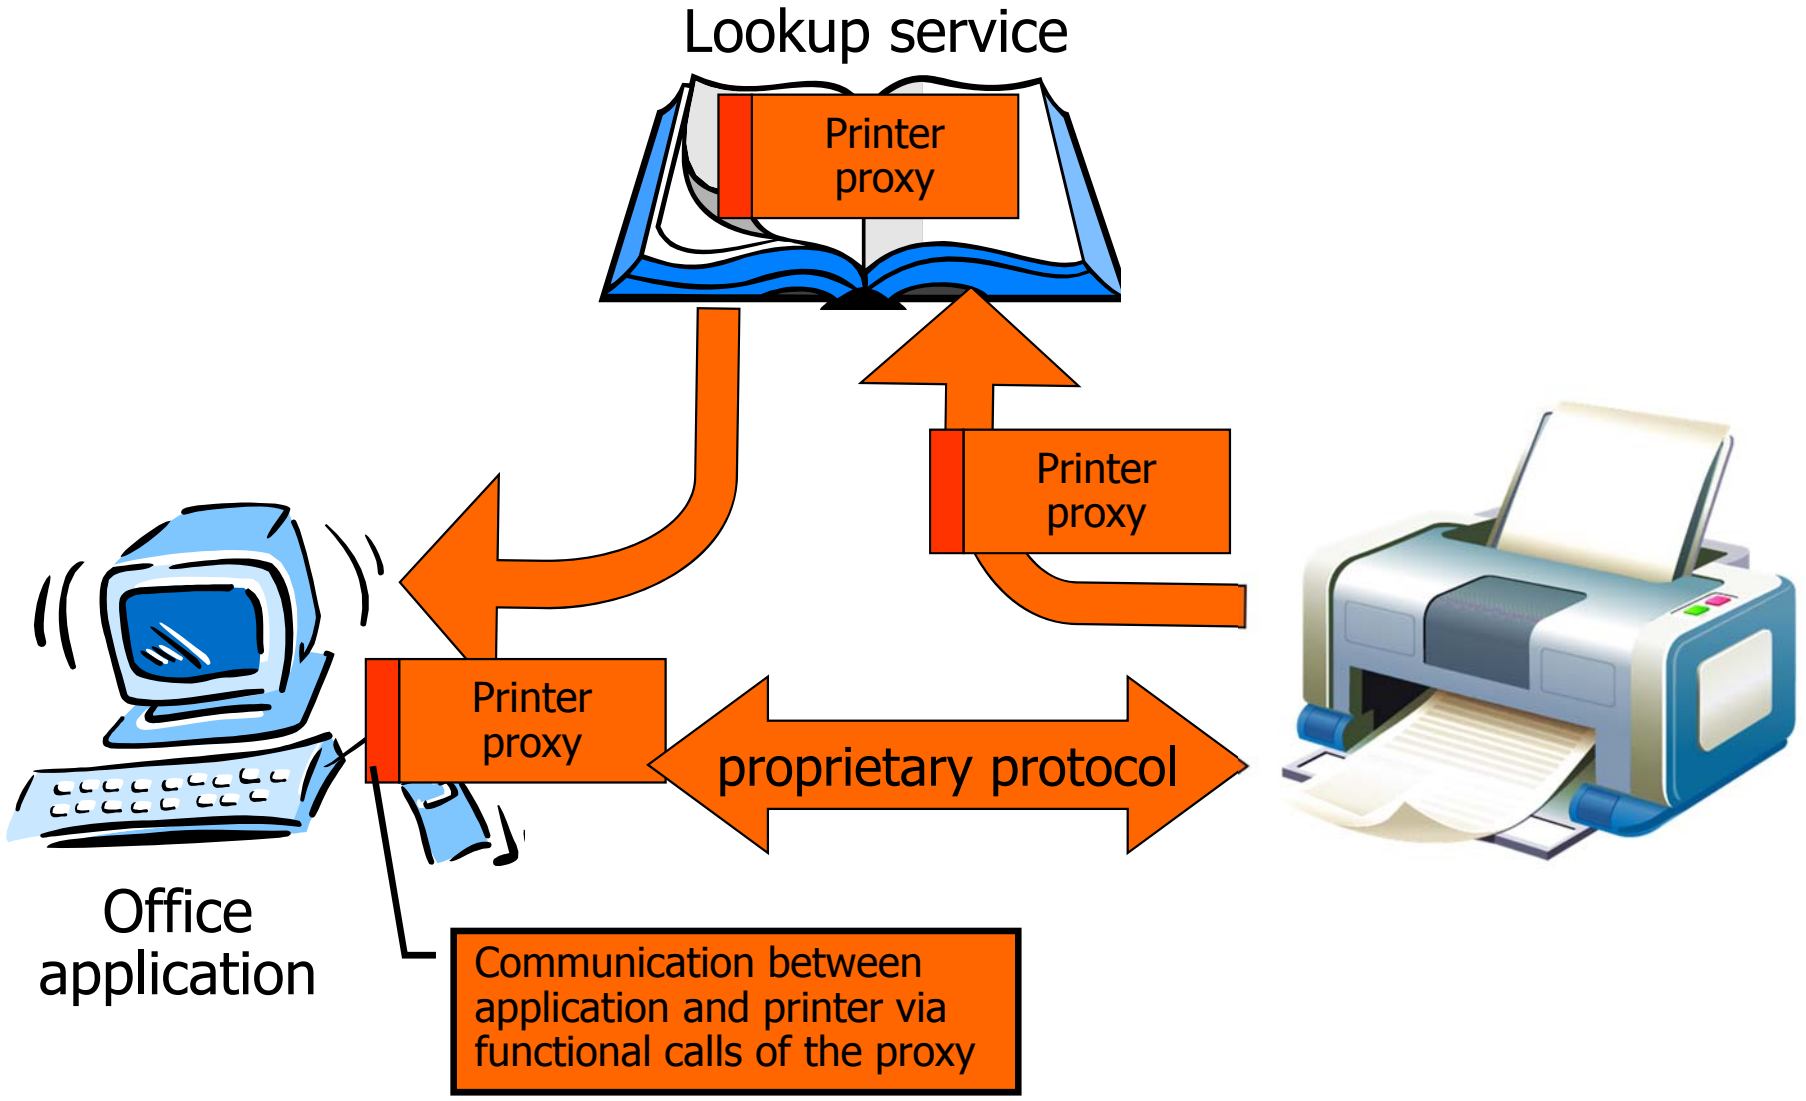
Lookup service
Printer proxy
Printer proxy
Printer proxy
proprietary protocol
Office application
Communication between application and printer via functional calls of the proxy

Lookup Service

- Uses Java RMI for communication
  - objects („proxies“) can migrate over the network
- Stores besides the name/address of a service:
  - set of attributes
    - e.g., printer(color: true, dpi: 600, ...)
  - proxies, which may be complex classes
    - e.g., user interfaces
- Further possibilities:
  - responsibility can be distributed to a number of (logically separated) lookup services
  - increase robustness by running redundant lookup services

Discovery: Finding a LUS

- Goal: Find a lookup service (without knowing anything about the network) to
  - advertise (register) an application service, or
  - find (look up) an existing application service
- Discovery protocol:
  - multicast to well-known address/port
  - lookup service replies with a serialized object (its proxy)
    - from then on communication with the LUS is via this proxy

Discovery

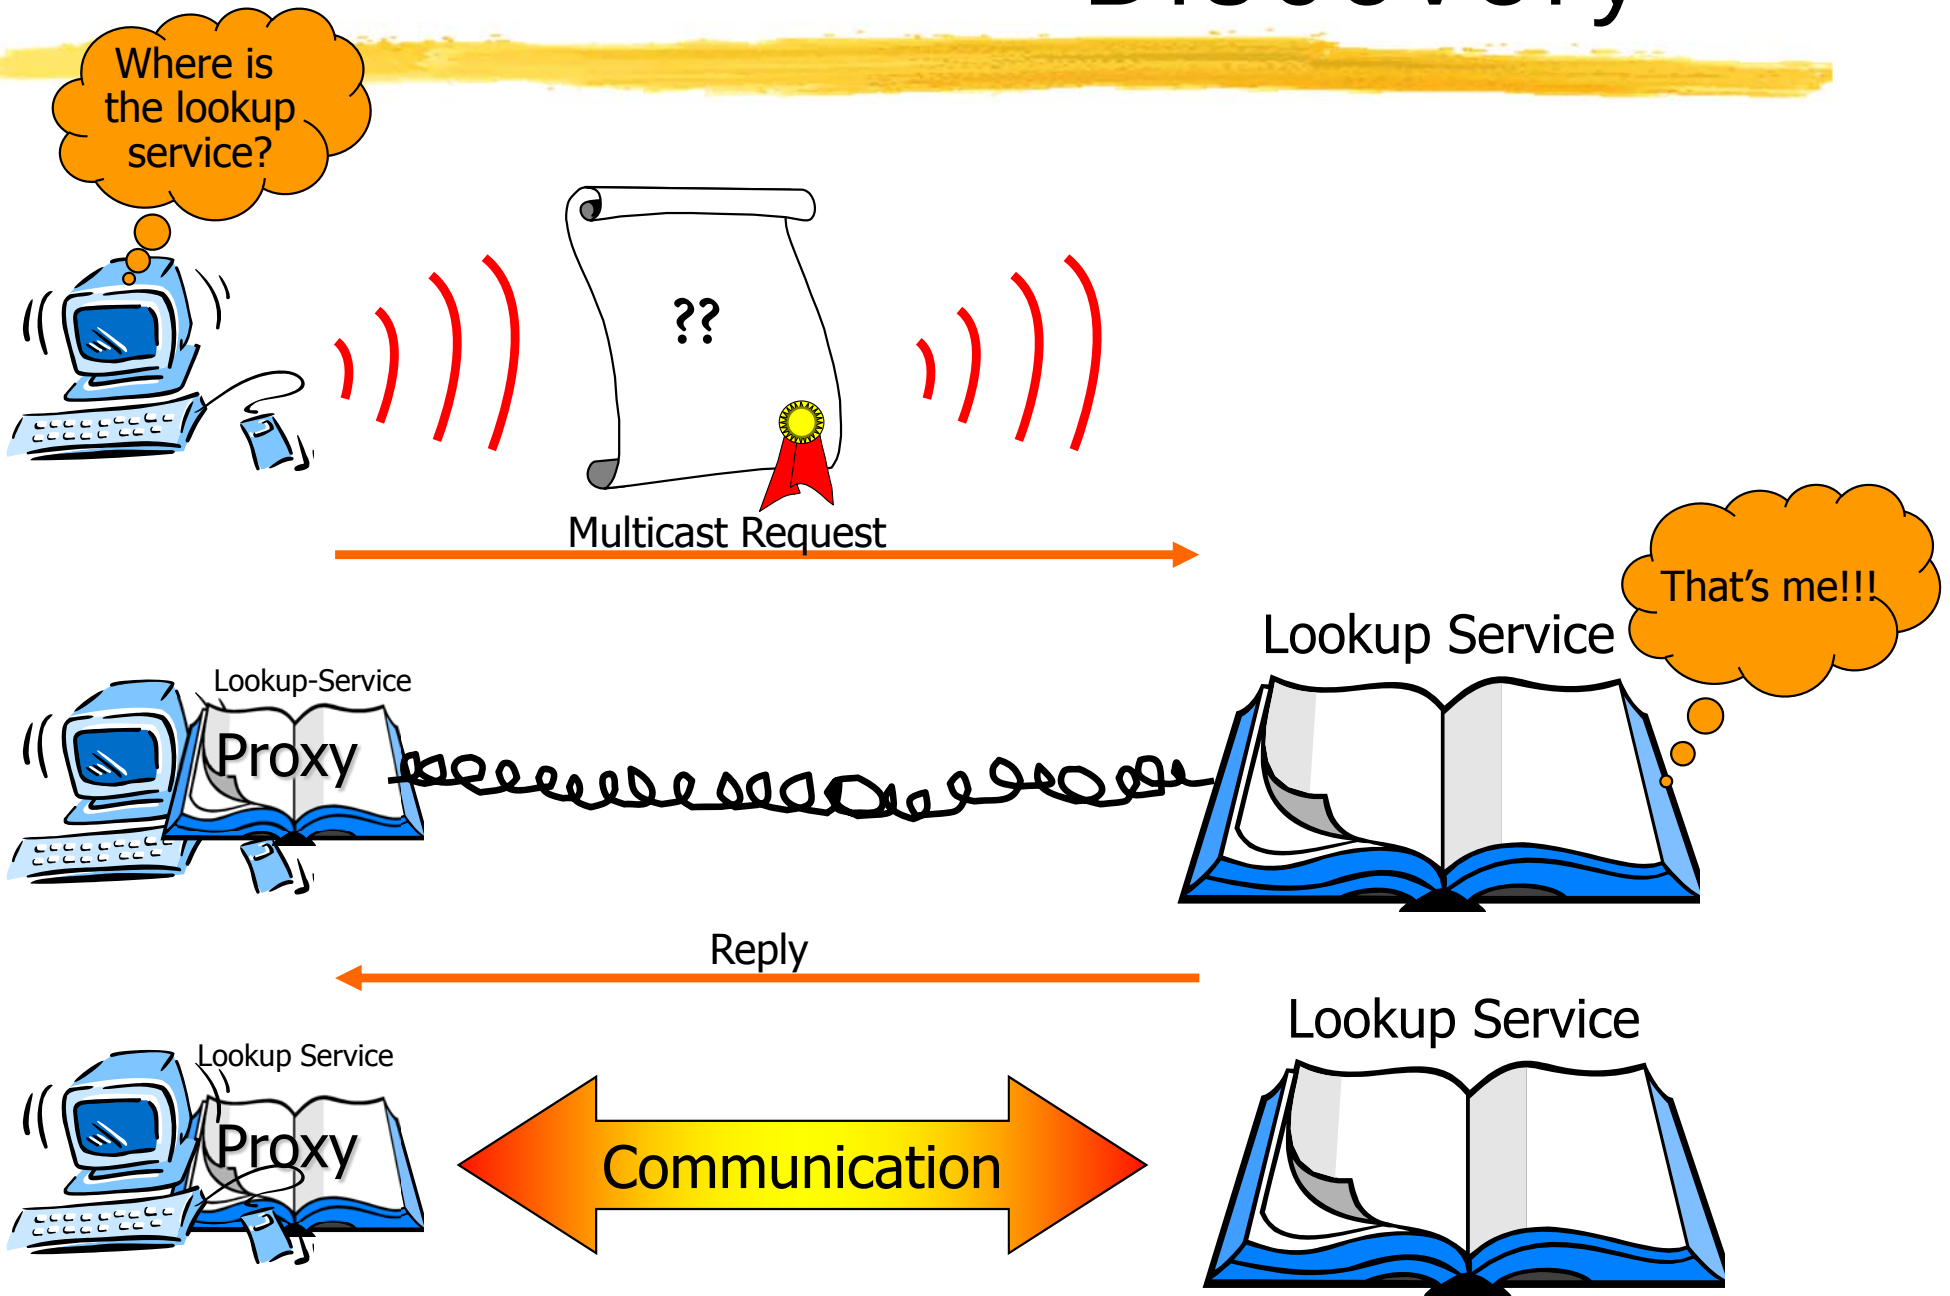
Where is the lookup service?
??
Multicast Request
That's me!!!
Lookup Service
Lookup-Service
Proxy
Reply
Lookup Service
Lookup Service
Proxy
Communication

Multicast Discovery Protocol

- Search for lookup services
  - no information about the host network needed
- Discovery request uses multicast UDP packets
  - multicast address for discovery (224.0.1.85)
  - default port number of lookup services (4160)
  - recommended time-to-live is 15
  - usually does not cross subnet boundaries
- Discovery reply is establishment of a TCP connection
  - port for reply is included in multicast request packet

Join: Registering a Service

- Assumption: Service provider already has a proxy of the lookup service (→ discovery)
- It uses this proxy to register its service
- Gives to the lookup service
  - its service proxy
  - attributes that further describe the service
- Service provider can now be found and its service be used in this Jini federation

Join

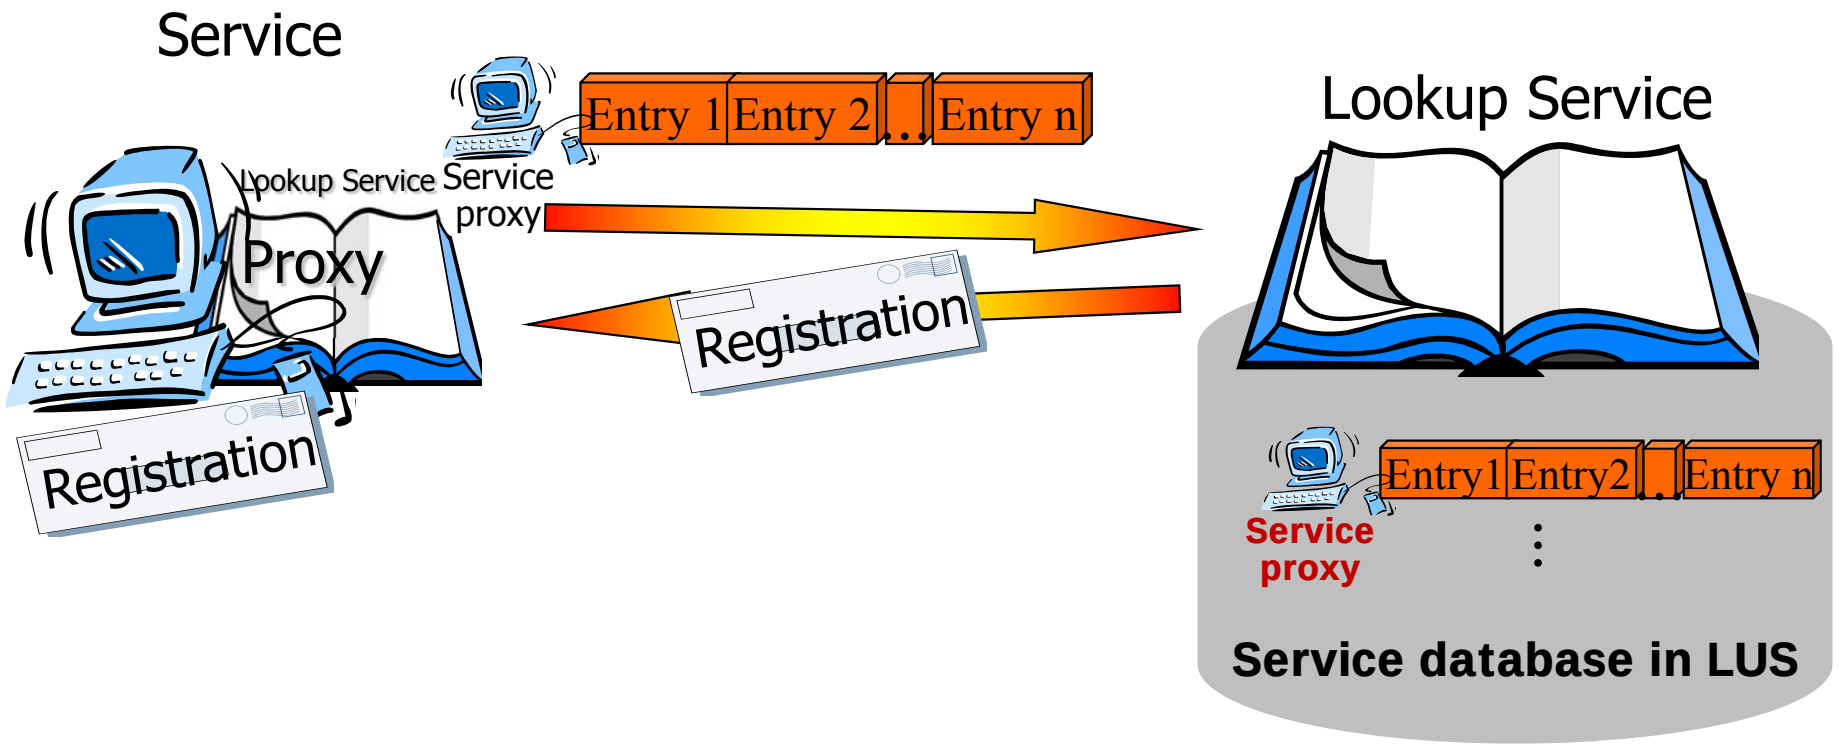
Service
Entry 1
Entry 2
Entry n
Lookup Service
Lookup Service
Service proxy
Proxy
Registration
Registration
Entry1
Entry2
Entry n
Service proxy
Service database in LUS

Join: More Features

- To join, a service supplies:
  - its proxy
  - a ServiceID (a "universally unique identifier")
  - a set of attributes
- Service waits a random amount of time after start-up
  - prevents packet storms after restarting a network segment
- Registration with a lookup service is bound to a lease
  - service has to renew its lease periodically

Lookup: Searching Services

- Client creates query for lookup service
  - matching by registration number of service (ServiceID) and/or service type and/or attributes
  - wildcards are possible („null“)
- Via its proxy at the client, the lookup service returns zero, one or more matches (i.e., server proxies)
- Selection among several matches is done by client

- Client uses the service by calling functions of the service proxy
- Any proprietary protocol between service proxy and service provider is possible

Lookup

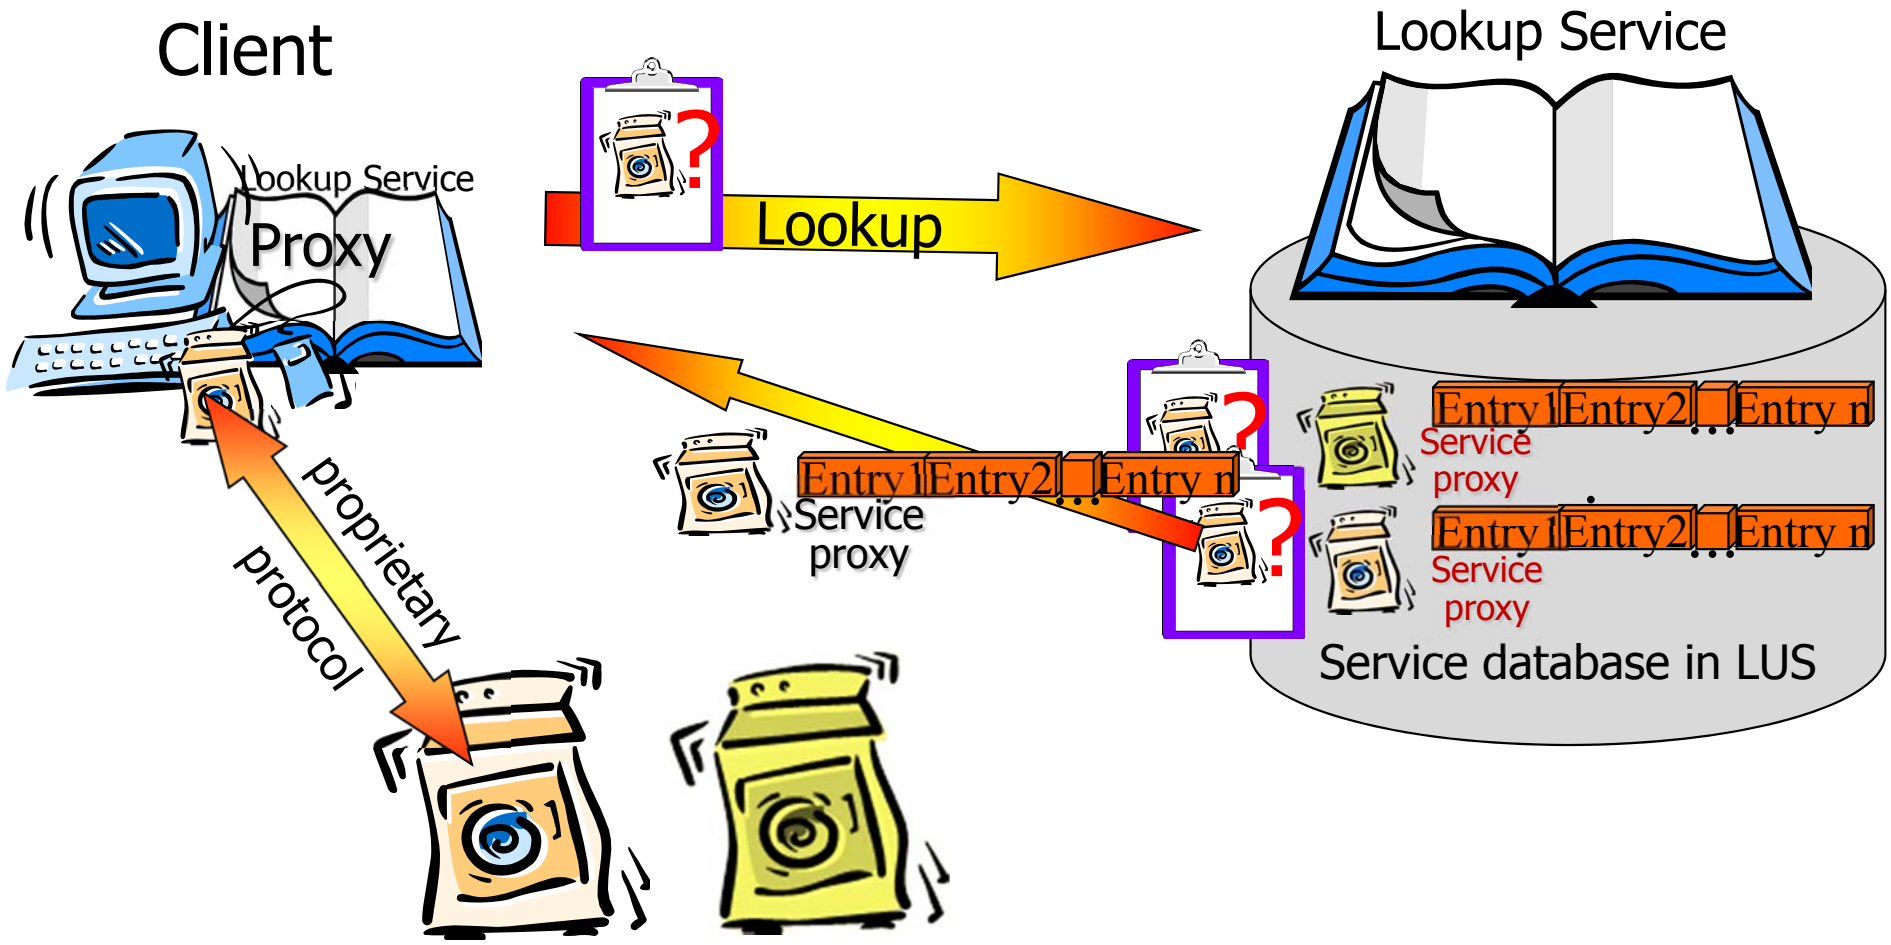
Client
Lookup Service
Proxy
Lookup
Lookup Service
Entry 1
Entry 2
Entry n
Service proxy
Entry 1
Entry 2
Entry n
Service proxy
Service database in LUS
Entry 1
Entry 2
Entry n
Service proxy
proprietary protocol

Proxies

- Proxy object is stored in the LUS upon registration
  - serialized object
  - implements the service interfaces
- Upon request, service proxy is sent to the client
  - client communicates with service implementation via its proxy: client invokes local methods of the proxy object
  - proxy implementation hidden from client

Smart Proxies

- Parts of (or the whole) service functionality may be executed by the proxy at the client
  - example: when dealing with large volumes of data, it usually makes sense to preprocess parts of the data (e.g., compressing video data before transfer)
- Partition of service functionality depends on service implementer's choice
  - client needs appropriate resources

Leases

- Leases are contracts between two parties
- Leases introduce a notion of time
  - resource usage is restricted to a certain time frame
- Repeatedly express interest in some resource:
  - I'm still interested in X
    - renew lease periodically
    - lease renewal can be denied
  - I don't need X anymore
    - cancel lease or let it expire

Distributed Events

- Objects on one JVM can register interest in certain events of another object on a different JVM
- "Publisher/subscriber" model

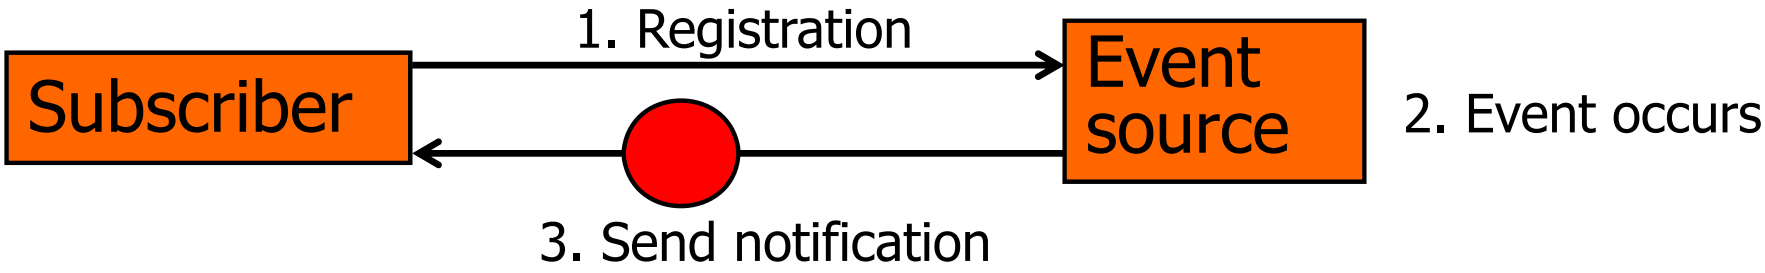

Distributed Events – Example

- Example: printer is plugged in
  - printer registers itself with local lookup service
- Maintenance application wants to update software

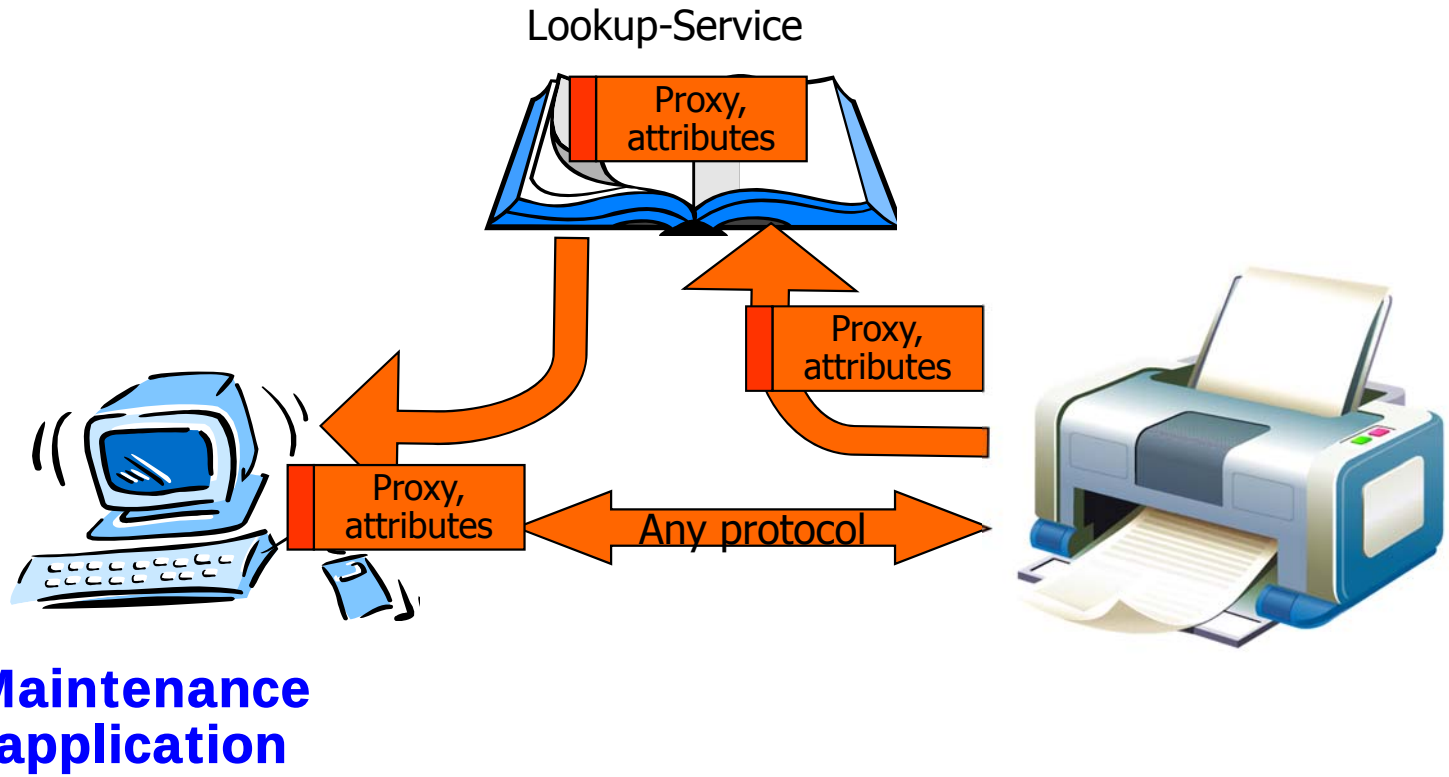

Distributed Events – Example

- Search for printers is "outsourced" to the lookup service
  - "sensor service" looks for certain services on behalf of the maintenance application
  - maintenance application registers for events showing the arrival of certain types of printers
  - sensor service observes the lookup service
  - notifies application as soon as matching printer arrives via distributed events

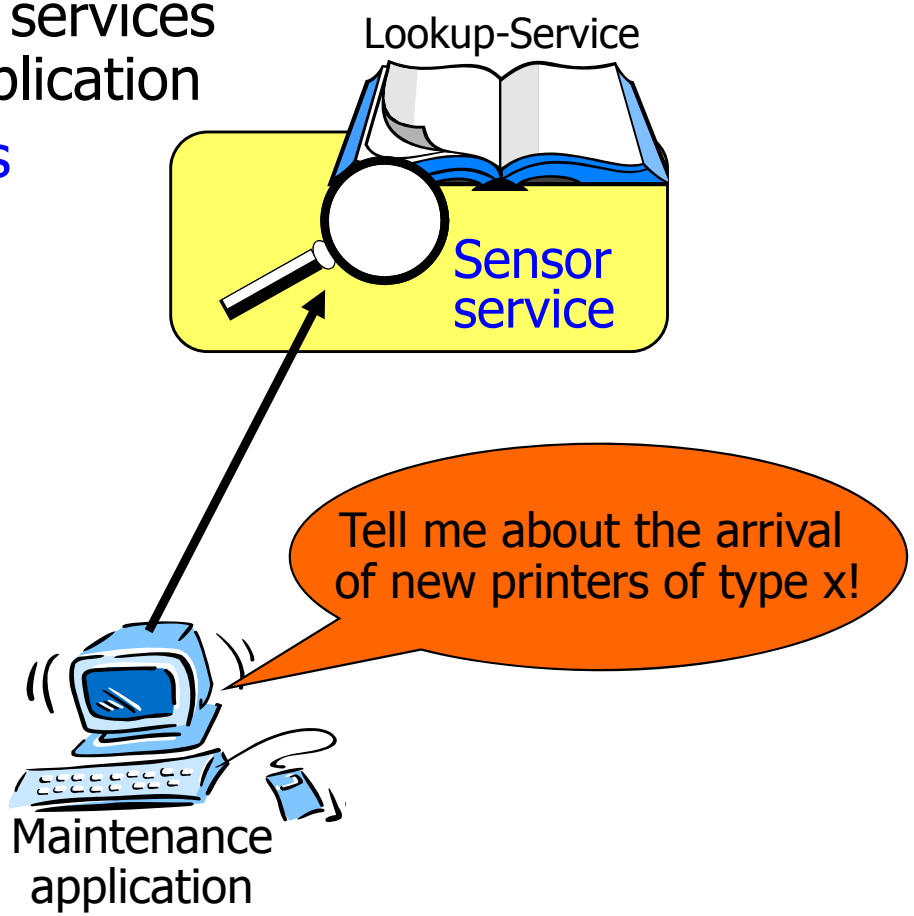

Distributed Events – Example

- Example: printer arrives, registers with lookup service
  - printer performs discovery and join
  - sensor finds new printer in lookup service
  - checks if there is an event registration for this type of printer
  - notifies all interested objects
  - maintenance application retrieves printer proxy and updates software

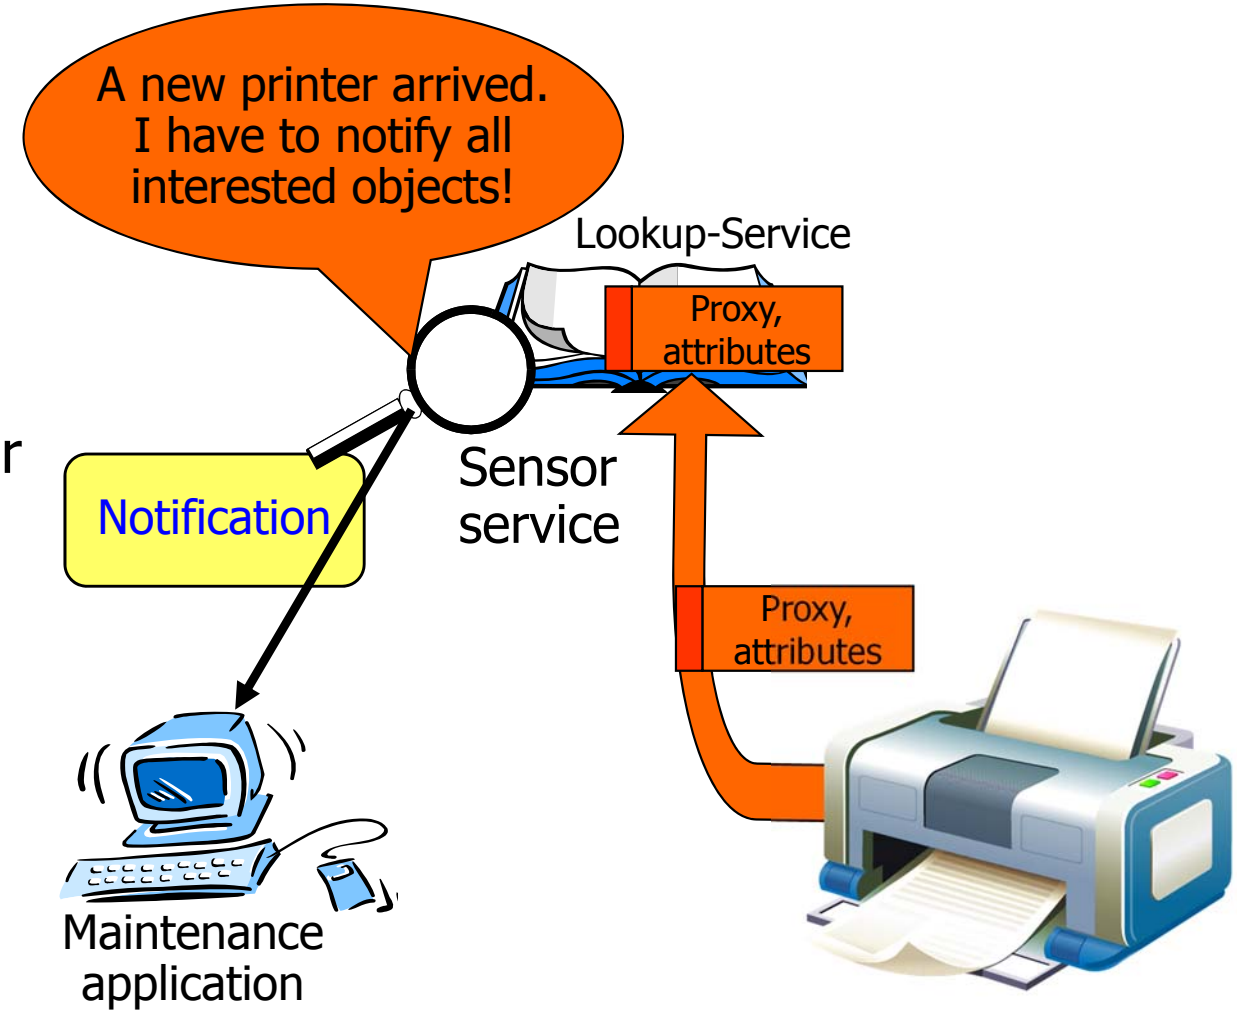

Broadcast / Multicast

Gruppenkommunikation
(Broadcast / Multicast)

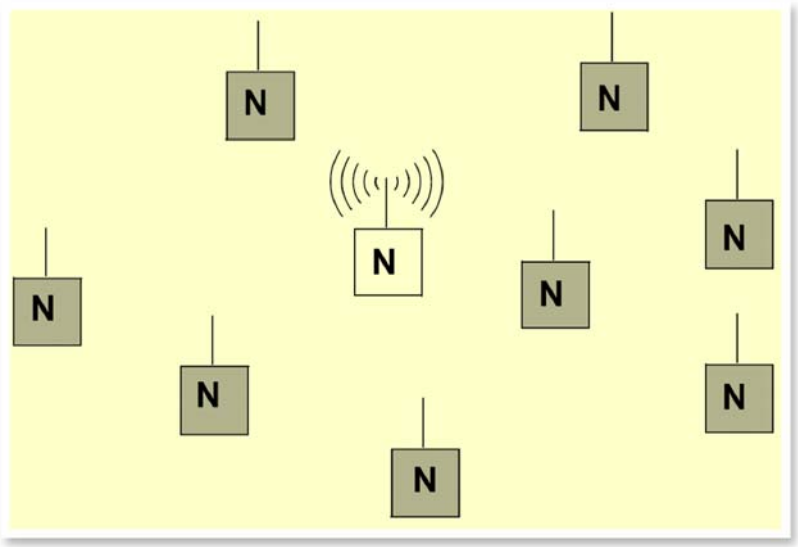

Broadcast: Senden an die Gesamtheit aller Teilnehmer

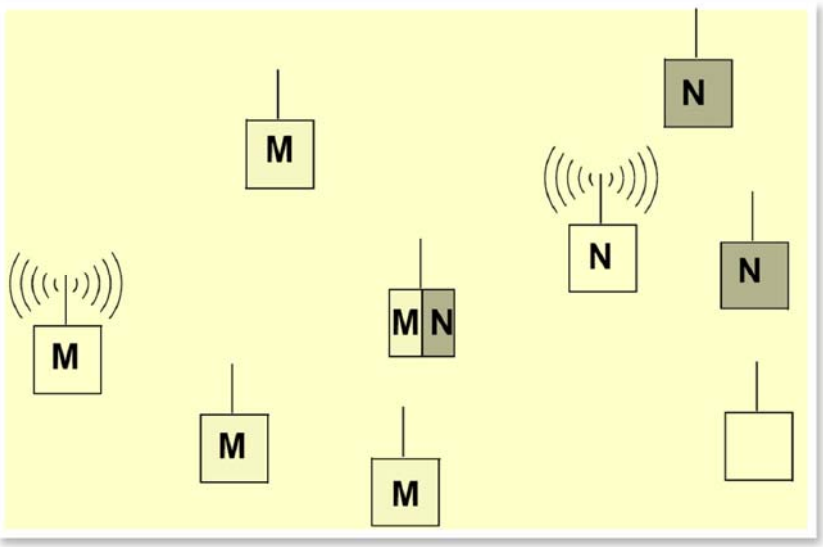

Multicast: Senden an eine Untergruppe aller Teilnehmer

- Multicast entspricht Broadcast bezogen auf die Gruppe
  - verschiedene Gruppen können sich evtl. überlappen
  - jede Gruppe hat typischerweise eine Multicastadresse

Anwendungen von Gruppenkommunikation

- Informieren
  - z.B. Newsdienste

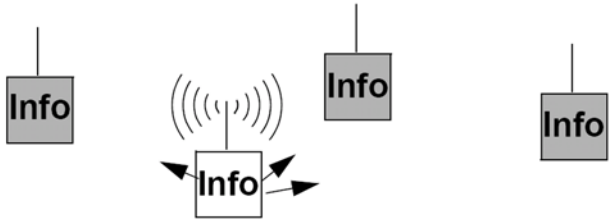

- Suchen
  - z.B. Finden von Objekten und Diensten

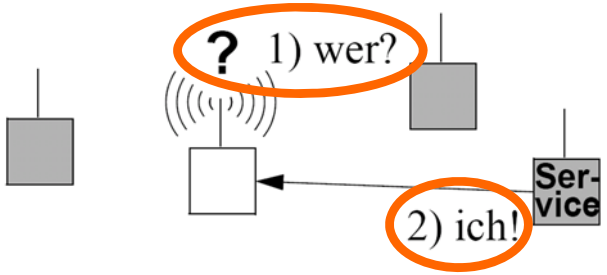

- „Logischer Unicast“
  - an replizierte Komponenten

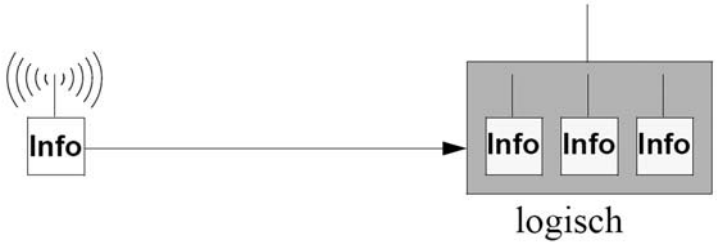

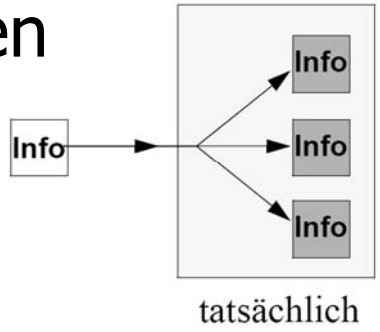

Typische Anwendungs-klasse von Replikation: Fehlertoleranz

Gruppenkommunikation – idealisierte Semantik

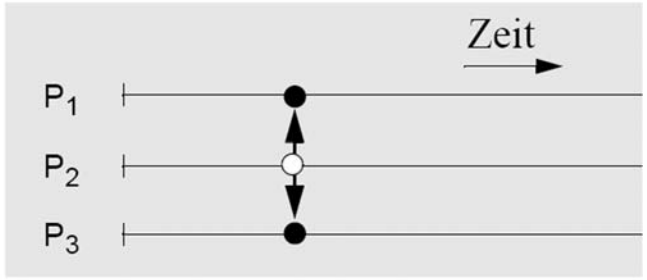

1. Modellhaftes Vorbild: Speicherbasierte Kommunikation
   - augenblicklicher „Empfang"
   - vollständige Zuverlässigkeit (kein Nachrichtenverlust etc.)

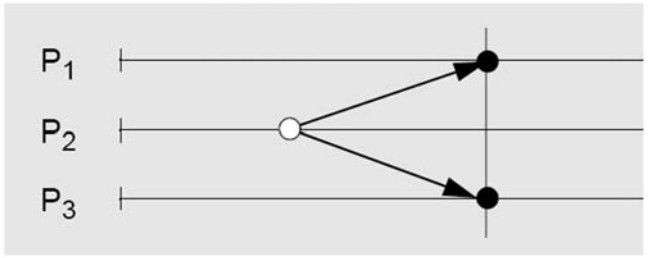

2. Idealisierte Sicht bei nachrichtenbasierter Kommunikation:
   - gleichzeitiger Empfang
   - vollständige Zuverlässigkeit

- In verteilten Systemen ist dies alles aber nicht realistisch

  (2. kann allerdings in der Praxis bei Vorhandensein einer globalen Zeit evtl. durch eine „Sperrfrist" als Zeitpunkt in der Zukunft erreicht werden)

Gruppenkommunikation – tatsächliche Situation

- Zugrundeliegendes Medium (Netz) oft nicht multicastfähig
  - LANs höchstens innerhalb von Teilstrukturen; WLAN als Funknetz a priori anfällig für Übertragungsstörungen
  - multicastfähige Netze sind typischerweise nicht verlässlich (keine Empfangsgarantie)

- Daher oft „Simulation“ von Multicast durch ein Protokoll aus vielen Punkt-zu-Punkt-Einzelnachrichten
  - z.B. Multicast-Server, der die Information an alle Empfänger einzeln weiterverteilt

Gruppenkommunikation – tatsächliche Situation (2)

- Nachrichtenkommunikation entspricht nicht dem „Ideal“
  - nicht-deterministische Zeitverzögerung
    → Empfang zu unterschiedlichen Zeiten
  - keine garantierte Zuverlässigkeit der Nachrichtenübermittlung

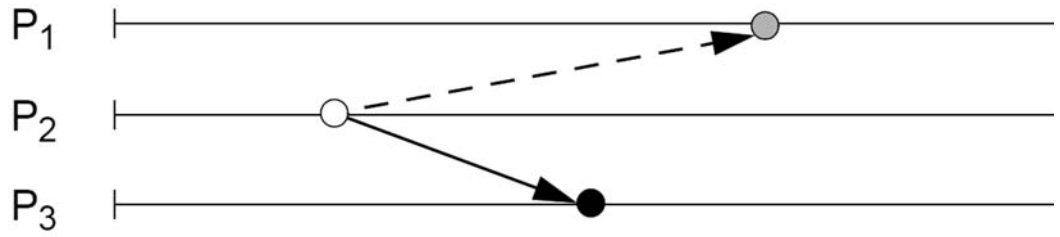

- Ziel von Broadcast- / Multicast-Protokollen
  - möglichst gute Approximation der Idealsituation
- Hauptproblem bei der Realisierung von Broadcast also:
  1. Zuverlässigkeit
  2. garantierte Empfangsreihenfolge

Das soll dem Problem nicht-deterministischer Nachrichtenverzögerungen begegnen

Typische Fehlerfälle bei der Gruppenkommunikation

- Während des Protokolls: Verlust von Einzelnachrichten (oder auch Ausfall des Senders)
  - Nachrichten können aus unterschiedlichen Gründen verloren gehen (z.B. Netzüberlastung, Empfänger hört gerade nicht zu, Hilfsprozess in der Kommunikationsinfrastruktur abgestürzt,...)
- Problem dann: Empfänger sind sich nicht einig, da manche, aber nicht alle, informiert werden
  - Uneinigkeit der Empfänger kann die Ursache für sehr lästige Folgeprobleme sein (da wäre es manchmal besser, gar kein Prozess hätte die Nachricht empfangen!)
  - partielle Abhilfe durch aufwändigere Protokolle und mehr Redundanz

→ folgende slides

„Best Effort“ Broadcast

- Euphemistische Bezeichnung, da keine extra Anstrengung
  - typischerweise einfache Realisierung ohne Ack etc.
- Keinerlei Garantien
  - unbestimmt, wie viele / welche Empfänger erreicht wurden
  - unbestimmte Empfangsreihenfolge
- Allerdings effizient (im Erfolgsfall)
- Geeignet für die Verbreitung unkritischer Informationen
  - z.B. Informationen, die Einfluss auf die Effizienz oder Qualität der Anwendung haben, nicht aber die Korrektheit in Frage stellen
- Evtl. als Grundlage zur Realisierung höherer Protokolle
  - wenn Fehlerfall selten und auf höherer Ebene feststellbar
    → aufwändiges Recovery auf höherer Ebene tolerierbar

„Reliable“ Broadcast

- Ziel: Unter gewissen (welchen?) Fehlermodellen einen „möglichst zuverlässigen“ Broadcast-Dienst realisieren

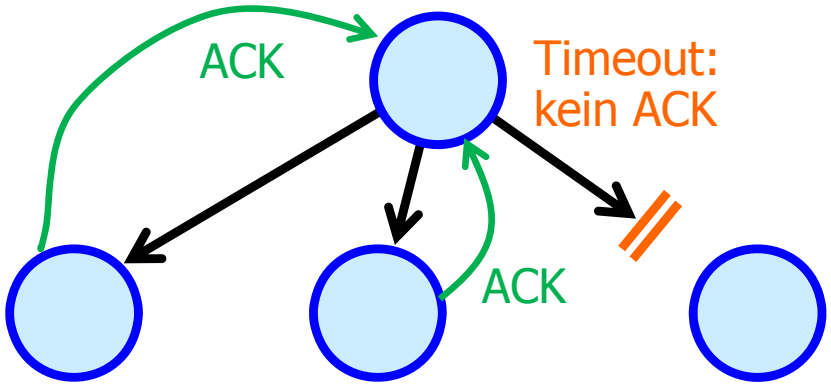

- Erste Idee: Quittung („positives Acknowledgement“: ACK) für jede Einzelnachricht
  - im Verlustfall z.B. einzeln nachliefern oder (z.B. bei broadcastfähigem Medium) einen zweiten Broadcast-Versuch (→ Duplikaterkennung!)
  - viele ACKs → teuer, Belastung des Senders (→ schlechte Skalierbarkeit)

„Reliable“ Broadcast mit negativen Acknowledements („NACK“)

- Alle broadcasts werden vom Sender nummeriert
- Empfänger erkennt so eine Lücke beim nächstem Empfang
- Dann wird ein NACK bzgl. fehlender Nachricht gesendet
- Fehlende Nachricht wird nachgeliefert
  - Sender muss daher Kopien von Nachrichten aufbewahren (wie lange?)
- Gelegentl. Broadcast einer „Nullnachricht“ ist evtl. sinnvoll
  - → schnelles Erkennen von Lücken
- Kombination von ACK / NACK mag sinnvoll sein

- Fehlermodell? Verfahren hilft gegen Verlust von Nachrichten, aber nicht gegen den Crash des Senders „mittendrin“
  - auch nicht gegen persistenten Nachrichtenverlust („Leitung kaputt“)

Ein weiterer Reliable-Broadcast-Algorithmus

- Zweck: Jeder nicht gecrashte und zumindest indirekt erreichbare Prozess soll die Broadcast-Nachricht erhalten
- Voraussetzung: zusammenhängendes „gut vermaschtes" Punkt-zu-Punkt-Netz

Denkübungen:
- Wie effizient ist das Verfahren (Anzahl der Einzelnachrichten)?
- Wie fehlertolerant? (Wie viel darf kaputt sein / verloren gehen...?)
- Könnte man nicht einige Nachrichten sparen? Welche?

Sender s: Realisierung von broadcast(N)
- *send(N, s, sequ_num)* an alle Nachbarn
- sequ_num ++

Beachte: receive ≠ deliver (unterscheide Anwendungsebene und Transportebene)

Empfänger r: Realisierung des Nachrichtenempfangs
- *receive(N, s, sequ_num);*
  wenn r noch kein *deliver(N)* für sequ_num ausgeführt hat, *dann*:
    wenn r ≠ s *dann* *send(N, s, sequ_num)* an alle Nachbarn von r ;
    Nachricht an die Anwendungsebene ausliefern („*deliver(N)*") ;

Prinzip: „Fluten" des Netzes (→ Vorlesung „Verteilte Algorithmen")

Broadcast: Empfangsreihenfolge

- Wie ist die Empfangsreihenfolge von Gruppennachrichten?
  - problematisch wegen der i.Allg. unterschiedlichen Übermittlungszeiten
  - Bsp.: Update einer replizierten Variablen mittels „function shipping“:

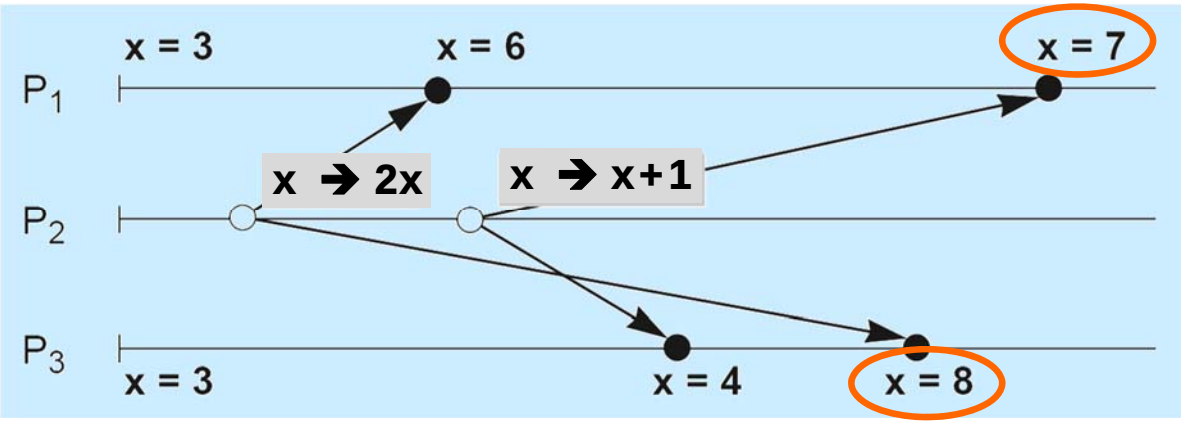

- Es sind diverse Semantiken zum Ordnungserhalt denkbar, z.B.:
  - FIFO
  - kausal geordnet
  - total geordnet

→ Wir besprechen dies nun der Reihe nach

FIFO-Ordnung bei Multicast

Definition (FIFO-Broadcast): Alle Broadcast-Nachrichten eines (d.h.: ein und des selben) Senders an eine Gruppe kommen bei allen Mitgliedern der Gruppe in FIFO-Reihenfolge an

- Denkübung: wie dies mittels eines Protokolls garantieren?

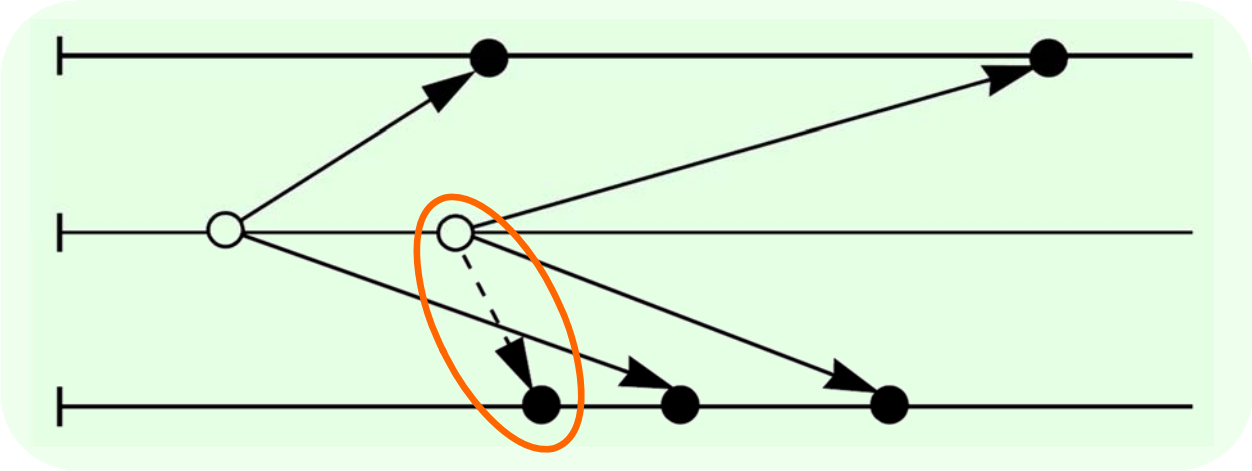

FIFO-Broadcasts sind aber nicht immer „gut genug“

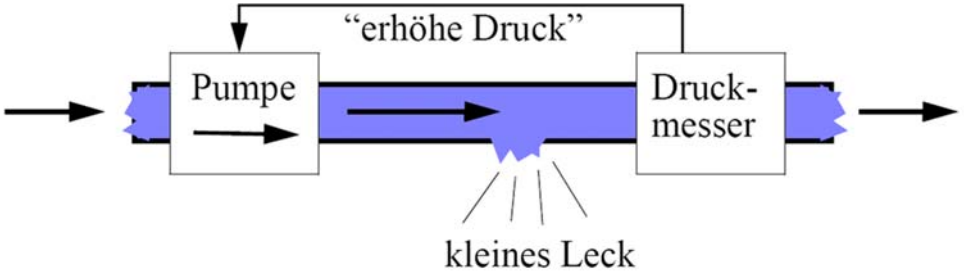

Annahme: Steuerelemente kommunizieren über **FIFO-Broadcasts**:

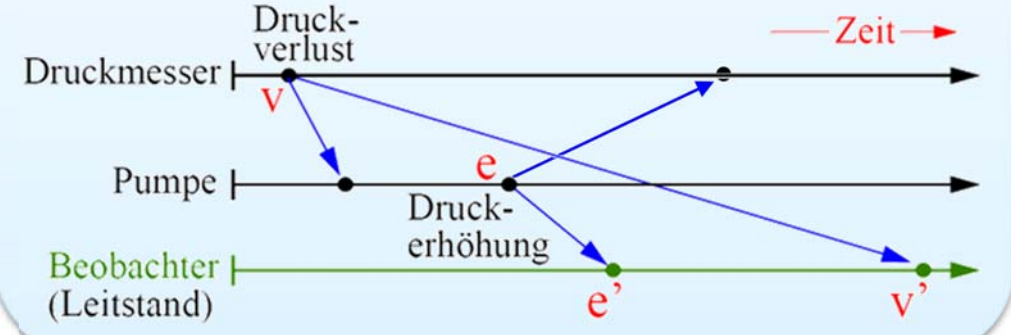

Falsche Schlussfolgerung des Beobachters:

„Aufgrund einer unbegründeten Pumpenaktivität wurde ein Leck erzeugt, wodurch schliesslich der Druck absank.“

„Irgendwie“ kommt beim Beobachter die Reihenfolge durcheinander!

Man sieht also:

- FIFO-Reihenfolge ist nicht immer ausreichend, um Semantik zu wahren
- eine Nachricht verursacht oft das Senden einer anderen (→ Kausalität!)

Das „Broadcastproblem“ ist nicht neu

wenn ein Zuschauer von der Ferne das Exercieren eines Bataillons verfolgt, so sieht er übereinstimmende Bewegungen desselben plötzlich eintreten, ehe er die Commandostimme oder das Hornsignal hört; aber aus seiner Kenntnis der Causalzusammenhänge weiss er, dass die Bewegungen die Wirkung des gehörten Commandos sind, dieses also jenen objectiv vorangehen muss, und er wird sich sofort der Täuschung bewusst, die in der Umkehrung der Zeitfolge in seinen Perceptionen liegt.

Das „Broadcastproblem“ ist nicht neu

- Natürlicher Broadcast bei Licht- und Schallwellen
  - wann handelt es sich dabei um FIFO-Broadcasts?
  - wie ist es mit dem Kausalitätserhalt?

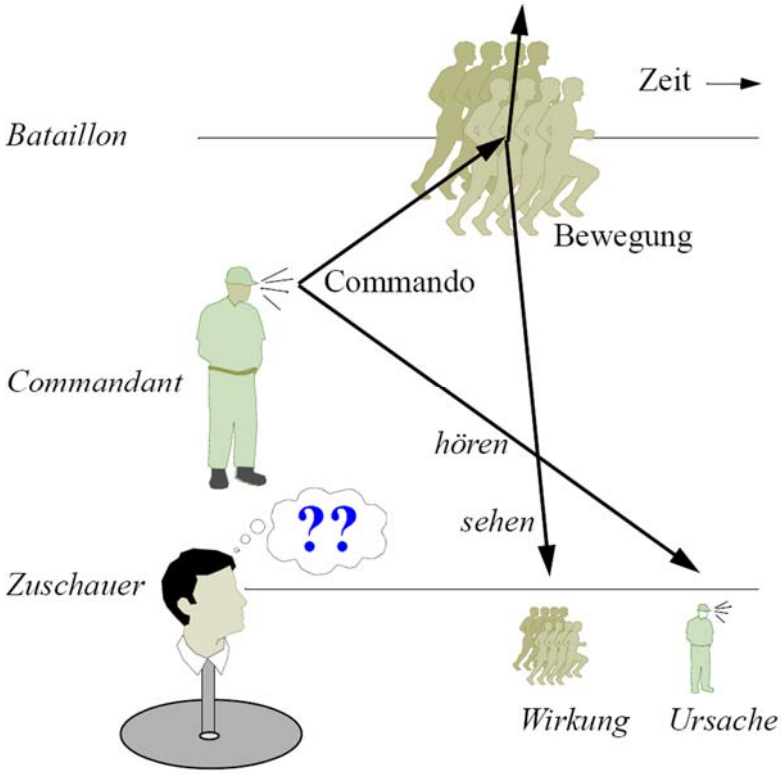

„Wenn ein Zuschauer von der Ferne das Exercieren eines Bataillons verfolgt, so sieht er übereinstimmende Bewegungen desselben plötzlich eintreten, ehe er die Commandostimme oder das Hornsignal hört; aber aus seiner Kenntnis der Causalzusammenhänge weiss er, dass die Bewegungen die Wirkung des gehörten Commandos sind, dieses also jenen objectiv vorangehen muss, und er wird sich sofort der Täuschung bewusst, die in der Umkehrung der Zeitfolge in seinen Perceptionen liegt.“

Christoph von Sigwart (1830-1904): *Logik. Zweiter Band. Die Methodenlehre* (1878)

Kausale Nachrichtenabhängigkeit

- *Definition 1:* Nachricht **Y** hängt kausal von Nachricht **X** ab, wenn es im Raum-Zeit-Diagramm einen von links nach rechts verlaufenden Pfad gibt, der vom Sendeereignis von **X** zum Sendeereignis von **Y** führt.

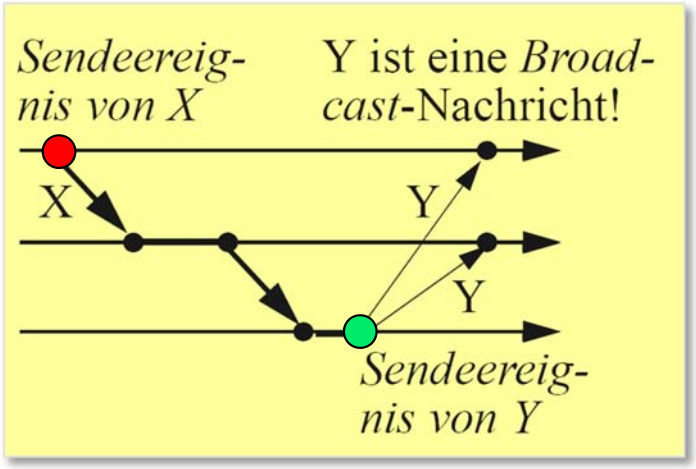

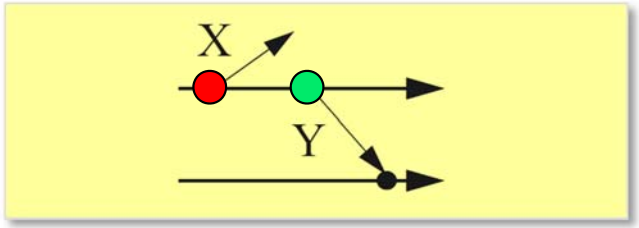

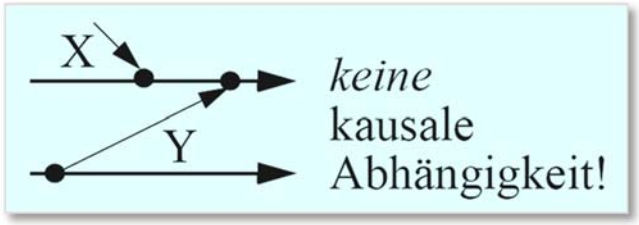

- *Beachte:* Dies lässt sich bei geeigneter Modellierung auch abstrakter ohne Rückgriff auf „Diagramme" etc. fassen (→ „logische Zeit" später in der Vorlesung, vor allem aber Vorlesung „Verteilte Algorithmen")

Kausaler Broadcast

Zweck: Wahrung von Kausalität bei der Kommunikation

- *Definition 2:* Kausale Reihenfolge („causal order"): Wenn eine Nachricht N kausal von einer Nachricht M abhängt, und ein Prozess P die Nachrichten N und M empfängt, dann muss er M vor N empfangen haben

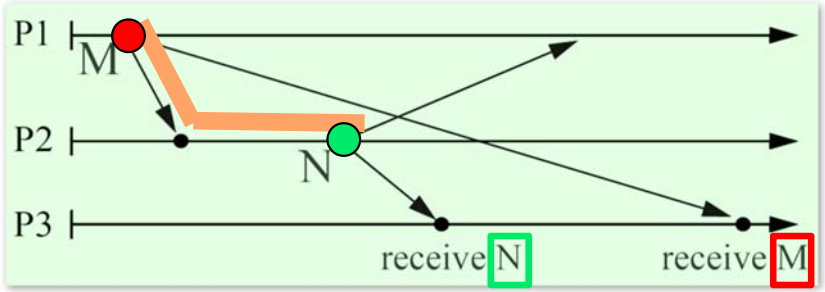

Gegenbeispiel: *Keine* kausalen Broadcasts!

- „Kausale Reihenfolge" (bzw. „kausale Abhängigkeit") lassen sich insbesondere auch auf Broadcasts anwenden → kausaler Broadcast
- Kausale Reihenfolge impliziert FIFO-Reihenfolge: kausale Reihenfolge ist eine Art „globales FIFO"

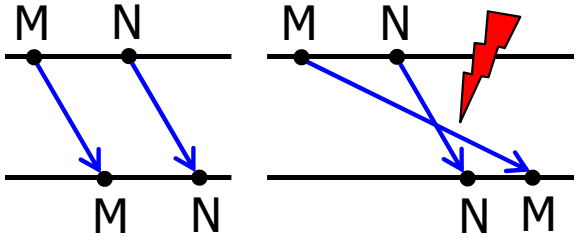

Das Erzwingen der kausalen Reihenfolge ist mittels geeigneter Algorithmen möglich (→ Vorlesung „Verteilte Algorithmen", z.B. Verallgemeinerung der Sequenzzählermethode für FIFO)

Probleme mit (kausalen) Broadcasts?

- Beispiel: Aktualisierung einer replizierten Variablen x:

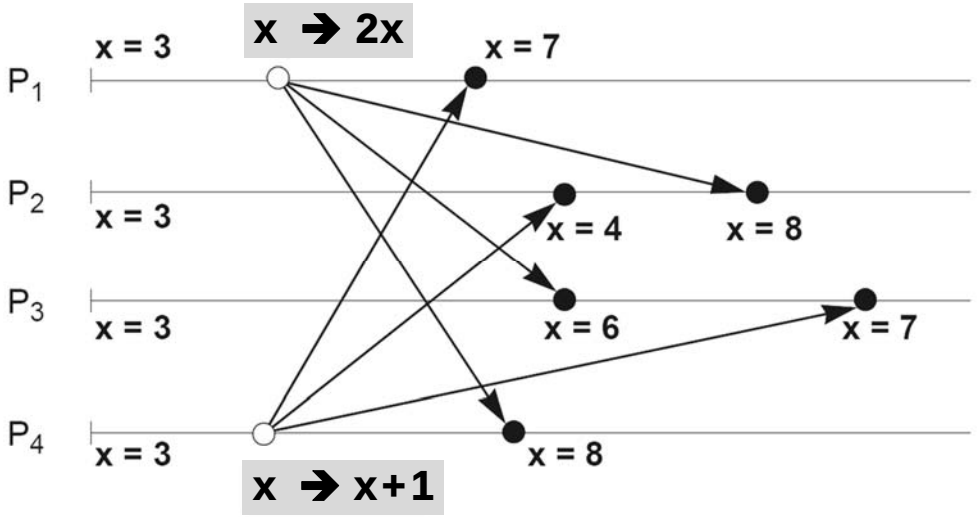

Konkrete Problemursache:

- Broadcasts werden nicht überall „gleich-zeitig" empfangen
- dies führt lokal zu verschiedenen Emp-fangsreihenfolgen

- Abstrakte Ursache:
  - die Nachrichtenübermittlung erfolgt (erkennbar!) „nicht-atomar"
- → Auch kausale Broadcasts haben keine „ideale" Semantik (im Sinne einer Illusion von speicherbasierter Kommunikation)

Atomarer Broadcast

- *Definition:* Atomarer Broadcast: Wenn zwei Prozesse P_1 und P_2 beide die Nachrichten M und N empfangen, dann empfängt P_1 die Nachricht M vor N genau dann, wenn P_2 die Nachricht M vor N empfängt
- Anschaulich: Nachrichten eines Broadcasts werden „überall quasi gleichzeitig“ empfangen

---

- Beachte: „Atomar“ heisst hier nicht „alles oder nichts“
  (wie etwa beim Transaktionsbegriff von Datenbanken)

Atomarer Broadcast: Beispiel

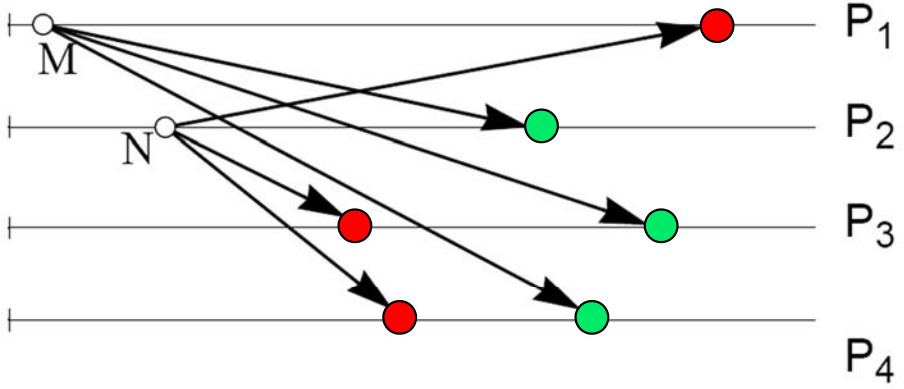

Äquivalent bzgl. „Gummiband-Transformation“

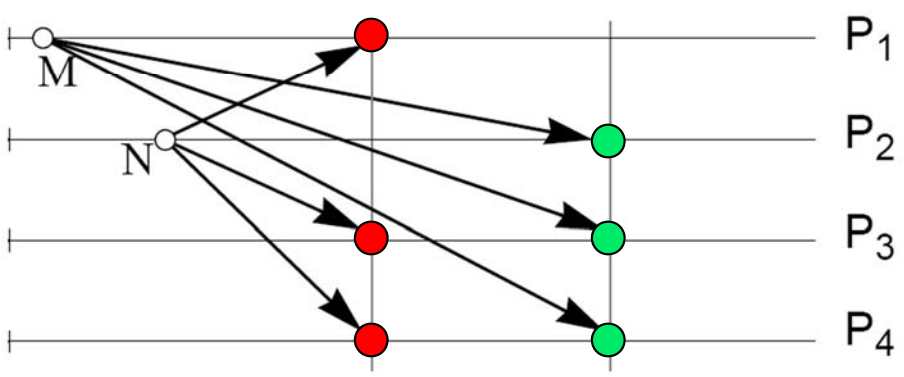

Beachte: das Senden wird nicht als Empfang der Nachricht beim Sender selbst gewertet

Realisierung von atomarem Broadcast

1. Lösung: Zentraler „Sequencer“, der Reihenfolge festlegt

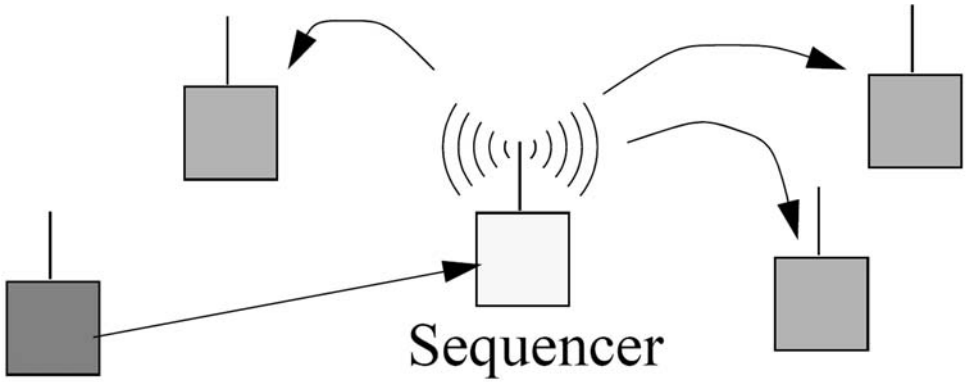

Sequencer ist allerdings ein potentieller Engpass!

- „Unicast“ vom Sender zum Sequencer
- Multicast vom Sequencer an alle
- Sequencer wartet jew. auf Acknowledgements von allen
  - vor dem Versenden des nächsten Auftrags
  - Denkübung: genügt anstelle von Acknoweldgements auch ein FIFO-Multicast (ohne Acknowledgements)?

Realisierung von atomarem Broadcast

Verfahren berücksichtigt auch Nachrichtenverluste und gecrashte Prozesse

2. Lösung: Token, das auf einem (logischen) Ring kreist

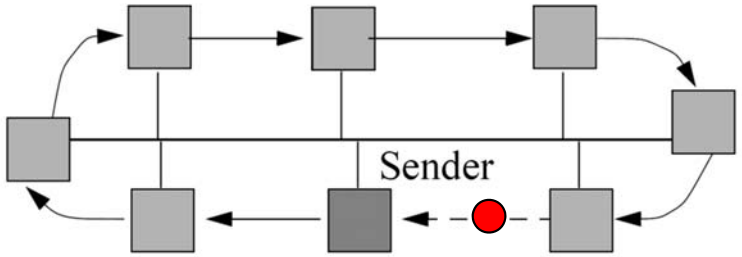

- Token = Senderecht (Token weitergeben!)
- Broadcast selbst z.B. über ein zugrundeliegendes broadcastfähiges Medium (oder Protokoll aus Einzelnachrichten, z.B. „fluten")

- Token führt eine Sequenznummer (inkrementiert beim Senden); so werden alle Broadcasts global nummeriert
- Empfänger wissen, dass Nachrichten entsprechend der (in den Nachrichten mitgeführten Sequenznummer) ausgeliefert werden müssen
- Bei Lücken in den Nummern: dem Token einen Wiederholungswunsch mitgeben (Sender erhält damit implizit ein NACK bzw. ACK)
- Tokenverlust (z.B. durch Prozessor-Crash) durch Timeouts feststellen (Vorsicht: Gefahr, dass dabei Token unabsichtlich verdoppelt wird!)
- Einen gecrashten Prozess (der z.B. das Token nicht entgegennimmt) aus dem logischen Ring entfernen
- Variante (z.B. bei vielen Teilnehmern): Statt Ring: Token auf Anforderung direkt zusenden (broadcast: „Token bitte zu mir"), dabei aber Fairness beachten

Wie „gut“ ist atomarer Broadcast?

1) Ist atomar auch kausal?

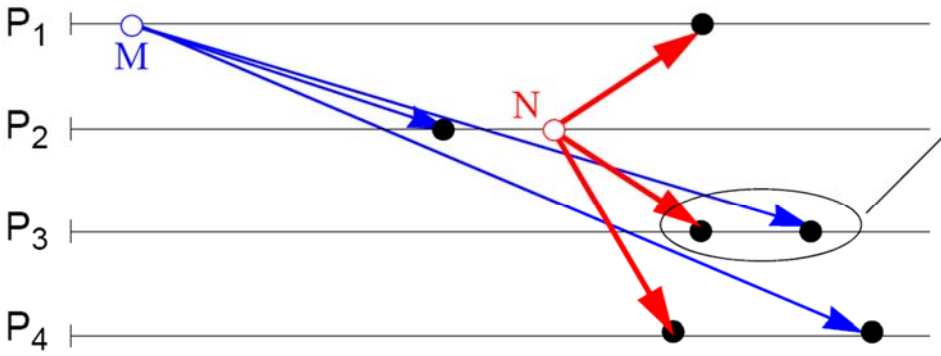

Nicht kausal!

Atomar: P3 und P4 empfangen beide M, N – und zwar in gleicher Reihenfolge

2) Ist atomar wenigstens FIFO?

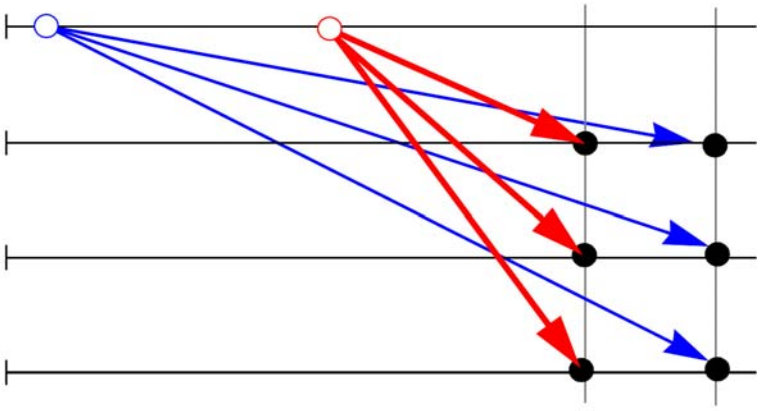

3) Ist atomar + FIFO evtl. kausal?

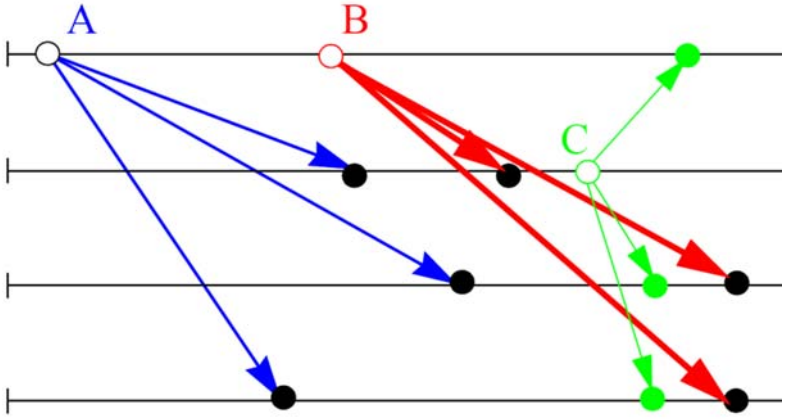

Fazit: Semantik von Broadcast

- Atomare Übermittlung $\not\Rightarrow$ kausale Reihenfolge
- Atomare Übermittlung $\not\Rightarrow$ FIFO-Reihenfolge
- Atomare Übermittlung + FIFO $\not\Rightarrow$ kausale Reihenfolge
  - Bemerkung zu vorheriger Seite: nicht nur 3), sondern auch 1) ist ein (Gegen)beispiel, da M, N FIFO-Broadcast ist

- Vergleich mit („idealer“) speicherbasierter Kommunikation:

  1) Kommunikation über gemeinsamen Speicher ist atomar
  (alle „sehen“ das Geschriebene gleichzeitig – falls sie hinschauen)

  2) Kommunikation über gemeinsamen Speicher wahrt Kausalität
  (Wirkung tritt unmittelbar mit dem Schreibereignis als Ursache ein)

Kausaler atomarer Broadcast

- Der speicherbasierten Kommunikation vergleichbares Kommunikationsmodell per Nachrichten:
  kausaler atomarer Broadcast
  - = kausaler Broadcast + atomarer Broadcast
- Man nennt daher kausale, atomare Übermittlung auch virtuell synchrone Kommunikation

---

- Denkübung: realisieren die beiden Implementierungen „zentraler Sequencer" bzw. „Token auf Ring" die virtuell syn. Kommunikation?

Stichwort: Virtuelle Synchronität

- Idee: Ereignisse finden zu verschiedenen Realzeitpunkten statt, aber zur gleichen „logischen" Zeit
  - logische Zeit berücksichtigt nur die Kausalstruktur der Nachrichten und Ereignisse; die exakte Lage der Ereignisse auf dem „Zeitstrahl" ist verschiebbar (Dehnen / Stauchen wie bei einem Gummiband)
- Innerhalb des Systems ist synchron (im Sinne von „gleichzeitig") und virtuell synchron nicht unterscheidbar
  - identische Kausalbeziehungen
  - identische totale Ordnung aller Ereignisse
- Konsequenz: Nur mit Hilfe Realzeit / echter Uhr könnte man (z.B. als externer Beobachter) den Unterschied feststellen
- Den Begriff „logische Zeit" werden wir später noch genauer fassen (mehr dazu dann wieder in der Vorlesung „Verteilte Algorithmen")

Broadcast – schematische Übersicht

- Warum nicht einziger Broadcast, der alles kann? „Stärkere Semantik" hat auch Nachteile:
  - Leistungsverlust
  - weniger potentielle Parallelität
  - aufwändiger zu implementieren

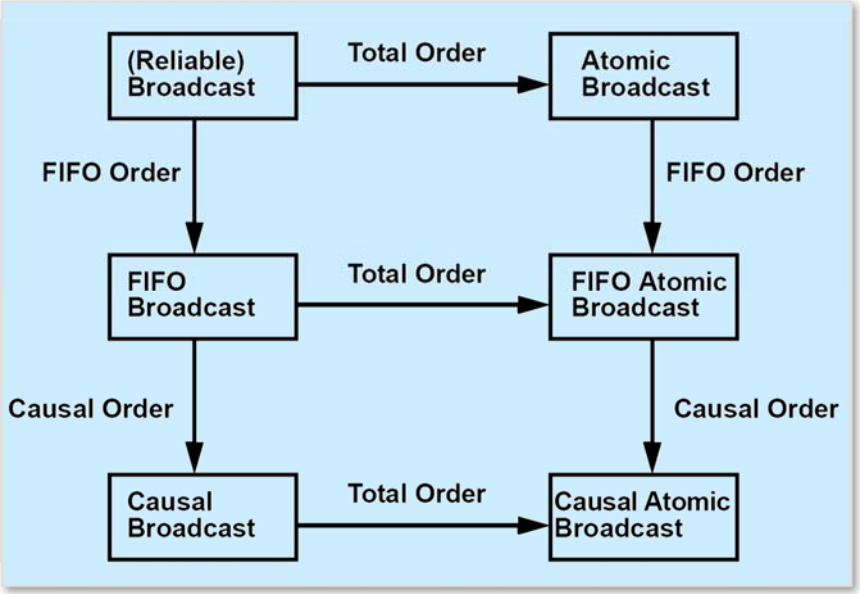

- Bekanntes Prinzip:
  - man begnügt sich daher, falls es der Anwendungskontext gestattet, oft mit einer billigeren, aber weniger perfekten Lösung
  - Motto: so billig wie möglich, so „perfekt" wie nötig
  - man sollte aber die Einschränkungen einer Billiglösung kennen!

- ⇒ grössere Vielfalt ⇒ komplexer bzgl. Verständnis und Anwendung

Multicast

- Multicast = Broadcast an eine Teilmenge von Prozessen
  - diese Teilmenge wird „Multicast-Gruppe“ genannt
- Zweck von Multicast-Gruppen
  - „selektiver Broadcast“
  - Vereinfachung der Adressierung (z.B. statt Liste von Einzeladressen)
  - Verbergen der Gruppenzusammensetzung nach aussen
  - „logischer Unicast“: Gruppen ersetzen Individuen (z.B. für transparente Replikation)
- Alles, was zur Broadcastsemantik gesagt wurde, gilt (innerhalb der Gruppe) auch bzgl. Multicastsemantik:
  - zuverlässiger Multicast, FIFO-Multicast, kausaler Multicast, atomarer Multicast, kausaler atomarer Multicast

„Hidden Channels“ beim Multicast

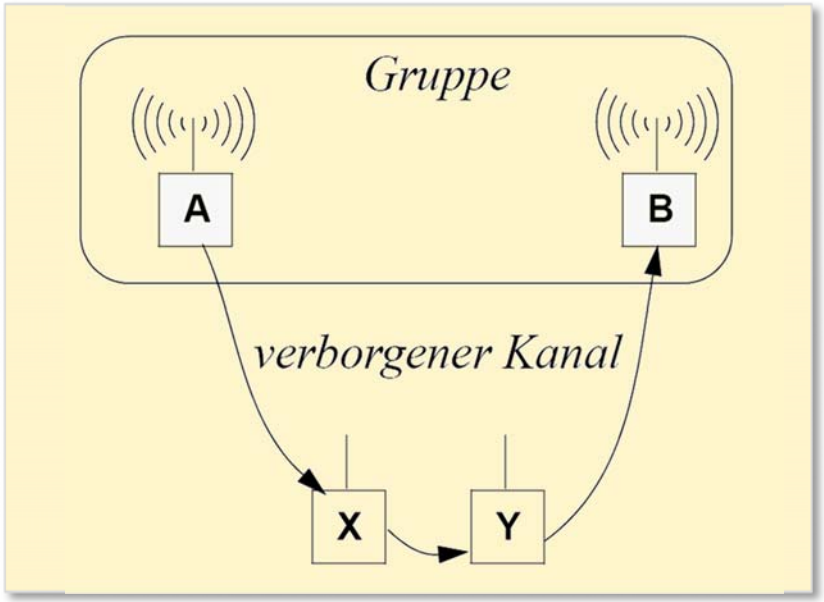

Kausalitätsbezüge verlassen (z.B. durch Gruppenüberlappung) die Multicastgruppe und kehren später wieder

- Soll nun das Senden von B als kausal abhängig vom Senden von A gelten? (→ definitorische Frage)
- Global gesehen ist das der Fall, innerhalb der Gruppe ist eine solche Abhängigkeit jedoch nicht erkennbar

Dynamische Multicastgruppen

- Bei dynamischen Gruppen können Prozesse jederzeit der Gruppe beitreten oder aus der Gruppe austreten
  - Crash kann als aussergewöhnliche Austrittsform modelliert werden
- Aber wenn dies während des Ablaufs einer Multicast-Operation geschieht?
  - haben dann z.B. verschiedene Sender an die Gruppe die gleiche Sicht bzgl. der Gruppenzusammensetzung?
- Man wünscht sich (Realisierung besprechen wir hier nicht!):
  - die Gruppe soll bei allen (potentiellen) Sendern an die Gruppe hinsichtlich der (logischen) Beitritts- und Austrittszeitpunkte jedes Gruppenmitglieds immer übereinstimmen
  - Beitritt und Austritt sollen atomar erfolgen

Weitere Kommunikationsparadigmen

Wir besprechen nachfolgend drei weitere Aspekte, die einen Bezug zur Gruppenkommunikation aufweisen:

1. Push-Paradigma
2. Publish & Subscribe
3. Tupelräume (und JavaSpaces)

Push-Paradigma

- Im Unterschied zum klassischen „Pull-“ (bzw. „Request / Reply“)-Paradigma, bei dem
  - Clients die gewünschte Information aktiv anfordern müssen,
  - sie aber oft nicht wissen, ob bzw. wann sich eine Information beim Server geändert hat,
  - dadurch periodisches Nachfragen („polling“) notwendig wird, wenn man an „Neuigkeiten“ interessiert ist
- Push: unangefragt (vom Client) schickt der Server etwas
  - der Client hat den Server dazu höchstens pauschal beauftragt
- Push: „event driven“ ↔ Pull: „demand driven“

Publish & Subscribe

- Subscriber (= Client) meldet sich für den Empfang des gewünschten Typs von Information („channel“) an
- Subscriber erhält automatisch (aktualisierte) Information vom Publisher (= Server), sobald diese zur Verfügung steht
  - push vom Publisher (bzw. „callback“ des Subscribers durch Publisher)

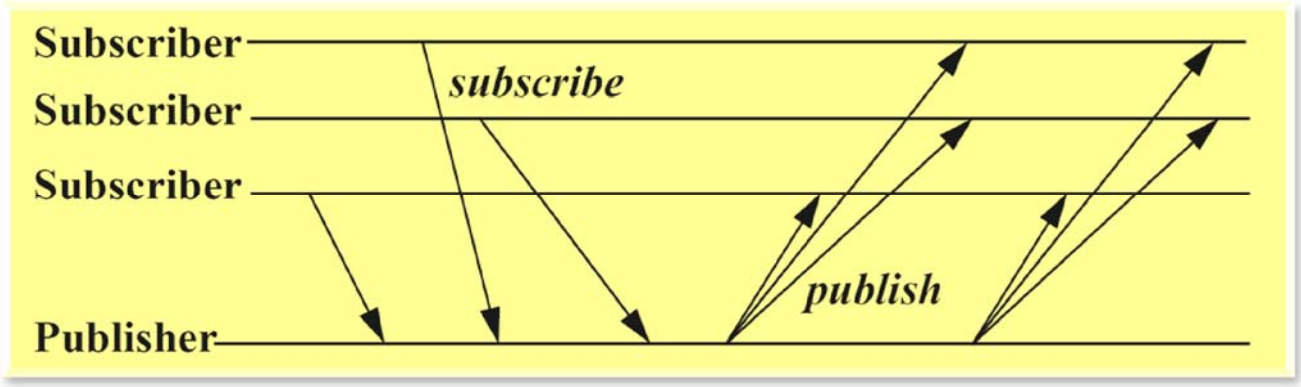

- Prinzip kennen wir aber schon: „Publish“ entspricht Multicast
  - „subscribe“ entspricht so gesehen dem Beitritt einer Multicast-Gruppe

Tupelräume

- Gemeinsam genutzter („virtuell globaler“) Speicher

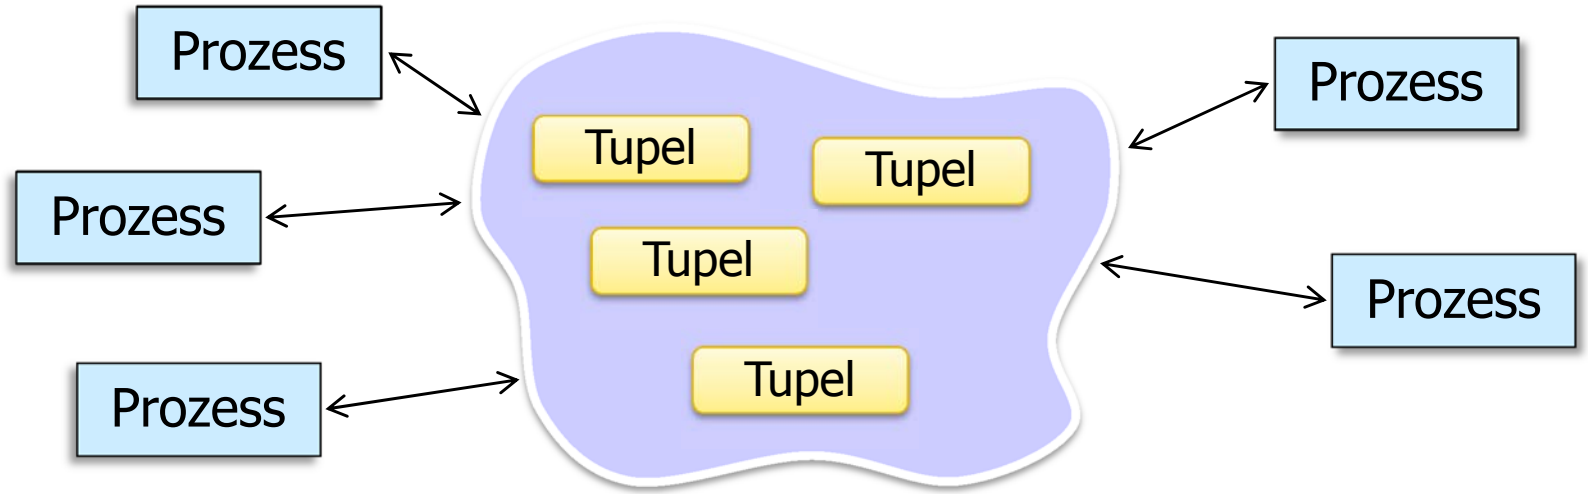

- Blackboard- oder Marktplatz-Modell
  - Daten (als „Tupel“) können von beliebigen Teilnehmern eingefügt, gelesen und entfernt werden
  - relativ starke Entkoppelung der Teilnehmer: „Sender“ kennt / adressiert „Empfänger“ nicht und umgekehrt

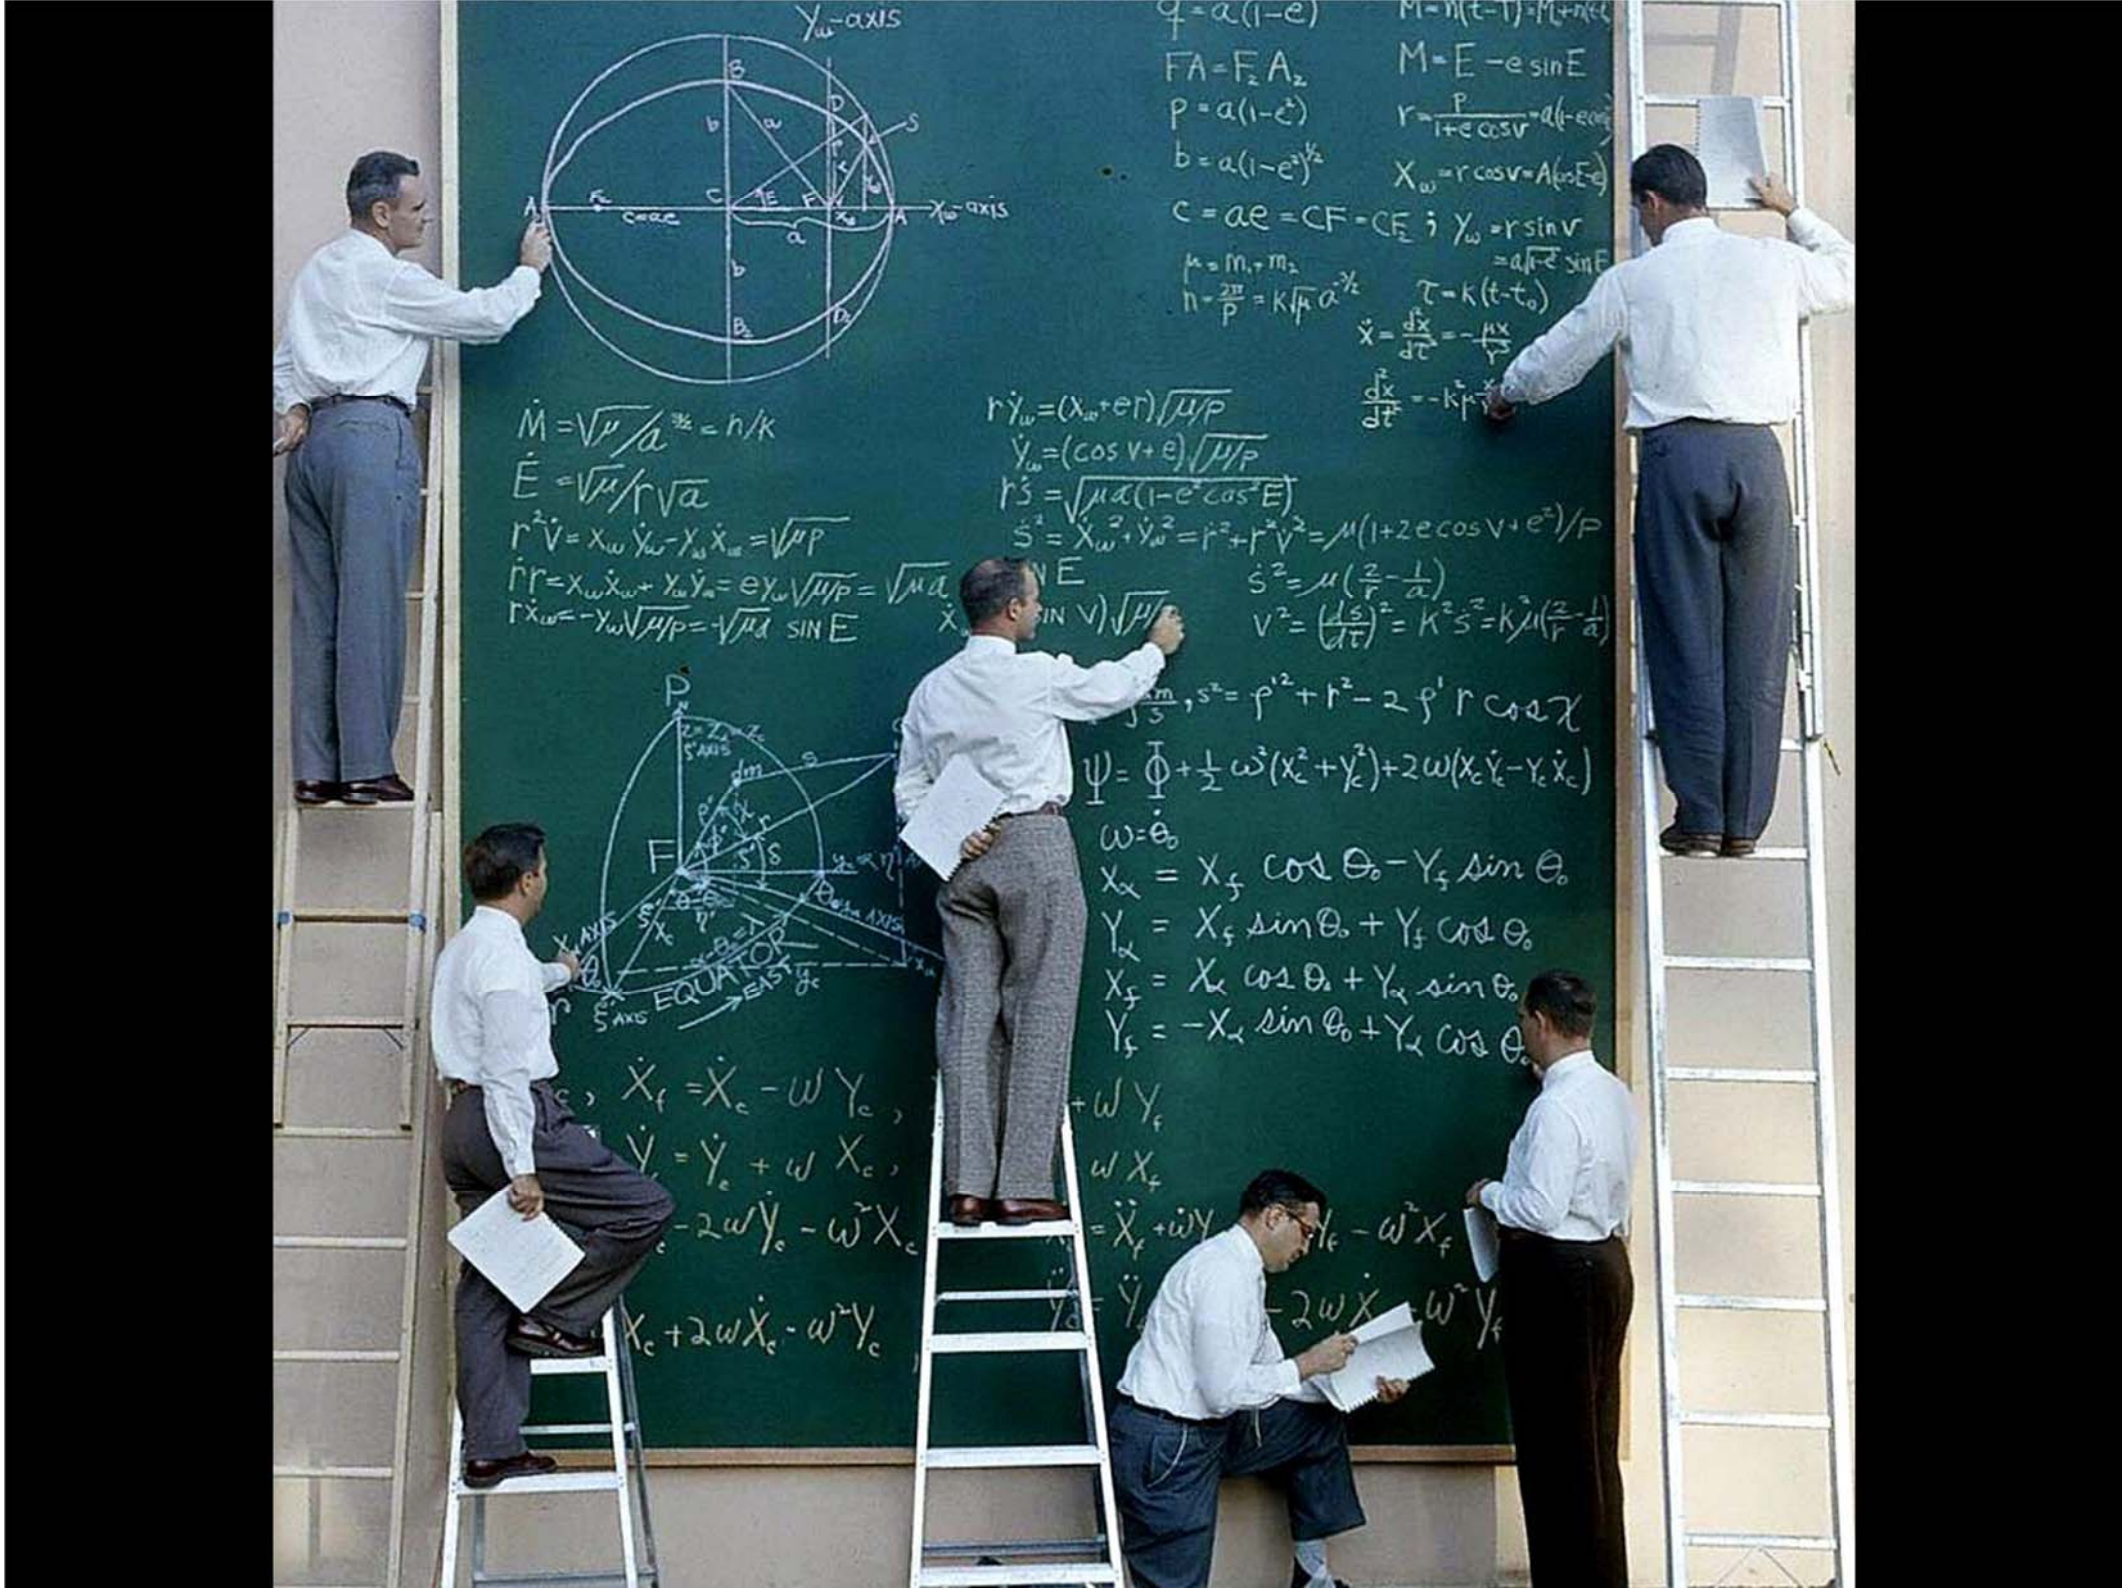
Y_ω-axis
X_ω-axis
$q = a(1-e)$
$FA = F_2 A_2$
$P = a(1-e^2)$
$b = a(1-e^2)^{1/2}$
$c = ae = CF = CE$
$M = E - e\sin E$
$r = \frac{P}{1+e\cos v} = a(1-e\cos E)$
$X_\omega = r\cos v = A(\cos E - e)$
$Y_\omega = r\sin v = a\sqrt{1-e^2}\sin E$
$\mu = m_1 + m_2$
$n = \frac{2\pi}{P} = k\sqrt{\mu}\,a^{-3/2}$
$\tau = k(t-t_0)$
$\dot{x} = \frac{dx}{d\tau} = -\frac{\mu x}{r^3}$
$\frac{d^2x}{d\tau^2} = -k^2\mu\frac{x}{r^3}$
$\dot{M} = \sqrt{\mu}/a^{3/2} = n/k$
$\dot{E} = \sqrt{\mu}/r\sqrt{a}$
$r^2\dot{v} = X_\omega\dot{Y}_\omega - Y_\omega\dot{X}_\omega = \sqrt{\mu p}$
$r\dot{r} = X_\omega\dot{X}_\omega + Y_\omega\dot{Y}_\omega = e Y_\omega\sqrt{\mu/p} = \sqrt{\mu a}$
$r\dot{X}_\omega = -Y_\omega\sqrt{\mu/p} = -\sqrt{\mu a}\sin E$
$r\dot{Y}_\omega = (X_\omega + er)\sqrt{\mu/p}$
$\dot{Y}_\omega = (\cos v + e)\sqrt{\mu/p}$
$r\dot{s} = \sqrt{\mu a(1-e^2\cos^2 E)}$
$\dot{s}^2 = \dot{X}_\omega^2 + \dot{Y}_\omega^2 = \dot{r}^2 + r^2\dot{v}^2 = \mu(1+2e\cos v+e^2)/p$
$\dot{s}^2 = \mu\left(\frac{2}{r} - \frac{1}{a}\right)$
$v^2 = \left(\frac{ds}{d\tau}\right)^2 = k^2\dot{s}^2 = k^2\mu\left(\frac{2}{r} - \frac{1}{a}\right)$
$s^2 = \rho'^2 + r^2 - 2\rho' r\cos\chi$
$\Psi = \Phi + \frac{1}{2}\omega^2(x_c^2 + y_c^2) + 2\omega(x_c\dot{y}_c - y_c\dot{x}_c)$
$\omega = \dot{\theta}_0$
$X_\alpha = X_f\cos\theta_0 - Y_f\sin\theta_0$
$Y_\alpha = X_f\sin\theta_0 + Y_f\cos\theta_0$
$X_f = X_\alpha\cos\theta_0 + Y_\alpha\sin\theta_0$
$Y_f = -X_\alpha\sin\theta_0 + Y_\alpha\cos\theta_0$
EQUATOR
EAST

Tupelräume (2)

- Entworfen 1985 von David Gelernter
  - für die Sprache Linda
    (→ Koordination paralleler Prozesse)
  - David Gelernter (Informatik-Professor an der Yale University) wurde 1993 schwer verletzt durch eine von insgesamt 16 Briefbomben des sogenannten Unabombers („university and airline bomber“) Theodore Kaczynski (ehemals Assistenzprofessor für Mathematik in Berkeley und Anarchist)
- Tupel = geordnete Menge typisierter Datenwerte
- Operationen:
  - out(t): Einfügen eines Tupels t in den (globalen) Tupelraum
  - in(t): Lesen und Löschen von t aus dem Tupelraum
  - read(t): Lesen („zerstörungsfrei“) von t im Tupelraum

Tupelräume (3)

- Inhaltsadressiert (Tupelraum ist „Assoziativspeicher“)
  - Vorgabe eines Zugriffsmusters (bzw. „Suchmaske“) beim Lesen; damit Ermittlung der restlichen Datenwerte eines Tupels („wild cards“)
  - z.B.: int p; in(„Artikelpreis“, 4711, ?p) liefert ein „passendes“ Tupel
  - analog zu typischen relationalen Datenbankabfragesprachen
- Synchrone und asynchrone Leseoperationen
  - ‘in’ und ‘read’ blockieren, bis ein passendes Tupel vorhanden ist
  - ‘inp’ und ‘readp’ blockieren nicht, sondern liefern als Prädikat („passendes Tupel vorhanden?“) ‘wahr’ oder ‘falsch’ zurück

Tupelräume (4)

- Mit Tupelräumen sind auch die üblichen Kommunikations-muster realisierbar (d.h. simulierbar), z.B. Client-Server:

```
/* Client */
...
out("Anfrage" client_Id, Parameterliste);
in("Antwort", client_Id, ?Ergebnisliste);
...
/* Server*/
...
while (true)
{  in("Anfrage", ?client_Id, ?Parameterliste);
   ...
   out("Antwort", client_Id, Ergebnisliste);
}
```

Zuordnung des „richtigen" Clients über die client_Id

Tupelräume (5)

- Kanonische Erweiterungen des Modells hinsichtlich
  - Persistenz (Tupel bleiben nach Programmende erhalten)
  - Transaktionseigenschaft (wichtig, wenn mehrere Prozesse parallel auf den Tupelraum bzw. gleiche Tupel zugreifen)
- Problem: effiziente, skalierbare Implementierung?
  1) zentrale Lösung: Engpass
  2) replizierter Tupelraum (jeder Teilnehmer hat vollständige Kopie des Tupelraums: schnelle Zugriffe, aber hoher Synchronisationsaufwand)
  3) aufgeteilter Tupelraum (jeder hat disjunkten Teil des Tupelraums: 'out' kann z.B. lokal ausgeführt werden, 'in' evtl. mit Broadcast)
- Generelle Kritik: Konzept des globalen Speichers ist strukturierter Programmierung und Verifikation abträglich
  - unüberschaubare potentielle Seiteneffekte

JavaSpaces

- „Tupelraum“ für Java
  - gespeichert werden Objekte → neben Daten auch „Verhalten“
  - Tupel entspricht Gruppen von Objekten
- Operationen
  - write: mehrfache Anwendung erzeugt verschiedene Kopien
  - read
  - readifexists: blockiert (im Gegensatz zu read) nicht; liefert u.U. ‘null’
  - take
  - takeifexists
  - notify: Benachrichtigung (mittels eines Ereignisses), wenn ein passendes Objekt in den JavaSpace geschrieben wird

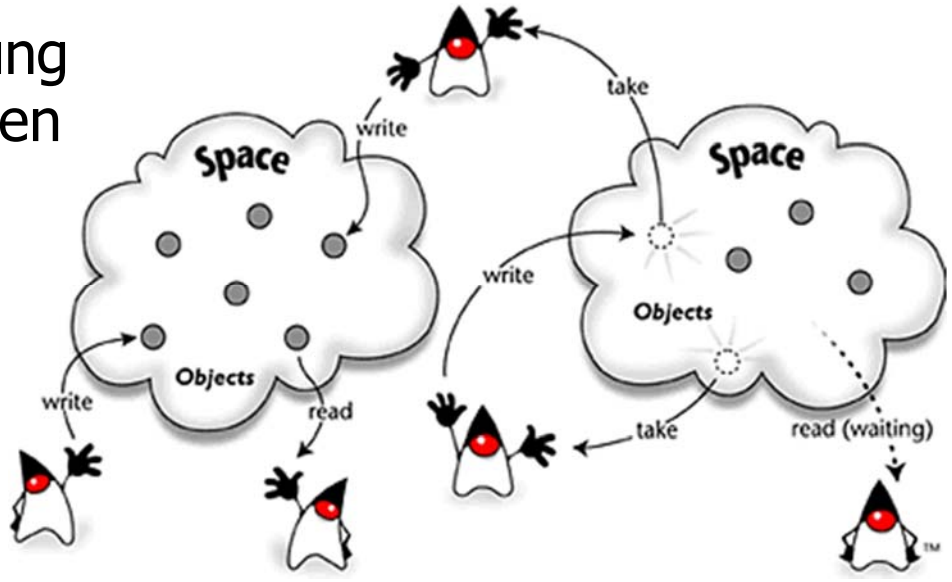

JavaSpaces (2)

- Teil von Jini (Infrastrukturplattform und Middleware für Java)
  - Kommunikation zwischen entfernten Objekten
  - Transport von Programmcode vom Sender zum Empfänger
  - gemeinsame Nutzung von Objekten
  - persistente Speicherung von Objekten (aber keine Festlegung, ob eine Implementierung fehlertolerant ist und einen Crash überlebt)

- Semantik: Reihenfolge der Wirkung von Operationen verschiedener Threads ist nicht festgelegt
  - selbst wenn ein write vor einem read beendet wird, muss read nicht notwendigerweise das lesen, was write geschrieben hat

Logische Zeit

Zeit?

Ich halte ja eine Uhr für überflüssig. Sehen Sie, ich wohne ja ganz nah beim Rathaus. Und jeden Morgen, wenn ich ins Geschäft gehe, da schau ich auf die Rathausuhr hinauf, wie viel Uhr es ist, und da merke ich's mir gleich für den ganzen Tag und nütze meine Uhr nicht so ab. -- Karl Valentin

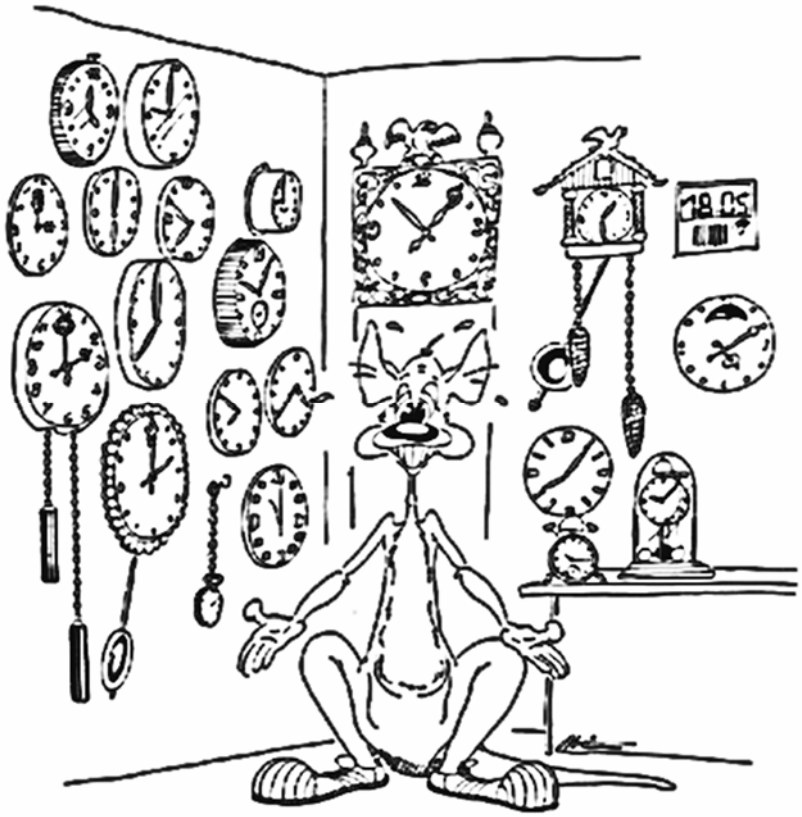

Zeit ist nützlich

Beispiele:

1. Volkszählung: Stichzeitpunkt in der Zukunft
   - liefert eine gleichzeitige „Beobachtung" im Nachhinein

2. Kausalitätsbeziehung zwischen Ereignissen
   - z.B. „Alibi-Prinzip": Ausschluss potentieller Kausalität
   - wurde Y später als X geboren, dann kann Y unmöglich Vater von X sein

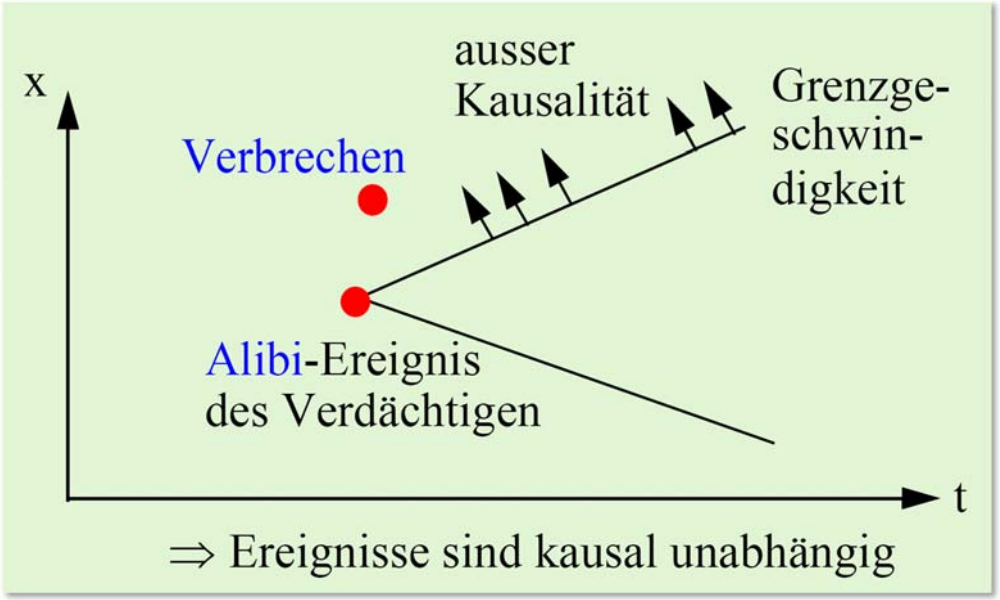

Zeit ist nützlich (2)

3. Fairer wechselseitiger Ausschluss
   - bedient wird derjenige, der am längsten wartet

4. Viele weitere nützliche Anwendungen von „Zeit“ in unserer verteilten realen Welt
   - z.B. kausaltreue Beobachtung durch „Zeitstempel“ der Ereignisse

---

- Zeit in verteilten Systemen ist vor allem auch dann wichtig, wenn es um Interaktionen mit der realen Welt geht
  - Prozesssteuerung, Realzeitsysteme, Cyber-Physical Systems,…

Eigenschaften der „Realzeit“

Struktureigenschaften eines „natürlichen“ Zeitpunktmodells:

- asymmetrisch (Zeit ist „gerichtet“)
- transitiv
- irreflexiv
- linear

(strenge) lineare Ordnung
(→ „später als“)

- unbeschränkt („Zeit ist ewig“: Kein Anfang oder Ende)
- dicht (es gibt immer einen Zeitpunkt dazwischen)
- kontinuierlich
- metrisch
- vergeht „von selbst“
  → jeder Zeitpunkt wird schliesslich erreicht

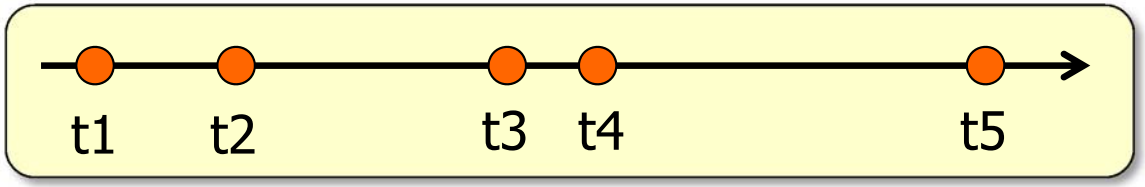

Eigenschaften der „Realzeit“ (2)

- Ist das Zeitpunktmodell adäquat? Oder sind Zeit-intervalle besser?

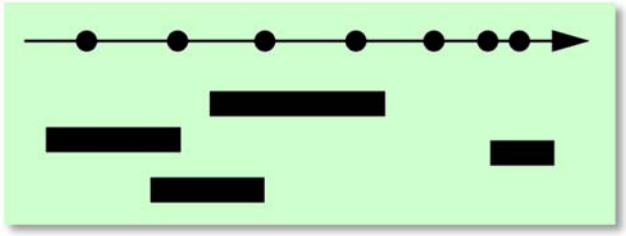

  - wann tritt das Ereignis (?) „Sonne wird rot“ am Abend ein?

- Welche Eigenschaften benötigen wir überhaupt?
  - Idee: „billigeren“ Ersatz für fehlende globale Realzeit konstruieren (z.B.: sind die reellen / rationalen / ganzen Zahlen gute Modelle?)
  - wann genügt welche Form „logischer“ statt „echter“ Zeit?
  - dazu vorher klären: was wollen wir mit „Zeit“ anfangen?

Raum-Zeitdiagramme und die Kausalrelation

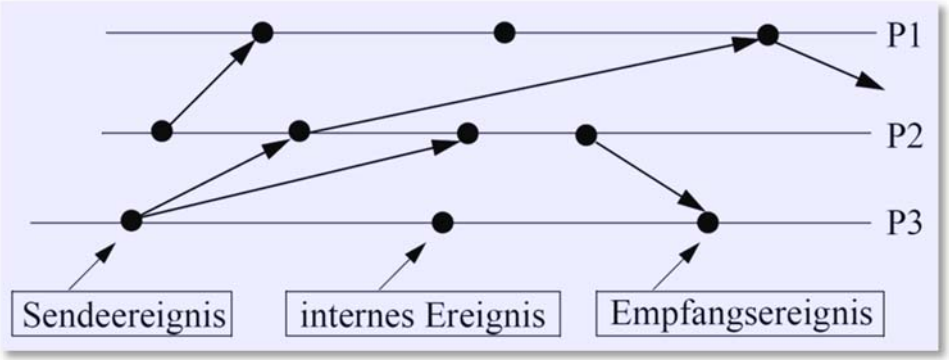

Interessant dabei: von links nach rechts verlaufende „Kausalitätspfade“

Bezeichnung oft:
„happened before“

- eingeführt von Leslie Lamport (1978)
- Vorsicht: damit ist nicht direkt eine „zeitliche“ Aussage getroffen!

Definiere eine Kausalrelation $\prec$ auf der Menge aller Ereignisse:

- Es sei $x \prec y$ genau dann, wenn:
  1) x und y auf dem gleichen Prozess stattfinden und x vor y kommt, oder
  2) x ist ein Sendeereignis und y korrespondierendes Empfangsereignis, oder
  3) $\exists$ z mit $x \prec z \ \wedge \ z \prec y$ (Transitivität)

links von

zur gleichen Nachricht gehörend

Logische Zeitstempel von Ereignissen

- Zweck: Ereignissen E eine Zeit geben
  - welche Zeit *zwischen* zwei Ereignissen herrscht, ist irrelevant
  - gesucht ist also eine Abbildung $C: E \rightarrow \mathbb{N}$ („C" steht für „Clock")
  - $\mathbb{N}$ genügt hier, $\mathbb{Z}$ oder $\mathbb{R}$ ist nicht nötig, wie wir sehen werden
- C(e) nennt man den Zeitstempel von e
  - wenn C(e) < C(e'), dann nennt man e früher als e'

- Sinnvolle Forderung: Uhrenbedingung: $e \prec e' \Rightarrow C(e) < C(e')$

Ordnungshomomorphismus

  - Interpretation („Zeit ist kausaltreu"):

    Kann ein Ereignis e ein anderes Ereignis e' beeinflussen, dann muss e einen kleineren Zeitstempel als e' haben

Communications of the ACM 21(7), 558-565, 1978: *Time, Clocks, and the Ordering of Events in a Distributed System*

Logische Uhren von Lamport

- $C: (E, \prec) \rightarrow (\mathbb{N}, <)$
  Zeitstempel-Zuordnung
- $e \prec e' \Rightarrow C(e) < C(e')$
  Uhrenbedingung

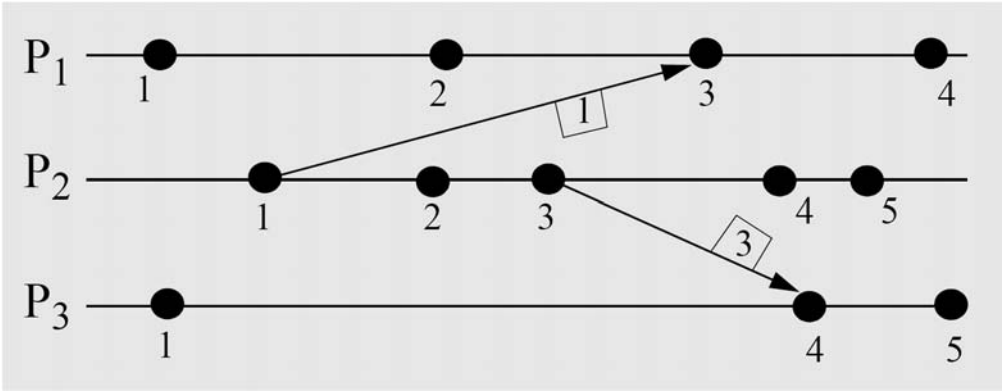

- Protokoll zur Implementierung der Uhrenbedingung:
  - bei jedem Ereignis tickt die lokale Uhr (= „Zähler") des Prozesses
  - Sendeereignis: akt. Uhrwert mitsenden (→ Zeitstempel der Nachricht)
  - Empfangsereignis: Uhr = max(Uhr, Zeitstempel der Nachricht)
    (zuerst max, unmittelbar danach erst tickt die Uhr)
- *Behauptung:* Protokoll respektiert Uhrenbedingung
  - *„Beweis":* Entlang von Kausalitätspfaden wächst logische Zeit monoton...

Lamport-Zeit: injektive Variante

- Die durch Lamports Protokoll definierte Abbildung ist nicht injektiv
  - wäre wichtig z.B. für: „Wer die kleinste Zeit hat, der gewinnt“

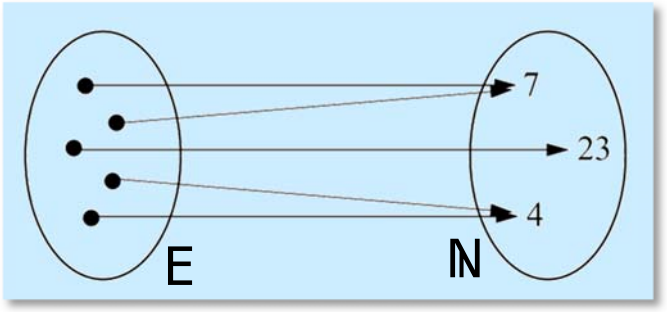

- Lösung: lexikographische Ordnung (C(e),i), wobei i die Prozessnummer bezeichnet, auf dem e stattfindet
  - Def.: $(a,b) < (a',b') \Leftrightarrow a<a' \vee a=a' \wedge b<b'$ (ist eine lineare Ordnung!)
- Alle Ereignisse haben nun verschiedene Zeitstempel
  - Abbildung ist injektiv
  - jede (nicht-leere) Menge von Ereignissen hat nun ein „frühestes“
- Abb. $(E,\prec) \rightarrow (\mathbb{N}\times\mathbb{N},<)$ respektiert die Uhrenbedingung

Umkehrung der Uhrenbedingung?

- Wieso gilt folgendes eigentlich nicht?

$$e \prec e' \Leftrightarrow C(e) < C(e')$$

  - Was kann man überhaupt über die beiden Ereignisse e und e' sagen, wenn man die Zeitstempel C(e) und C(e') vergleicht?

- Kann man eine andere Art von Zeitstempeln finden, für die die Umkehrung der Uhrenbedingung gilt?
  - wofür wäre das nützlich?
  - → Vorlesung „verteilte Algorithmen": Vektor-Uhren

I'll admit that the first time I heard the terms "vector clock" or "Lamport timestamp", I figured they were some insane mathematical algorithm that I'd never understand. Perhaps more importantly, I avoided learning about the subject altogether because of this fear. Fortunately, I discovered that their behavior is actually far simpler than I imagined.
Rylan Dirksen, http://blog.8thlight.com/rylan-dirksen/2013/10/04/synchronization-in-a-distributed-system.html

Wechselseitiger Ausschluss


Bitte
einzeln
eintreten

Wechselseitiger Ausschluss
(Mutual Exclusion, „Mutex“)

- Koordination, wenn viele wollen, aber nur einer darf
- „Streit“ um exklusives Betriebsmittel, z.B.:
  - konkrete Ressource (z.B. gemeinsamer Datenbus)
  - abstrakte Ressource (z.B. ein „Termin“ in einem verteilten Terminkalendersystem)
  - „kritischer Abschnitt“ in einem nebenläufigen Programm

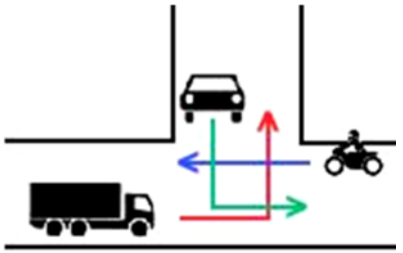

- Es gibt klassische Lösungen bei shared memory
  - z.B. Semaphore und Monitore (→ Betriebssystemtheorie)
  - sind in unserem verteilten Kontext aber nicht relevant

Anforderungen an eine Lösung: Safety, Liveness und Fairness

(1) **Safety** *(„nothing bad will ever happen")*

Wenn ein Prozess das Betriebsmittel (BM) hat, dann kein anderer.

Das alleine genügt aber nicht; sonst wäre ein Protokoll, das keinem Prozess je den Zugriff erlaubt, korrekt! (Alle Verkehrsampeln auf Dauerrot machen Zürich sicher!)

(2) **Liveness** *(bzw. „progess": „something good will eventually happen")*

Wenn kein Prozess das BM hat, aber einige sich „bewerben", dann bekommt einer von diesen schliesslich das BM.

Liveness ohne Safety ist auch wieder trivial! Gesucht ist eine Lösung, die Safety *und zugleich* Liveness erfüllt

(3) **Fairness**

Ein sich bewerbender Prozess darf nicht beliebig oft von anderen Prozessen übergangen werden.

Sonst könnten sich etwa zwei Prozesse abwechselnd das Recht zuspielen und einen dritten Prozess verhungern lassen

„Nicht beliebig oft" ist allerdings eine recht schwache Form von Fairness – in der Praxis wünscht man sich oft eine stärkere Garantie

Fairness?


LIFE IS UNFAIR!
FOR PROOF, INSERT $1.
GET NOTHING IN RETURN
SCHWADRON

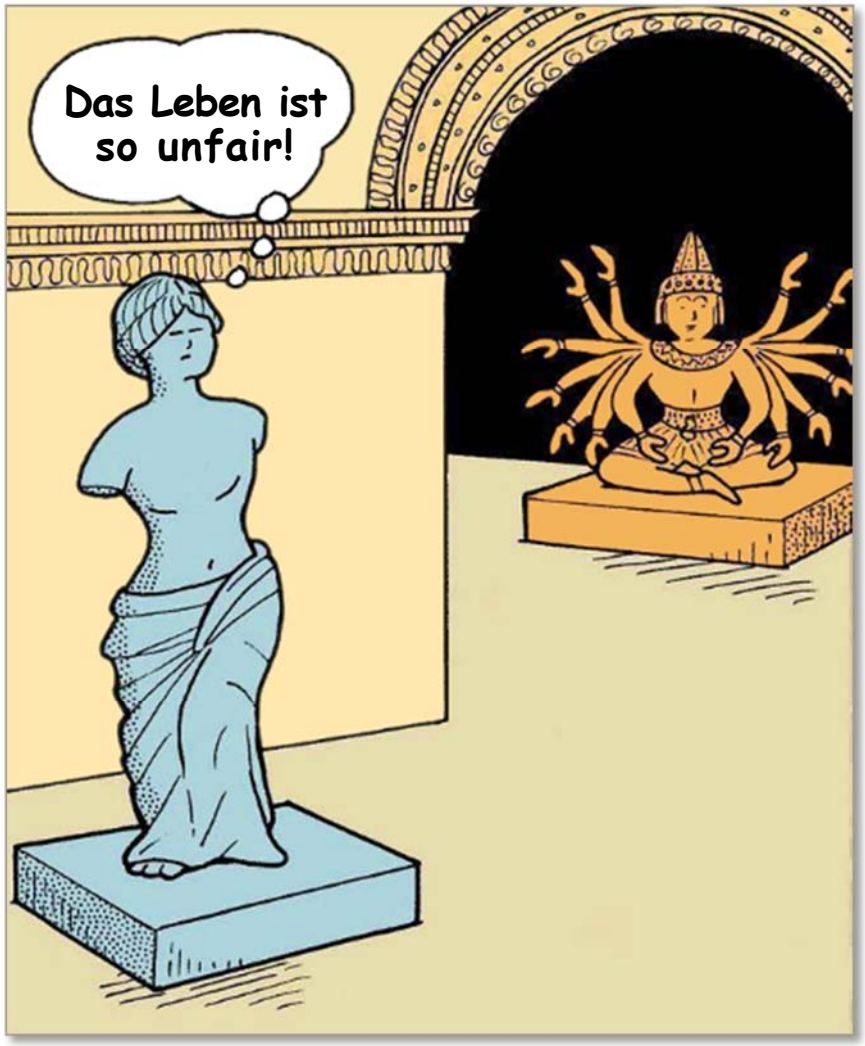
Das Leben ist so unfair!

Zentraler Manager?

- Hier: Nachrichtenbasiertes System konkurrierender Prozesse
- Idee: Manager, der Ressourcen (exklusiv aber fair!) zuordnet
  - ein Prozess bewirbt sich um die Ressource mit „request“
  - wartet dann auf Erlaubnis („grant“)
  - teilt schliesslich Freigabe der Ressource dem Manager durch „release“ mit

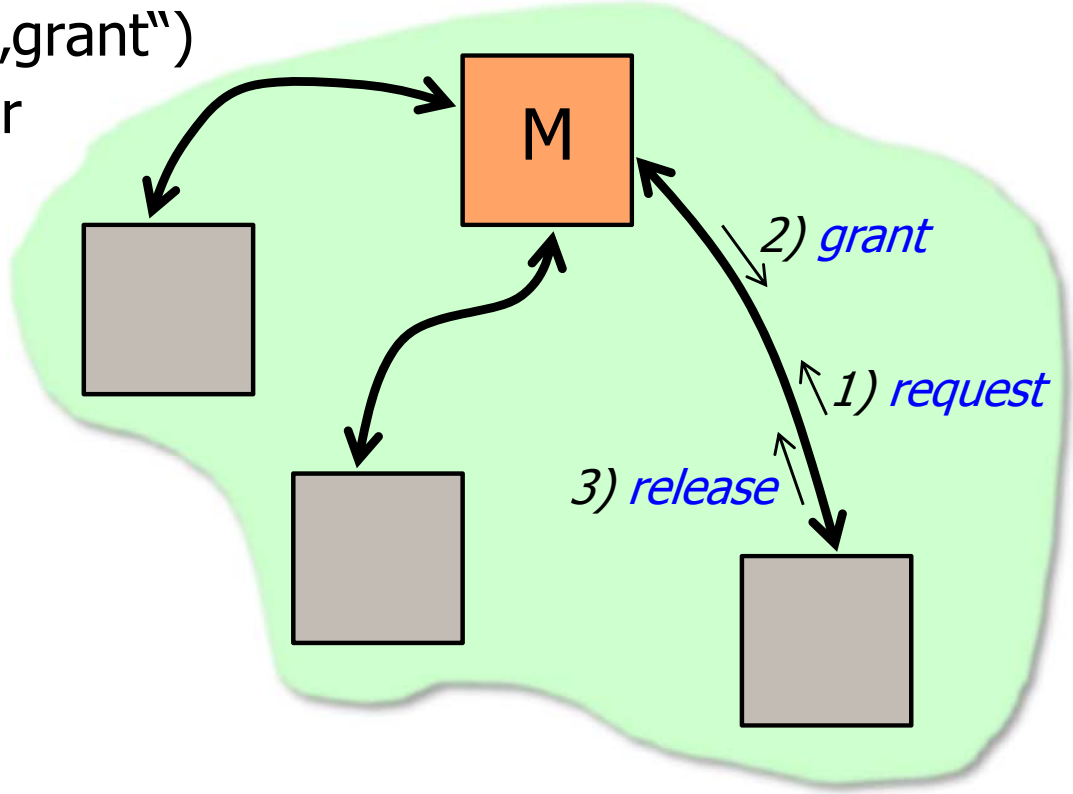

- Vergleichsweise einfach und wenige Nachrichten, aber
  - potentieller Engpass
  - single point of failure

Globale Warteschlange garantiert Fairness

- Zentraler Manager-Prozess hält eine (zeitlich geordnete) Warteschlange („Queue“) von Requests:

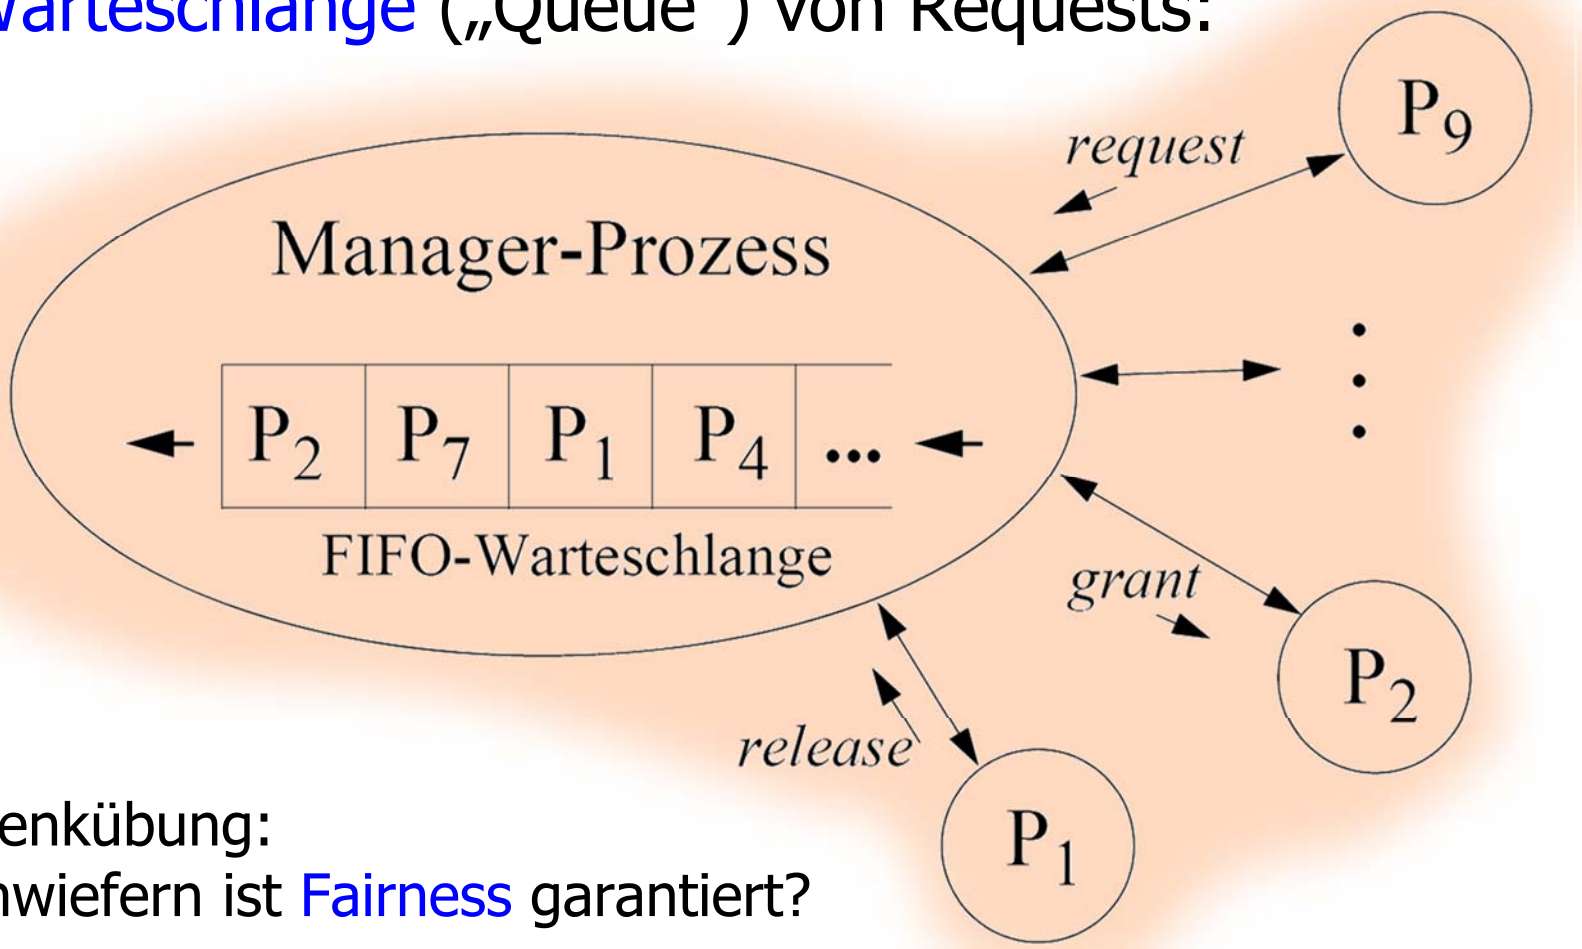

- Denkübung:
  Inwiefern ist Fairness garantiert?

Replizierte Warteschlange?

- Idee für eine dezentrale Lösung: Anstelle einer globalen Warteschlange diese nun bei jedem Prozess replizieren

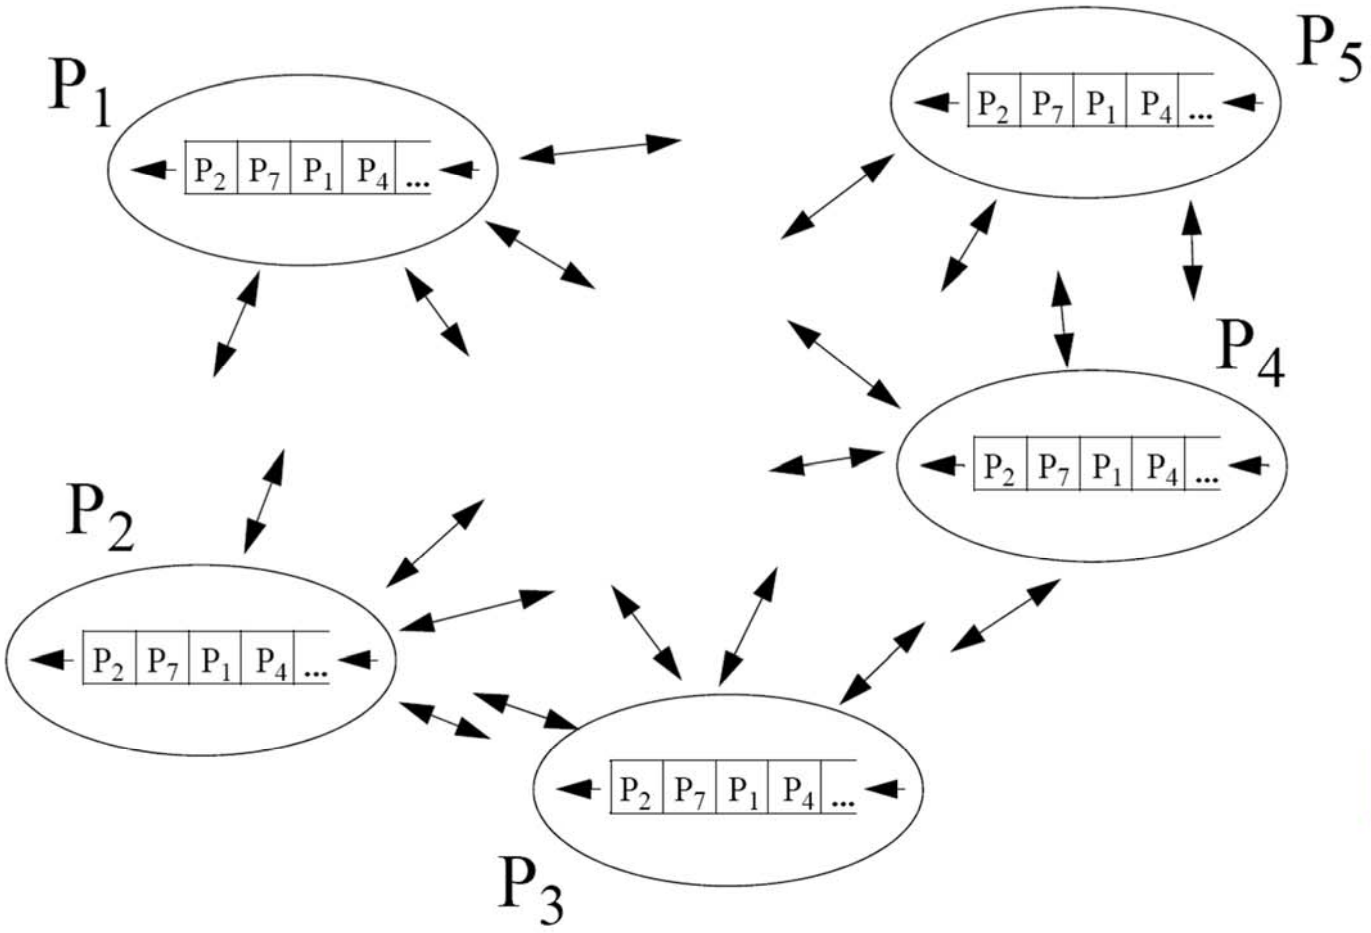

- Alle Prozesse sollen die gleiche Sicht der „virtuell globalen" Warte-schlange haben
- Konsistenz wird mit (vielen) Nachrichten und (logischer?) Zeit erreicht (→ nächste zwei slides)

Synchronisation der Warte-schlangen mit Zeitstempeln

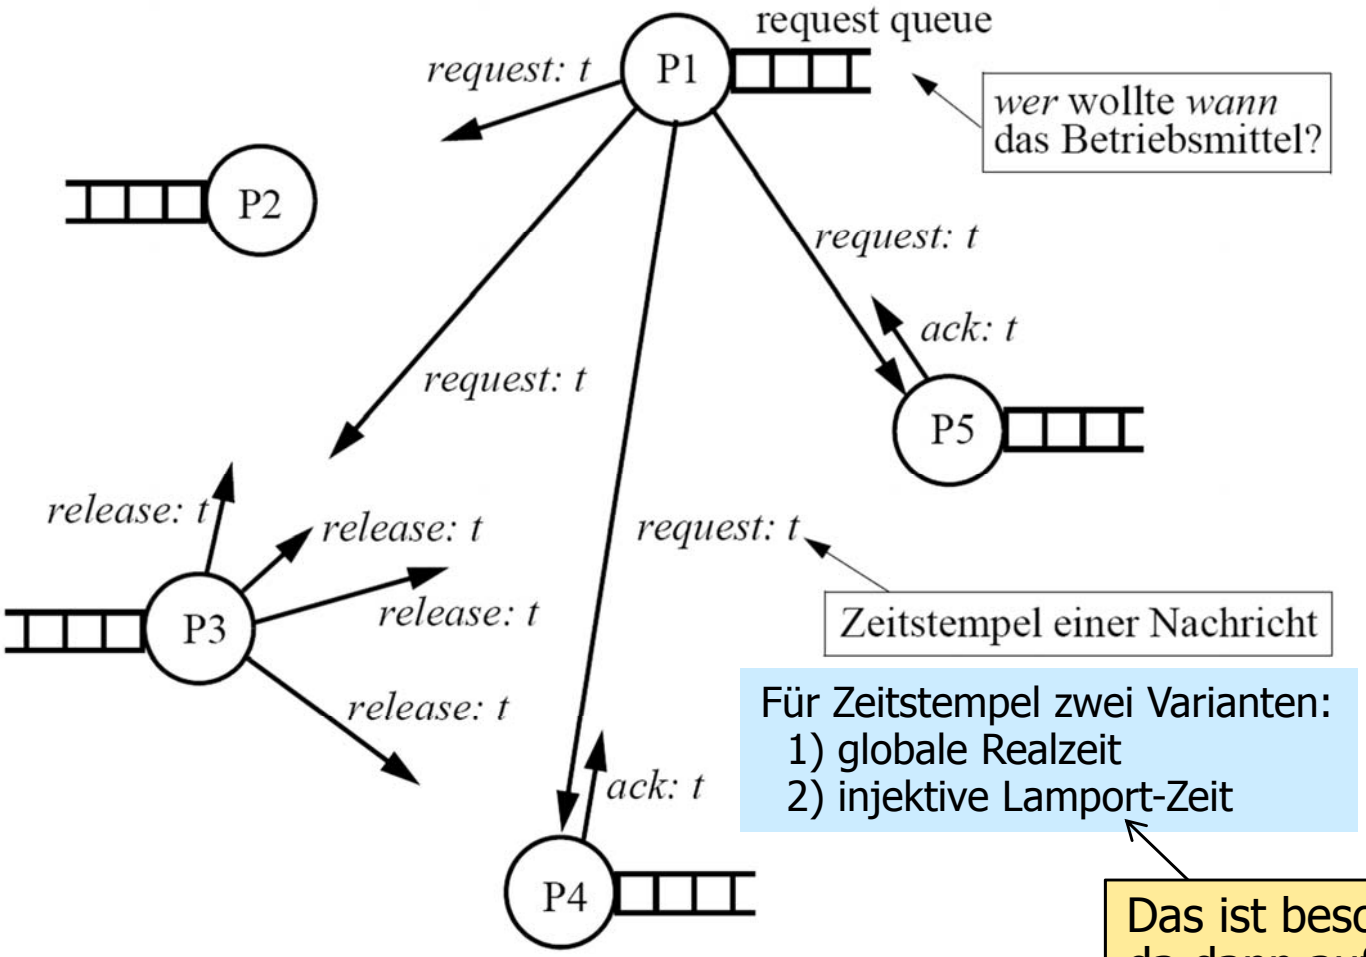

Für Zeitstempel zwei Varianten:
1) globale Realzeit
2) injektive Lamport-Zeit

Das ist besonders interessant, da dann auf synchronisierte Uhren verzichtet werden kann

- Voraussetzung: FIFO-Kommunikationskanäle
- Alle Nachrichten tragen (eindeutige!) Zeitstempel
- Request- und Release-Nachrichten immer an alle senden (FIFO-Broadcast)
- Requests werden bestätigt („ack“)

Der Algorithmus (Lamport 1978)

1) Bewerbung um Betriebsmittel: Request mit Zeitstempel und Absender an alle senden und in eigene Queue einfügen
2) Bei Empfang eines Request: Request in eigene Queue einfügen, ack versenden
3) Bei Freigabe des Betriebsmittels: Aus eigener Queue entfernen und Release an alle versenden
4) Bei Empfang eines Release: Zugehörigen Request aus eigener Queue entfernen
5) Ein Prozess darf das Betriebsmittel nutzen, wenn:
   a) der eigene Request der früheste in seiner Queue ist
   b) und er bereits von jedem anderen Prozess (irgendeine) spätere Nachricht bekommen hat

(Frühester Request ist global eindeutig ⇒ die beiden Bedingungen garantieren, dass kein früherer Request mehr kommt (wieso?))

Denkübungen:

- Wieso ist FIFO notwendig?
- Wo geht (bei Lamport-Zeit) die Uhrenbedingung ein?

Wieso sind garantiert:

1) Safety (zu jedem Zeitpunkt höchstens einer),
2) Fairness (jeder Request wird „schliesslich" erfüllt)?

3(n-1) Nachrichten pro Bewerbung (n = Zahl der Prozesse)

Ein anderer verteilter Mutex-Algorithmus (Ricart / Agrawala, 1981)

- Nur 2(n-1) Nachrichten (Reply übernimmt Rolle von Release und ack)

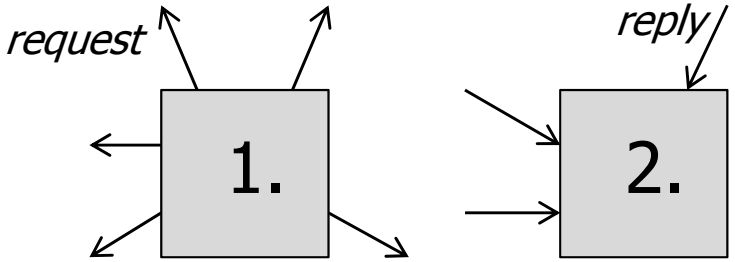

1. Sende Request (mit log. Zeit-stempel!) an alle n-1 anderen
2. Dann auf n-1 Replies warten, danach Betriebsmittel nutzen

- Bei Eintreffen einer Request-Nachricht:

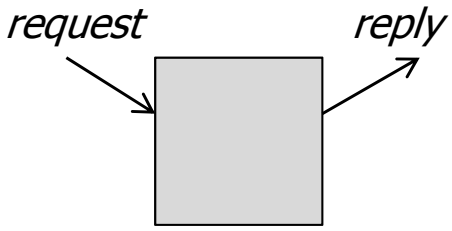

  - wenn nicht selbst beworben oder der Sender „ältere Rechte" (bzgl. logischer Zeit!) hat, dann Reply sofort schicken
  - ansonsten Reply erst später (im Sinne von Release, s.o.) schicken, nach Erfüllen des eigenen Requests (d.h. dem exklusivem Zugriff)

Nur älteste Bewerbung setzt sich überall durch!

Denkübungen: Safety? Fairness? Liveness? FIFO notwendig?

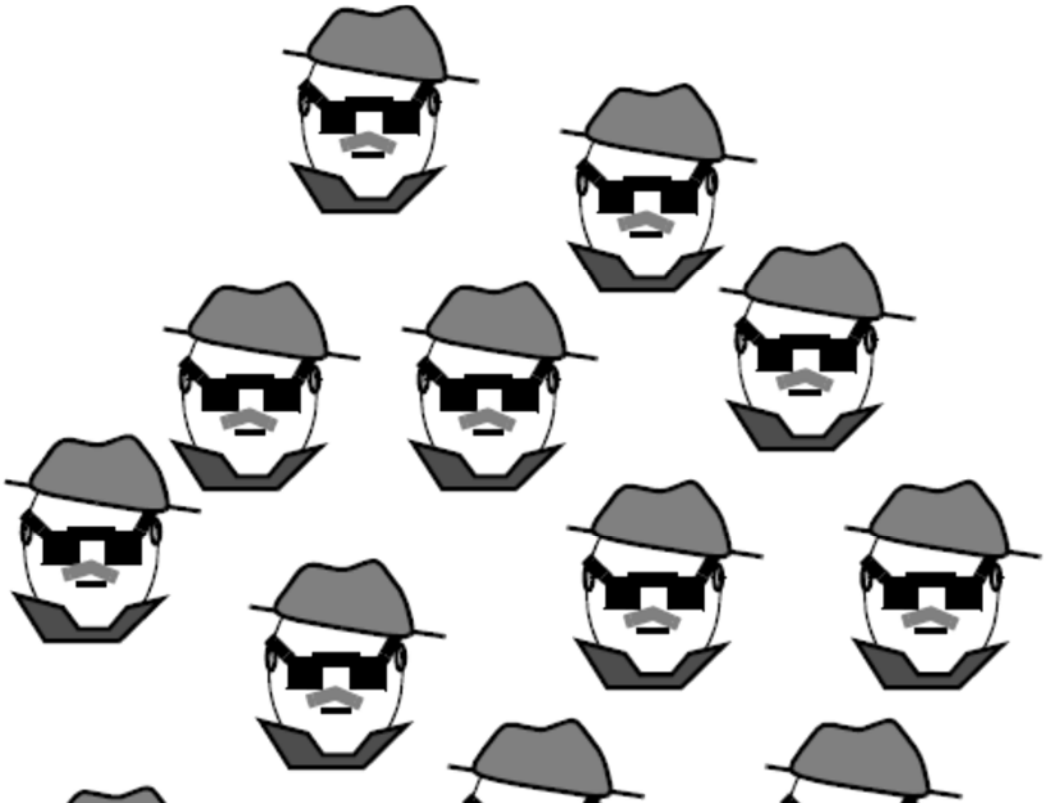

Sicherheit

Sicherheit in verteilten Systemen

Problemaspekte und Angriffsszenarien:

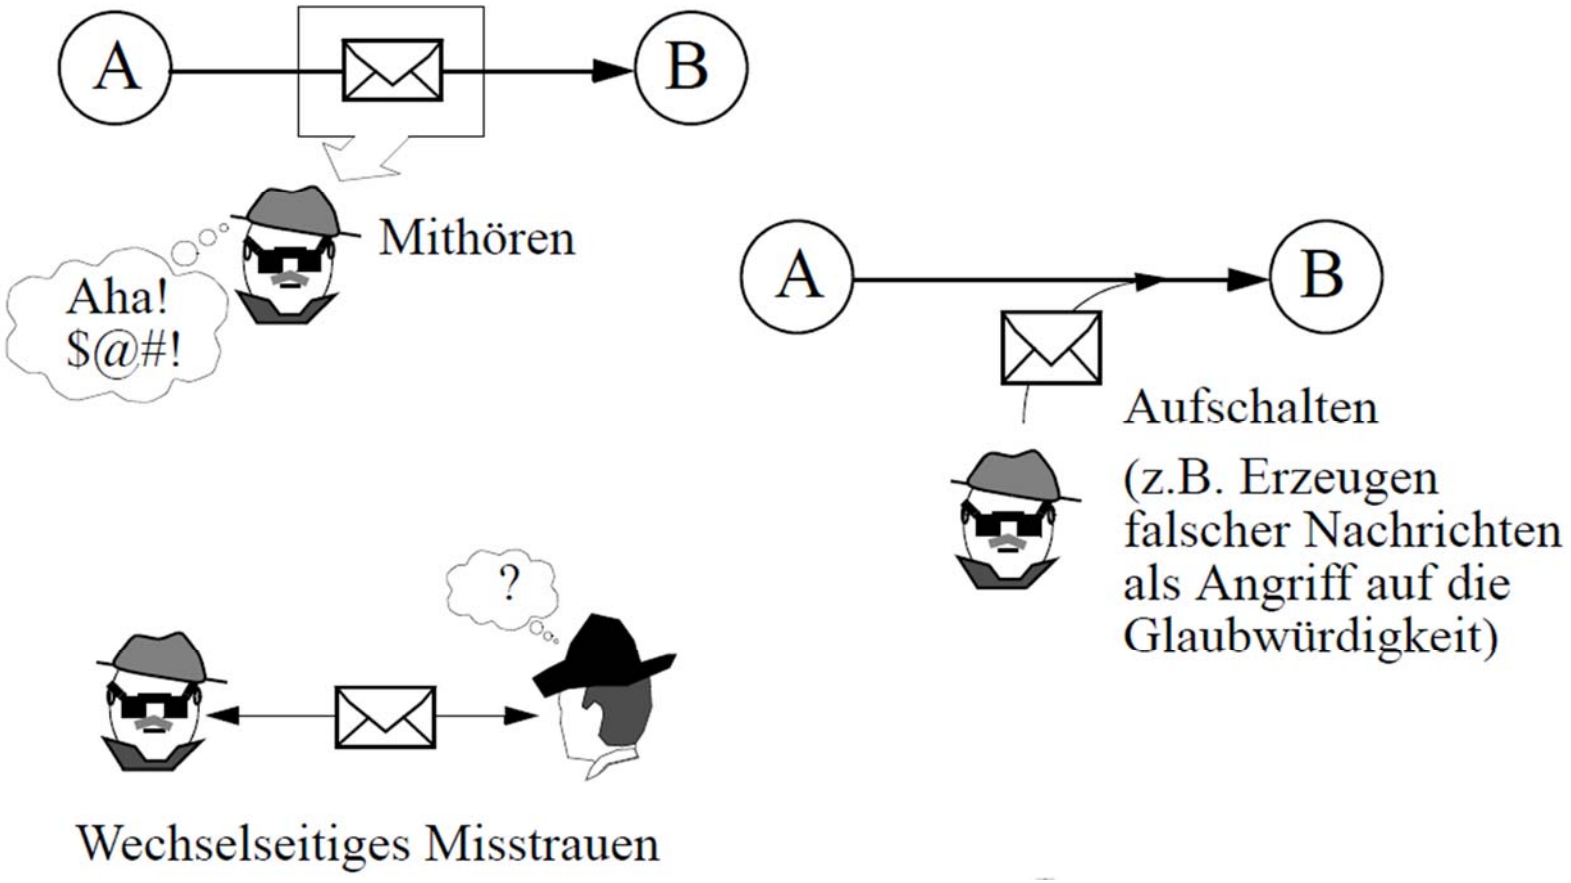

Sicherheit in verteilten Systemen (2)

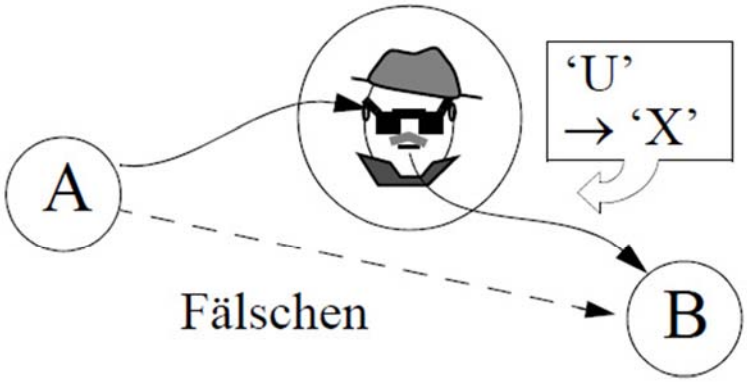

Fälschen

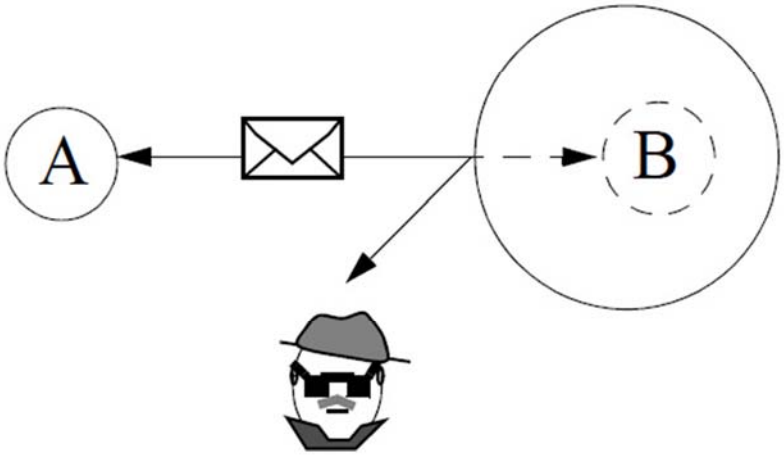

Vorspiegeln falscher Identität

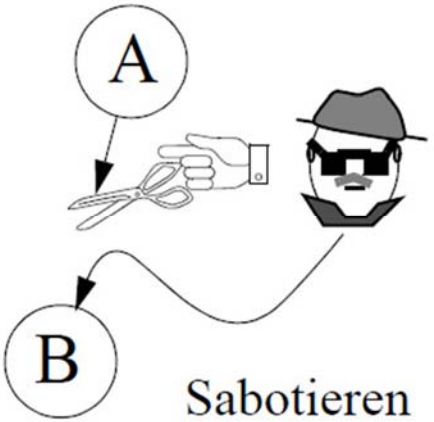

Sabotieren

Sicherheit: Anforderungen

- Autorisierung / Zugriffsschutz
  - Einschränkung der Nutzung auf den Kreis der Berechtigten
- Vertraulichkeit
  - Daten / Nachrichteninhalt gegen Lesen Unberechtigter schützten
  - Kommunikationsverhalten (wer mit wem etc.) geheim halten
- Authentizität
  - Absender "stimmt" (z.B. Server ist der, für den er sich ausgibt)
  - Daten sind "echt" und aktuell (→ Integrität)
- Integrität
  - Wahrung der Unversehrtheit von Nachrichten, Programmen, Daten
- Verfügbarkeit der wichtigsten Dienste
  - keine Zugangsbehinderung ("denial of service") durch andere
  - kein provozierter Absturz ("Sabotage")

Weitergehende Anforderungen

Wie zum Beispiel:

- Nichtabstreitbarkeit
- Accountability
- Strafrechtliche Verfolgbarkeit
  - Protokollierung
  - „Key Escrow"
- Compliance
  - Konformität zu rechtlichen, vertraglichen und politischen Vorgaben
- …

Sicherheit: Verteilungsaspekte

- Offenheit in verteilten Systemen begünstigt Angriffe
  - grosse Systeme → vielfältige Angriffspunkte
  - standardisierte Kommunikationsprotokolle → Angriff einfach
  - räumliche Distanz → Ortung des Angreifers schwierig, Angriff sicher
  - breiter Einsatz, allgemeine Verwendung → Angriff reizvoller
  - physische Abschottung oft nicht durchsetzbar
  - technologische Gegebenheiten: z.B. Wireless LAN ("broadcast")
- Heterogenität
  - induziert zusätzliche Schwachstellen
  - erschwert Durchsetzung einer einheitlichen Schutzphilosophie
- Dezentralität
  - fehlende netzweite Sicherheitsautorität

Sicherheit: Verteilungsaspekte

- → Gewährleistung der Sicherheit ist in verteilten Systemen wichtiger und schwieriger als in alleinstehenden Systemen

- Typische Techniken und "Sicherheitsdienste":
  - *Verschlüsselung*
  - *Autorisierung* ("der darf das!")
  - *Zertifizierung bzw. Authentisierung* ("X ist wirklich X!")

Hierfür Kryptosysteme und Krypto-protokolle als "Security Service"

Angriffsformen – Passive Angriffe

- Beobachten der Kommunikation
  - Nachrichteninhalt in Erfahrung bringen
  - Kommunikationsverhalten analysieren (“wer mit wem wie oft?”)

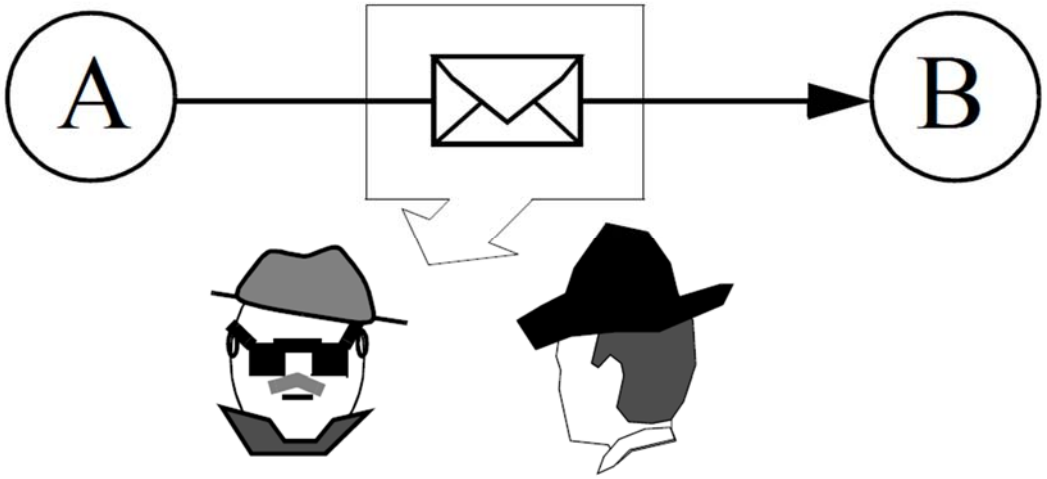

→ Verschlüsselung
→ Anonymisierung

Aktive Angriffe: Eindringen, Vorsätzliche Täuschung etc.

- Einbruch (Zugangsschranken durchbrechen)
  - Diebstahl von Daten, Nachrichteninhalten,…
- Verändern des Nachrichtenstroms
  - Ändern, Vernichten, Erzeugen, Vertauschen, Verzögern, Wieder-holen (“replay”) von Nachrichten

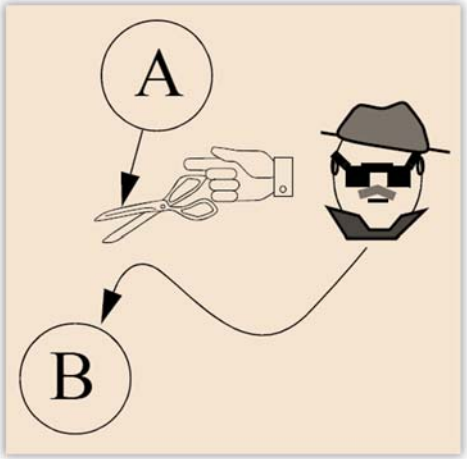

- Falsche Identität vorspiegeln
  - Maskerade: Nachahmen anderer Prozesse oder Nutzung eines fremden Passwortes
- Missbräuchliche Nutzung von Diensten
- Denial of Service durch Sabotage oder Verhindern des Dienstzugangs, z.B. durch Überfluten mit Nachrichten

Authentizität

Seid auf eurer Hut vor dem Wolf; wenn er hereinkommt, so frisst er euch alle mit Haut und Haar. Der Bösewicht verstellt sich oft, aber an seiner rauen Stimme und seinen schwarzen Füssen werdet ihr ihn gleich erkennen.

(*Der Wolf und die sieben Geisslein*, Grimm'sche Märchen)

- Authentizität ist elementar und essentiell für die Sicherheit eines verteilten Systems
  - zu authentischen Nachrichten / Daten vgl. auch "Integrität"

- Authentizität eines Subjekts
  - Kommunikationspartner, Client, Server,…
  - ist der andere wirklich der, der er vorgibt zu sein?
  - z.B.: darf ich als Server daher ihm (?) den Zugriff gewähren?

Authentizität (2)

- Authentizität eines Dienstes
  - Bsp.: Handelt es sich wirklich um den Druckdienst oder um einen böswilligen Dienst, der die Datei ausserdem noch heimlich kopiert?
- Authentizität einer Nachricht
  - hat mein Kommunikationspartner dies wirklich so gesagt?
  - soll ich als Geldautomat wirklich so viel Geld ausgeben?
- Authentizität gespeicherter Daten
  - ist dies wirklich der Vertragstext, den wir gemeinsam elektronisch hinterlegt haben?
  - hat der Autor Casimir von Hinkelstein wirklich *das* geschrieben?
  - ist das Foto nicht eine Fälschung?
  - ist dieser elektronische Schlüssel wirklich echt?

Hilfsmittel zur Authentifizierung

- Wahrung der Nachrichten-Authentizität
  - Verschlüsselung, so dass inhaltliche Änderungen auffallen (Signatur, kryptograph. Hashcode / Prüfsumme)
  - Beachte: Authentizität des Nachrichteninhalts garantiert nicht Authentizität der Nachricht als solche! (z.B. Replay-Attacke: Neuversenden einer früher abgehörten Nachricht)
  - Massnahmen gegen Replays: z.B. mitcodierte Sequenznummer

- Peer-Authentifizierung z.B. mit Frage-Antwort-Spiel
  - "challenge / response": Antworten sollte nur der echte Kommunikationspartner kennen
  - idealerweise stets neue Fragen verwenden (Replay-Attacken!)

Passwörter zur Authentifizierung

- Authentifizierung mit Passwort („Kennwort“)
  - typischerweise zur Authentifizierung eines Benutzers (“Client”) zum Schutz des Dienstes vor unbefugter Benutzung (Autorisierung)
  - Kenntnis des Passworts gilt als Identitätsbeweis (gerechtfertigt?)
- Potentielle Schwächen von Passwörtern
  - Geheimhaltung (Benutzer kann Passwörter “verleihen” etc.)
    - Angriffsformen: Raten bzw. systematische Suche (“dictionary attack“)
    - Gegenmassnahmen: Zurückweisung zu “simpler” Passwörter,
    - Zeitverzögerung nach jedem Fehlversuch und Maximalzahl von Fehlversuchen,
    - security logs
  - Abhörgefahr (möglichst kein Übermittlung im Klartext; Speicherung nur in codierter Form, so dass Invertierung prakt. unmöglich)
  - Replay-Attacke (Gegenmassnahme: Einmalpasswörter)

Einwegfunktionen

- Bilden die Basis vieler kryptographischer Verfahren

- Prinzip: **y = f(x)** einfach aus x berechenbar, aber **x = f^{-1}(y)** ist extrem schwierig aus y zu ermitteln
  - f^{-1} typw. exponentielle Zeitkomplexität
  - zeitaufwändig (→ praktisch undurchführbar)

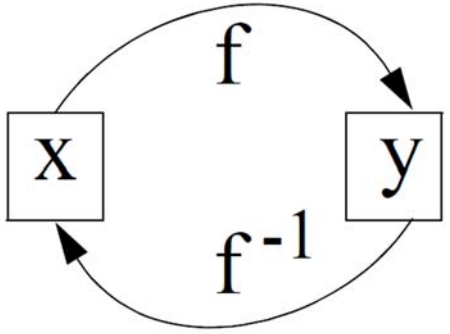

z.B. f = O(n), O(n log n),...
aber $f^{-1} = O(2^n)$

- Es gibt (noch) keinen mathematischen Beweis, dass Einwegfunktionen überhaupt existieren
  - Beweis ihrer Existenz würde Beweis für P≠NP implizieren
  - aber einige Funktionen sind es *allem Anschein nach*

Einwegfunktionen (2)

- Einwegfunktionen mögen zunächst sinnlos erscheinen :

Ein zu y = f(x) verschlüsselter Text x kann nie wieder entschlüsselt werden!

  - zweifelhaften Sinn findet dies z.B. in Ransomware (Kryptotrojaner)...

- Aber: Einwegfunktionen mit "trap-door"
(ein Geheimnis, das es erlaubt, f^{-1} effizient zu berechnen)
  - Idee: Nur der "Besitzer" oder "Erfinder" von f kennt dieses
  - Beispiel Briefkasten: Einfach etwas hineinzutun; schwierig etwas herauszuholen; mit Schlüssel (= Geheimnis) ist das aber einfach!
  - Anwendung z.B. Public-Key-Verschlüsselung oder Einmalpasswörter

Prinzipien typischer (vermuteter) Einwegfunktionen

- Das Multiplizieren zweier (grosser) Primzahlen p, q ist effizient; das Zerlegen einer Zahl (z.B. n = pq) in ihre Primfaktoren i.Allg. schwierig (d.h., sehr aufwändig)

- In einem Restklassenring (mod m) ist die Bildung der Potenz a^k einfach; die k-te Wurzel oder den (diskreten) Logarithmus zu berechnen, ist i.Allg. schwierig
  - aber: k-te Wurzel einfach, wenn Primzerlegung von m = pq bekannt → trap-door!

Einmalpasswörter mit Einwegfunktionen

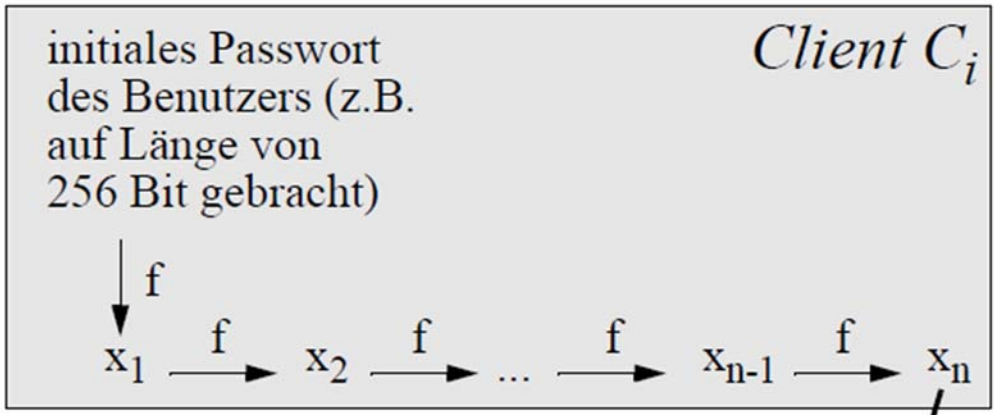

Durch iterierte Anwendung einer Einwegfunktion f wird (quasi auf Vorrat) eine Liste von n Einmal-passwörtern x_1 ... x_n (auch „hash chain" genannt) erzeugt

Kommunikation über das Netz ist unsicher!

Zunächst wird x_n verwendet, beim nächsten Mal x_{n-1}, dann x_{n-2} etc.

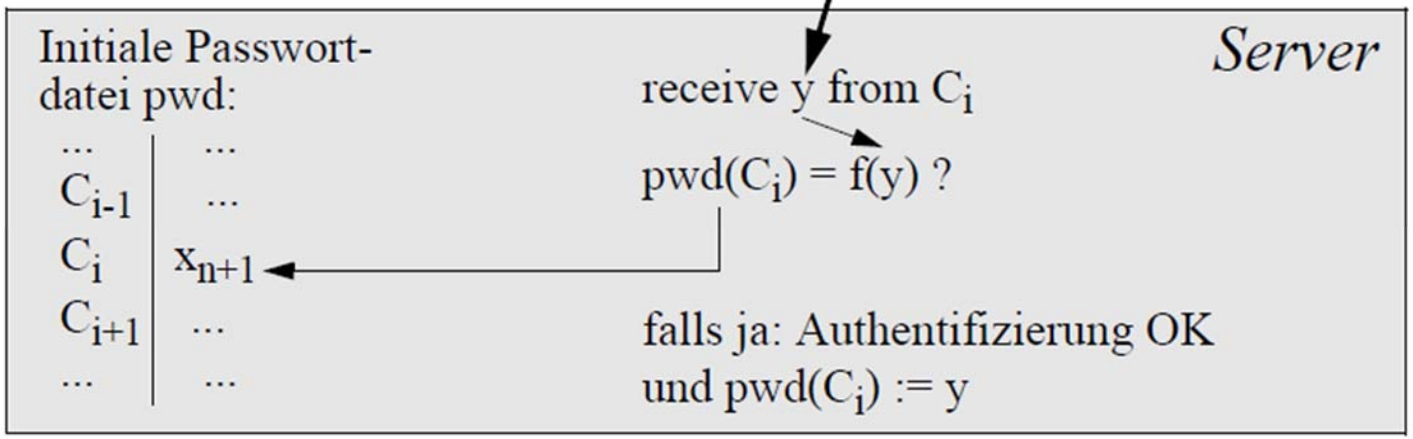

Einmalpasswörter mit Einwegfunktionen: Eigenschaften

- Ein abgehörtes Passwort x_i nützt nicht viel
  - Berechnung von x_{i-1} aus x_i ist (praktisch) nicht möglich
- Ein Lesen der Passwortdatei des Servers ist nutzlos
  - dort nur das *vergangene* Passwort vermerkt
- Einwegfunktion f muss nicht geheimgehalten werden

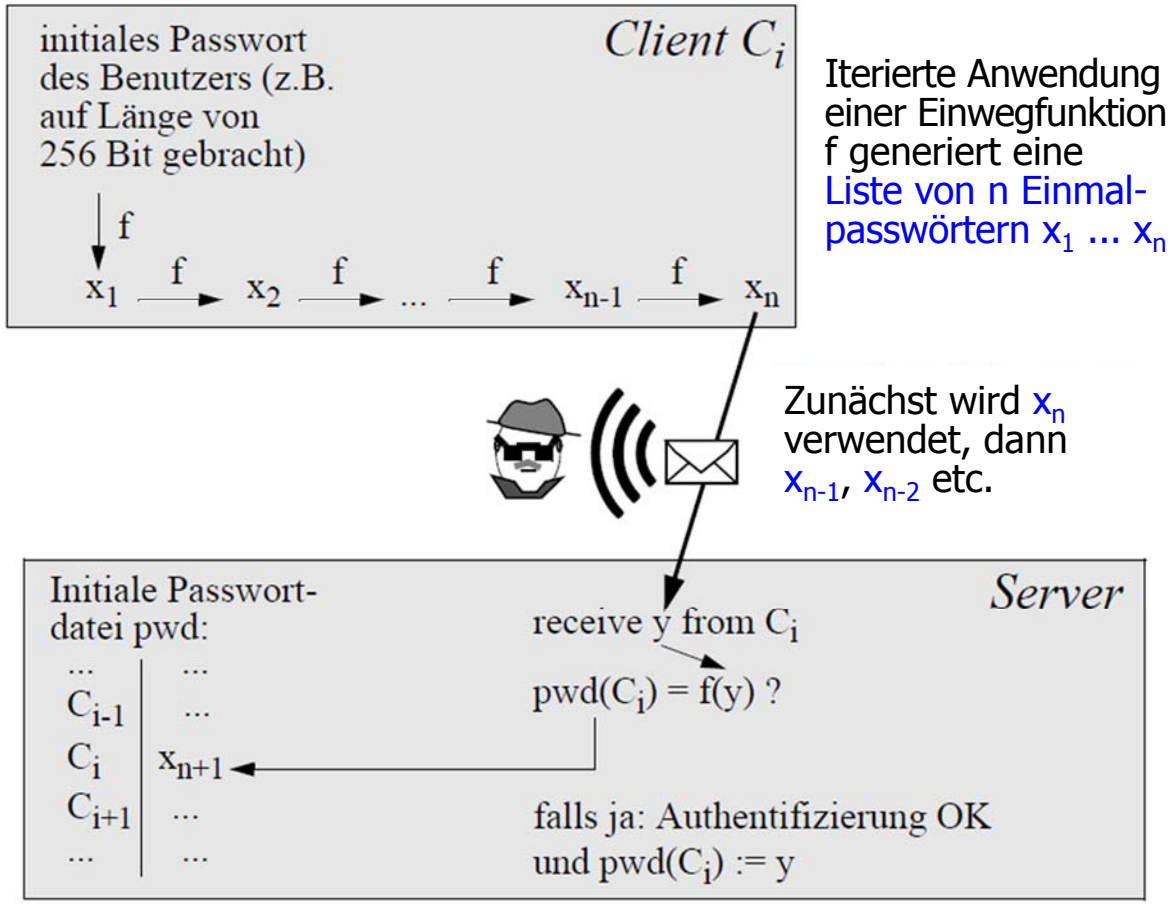

- Verfahren ist z.B. im S/KEY-System (RFC 1760) realisiert

Kryptosysteme

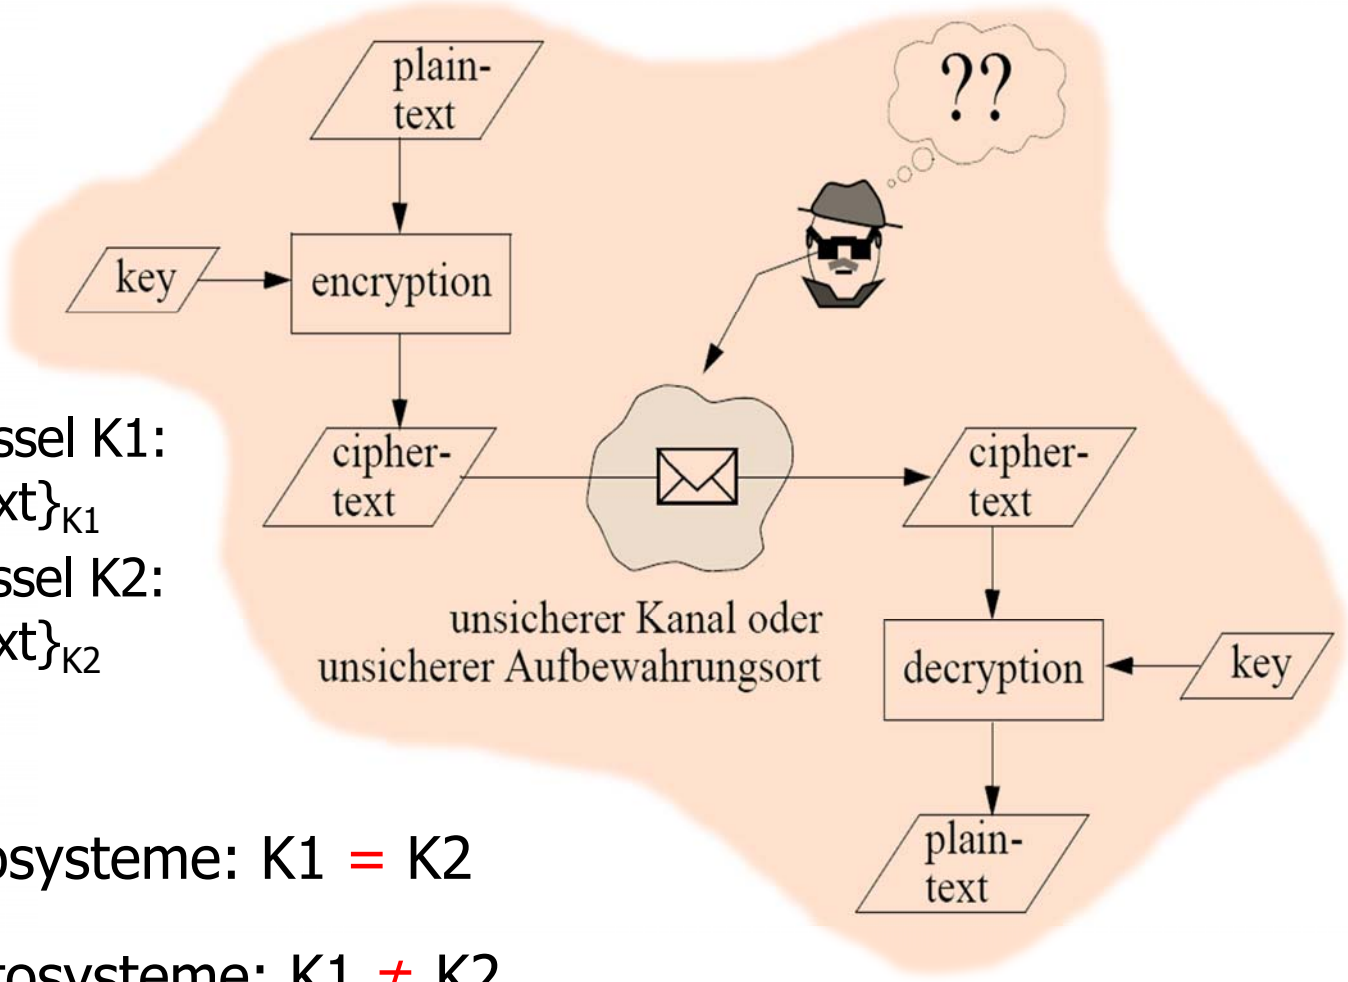

Schreibweisen:

- Verschlüsseln mit Schlüssel K1:
  Schlüsseltext = $\{\text{Klartext}\}_{K1}$
- Entschlüsseln mit Schlüssel K2:
  Klartext = $\{\text{Schlüsseltext}\}_{K2}$

- Symmetrische Kryptosysteme: K1 = K2
- Asymmetrische Kryptosysteme: K1 ≠ K2

Kryptosysteme (2)

- Forderung an das Verfahren:
  Verschlüsselung ist ohne Kenntnis der Schlüssel höchstens mit unverhältnismässig hohem Rechenaufwand umkehrbar

- Geheimhalten eines konkreten Verschlüsselungsverfahrens stellt i.Allg. keinen Sicherheitsgewinn dar
  - organisatorisch oft nicht lange durchhaltbar
  - kein öffentliches Feedback über erkannte Schwächen des Verfahrens
  - Verfahren, die geheimgehalten werden, erscheinen eher "verdächtig"

Verfahren mit symmetrischen Schlüsseln

- Nachteile (gegenüber Verfahren mit asymmetrischen Schlüsseln):
  - Schlüssel muss geheimgehalten werden
  - mit allen Kommunikationspartnern separaten Schlüssel vereinbaren
  - hohe Komplexität der Schlüsselverwaltung bei vielen Teilnehmern
  - Problem des geheimen Schlüsselaustausches
- Vorteile:
  - ca. 100 bis 1000 Mal schneller als typ. asymmetrische Verfahren
- Beispiele für symmetrische Verfahren:
  - IDEA (International Data Encryption Algorithm): Einsatz in PGP
  - DES (Data Encryption Standard) bzw. „Triple DES“ (TDES)
  - AES (Advanced Encryption Standard) als Nachfolger von DES: Verwendung bei WPA2, SSH, IPsec

One-Time Pads

- „Perfektes“ symmetrisches Kryptosystem
  - Denkübung: Wieso und unter welchen Voraussetzungen?

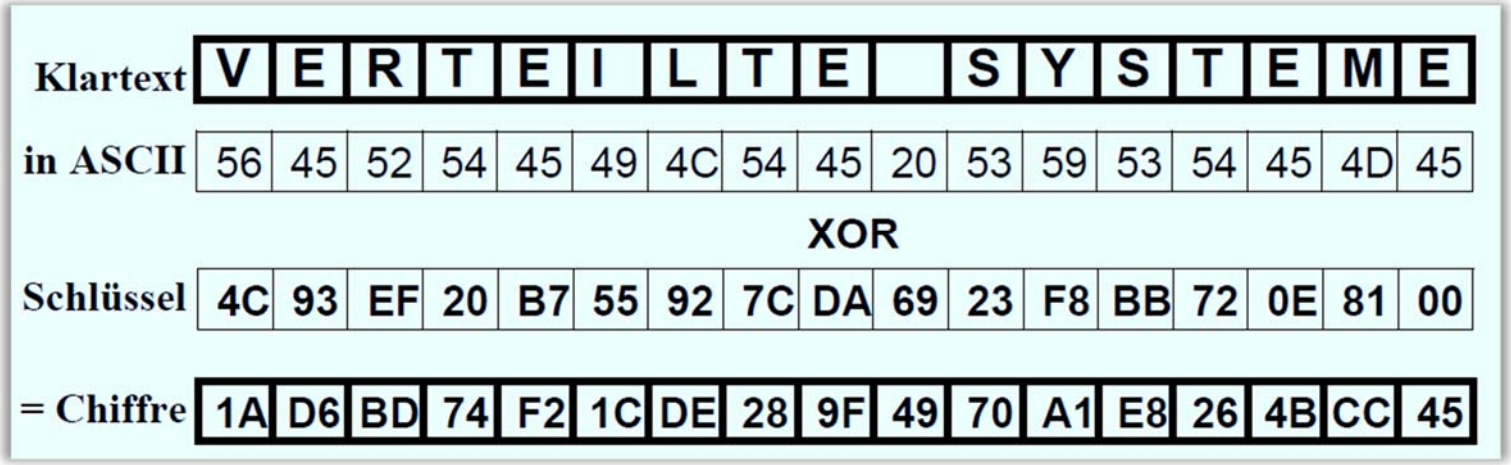

Klartext	V	E	R	T	E	I	L	T	E		S	Y	S	T	E	M	E
in ASCII	56	45	52	54	45	49	4C	54	45	20	53	59	53	54	45	4D	45
								XOR									
Schlüssel	4C	93	EF	20	B7	55	92	7C	DA	69	23	F8	BB	72	0E	81	00
= Chiffre	1A	D6	BD	74	F2	1C	DE	28	9F	49	70	A1	E8	26	4B	CC	45

- Prinzip: Wähle zufällige Sequenz von Schlüsselbits
  - Verschlüsselung: Schlüsseltext = Klartext XOR Schlüsselbitsequenz
  - Entschlüsselung: Klartext = Schlüsseltext XOR Schlüsselbitsequenz
  - Begründung: (a XOR b) XOR b = a (für alle Bitbelegungen von a, b)

One-Time Pads (2)

- Anforderungen an Schlüsselbitsequenz:
  - keine Wiederholung von Bitmustern
    (→ Schlüssellänge = Klartextlänge)
  - Schlüsselbitsequenz ohne Bildungsgesetz („echte" Zufallsfolge)
  - Schlüsselbitsequenz wirklich „one-time" (keine Mehrfachverwendung!)
- Kryptoanalyse ohne Schlüsselkenntnis unmöglich
- Nachteile von One-Time Pads:
  - Verwendung unhandlich (hoher Bedarf an frischen Schlüsselbits, dadurch aufwändiger Schlüsselaustausch)
  - Synchronisationsproblem bei Übertragungsstörungen (wenn Empfang ausser Takt gerät, ist Folgetext verloren)
  - → nur für hohe Sicherheitsanforderungen üblich (z.B. „rotes Telefon")

Rotes „Telefon“

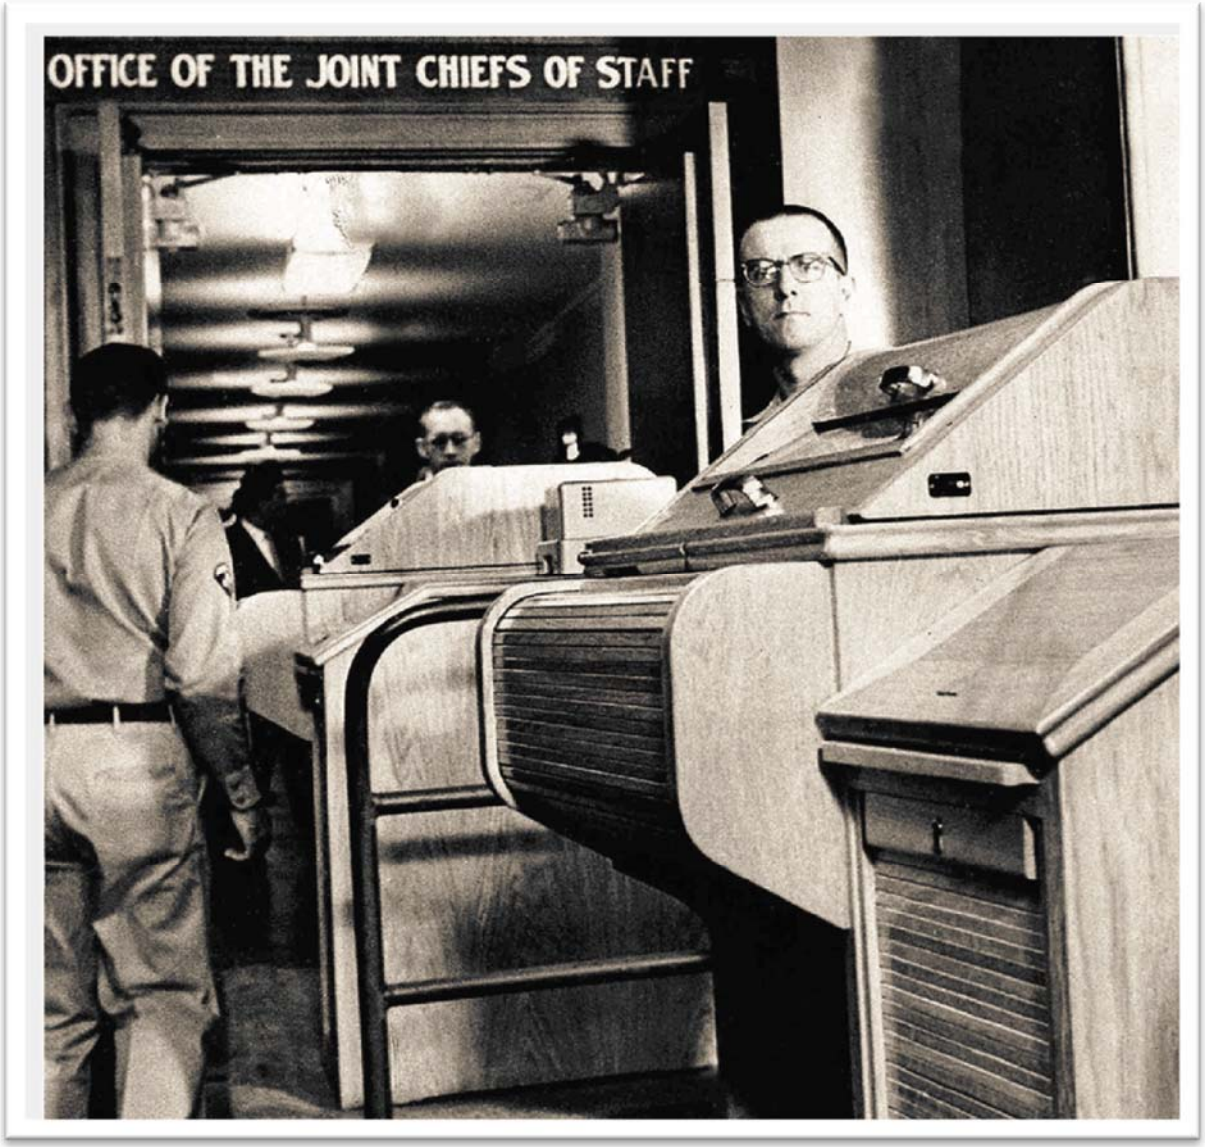

Der „heisse Draht“ zwischen Washington und Moskau wird am 26. August 1963 installiert; es handelt sich um Fernschreib-einrichtungen (Telex) mit Kabel via London und Helsinki.

Ständige Prüfnachricht war „THE QUICK BROWN FOX JUMPS OVER THE LAZY DOG 1234567890“.

Rotes „Telefon“

Der „heisse Draht“ zwischen Washington und Moskau wird am 26. August 1963 installiert; es handelt sich um Fernschreib-einrichtungen (Telex) mit Kabel via London und Helsinki.

Ständige Prüfnachricht war „THE QUICK BROWN FOX JUMPS OVER THE LAZY DOG 1234567890“.

Ab 1971 auch Kommunikation via Satellit, seit 2008 auch Glaserfaserkabel.

Seit 1980 wird Fax benutzt, seit 2010 auch E-Mail.

Die Kenngruppen dürfen nur einmal zur Bildung eines Spruchschlüssels verwendet werden.

(1) Der Tagesschlüssel ist ein Zeitschlüssel und hat jeweils 24 Stunden Gültigkeit. Der Schlüsselwechsel erfolgt 00.01 Uhr.

(2) Der Spruchschlüssel hat nur Gültigkeit für jeweils einen Spruch.

(3) Tagesschlüsseltabellen und Schlüssellochkarten, die auf Grund von Beschädigungen oder Kompromittierung nicht benutzt wurden, sind der Leitstelle (für die Chiffrierverbindung verantwortliche Chiffrierstelle) des Schlüsselbereiches chiffriert oder mittels Kurier zu melden. Der neue Tagesschlüssel (bzw. die neue Folge der Tagesschlüssel) wird durch die Leitstelle chiffriert oder mittels Kurier angewiesen.

(4) Alle Schlüsselmittel, einschließlich entnommene, zur Bearbeitung nichtbenutzte bzw. nichtverwendbare, sind bis zur Vernichtung so aufzubewahren, daß ein Zugriff durch unbefugte Personen ausgeschlossen ist.

(5) Wenn nicht anders angewiesen, sind zur Bearbeitung benutzte, entnommene unbenutzte bzw. nichtverwendbare Tagesschlüsseltabellen, Schlüssellochkarten, Spruchschlüsseltabellen und vollständig aufgebrauchte Kenngruppentafeln innerhalb von 48 Stunden zu vernichten.

(6) Die Vernichtung von Schlüsselmitteln ist lückenlos mit Datum und durch zwei Unterschriften nachzuweisen. Der Nachweis d. Vernichtung der Tagesschlüsseltabellen, Schlüssellochkarten und Spruchschlüsseltabellen hat in der Entnahmetabelle zu erfolgen.

Schlimm ſind die Schlüſſel, die nur ſchließen auf, nicht zu;
Mit ſolchem Schlüſſelbund im Haus verarmeſt du.

Friedrich Rückert, Die Weisheit des Brahmanen – ein Lehrgedicht in Bruchstücken

Ein indiſcher Brahman, geboren auf der Flur,
Der nichts geleſen als den Weda der Natur;
Hat viel geſehn, gedacht, noch mehr geahnt, gefühlt,
Und mit Betrachtungen die Leidenſchaft gefühlt;

Spricht bald was klar ihm ward, bald um ſich's klar zu machen,
Von ihn angeh'nden halb, halb nicht angeh'nden Sachen.
Er hat die Eigenheit, nur Einzelnes zu ſehn,
Doch alles Einzelne als Ganzes zu verſtehn.

Asymmetrische Kryptosysteme

- Schlüssel zum Ver- / Entschlüsseln sind verschieden
  - z.B. RSA-Verfahren (Rivest, Shamir, Adleman, 1978); beruht auf der Schwierigkeit von Faktorisierung
  - andere Verfahren beruhen z.B. auf diskreten Logarithmen

- Für jeden Teilnehmer X existiert ein Paar (p,s)
  - p = *public key* (zum *Verschlüsseln* von Nachrichten an X)
  - s = *secret key* (oder: private key) (zum *Entschlüsseln* von mit p verschlüsselten Nachrichten)

Asymmetrische Kryptosysteme

- Jeder Prozess, der an X sendet, kennt p
- Nur X selbst kennt s

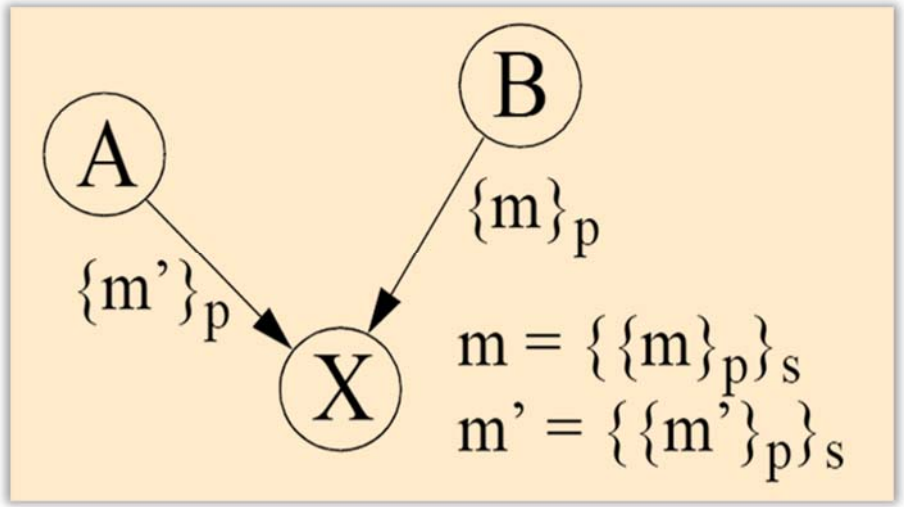

- Public-Key-Server
  - Welchen Schlüssel hat Prozess X_i?
  - Server muss vertrauenswürdig sein
  - Kommunikation zum Server darf nicht manipuliert sein

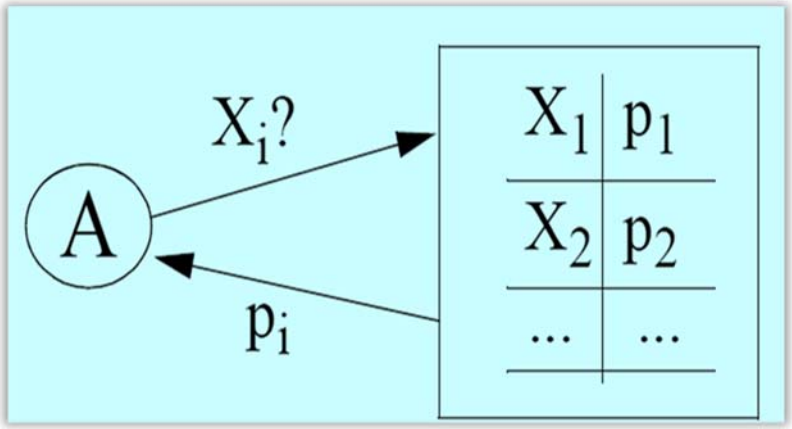

Asymmetrische Kryptosysteme

Gewünschte Eigenschaften:

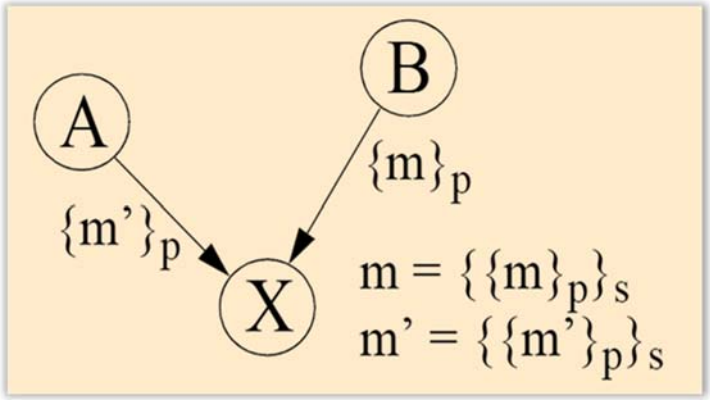

- 1) m lässt sich nicht allein aus $\{m\}_p$ ermitteln
- 2) s lässt sich aus p oder einer verschlüsselten, bekannten Nachricht nicht (mit vertretbarem Aufwand) ableiten
- 3) $m = \{\{m\}_p\}_s$
- 4) Evtl. zusätzlich: $m = \{\{m\}_s\}_p$

  (Rolle von Verschlüsselung und Entschlüsselung austauschbar)

Vorteil asymmetrischer Verfahren gegenüber symmetrischen

- Vereinfachte Schlüsselvereinbarung
  - jeder darf den übermittelten public key p mithören
  - secret key s braucht grundsätzlich nie Dritten mitgeteilt zu werden
  - bei n Teilnehmern genügen 2n Schlüssel (statt $O(n^2)$ bei sym. Verfahren)
- Kenntnis von s authentifiziert zugleich den Besitzer
  - "wer $\{M\}_{pA}$ entschlüsseln kann, der ist wirklich A" (wirklich?)
- Digitale Unterschrift
  - "wenn (zu M) ein $\{M\}_{sA}$ existiert mit $\{M\}_{sA}\}_{pA} = M$, dann muss dies (M bzw. $\{M\}_{sA}$) von A erzeugt worden sein" (wieso?)

sA bzw. pA bezeichnen secret bzw. public key von A

Authentifizierung mit symmetrischen Schlüsseln

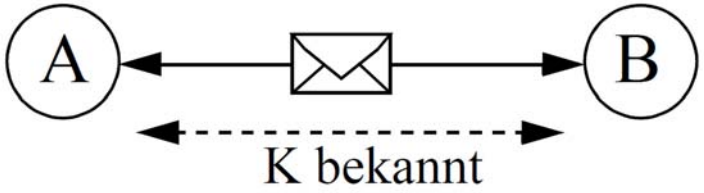

Sei K der zwischen A und B vereinbarte (und sonst geheimzuhaltende!) Schlüssel

- Problem: B soll die Authentizität von A feststellen
  - *Idee:* "Wenn X *das* weiss und kann, dann muss X wirklich X sein, denn sonst weiss und kann das niemand"
  - *Bemerkung:* Oft ist eine gegenseitige Authentifizierung nötig

1. Verfahren:

A: m := "Ich bin A"
m' := $\{m\}_K$

A→B: m', m

B: überprüfe, ob $\{m\}_K$ = m'

Damit B den richtigen Schlüssel (für A) wählt

- *Idee*: Überprüfe die Fähigkeit, Nachrichten mit einem geheimen Schlüssel zu kodieren

- *Nachteil*: Möglichkeit von replays durch Abhören

Authentifizierung mit symmetrischen Schlüsseln

2. Verfahren (Challenge-Response):

A→B: "Ich bin A"

B→A: n ← Einmalkennung ("nonce")

A: n' := $\{n\}_K$

A→B: n'

B: überprüfe, ob $\{n\}_K$ = n'

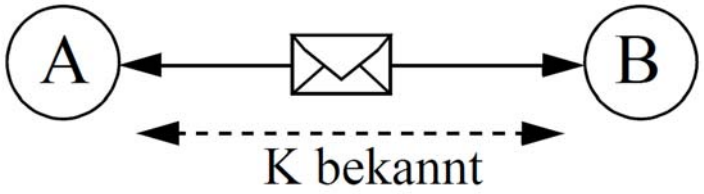

Genereller Nachteil bei symmetrischen Schlüsseln: Viele individuelle Schlüsselpaare für jede Client / Server-Beziehung

Authentifizierung mit asymmetrischen Schlüsseln

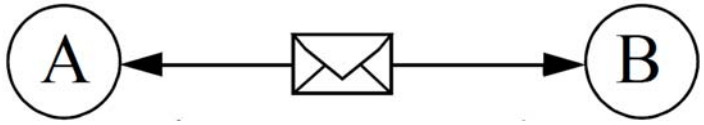

Notation: sX = secret key von X;
pX = public key von X

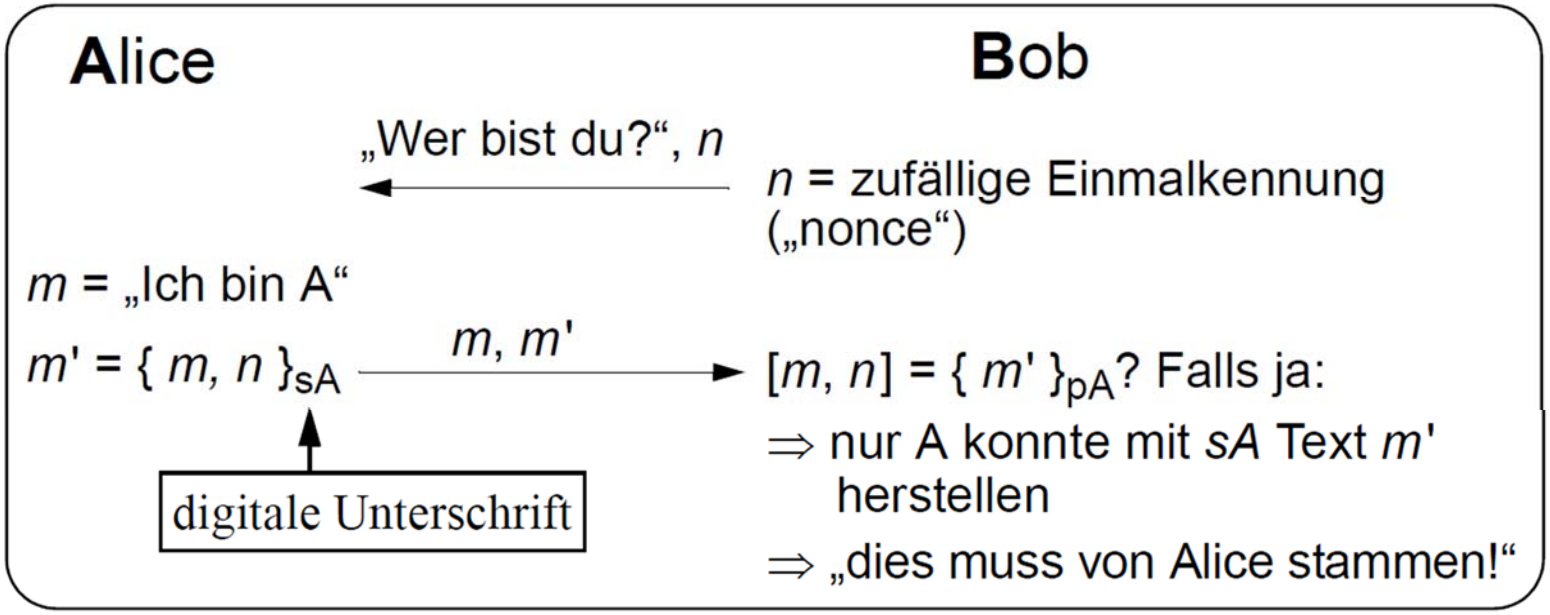

- Geschützt gegen Replays (wieso?)
- Vorsicht: “Man in the middle”-Angriff möglich (wie?)

Einbezug eines Schlüsselservers

- Nachteil obiger Lösung: B muss viele public keys speichern
- Alternativ mit Key Server KS: dieser kennt alle public keys
  - B erfragt public key von A bei KS
  - KS signiert alle seine Nachrichten
  - jeder kennt public key von KS (um Unterschrift von KS zu verifizieren)

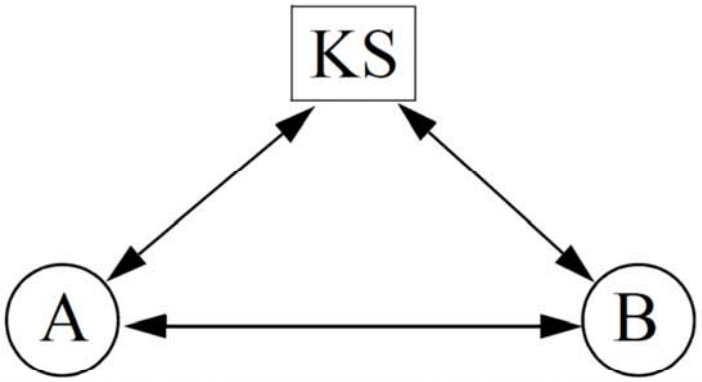

- Angriff auf den Schlüsselserver KS liefert keine Geheimnisse; erlaubt aber u.U., in dessen Rolle zu schlüpfen und falsche Auskünfte zu geben!
- KS ist evtl. verteilt realisiert (repliziert oder partitioniert)

Gegenseitige Authentifizierung (inklusive Schlüsselvereinbarung)

- Im Prinzip wie oben beschrieben nacheinander in beide Richtungen möglich; effizienter beides zusammen erledigen

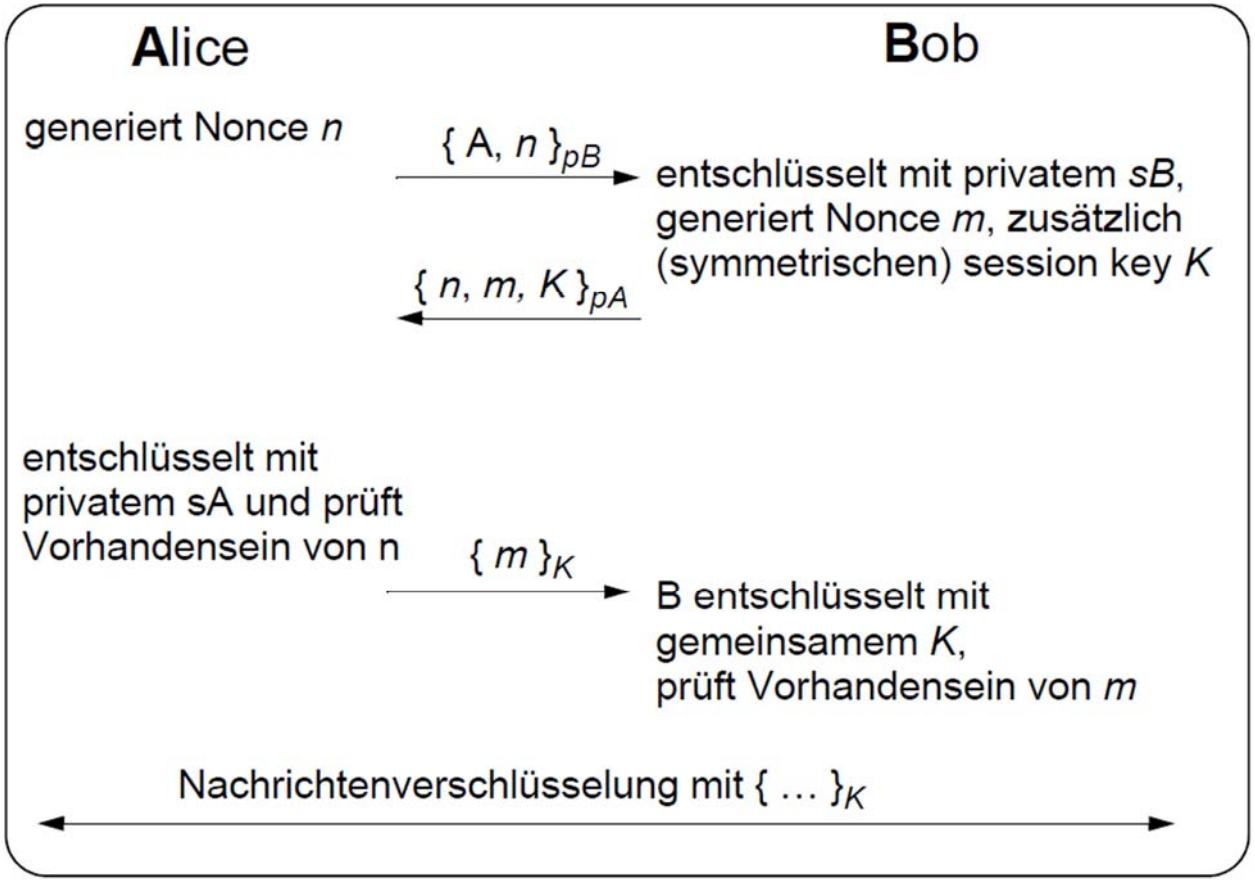

- Voraussetzung: A und B kennen die public keys pB bzw. pA des jeweiligen Partners
- Hier zusätzlich: Vereinbarung eines symmetrischen "session keys" K, der nach der Authentifizierung zur effizienten Verschlüsselung benutzt wird

Replays

- Generelles Problem: Auch wenn ein Angreifer eine Nachricht nicht entschlüsseln kann, kann er sie evtl. dennoch kopieren und später wieder einspielen
  - Autorisierungscodes für Geldautomaten?,...

Mögliche Gegenmassnahmen:

1) Challenge-Response: Verwendung von Einmalkennungen, ("nonce"), die vom Empfänger vorgegeben werden
   → alle relevanten Nachrichten sind verschieden

Replays (2)

2) Verwendung von mitkodierten Sequenznummern

- nur bei einer Nachrichtenfolge zwischen 2 Prozessen möglich

3) Mitverschlüsseln der Absendezeit

- Empfänger akzeptiert Nachricht nur, wenn seine Zeit max. Δt abweicht
  - globaler Zeitservice bzw. gut synchronisierte Uhren nötig
  - Angreifer darf Zeitservice nicht manipulieren können
- Zeitfenster Δt geschickt wählen
  - Nachrichtenlaufzeiten berücksichtigen
  - *zu gross* → unsicher durch mögliche Replays
  - *zu klein* → falscher Alarm

Schlüsselvergabe als Service (public key)

- Zur Erzeugung und Verwaltung von Schlüsseln existiert typischerweise ein eigener Dienst (mit Schlüsselserver)
- Zum Bsp. Vergabe eines Paares von public / secret keys:

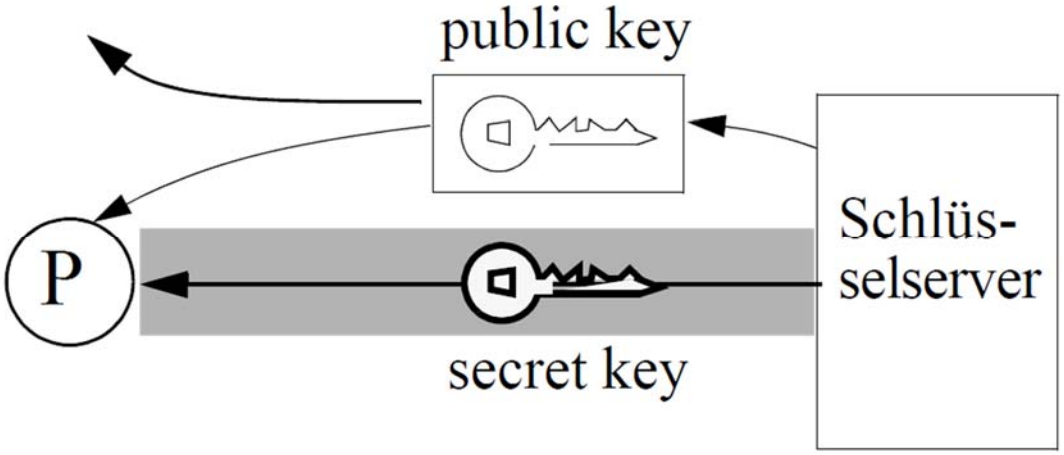

  - Secret key muss auf sicherem Kanal zu P gelangen
  - Public key von P kann an beliebige Prozesse offen verteilt werden (jedoch i.Allg. "zertifiziert", dass der Schlüssel authentisch ist, d.h. digitale Signatur durch den authentifizierten Schlüsselserver)

Schlüsselvergabe als Service (session key)

- Zur Generierung von temporären symmetrischen Schlüsseln ("session key"):

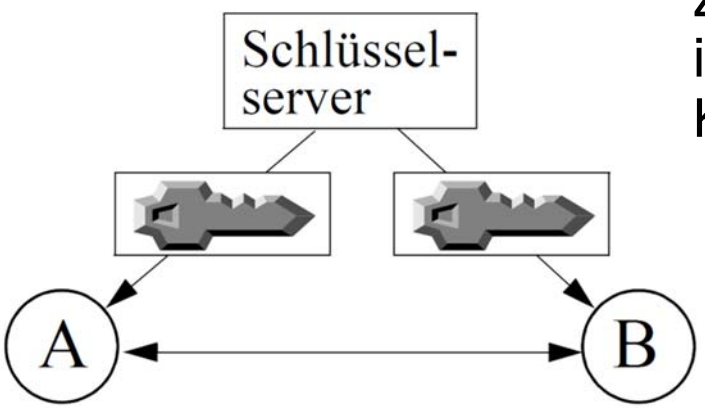

Z.B. bittet A den Schlüsselserver, sowohl ihm als auch B einen session key für die Kommunikation zwischen ihnen zu schicken

Session keys werden sicher und authentisch, z.B. mit einem Public-Key-Verfahren, an die Kommunikationspartner übertragen

- Schlüsselserver kann session key nach Übertragung bei sich löschen
- Aufwändige Public-Key-Methode nur ein einziges Mal pro "Session", tatsächliche Nachrichtenverschlüsselung auf dem Kanal zwischen A und B dann effizient mit symmetrischem Verfahren

Direkte Schlüsselvereinbarung?

- Problem: A und B wollen sich ohne Schlüsselserver über einen unsicheren Kanal auf einen (geheimen) gemeinsamen Schlüssel einigen

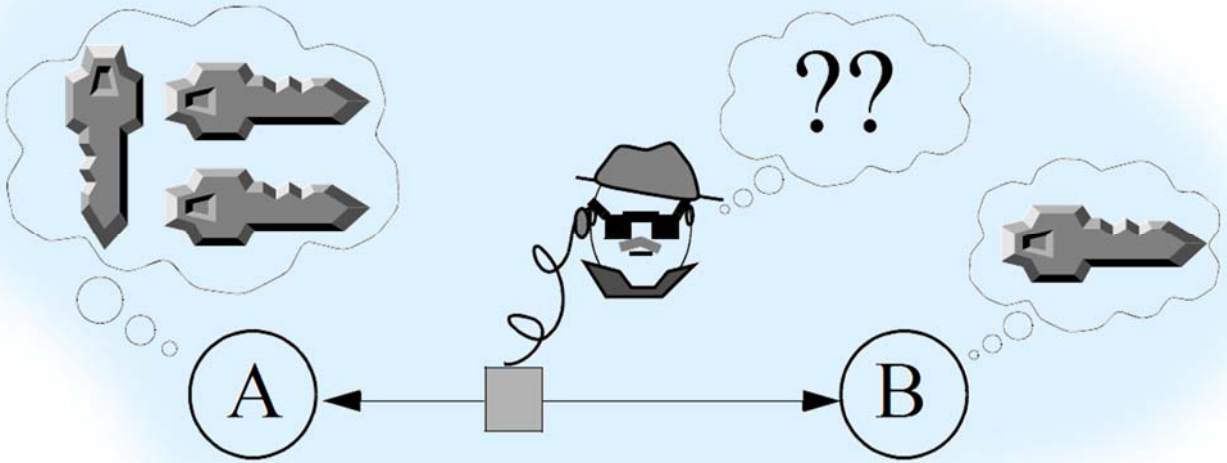

- Sinnvoll z.B. bei dynamisch gegründeten Prozessen, die vorher noch nie kommuniziert haben
  - z.B. wenn keine public keys vorhanden bzw. nicht bekannt
- Wie geht dies?
  - wir erinnern uns an die "Schatzkiste mit zwei Vorhängeschlössern"

Direkte Schlüsselvereinbarung?

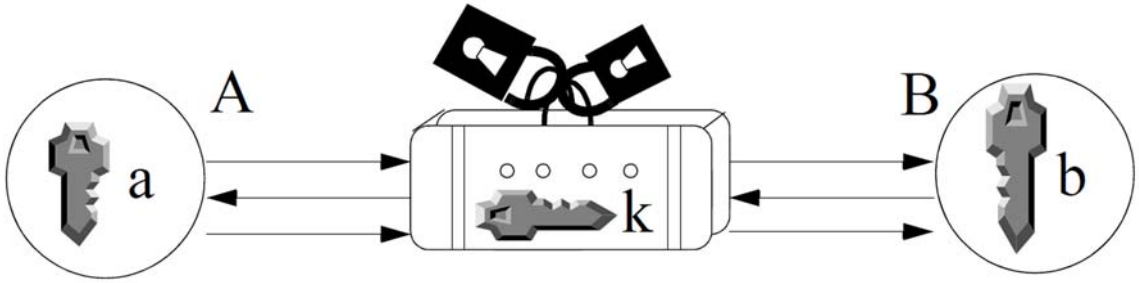

1. A generiert einen Sitzungsschlüssel k
2. A verschlüsselt k mit einem geheimen Schlüssel a
3. A→B: $\{k\}_a$
4. B verschlüsselt dies mit seinem Schlüssel b
5. B→A: $\{\{k\}_a\}_b$
6. A entschlüsselt mit seinem Schlüssel a:
   $\{\{\{k\}_a\}_b\}_{\bar{a}} = \{\{\{k\}_a\}_{\bar{a}}\}_b = \{k\}_b$
7. A→B: $\{k\}_b$
8. B entschlüsselt mit seinem Schlüssel: $\{\{k\}_b\}_{\bar{b}} = k$

a und b sind "lokal erfunden"

Forderung!

Bezeichne $\bar{x}$ den zu x inversen Schlüssel (oft: $\bar{x} = x$)

gemeinsames Geheimnis

Beachte: k wird nie offen transportiert!

Frage: Geht hier xor mit "one-time pads" a, b ?

- xor erfüllt die Forderung (ist assoziativ und kommutativ)
- xor mit one-time pads ist sicher (wirklich?) und effizient

- Aber: Wenn Schritt 3 $\{k\}_a$ und Schritt 5 $\{\{k\}_a\}_b$) abgehört wird, dann kann daraus der Schlüssel b ermittelt werden, so dass in Schritt 7 aus dem abgehörten $\{k\}_b$ das geheime k ermittelt werden kann!

- Geht anstelle von xor etwas anderes, das sicher ist?
  → Idee des Diffie-Hellman-Verfahrens

Diffie-Hellman-Verfahren

- Hier als Gleichnis in Form von Farbenmischen
- Ziel: A und B sollen sich über einen unsicheren Kanal auf ein gemeinsames "Geheimnis" (hier: eine Farbe) einigen, ohne dass ein Angreifer es erfährt
  - Auch wenn der Angreifer aus den beiden übermittelten Farben eine Probe mischt?

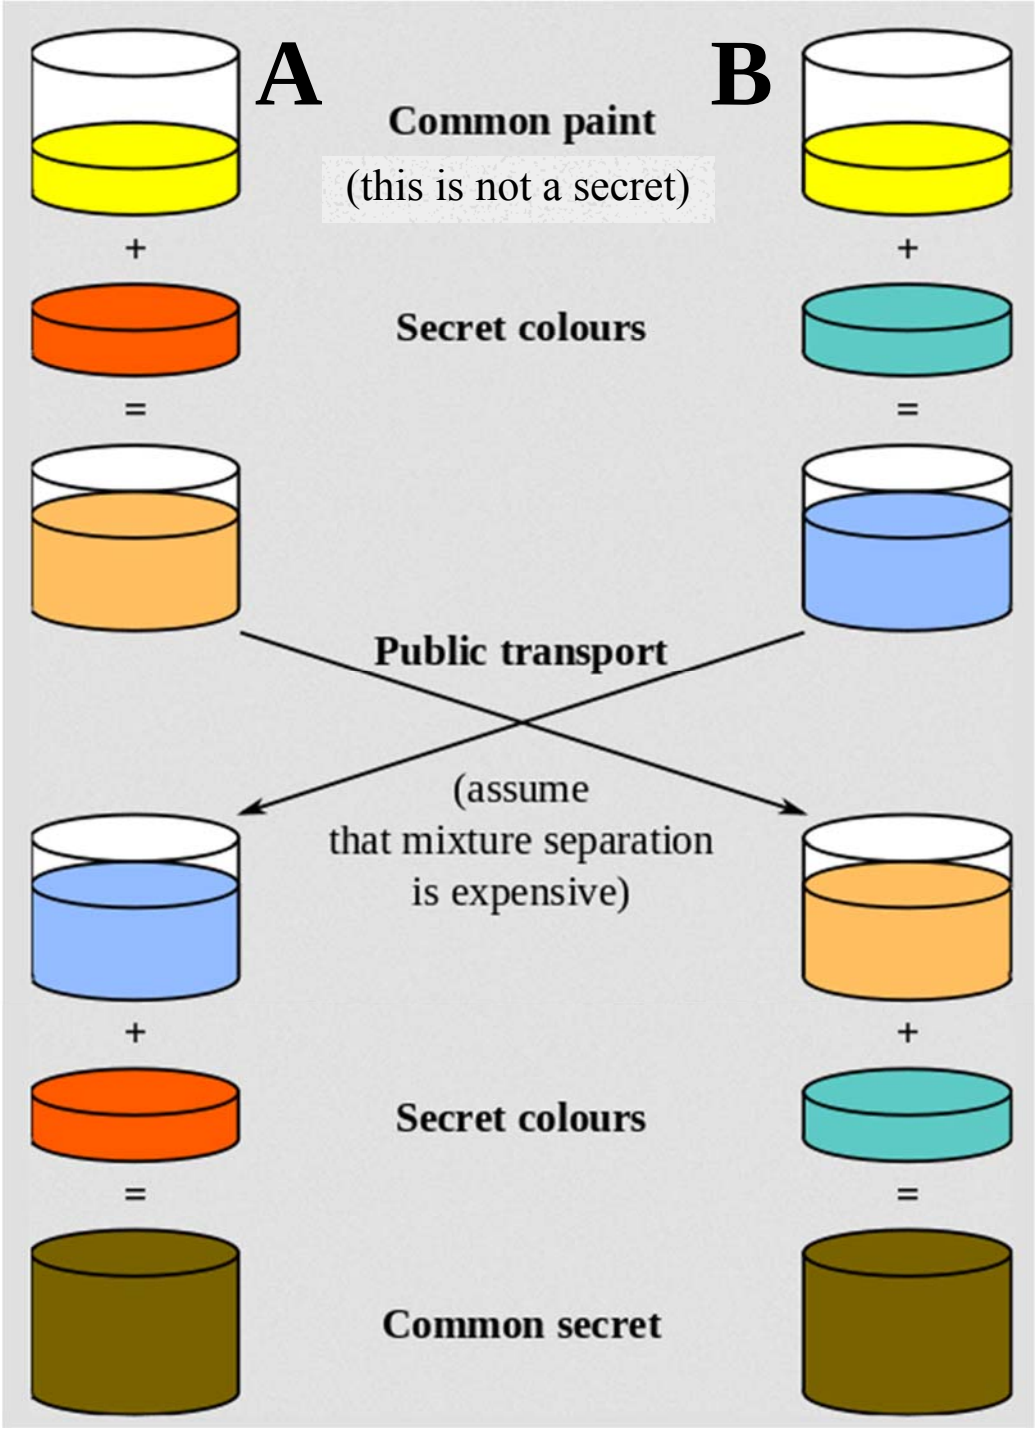

Bildquelle: Wikipedia

Schlüsselvereinbarung mit dem Diffie-Hellman-Verfahren

- Ziel: A und B sollen sich über einen unsicheren Kanal auf ein gemeinsames "Geheimnis" G einigen, ohne dass ein Angreifer es erfährt

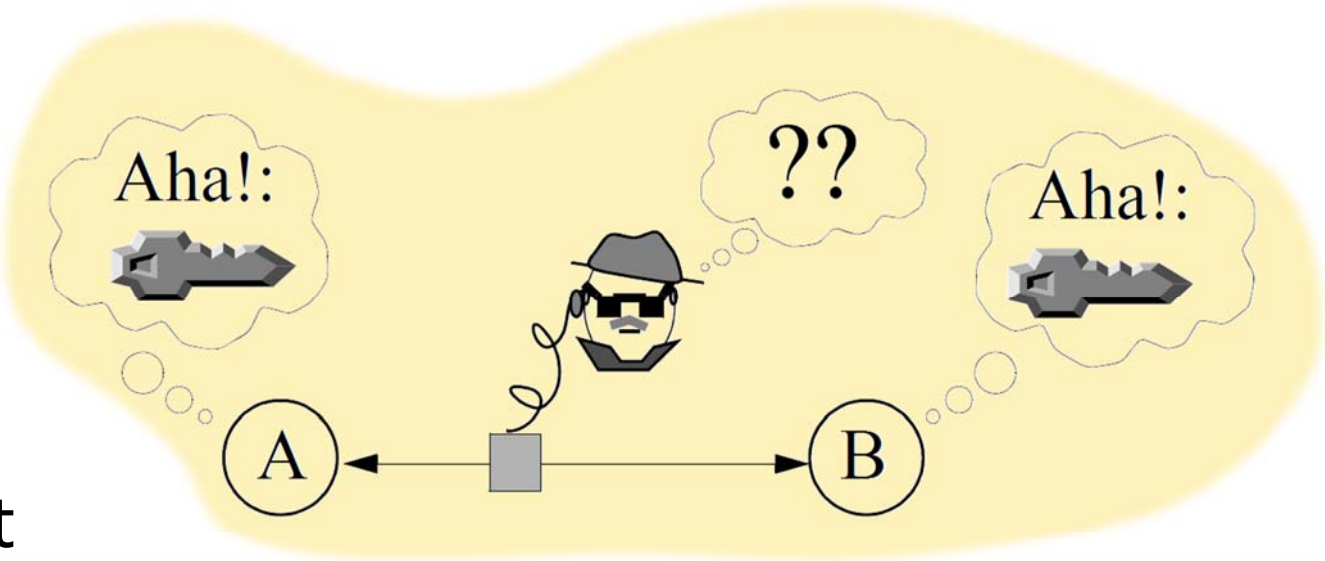

- Nutzung einer Einwegfunktion: $f(x) = c^x \bmod p$
  (1 < c < p; wobei p eine grosse Primzahl ist)
  - in einem Restklassenring ist die Bestimmung diskreter Logarithmen (als Umkehrfunktion) viel schwieriger als die Bildung von Potenzen

Der Diffie-Hellman-Algorithmus

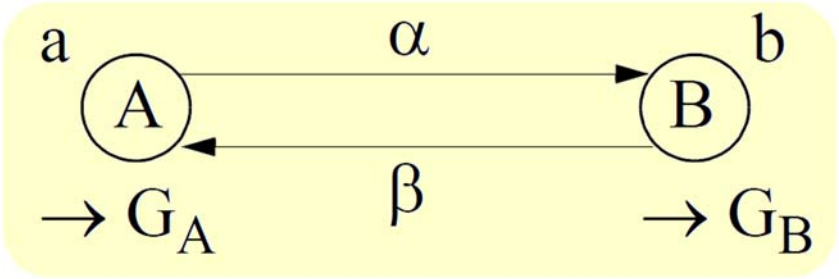

1. A wählt eine Zufallszahl a
2. A berechnet $\alpha = f(a)$
3. A → B: α

---

4. B wählt eine Zufallszahl b
5. B berechnet $\beta = f(b)$
6. B → A: β

---

7. A berechnet $G_A = \beta^a \bmod p$
8. B berechnet $G_B = \alpha^b \bmod p$

- wenig Nachrichten
- effizient

Bem.: a und b sind nur lokal bekannt und bleiben geheim

Behauptung: $G_A = G_B$
(gemeinsames Geheimnis!)

Beispiel (für c = 5 und unrealistisch kleines p = 7):

$f(x) = 5^x \bmod 7$
$a = 3 \rightarrow \alpha = 6$
$b = 4 \rightarrow \beta = 2$
$\rightarrow G_B = 6^4 \bmod 7 = 1$
$\rightarrow G_A = 2^3 \bmod 7 = 1$

$G_A = G_B$

Zu zeigen: $\beta^a \bmod p = \alpha^b \bmod p$, also:

$$(c^b \bmod p)^a \bmod p = (c^a \bmod p)^b \bmod p$$

$f(x) = c^x \bmod p$

$\beta = c^b \bmod p$

$\alpha = c^a \bmod p$

Lemma: $(k \bmod p)^n \bmod p = k^n \bmod p$ ← Restklassen-arithmetik...

$$\begin{aligned}
(c^b \bmod p)^a \bmod p &= (c^b)^a \bmod p \quad \text{[Lemma]} \\
&= c^{(b\,a)} \bmod p \\
&= c^{(a\,b)} \bmod p \\
&= (c^a)^b \bmod p \quad \text{[Lemma]} \\
&= (c^a \bmod p)^b \bmod p
\end{aligned}$$

Bemerkungen:

- Lässt sich auch auf $k > 2$ Benutzer verallgemeinern
- Der Algorithmus (entdeckt 1976) wurde 1977 patentiert

United States Patent [19]

Hellman et al.

[11] **4,200,770**

[45] **Apr. 29, 1980**

[54] CRYPTOGRAPHIC APPARATUS AND METHOD

[75] Inventors: **Martin E. Hellman**, Stanford; **Bailey W. Diffie**, Berkeley; **Ralph C. Merkle**, Palo Alto, all of Calif.

[73] Assignee: **Stanford University**, Palo Alto, Calif.

[21] Appl. No.: **830,754**

[22] Filed: **Sep. 6, 1977**

[51] **Int. Cl.**[2] **H04L 9/04**

[52] **U.S. Cl.** ..... **178/22**; 340/149 R; 375/2; 455/26

[58] **Field of Search** ..... 178/22; 340/149 R

[56] **References Cited**

PUBLICATIONS

"New Directions in Cryptography", Diffie et al., *IEEE Transactions on Information Theory*, vol. IT-22, No. 6, Nov. 1976.

Diffie & Hellman, Multi-User Cryptographic Techniques", *AFIPS Conference Proceedings*, vol. 45, pp. 109–112, Jun. 8, 1976.

Primary Examiner—Howard A. Birmiel

Attorney, Agent, or Firm—Flehr, Hohbach, Test

[57] **ABSTRACT**

A cryptographic system transmits a computationally secure cryptogram over an insecure communication channel without prearrangement of a cipher key. A secure cipher key is generated by the conversers from transformations of exchanged transformed signals. The conversers each possess a secret signal and exchange an initial transformation of the secret signal with the other converser. The received transformation of the other converser's secret signal is again transformed with the receiving converser's secret signal to generate a secure cipher key. The transformations use non-secret operations that are easily performed but extremely difficult to invert. It is infeasible for an eavesdropper to invert the initial transformation to obtain either conversers' secret signal, or duplicate the latter transformation to obtain the secure cipher key.

8 Claims, 6 Drawing Figures

US4218582: Public key cryptographic apparatus and method

Issued/Filed Dates: Aug. 19, 1980 / Oct. 6, 1977

Abstract:
A cryptographic system transmits a computationally secure cryptogram that is generated from a publicly known transformation of the message sent by the transmitter; the cryptogram is again transformed by the authorized receiver using a secret reciprocal transformation to reproduce the message sent. The authorized receiver's transformation is known only by the authorized receiver and is used to generate the transmitter's transformation that is made publicly known. The publicly known transformation uses operations that are easily performed but extremely difficult to invert. It is infeasible for an unauthorized receiver to invert the publicly known transformation or duplicate the authorized receiver's secret transformation to obtain the message sent.

What is claimed is:
1. In a method of communicating securely over an insecure communication channel of the type which communicates a message from a transmitter to a receiver, the improvement characterized by: providing random numbers at the receiver; generating from said random numbers a public enciphering key at the receiver; generating from said random numbers a secret deciphering key at the receiver such that the secret deciphering key is directly related to and computationally infeasible to generate from the public enciphering key; communicating the public enciphering key from the receiver to the transmitter; processing the message and the public enciphering key at the transmitter and generating an enciphered message by an enciphering transformation, such that the enciphering transformation is easy to effect but computationally infeasible to invert without the secret deciphering key; transmitting the enciphered message from the transmitter to the receiver; and processing the enciphered message and the secret deciphering key at the receiver to transform the enciphered message with the secret deciphering key to generate the message.
2. ...

Sweet Little Secret G

- A und B könnten $G = G_A = G_B$ nun als symmetrischen Schlüssel zur Kodierung ihrer Nachrichten verwenden
  - Besser: G nur als „master key“ verwenden, um daraus (mittels Einwegfunktion) einen session key zu erzeugen
  - Motivation: G selbst so selten wie möglich benutzen
- Einzusehen bliebe noch, dass aus Kenntnis von α und β (sowie von c und p aus f) G von einem Mitlauscher (in effizienter Weise) nicht ermittelt werden kann
  - α und β sind unabhängig voneinander (wieso ist das ein Argument?)
  - Bem.: nicht jedes p ist „gut“ und sollte auch einige 100 Bit lang sein

How the NSA Can Break Trillions of Encrypted Web and VPN Connections
Ars Technica (Oct 15, 2015), Dan Goodin

Researchers at the universities of Michigan and Pennsylvania warn a serious flaw in the way the Diffie-Hellman cryptographic key exchange is implemented is allowing the U.S. National Security Agency (NSA) to break and eavesdrop on trillions of encrypted connections. For commonly used 1024-bit keys, it would take about a year and millions of dollars to crack just one of the extremely large prime numbers that form the starting point of a Diffie-Hellman negotiation. However, the researchers found only a few primes are commonly used, putting the price well within NSA's $11-billion annual budget for "groundbreaking cryptanalytic capabilities." "Breaking a single, common 1024-bit prime would allow NSA to passively decrypt connections to two-thirds of VPNs and a quarter of all SSH servers globally. Breaking a second 1024-bit prime would allow passive eavesdropping on connections to nearly 20% of the top million HTTPS websites. In other words, a one-time investment in massive computation would make it possible to eavesdrop on trillions of encrypted connections," say researchers J. Alex Halderman and Nadia Heninger. "While the documents make it clear that NSA uses other attack techniques, like software and hardware 'implants' to break crypto on specific targets, these don't explain the ability to passively eavesdrop on virtual private network traffic at a large scale." In addition, they say the technique makes it possible for other countries, including adversaries of the U.S., to decrypt communications on a massive scale.

http://arstechnica.co.uk/security/2015/10/how-the-nsa-can-break-trillions-of-encrypted-web-and-vpn-connections/

Ist das Diffie-Hellman-Prinzip gefeit gegen einen Eindringling?

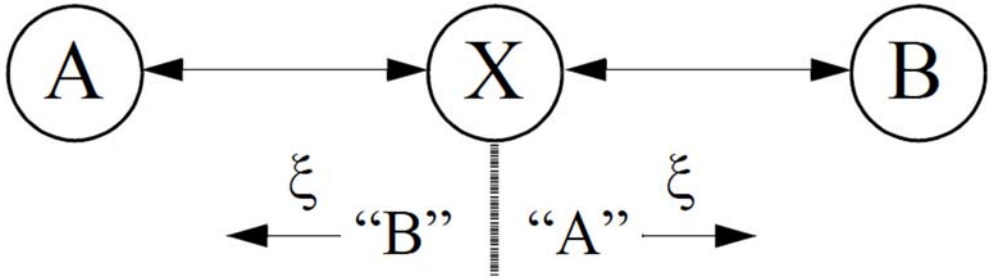

- X ist ein sogen. „man in the middle"
  - mimt die Identität des jeweils anderen
- X kann unter Vortäuschung falscher Identitäten jeweils eigene Schlüssel für Teilstrecke AX bzw. XB vereinbaren!
  - „ein ξ für ein α bzw. β vormachen"

Aktive Angriffe: Man in the Middle

- Ein generelles Problem: X verhält sich gegenüber A wie B, gegenüber B wie A (→ X arbeitet "transparent")
  - z.B. eigene Schlüssel für die Teilstrecken vereinbaren

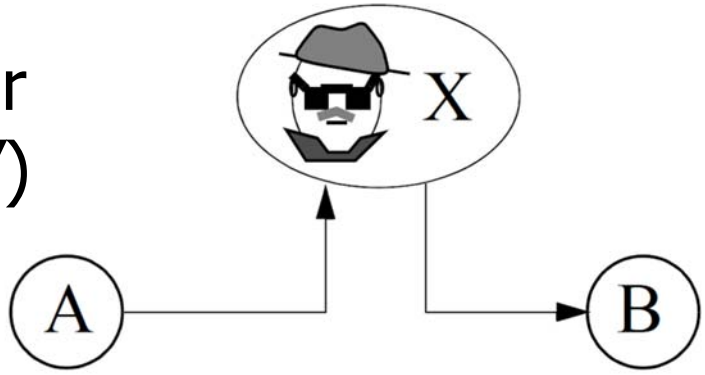

- Challenge-Response-Test nützt so nichts: X reicht Challenges einfach an den von ihm vorgetäuschten Partner weiter und mimt mit der abgefangenen Antwort die angenommene Identität

Aktive Angriffe: Schlüssel-fälschung beim Key-Server

- Kompromittierter Key-Server bzw. Verschwörung von X, X'
- X kann alle von A mit dem falschen Schlüssel verschlüsselten Nachrichten an B entziffern
  - X verschlüsselt danach die Nachricht neu mit dem richtigen Schlüssel für B

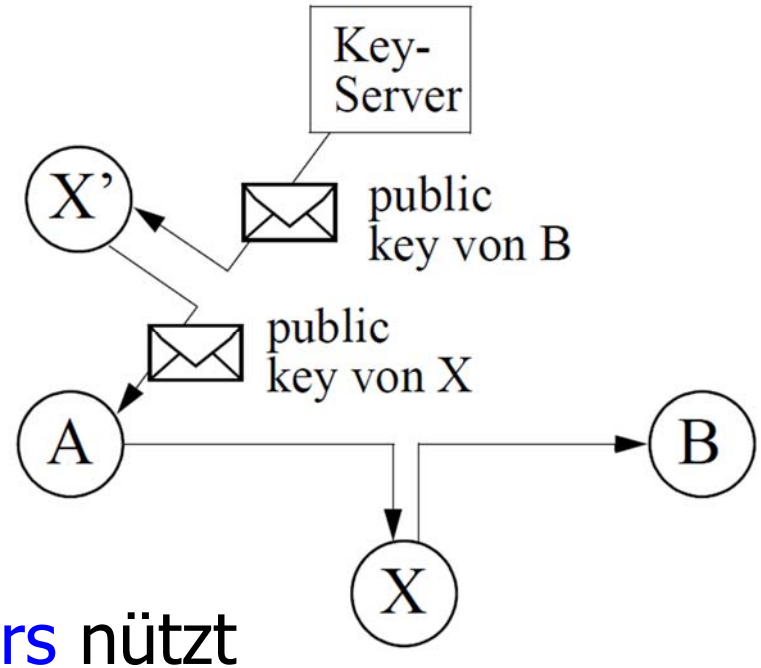

- Digitale Unterschrift des Key-Servers nützt nichts, wenn A den Prozess X' für den Key-Server hält und dessen Unterschrift akzeptiert

---

- Ist es überhaupt möglich, X in diesen Szenarien zu erkennen?
- Nützt die allgemeine Bekanntgabe des public keys des Key-Servers?

Erkennen von Eindringlingen?

Hier: Das sogen. „interlock protocol“

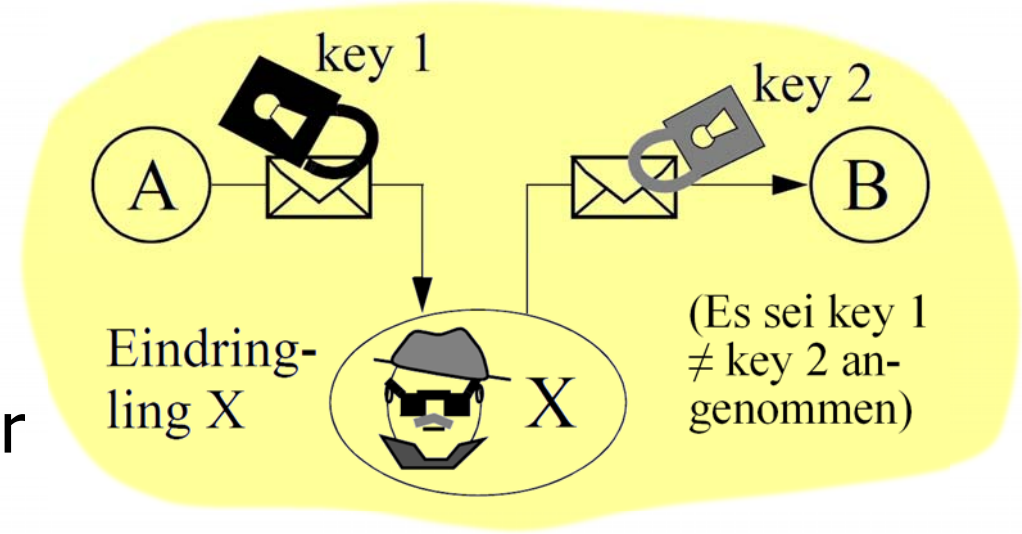

1) B stellt eine Anfrage, die nur A beantworten kann
2) A generiert die Antwort und verschlüsselt diese
3) A sendet zunächst aber nur die “Hälfte” davon zurück
   - z.B. nur jedes zweite Bit (also die “geraden” Bits)
   - B erwartet diese Hälfte der Antwort in weniger als t Zeiteinheiten
4) Ohne die andere Hälfte kann X dies nicht entschlüsseln und neu (mit key 2) verschlüsseln
5) Erst nach t Zeiteinheiten sendet A die andere Hälfte
   - B setzt Schlüsseltexthälften zusammen und überprüft Antwort

Das Dilemma des Eindringlings

- Gibt X die halbe Nachricht sofort unverändert weiter, kann B das Ganze nicht entschlüsseln → Fälschung erkannt
- Behält X die halbe Nachricht bis zum Eintreffen der anderen Hälfte, um alles zu entschlüsseln und neu mit key 2 zu verschlüsseln (und verzögert dann die Hälfte der ungeraden Bits um t Zeiteinheiten), dann arbeitet X nicht mehr zeittransparent → Eindringling vermutet

---

- Fragen: Wird in (in Schritt 1) nicht schon ein gemeinsames Geheimnis vorausgesetzt?
- Können (im Kontext des Diffie-Hellman-Verfahrens) A und B nicht dieses benutzen, um einen von X nicht ermittelbaren gemeinsamen Schlüssel zu finden? Oder genügt in 1) eine schwächere Eigenschaft ("originelle" Antwort; Fähigkeit, die nur A hat...)?

Zertifikate im gläsernen Tresor?

- Anschauen: ja
- Stehlen oder kopieren: nein

Authentifizierung mit geheimen Zertifikaten?

- A lässt sich von einer Autorität ein Zertifikat Z_A geben
  - Z_A soll von der Autorität (z.B. digital) signiert sein
  - Autorität gilt als vertrauenswürdig und hat A evtl. persönlich in Augenschein genommen (oder einem fremden Zertifikat vertraut)
- Wenn B an der Identität von A zweifelt, wird B von A auf sein Zertifikat Z_A hingewiesen
  - Besitz des Zertifikates = Authentifizierung
- Aber: A darf Z_A nie vorzeigen – sonst könnte B es sich kopieren und sich fortan als A ausgeben!
  - „Dokumente" (Bitfolgen) der digitalen Welt lassen sich perfekt kopieren
  - wie vermeidet man daher "raubkopierte Zertifikate"?
- Offenbar muss Z_A ein Geheimnis bleiben, das niemand ausser der Autorität und A kennt!
- Taugt ein solches Geheimnis als Zertifikat??
  - wie beweist man den Besitz eines Zertifikates, ohne es zu zeigen?

Geheime Zertifikate?

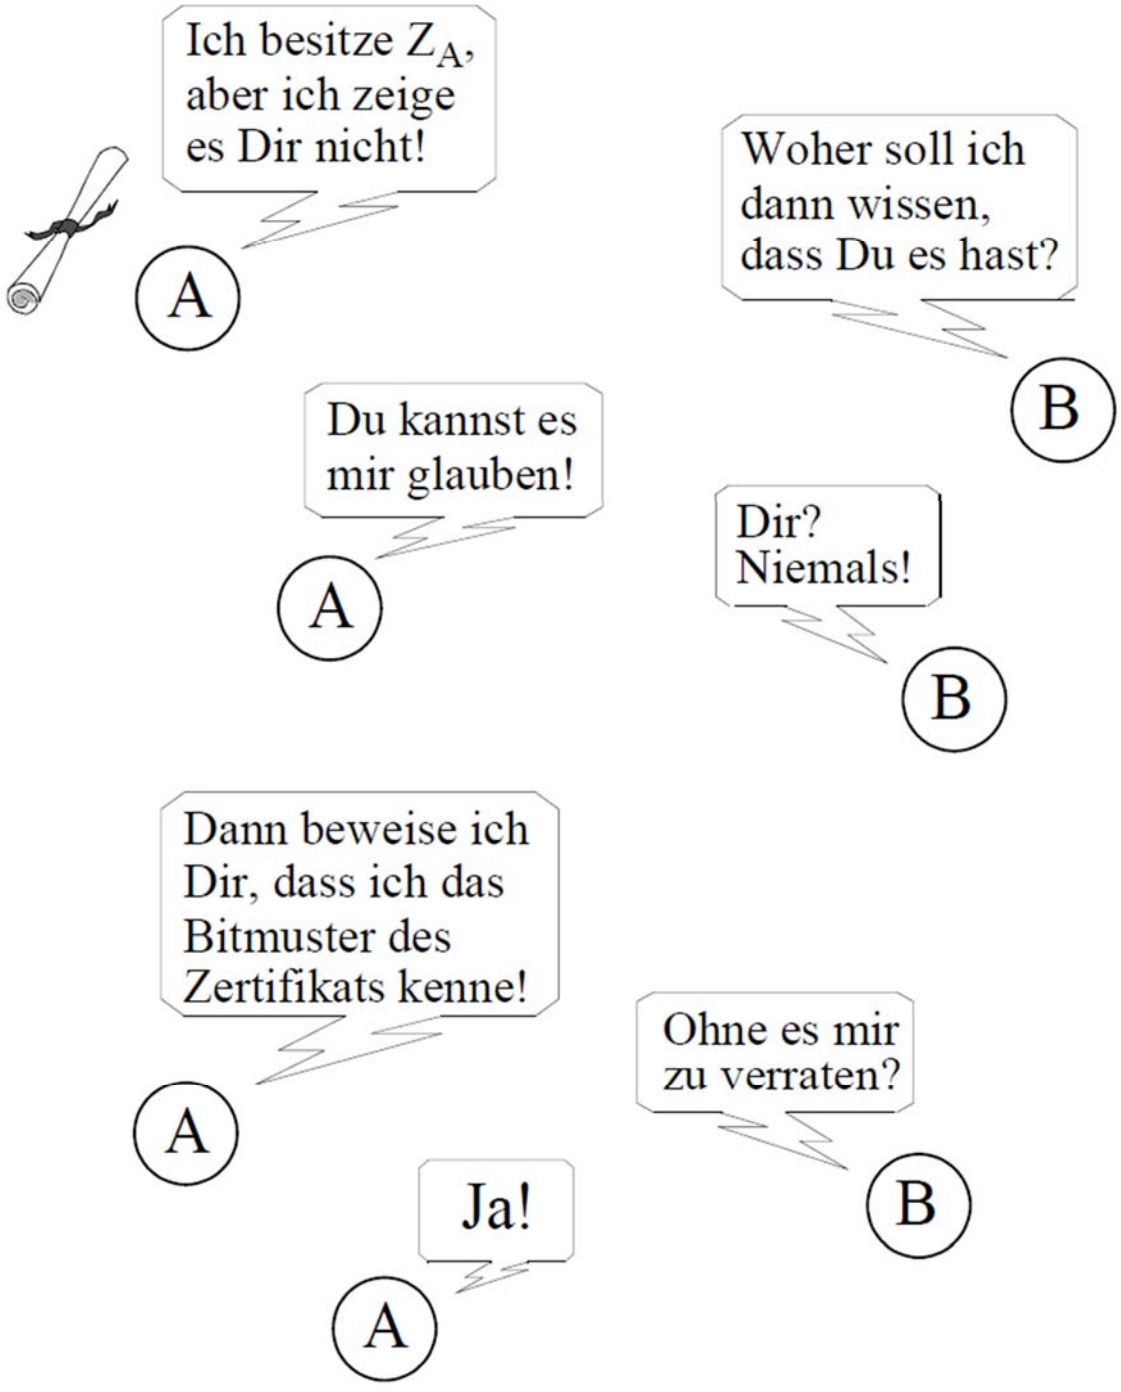

Nachweisen ohne vorzuweisen?

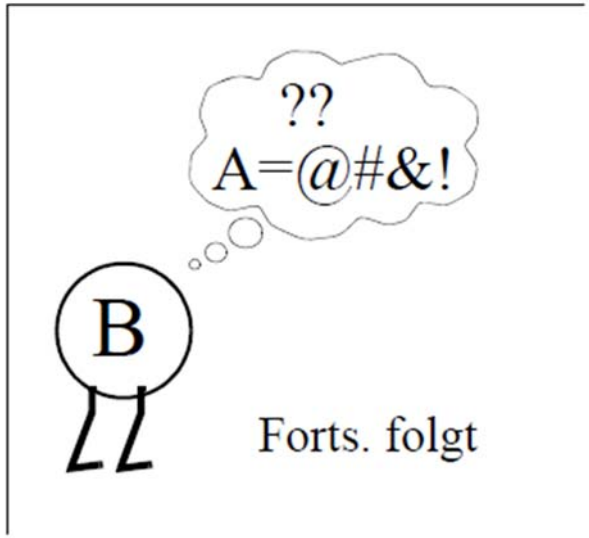

Geheime Zertifikate!

- Im Prinzip wissen wir schon, dass das geht:
  Der secret key sA eines asymmetrischen
  Verfahrens stellt ein solches Zertifikat dar
  - braucht von A nicht verraten zu werden
  - B kann dennoch überprüfen, ob A das Zertifikat hat (z.B. indem sich B von A etwas mit sA verschlüsseln lässt und anschliessend durch Anwenden von pA prüft; bzw. indem B eine Challenge $\{n\}_{pA}$ an A schickt und sich dies von A mit sA entschlüsseln lässt)
- Eine andere Realisierung geht mit "zero knowledge proof"
  - beweist Kenntnis eines Geheimnisses G, ohne relevante Information preiszugeben

Ein Höhlengleichnis

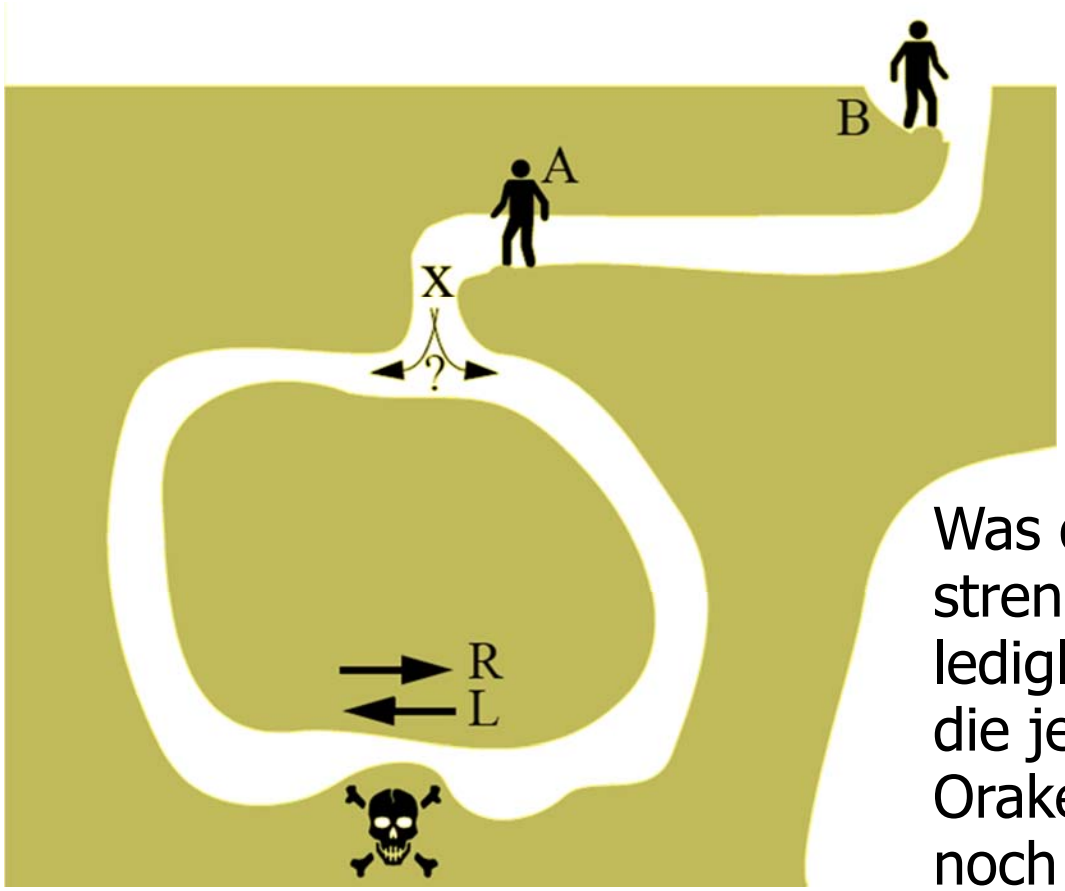

Der Höhlendämon lässt nur diejenigen die Engstelle lebendig passieren, die dort in der richtigen Richtung (L oder R) vorbeigehen.

Was die richtige Richtung ist, ist ein streng gehütetes Geheimnis; es ist lediglich bekannt, dass der Dämon die jeweilige Entscheidung einer Orakelbox entnimmt, die bisher noch niemand öffnen konnte.

- A sagt zu B: "Ich kenne das Geheimnis. Das beweise ich Dir, ohne das Geheimnis zu verraten!"

Ein Höhlengleichnis

- A sagt zu B: "Ich kenne das Geheimnis. Das beweise ich Dir, ohne das Geheimnis zu verraten!"
- A begibt sich in die Höhle bis zur Engstelle; erst danach folgt B bis zur Stelle x
  - B weiss nicht, welche Richtung A bei x einschlug
- B (an der Stelle x) ruft A *entweder*
  - "komm links heraus!" *oder*
  - "komm rechts heraus!" zu
- A tut dies, indem A evtl. die Engstelle (in der richtigen Richtung) passiert
- A und B verlassen zusammen die Höhle
- Nachdem A das ganze n Mal überlebt hat, ist B überzeugt, dass A das Geheimnis (= Funktion der Orakelbox) kennt!

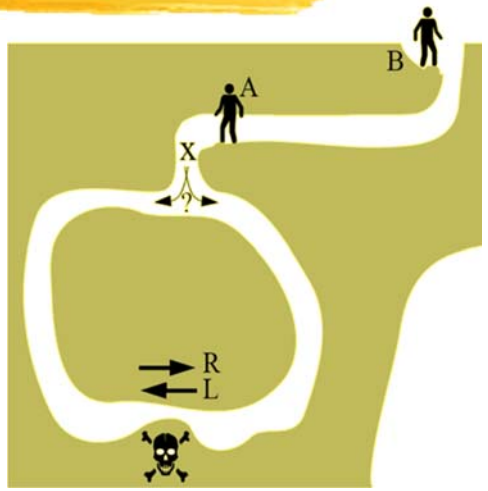

Die Irrtumswahrscheinlichkeit nimmt exponentiell ab

B hat in diesem "interaktiven Beweis" das Geheimnis nicht erfahren!
→ "Zero knowledge proof"

Zero-Knowledge-Beweis

- "Beweis" = Nachweis, dass P eine bestimmte Bitfolge (= Zahl, Algorithmus, Zertifikat,...) höchstwahrscheinlich kennt

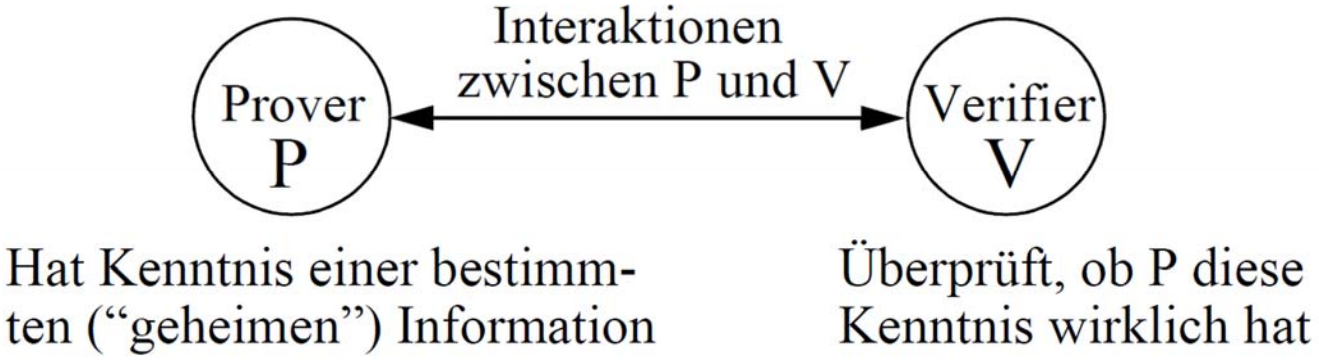

- P soll V (praktisch) nicht betrügen können: Wenn P die Information nicht hat, sollen seine Chancen, V zu überzeugen, verschwindend gering sein
  - V soll über die eigentliche Kenntnis von P nichts erfahren
  - V erfährt auch sonst nichts Relevantes von P, was V nicht auch alleine in Erfahrung bringen könnte

Zero-Knowledge-Beweis

- Idee: geheime Information =
  Lösung eines schwierigen Problems X

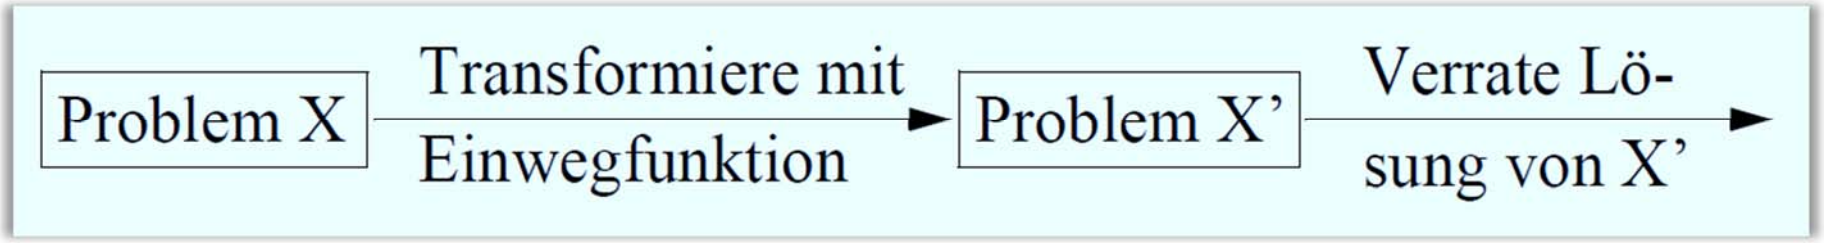

- Wobei die Lösung von X' die Lösung von X logisch impliziert, sie jedoch nicht effektiv-konstruktiv liefert
  - X' spielt quasi die Rolle eines vertrauenswürdigen Zeugen

Beispiel (für Zero-Knowledge): Isomorphie von Graphen

Bemerkung: Ob zwei grosse (z.B. in Form von Adjazenz-matrizen) gegebene Graphen G_1, G_2 topologisch isomorph ($G_1 \sim G_2$) sind (d.h. bis auf Umbenennung von Knoten und evtl. Kanten identisch sind), ist ein schwieriges Problem

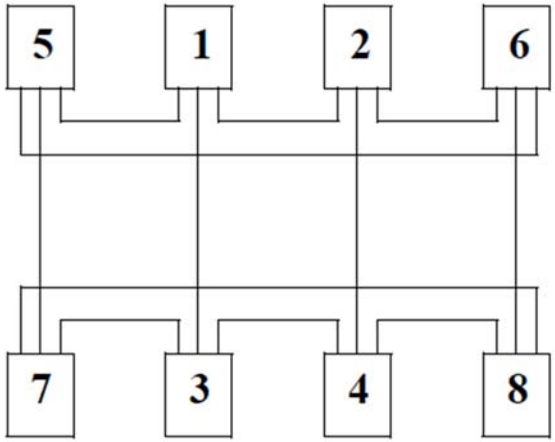

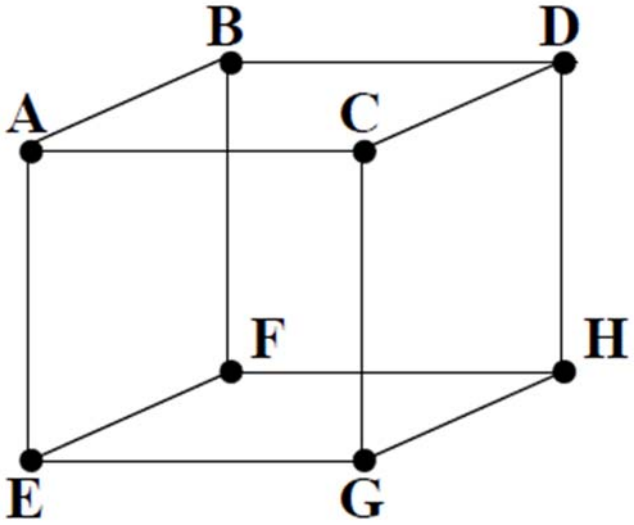

A = 7
B = 5
C = 8
D = 6
E = 3
F = 1
G = 4
H = 2

Hier nur ein kleines und daher einfaches (also unrealistisches) Beispiel

Überprüfung eines (durch eine Knotenzuordnung gegebenen) Isomorphismus ist allerdings "einfach"!

Isomorphie von Graphen

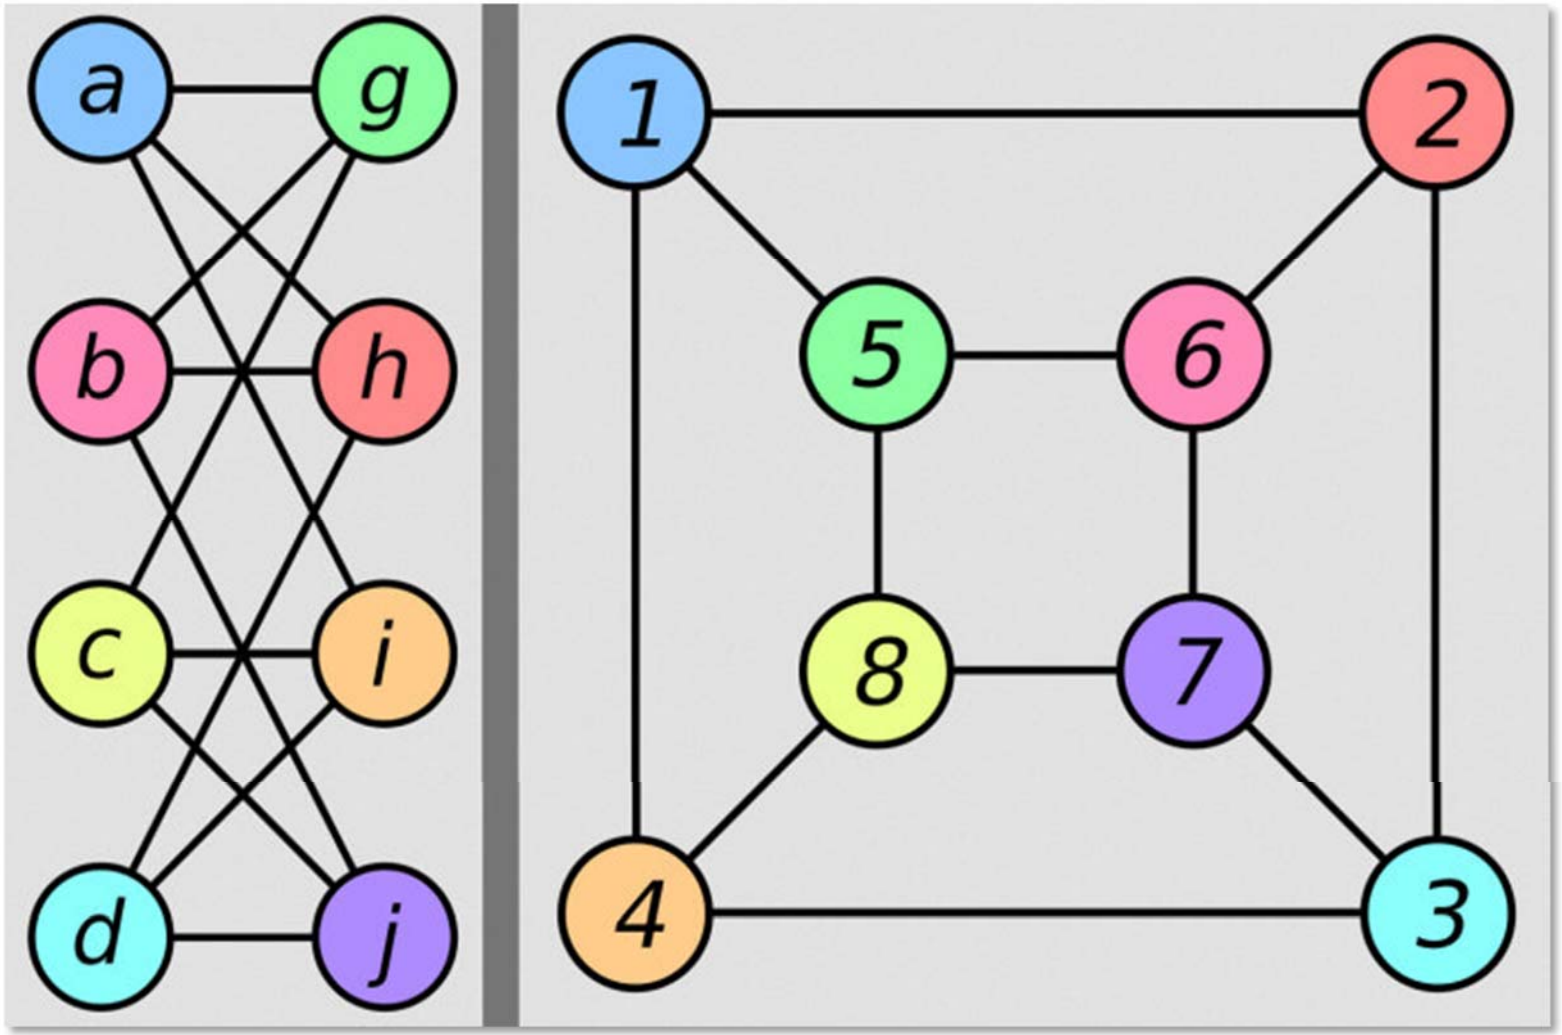

Das gleiche nochmal in bunt

Zero-Knowledge bei Graphisomorphie

- P behauptet, einen Beweis zu haben, dass zwei gegebene Graphen G_1, G_2 isomorph sind, möchte den Beweis aber nicht verraten
  - weil Kenntnis der Isomorphie seinen „Identitätsausweis“ darstellt

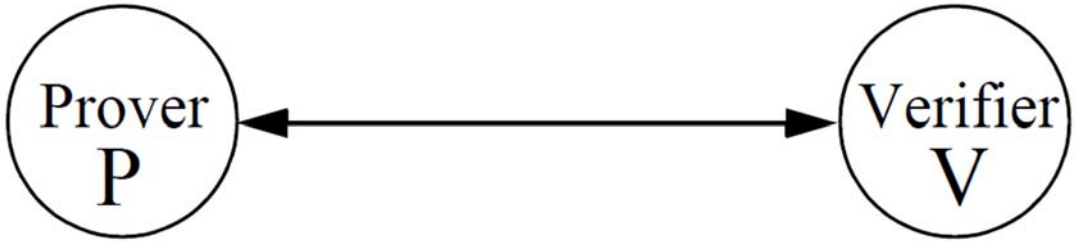

- Folgendes Protokoll überzeugt V davon, wobei der Isomorphismus selbst ein Geheimnis von P bleibt →

Zero-Knowledge bei Graphisomorphie

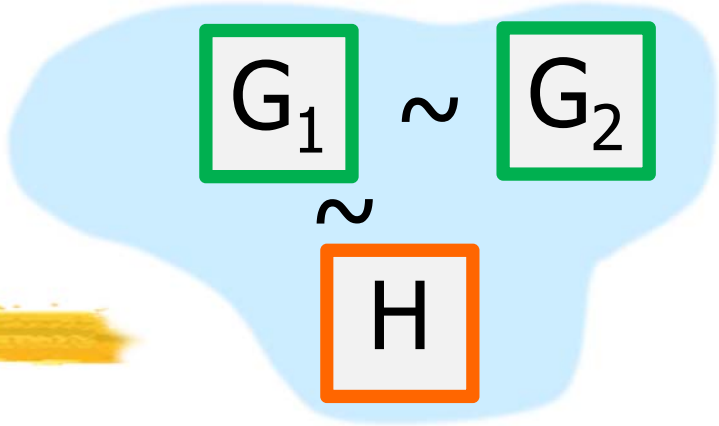

- P erzeugt durch zufällige Umbenennung der Knoten einen Graphen H mit $H \sim G_1$ (und damit $H \sim G_2$)
  - für P ist dies einfach
- P sendet H an V
- V bittet dann P, entweder $H \sim G_1$ nachzuweisen, oder $H \sim G_2$
- Da P den Graphen H konstruiert hat, kann P das Gewünschte einfach tun
  - für Andere aber ist $H \sim G_1$ und $H \sim G_2$ genauso schwierig wie $G_1 \sim G_2$
  - P hütet sich allerdings davor, auch noch die andere, von V nicht gewünschte, Alternative nachzuweisen – wieso?
- V kann den gelieferten Isomorphiebeweis einfach verifizieren

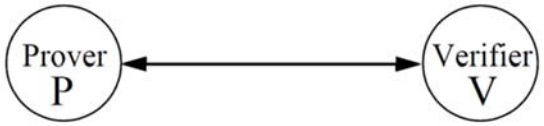

Unvorher-sehbar für P

P und V wiederholen alles n Mal, wobei von P jedes Mal ein anderer "Zeuge" H konstruiert wird
→ Beweissicherheit = $1-2^{-n}$

Zero-Knowledge bei Graphisomorphie – Eigenschaften

- Falls P lügt, also keinen Isomorphismus zwischen G_1 und G_2 kennt, kann P (effektiv) keinen Graphen H konstruieren, der nachweislich isomorph zu *beiden* ist
  - verschiedene H_1, H_2 zu finden mit $H_1 \sim G_1$ und $H_2 \sim G_2$ ist einfach; mit 50% Wahrscheinlichkeit wird P so allerdings der Lüge überführt!
- V lernt nichts über die Isomorphie $G_1 \sim G_2$
  - glaubt aber schliesslich, dass P eine solche kennt

- Zur Minimierung der Interaktionen lassen sich die "Runden" parallelisieren: P sendet mehrere "isomorphe Zeugen" an V, und V sendet einen Bitvektor zurück, der die Einzelnachweise auswählt

Zero-Knowledge bei Graphisomorphie – Eigenschaften

- V kann einem Dritten W gegenüber nicht beweisen, dass P den Isomorphismus kennt: Selbst ein exaktes Protokoll der Kommunikationsvorgänge muss W nicht überzeugen: P und V könnten sich verschworen haben!
- Da V nichts Relevantes gelernt hat, kann V sich anderen gegenüber auch nicht mit der Kenntnis schmücken
  - sich also nicht für P ausgeben (Kenntnis ist Identitätsausweis von P)

- Grosse Graphen sind in der Praxis etwas unhandlich; es gibt praktischere Ausprägungen des Zero-Knowledge-Verfahrens, z.B. das Protokoll von Fiat und Shamir; dieses beruht auf der Schwierigkeit, die k-te Wurzel in einem Restklassenring zu berechnen

Verteilte Systeme

Friedemann Mattern

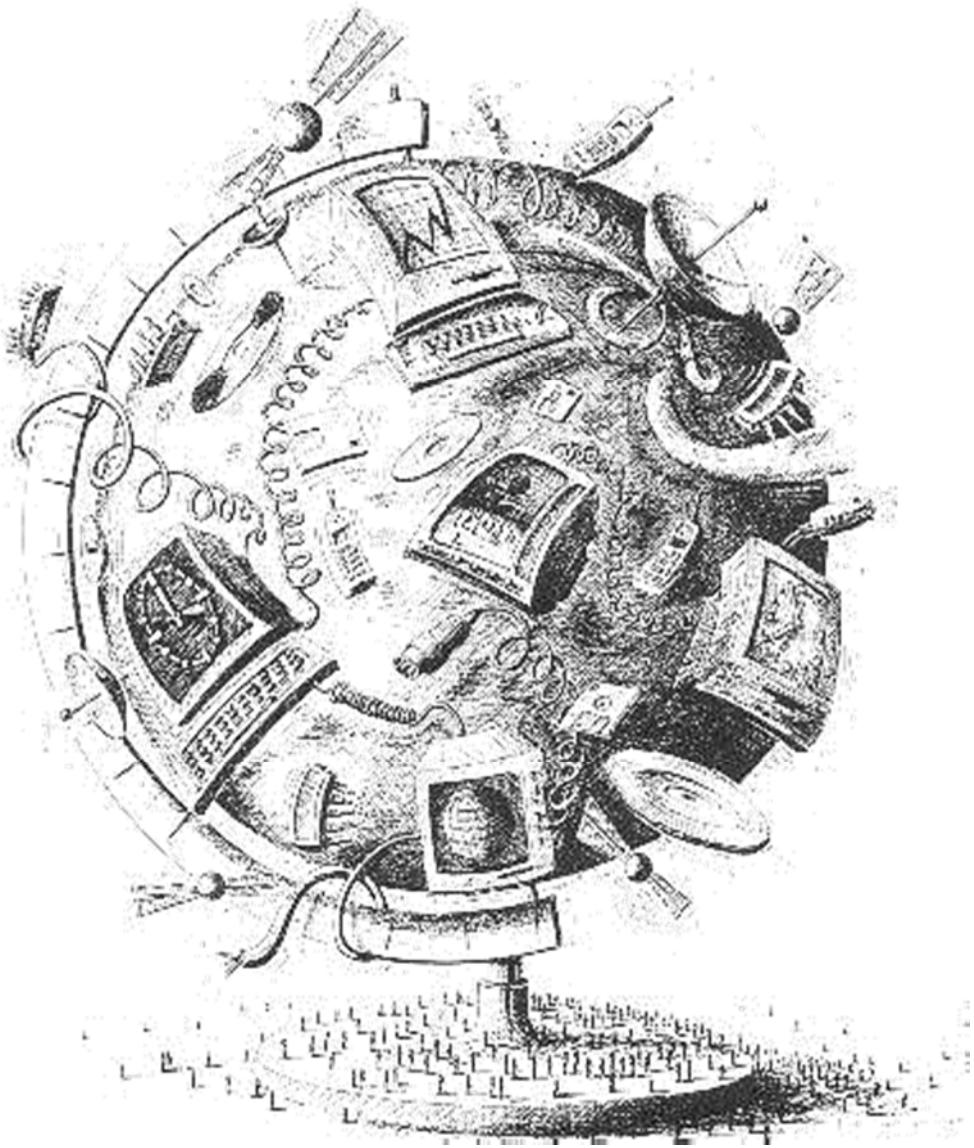

Prüfungsrelevant ist der Inhalt der Vorlesung, nicht alleine der Text dieser Foliensammlung!

ETH zürich