Willkommen bei Verteilte Systeme!

Von Datenbanken
über Webdienste
bis zu p2p und Sensornetzen.

Heute: **Einführung und Überblick**

> *A distributed system is a system that prevents you from doing any work, when a computer you have never heard about fails.*

Materialien

- Distributed Systems
  - Martin van Steen and Tanenbaum (2017)
  - kostenloses ebook: https://www.distributed-systems.net
  - ISBN-13: 978-1543057386
- Distributed Systems - An Algorithmic Approach – Sukumar Ghosh (2015).

Folien u.ä.

- Weitere Quellen werden bei Verwendung aufgeführt.
- Folien: https://www.draketo.de/software/vorlesung-verteilte-systeme
- Glossar zu Netztechnik: https://www.draketo.de/software/vorlesung-netztechnik#glossar-netztechnik
- Gemeinsamer Glossar und Notizen in einem cryptpad.

Zur Vorbereitung: Drucken Sie bitte die Version mit vielen Folien pro Seite für schnelle Notizen.

Dozent

Arne Babenhauserheide

- Physik (Dipl., Dr., CO_2
- Seit 2004 p2p Netze
- Seit 2017 Softwareentwickler als Beruf
- Python, Scheme, HTML/CSS, Java, JS/TS, Fortran, Bash, Emacs, Ruby, ...
- arne_bab@web.de

Vorlesung bis 2020 gemeinsam mit Carlo Götz.

Arbeitsstelle

- Disy Informationssysteme GmbH in KA
- Datenanalyse, Reporting, Geoinformation und Geo-Analytics
- ~ 200 MA, Gründung 1997 (ich bin seit 2017 dabei)

https://www.disy.net

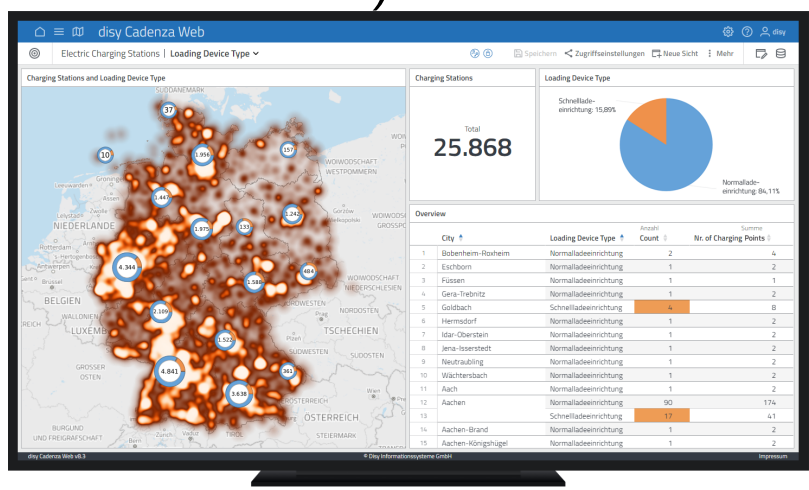

Arbeitshintergrund

Tech hinter Cadenza

- Java 24 (mit Spring und Ignite)
- Web-Tech (Web-Components, JS/TS)
- Verschiedene Datenbanken
- 3 mio LOC

Organisation

- ~80% in Karlsruhe, weitere international verteilt.
- N-Wochen Sprints, viel Home-Office ⇒ Zoom, Rocket Chat
- Tools: Linux, Mac, Windows, IntelliJ, VS Code, Emacs, ...
- Infrastruktur: CI mit Jenkins und Gitlab, Kubernetes-Cluster
- Trunk-based development mit slbs gegen Merge-Konflikte

Sie

- Motivation für das Studium?
- Vorwissen zu verteilten Systemen?
- Erinnerung an Netztechnik?

Ziele der Vorlesung

- Sie verstehen, wo sie Verteilung vermeiden sollten.
- Sie verstehen, was sie beachten müssen, wenn Sie verteilen.
- Sie kennen Werkzeuge und Techniken, die ihnen helfen.
  - Sie können einschätzen, welche Garantien sie wirklich brauchen.
- Sie können einschätzen, welche **Kompromisse** sie eingehen sollten und welche nicht.
  - Latenz $<$ 300ms für eine Webseite
  - Latenz $<$ 30ms für Interaktive Systeme!
- Das passiert Ihnen nicht:
  https://www.ccc.de/de/updates/2022/web-patrouille-ccc

Erwartungen

Meine Wünsche

Ich will, dass Sie gerne kommen.
Es ist Arbeit, und Arbeit sollte Spaß machen.
Ich will, dass Sie Verständnis von Verteilten Systemen mitnehmen.

Ihre Wünsche

- Projekt Erfolgreich abschließen
-
-
-

Im Cryptpad / auf Tafel sammeln.

Fragen

- Verteilung der Slides?
- Mail der Kurssprecher(in)?

Ablauf Semester

0. Grundlagen
1. p2p (peer-to-peer)
2. Clocks/Zeit, usw.
3. Algorithmen, Shared State
4. Datenbanken konkret: CAP, DBs
5. Sicherheit in der Praxis, Sensornetze
6. Präsentationen der Studierenden, 15min pro 3er-Gruppe
7. tbd, Wiederholung

Präsentationen

- Wählen Sie ein Thema
- Themenvorschlag per E-Mail
  - gerne auch eigene
  - sehr gerne mit Vorwissen / Hobby
  - bis zur dritten VL

Themenideen

- FOSDEM Vorträge
- Verblindung in GNU Taler
- Wifi and LoRa mit Reticulum
- libresilient (p2p web fallback)
- Distributed Game Architecture
- Virtualization & Containerization
- Load Balancing + Autoscaling
- Verschlüsselung in Signal
- Botnet(-s)
- Message Queues: Rabbit, Kafka, ZeroMQ, ...
- Seti@home / Folding@Home
- telnet
- IRC
- ssh
- OAuth
- Ein eigenes Projekt
- Papers we love
- OWASP Top 10

Projekte 2021

- All Chats Are Beautiful
- Distributed Key/Value Store
- FreeChat
- HTTP-Tunneling
- IPC in Interpreter
- Kooperative WLED-Steuerung
- Load Balancer
- p2p Chat in Minecraft
- p2p iOS Kommunikation (Local Pal)
- Risiko Multiplayer
- Schiffe versenken
- Snake Multiplayer (Butchered Snake)
- Statuspage (openmonitor)
- Vier gewinnt
- Vollständig dezentralisierte MessageQueue
- WebChat

Projekte 2022

- Berechnung auf mehreren Servern
- Botnetz mit CnC
- Chat mit 2 Servern
- Chat mit Python
- ESP32-Chat Captive Portal
- Game Of Life verteilt
- Gruppenchat in Java
- Gruppenchat mit Javascript
- IoT im Heimnetz
- Kommunikation zwischen Spieleservern
- MQTT Broker
- Multithreading in Spice
- Nerdlegame als 1vs1
- Online TicTacToe
- Online-Spiel in GoDot
- P2P-Chat mit Directory-Server
- RPi Captive Portal
- Schiffeversenken 1vs1
- P2P Voice Chat über UDP
- Teilen von Trainingsplänen
- VS Chat in Java
- Viewer-Room

Projekte 2023

- Kaesekaestchen
- BlackJack
- ChannelMaster
- DistributedKeyValueStore
- distripool
- Password Encryption App
- Sonoff Basic R2 Webservice
- ChatABC
- MapReduce on Steroids
- Der Pizzabesteller
- dezentraler Chat
- SmartDown
- eins-chat
- peer gewinnt
- MileStarter
- DontGetAngry

Projekte 2024

- PrivateCA
- bilder malen und verschicken
- Nudge
- MonteCarloPi
- Paradocs
- Schaltsimulation
- Ambi Mesh
- Suntimer
- ChatApp
- Schachspiel
- Schiffeversenken
- JWT Chat
- Chat in Python
- Konsolenbasierter Gruppenchat in Java
- Verteilte 3DS-ButtonBox
- Dokument-Kollaborationsanwendung
- Taskify

Projekte 2025

- Task Manager
- Online 4-gewinnt
- SSL Chat Projekt
- Musik Synchronisation
- Kollaboratives Whiteboard
- Ich packe meinen Koffer
- lightweight Load Balancer
- Multiplayer Dartscounter
- Tic Tac Toe
- Reversi

- Asynchrone Kommunikation in Microservice Architekturen
- Verteilte Sensorauswertung
- Telefunken
- FileShare
- Verteilte Datenbank
- pushNotification
- QuizTogether
- Werwolf
- YT-Watch-Together
- Hot Potato

Ablauf heute

- Grundlagen und -begriffe verteilter Systeme
- Architekturen verteilter Systeme
- Prozesse und Threads
- Kommunikation

Einführung

- Sie kennen Charakteristiken verteilter Systeme
- Sie kennen Ziele verteilter Systeme
- Sie kennen die Dimensionen und Probleme der Skalierung
- Sie erkennen jede der „Fallacies of distributed systems“
- Sie kennen Arten verteilter Systeme

Was sind verteilte Systeme?

- Was sind für Sie verteilte Systeme?
- Beispiele?

Im Cryptpad / auf Tafel sammeln.

Was sind verteilte Systeme?

> *Ein verteiltes System ist eine Sammlung autonomer Rechenelemente, die den Nutzenden wie ein einzelnes kohärentes System erscheint.*

autonome Rechenelemente Arbeiten voneinander unabhängig, egal ob Soft- oder Hardware, auch **Knoten** genannt

einzelnes kohärentes System Nutzende haben den Eindruck ein einzelnes System zu bedienen (Erfordert Zusammenarbeit der Knoten).

Prozesse? (Abgrenzung)

Bilden mehrere Prozesse auf einem Computer ein verteiltes System?

- Autonome Knoten verfügen über eigenen Zeitbegriff.
- Es gibt keine globale Uhr.
- Probleme bei Synchronisation und Koordination.
- Prozesse auf einem System können sich hardwaregestützt synchronisieren.
  - aber mit Effizienzverlust[1]

[1] Auch low-level → branchless algorithms for koordinationsfreien Code

Sammlung von Knoten: Gruppenzugehörigkeit

- Einstieg ins System
- Darf jeder Knoten beitreten?
- Wie finden sie sich?
- Wie wird sichergestellt, dass nur mit Knoten innerhalb des Systems kommuniziert wird?
- Oft als Overlay Network realisiert.

Overlay Networks

- Meist dicht verbunden
  - Für jedes Knotenpaar existiert ein Pfad zwischen den Knoten
- Zwei Varianten:

strukturierte Overlays Jeder Knoten hat eine definierte Auswahl an Nachbarn mit denen er kommuniziert.

unstrukturierte Overlays Jeder Knoten hat Referenzen zu zufällig ausgewählten anderen Knoten.

Kohärentes, einzelnes System

- Nutzer kann nicht sagen, ob:
  - Berechnungen verteilt stattfinden
  - Daten verteilt gespeichert werden
  - Daten repliziert werden
- „Verteilungstransparenz“
- Problem: Knoten und Verbindungen zwischen Knoten können (und werden) jederzeit ausfallen.
  - Ausfall-Transparenz schwierig bis unmöglich.

Middleware

- Separate Schicht über dem Betriebssystem.
- Von Applikationen verwendete Funktionalität:
  - verteilte Transaktionen
  - Fehler Recovery
  - Authentication & Authorization
  - Kommunikation mit anderen Knoten
  - ...
- Risiko: Effizienzverlust durch zu starke Garantien.

Middleware als Betriebssystem für verteilte Systeme

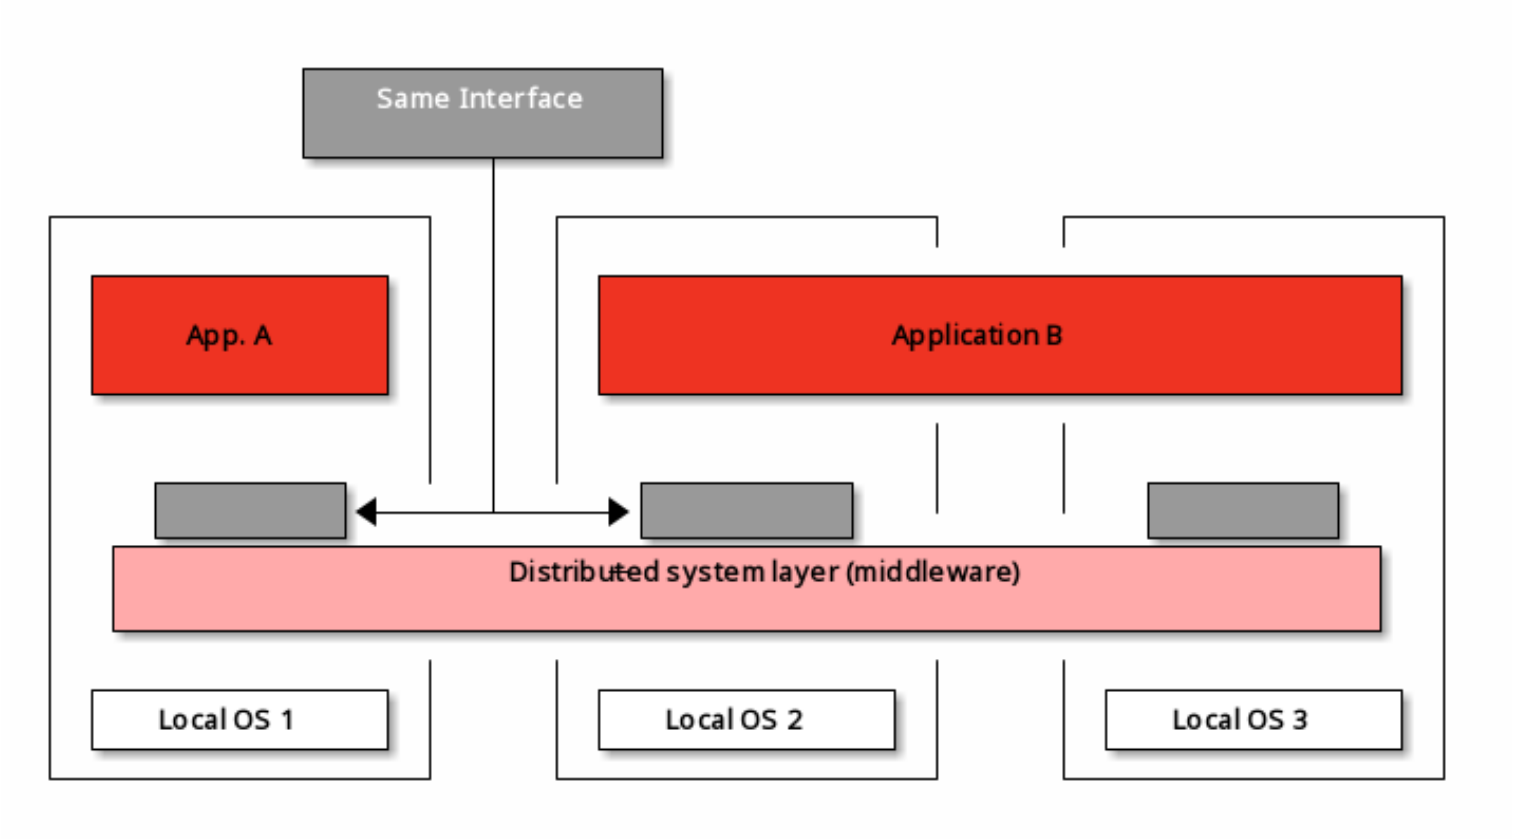

Warum? Ziele verteilter Systeme

Just because it is possible to build a distributed system does not necessarily mean that it is a good idea.

- Teilen von Ressourcen
- Verteilungstransparenz
- Offenheit
- Skalierbarkeit
- Macht minimieren

Teilen von Ressourcen

Auf geteilte Ressourcen zugreifen

- Beispiele:
  - Dropbox, GDrive etc.
  - Google Docs
  - p2p Filesharing (Bittorrent, Blizzard Launcher)
  - p2p Streaming (Spotify anfangs)
  - p2p Accountsuche (Skype anfangs)

Verteilungstransparenz

Nutzenden soll nicht auffallen, dass Berechnungen und Daten über mehrere Computer verteilt sind.

Transparenz	Beschreibung
Zugriff	Verstecke Unterschiede in Datenrepräsentation.
Ort	Nutzer können nicht sagen wo sich ein Objekt physisch befindet
Relokation	Objekte können während ihrer Benutzung den Ort ändern.
Replikation	Verberge, dass ein Objekt repliziert ist.
Concurrency	Verberge gleichzeitige Nutzung eines Objekts.
Fehler	Verstecke Ausfall und Wiederinbetriebnahme von Objekten.

Verteilungstransparenz: Probleme

- Latenz[2]
- Tradeoff: Verteilungstransparenz vs. Performance
- Konsistenz bei Replikation
- komplette Verteilungstransparenz ist unmöglich
  - Verteilung für Entwickelnde explizit? (Abstraktionsbruch; aber Effizienz!)

[2] Vielleicht nur eine langsame Datenbank? Optimieren mit Promises? Beispiel: on-demand overlay

Offenheit

- Verteilte Systeme bieten und verwenden Komponenten, die einfach integriert oder wiederverwendet werden können
- Anforderungen:
  - definierte Schnittstellen (IDL (Syntax) + docs (Semantik))
  - Anwendungen portabel
  - Systeme erweiterbar

IDL: Interface Definition Language.[3]

Wer kontrolliert die API?

[3] Im OS: Hurd translator. Beispiele: `https://git.savannah.gnu.org/cgit/hurd/hurd.git/tree/hurd/msg.defs#n28`

Skalierbarkeit

3 Dimensionen:

- Größe: Nutzer- und Ressourcenanzahl können ohne Performanceprobleme steigen.
- Geographie: Nutzer und Ressourcen können durch große Distanzen getrennt sein, ohne dass Latenz wirklich auffällt.
- Administration: Das System kann unterschiedliche Organisationen umspannen.

log(N) ist gut.

Probleme bei Skalierung

- “There is no free lunch”
- “There is no silver bullet”[4]
- “Law is hard”

[4] Bild: GermanWoodcut1722.

Probleme bei Skalierung der Größe

- Speicherkapazität inkl. I/O Transferrate
- Rechenkapazität, begrenzt durch CPUs
- Netzwerk zwischen Nutzer und System

Probleme bei geographischer Skalierung

- viele bestehende Systeme erwarten schnelle LANs
  - Oft synchrone Kommunikation
  - werden langsam durch erhöhte Latenz[5]

[5] Manchmal sogar mit InfiniBand als Anforderung.

Probleme bei Administrativer Skalierbarkeit

- Unterschiedliche Richtlinien für Verwaltung, Sicherheit etc.
- teilweise politische und soziologische Probleme

DSGVO?

Skalierungstechniken für Anwendungen

vertikale Skalierung mehr CPU, RAM etc. für die Computer (limitiert)

horizontale Skalierung mehr Kapazität durch Hinzufügen neuer Computer

Verstecken von Latenz

- Asynchrone Kommunikation
  - manchmal nicht möglich (Bsp: interaktive Anwendungen)
  - oft komplexere Algorithmen
- Berechnung im Client
  - Bsp: Form-Validierung in JS
  - Konsistenz?
    - Gleicher Code?
    - Gleiche Daten?

Partitionierung, Replikation, Caching

Partitionierung verteile komponenten auf mehrere Maschinen

- Bsp: DNS, DB-Sharding, WWW

Replikation und Caching Kopien auf mehreren Computern

- Bsp: Replizierte DBs, Browsercache, Proxies
- Führt zu Inkonsistenz
- globale Synchronisation ist langsam
- Abhängig von der Anwendung

Fallbeispiel

Um welche Dimension der Skalierung handelt es sich? Welche Skalierungstechnik wird eingesetzt?

- Ziel: Windows Updates gleichzeitig laden
- Problem: Einbruch Netzleistung durch viele Downloads
- Skalieren: Proxyserver, der die Updates einmal von MS lädt
  - Downloads aus dem Firmennetz vom Proxy

Dimensionen: Größe, Geographie, Administration

Techniken: Latenz verbergen, Partitionierung, Replikation

PAUSE

PAUSE

Fallacies of distributed Systems

1. The network is reliable
2. The network is secure
3. The network is homogeneous
4. The topology does not change
5. Latency is zero
6. Bandwidth is infinite
7. Transport cost is zero
8. There is one administrator

Arten verteilter Systeme

- High Performance Distributed Computing (HPC)
- Cloud
- Distributed Information Systems
- Pervasive Systems

HPC: Cluster Computing

- einzelne (rechenintensive) Anwendung wird parallel auf mehreren Computern ausgeführt
- Knoten durch LAN verbunden
- homogen

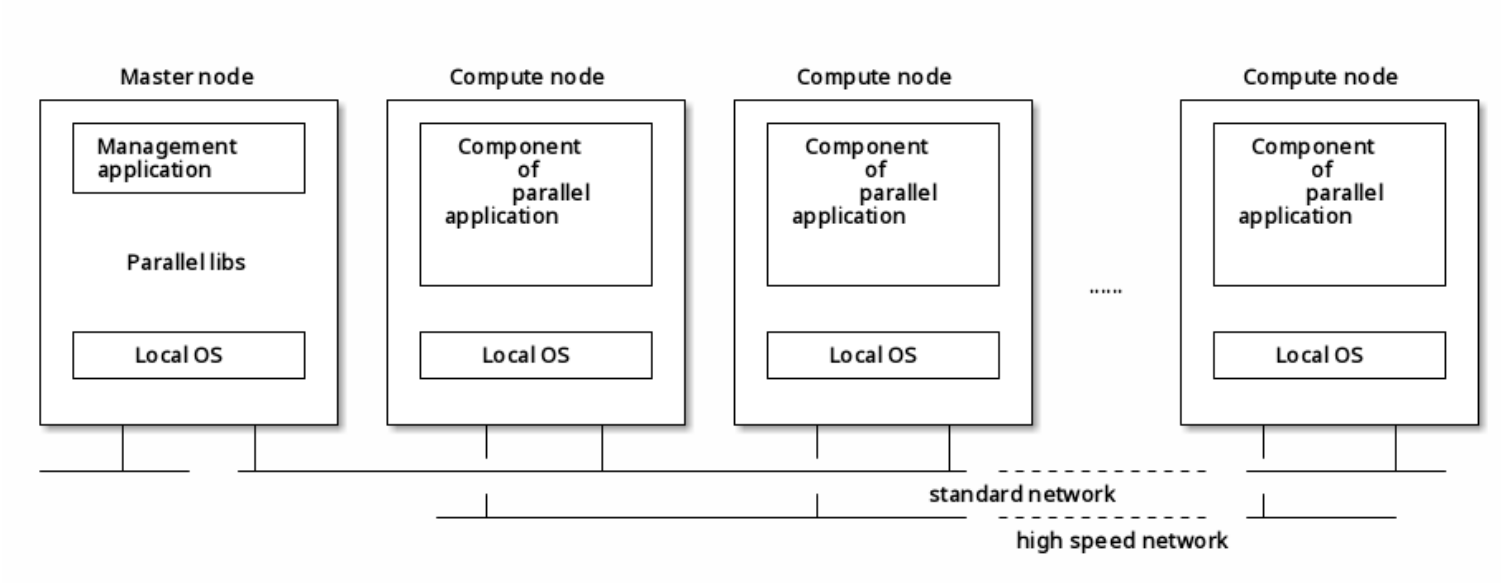

HPC: Grid Computing

- keine Annahmen bzgl. Ähnlichkeit von:
  - Hardware
  - Betriebssystem
  - Netzwerk
  - Sicherheit
  - Administrative Domänen
- Bsp: mehrere Hochschulen schließen ihre Cluster zu einem Grid zusammen.
  - Grid kann von Allen verwendet werden.

Forschung: Probleme wie beim Cluster, aber Grid gibt Förderung.

Cloud Computing

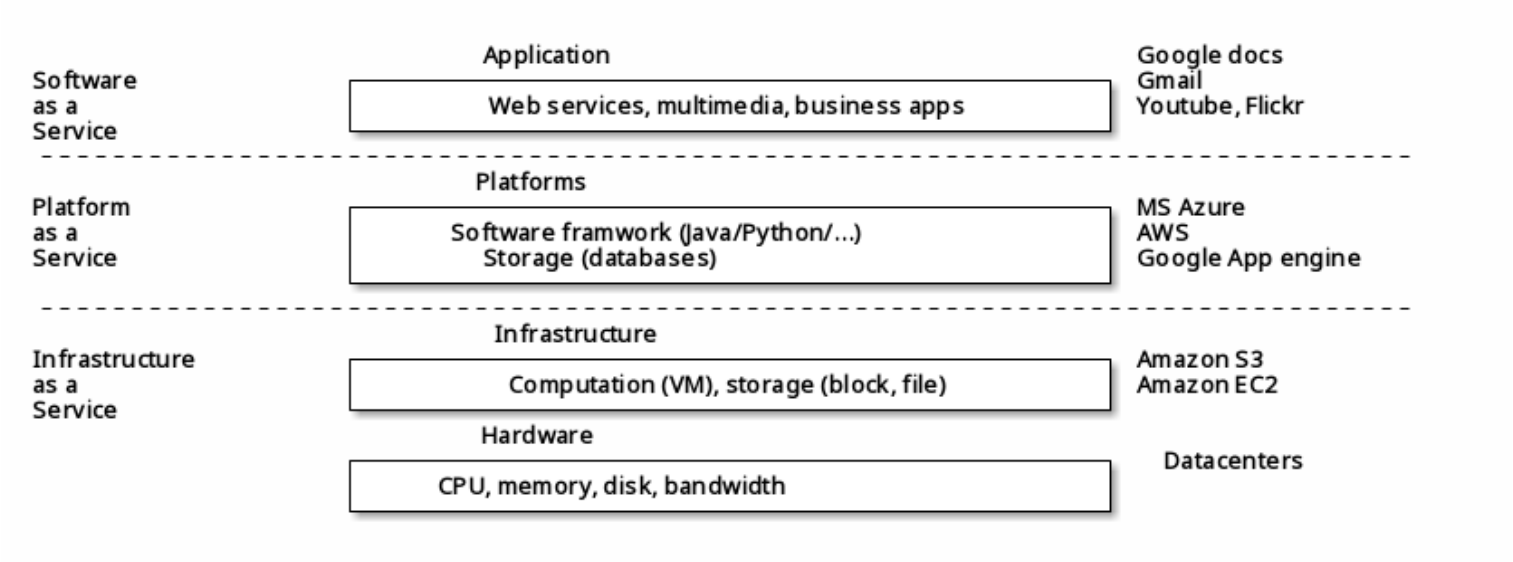

Forschung: Probleme wie beim Grid, aber Cloud gibt Förderung.

Cloud Computing - Schichten

Hardware CPUs, Router, USVs, Kühlung

Infrastruktur verwendet Virtualisierung, um Kunden mit virtuellen Servern und Speichern zu versorgen

Plattform bietet Kunden APIs für Speicher usw. (Amazon S3)

Anwendung Programme für Endanwender (Google Docs)

Cloud Computing - Gefahren

- Vendor Lock-in
- Sicherheit
- Datenschutz

Distributed Information Systems (DIS)

- Einzelne Anwendungen zu einem verteilten System zusammenfassen
- Oft Legacy-Anwendungen.
- Methoden: verteilte Transaktionen, Enterprise Application Integration

Pervasive Systems

Das Netz ist immer dabei.

- Treten durch Mobile und IOT verstärkt auf.
- Wird unterteilt in:
  - Ubiquitous Computing
  - Mobile Computing
  - Sensornetze

Ubiquitous Computing

- Geräte sind vernetzt
- Interaktion mit Benutzer ist kaum merkbar
- System erkennt Nutzerkontext und optimiert Interaktion
- Geräte laufen weitestgehend autonom
- System beherrscht viele Interaktionen
- Wer weiß, was ich mache?

Mobile Computing

- Viele unterschiedliche Geräte: Smartphones etc.
- ständige Änderung des Ortes
- –> keine stabilen Routen, schwankende Geschwindigkeiten, Verbindungsausfall

Sensornetze

- Viele Sensoren (bis zu mehreren Tausend)
- Teilweise Grundlage für ubiquitous computing
- Arbeiten zusammen für effiziente Verarbeitung der Daten
- Meistens drahtlos und batteriebetrieben (leicht aufzusetzen)
- Energieverbrauch und Kommunikation minimieren! WLAN ist hier teuer.

Zusammenfassung

- Verteilte Systeme sind eine Sammlung autonomer Knoten, die als einzelnes kohärentes System erscheinen.
- Verteilte Systeme versuchen zu bieten:
  - Teilen von Ressourcen
  - Verteilungstransparenz
  - Offenheit
  - Skalierbarkeit
- Verteilung hat immer einen Preis

Zusammenfassung 2

- Skalierung in: Größe, Geographie und Administration.
- Techniken: Verstecken von Latenz, Partitionierung, Replikation und Caching.
- 'Fallacies of distributed systems' erkennen!
- Verteilte Systeme: Cluster-, Grid-, Cloud-, Ubiquitous-, Mobile Computing, verteilte Informationssysteme, Sensornetze

Fallacies of distributed Systems

1. The network is reliable
2. The network is secure
3. The network is homogeneous
4. The topology does not change
5. Latency is zero
6. Bandwidth is infinite
7. Transport cost is zero
8. There is one administrator

PAUSE

PAUSE

Fallacies

Um sie zu erkennen.

Fallacies of distributed Systems

Nochmal?? Meinst du das ernst?? ***Ja*** *:-)*

1. The network is reliable
2. The network is secure
3. The network is homogeneous
4. The topology does not change
5. Latency is zero
6. Bandwidth is infinite
7. Transport cost is zero
8. There is one administrator

Transport cost is zero

The two most expensive operations in terms of cost were the orchestration workflow and when data passed between distributed components.

. . .

Moving our service to a monolith reduced our infrastructure cost by over 90%. It also increased our scaling capabilities.

— *Marcin Kolny, 2023, für Amazon Prime Video*

One Administrator

- Wo läuft „das System“ — wer kontrolliert die Rechner?
- Gelten für alle die gleichen Gesetze?
- Welche Regeln gelten für Kommunikation?[6]
- Gibt es mehr als eine Implementierung?
- . . . ?

[6] Kontext: Solving the Moderator’s Trilemma with Federation

Fallacies of Consumer-Level Services

1. The harddisk is reliable
2. Power is constant
3. Your IP is reachable
4. Constant factors are negligible
5. Libraries are stable[7] and API's are maintained
6. Textfiles are simple,
   the protocol is stable, and
   the dataformat is fixed

[7] Volatile Software:
https://stevelosh.com/blog/2012/04/volatile-software/

Architekturen verteilter Systeme

Aus der Vogelperspektive.

Ziele

- Sie kennen verbreitete Architekturstile
- Sie verstehen das Konzept von Overlay-Netzwerke

Merkmale von Architekturstilen

- Verwendete Komponenten und ihre Schnittstellen.
- Verbindung zwischen Komponenten (RPC, Messaging).
- Daten, die zwischen Komponenten ausgetauscht werden.
- Konfiguration der Komponenten zu einem System

Architekturstile

- Layered | Schichten
- Object-based | Objektbasiert
- Resource-centered | Resourcenzentriert | wie REST
- Event-based | Ereignisbasiert

Stile meist kombiniert.

Layered | Schichten

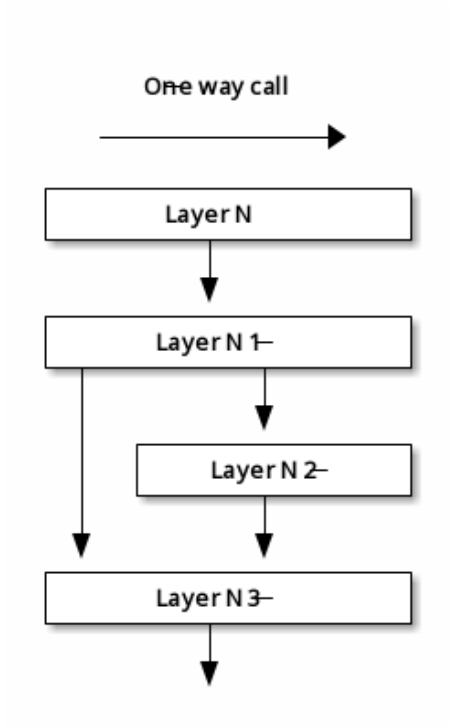

- Calls gehen (meist) nur in eine Richtung
  - Bsp für Ausnahme: Callback in async IO

Dreischicht

- Wird oft verwendet
- Unterteilt in 3 Schichten:
  - Benutzerschnittstelle (GUI oder API)
  - Verarbeitung, enthält die Funktionen einer Anwendung
  - Persistenz, verwaltet die Daten, die von der Verarbeitung verändert werden

Beispiel: Web, Backend, Datenbank.[8]

[8] Disy Cadenza ist (inzwischen) ein klassischer Vertreter. Mit (wenig) Server-side Rendering) für Startzeit.

Object-based | Objektbasiert

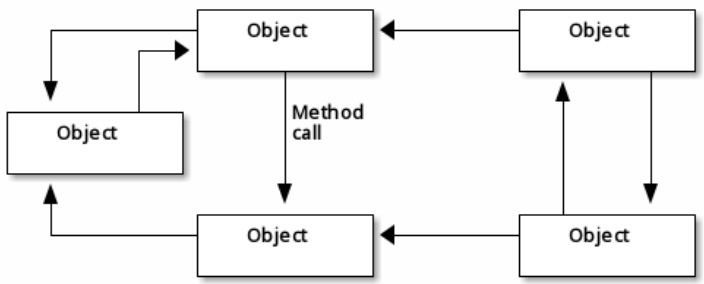

- losere Organisation der Komponenten
- Kommunikation durch z.B. RPC
- Zustand meist in seiner Komponente/Objekt gekapselt
- *Service statt Objekt*: SOA (Service oriented architecture, jetzt „Microservices“)[a]

[a] Capabilities im Netz: https://spritelyproject.org/

Resource-based - an REST orientiert

- Ressourcen über Namen idenitfiziert (URLs bei REST).
- Alle bieten die gleiche Schnittstelle (HTTP Verben bei REST).
- **Alle** benötigten Informationen sind **im Serviceaufruf enthalten** (z.B. als URL-Parameter).
- Nach einem Aufruf vergisst der Service alles über den Aufrufer.

Bsp: REST interface für S3 `PUT`
`http://bucket.s3.amazonaws.com/Key`

Problem: Großer Zustand (z.B. Error 414: Request-URI Too Long — ab 2048 Zeichen in IE11/Edge16, 8k in CDNs)

Event-based | Eventbasiert

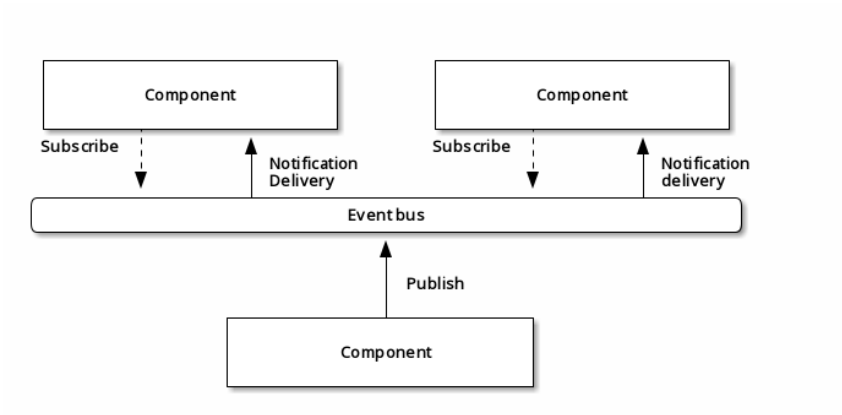

- Komponenten kommunizieren durch Events
- Events durch **Event Bus** propagiert
- Komponenten referentiell entkoppelt ($\Rightarrow$ kein shared memory)
- persistente Speicherung der Events führt zu temporaler Entkoppelung
- Verwandte Events als topic abonnieren

Verschiedene Arten von Koordination

	Temporally coupled	Temporally decoupled
Referentially coupled	Direct	Mailbox
Referentially decoupled	Event-based	Shared data space

- *Shared data space: fancy für „wie eine Datenbank“*
- *Wie unterscheiden sich die Kosten?*

Zentralisierte System-Architekturen

- Prozesse in 2 (evtl. überlappende) Gruppen unterteilt:
  - Clients
  - Server
- Server bieten Dienste an.
- Clients nutzen diese Dienste.
- Kommunikation meist Request-Reply

Macht beim Server $\Rightarrow$ *Hierarchie.*

Zweischichtige Konfiguration Diagramm

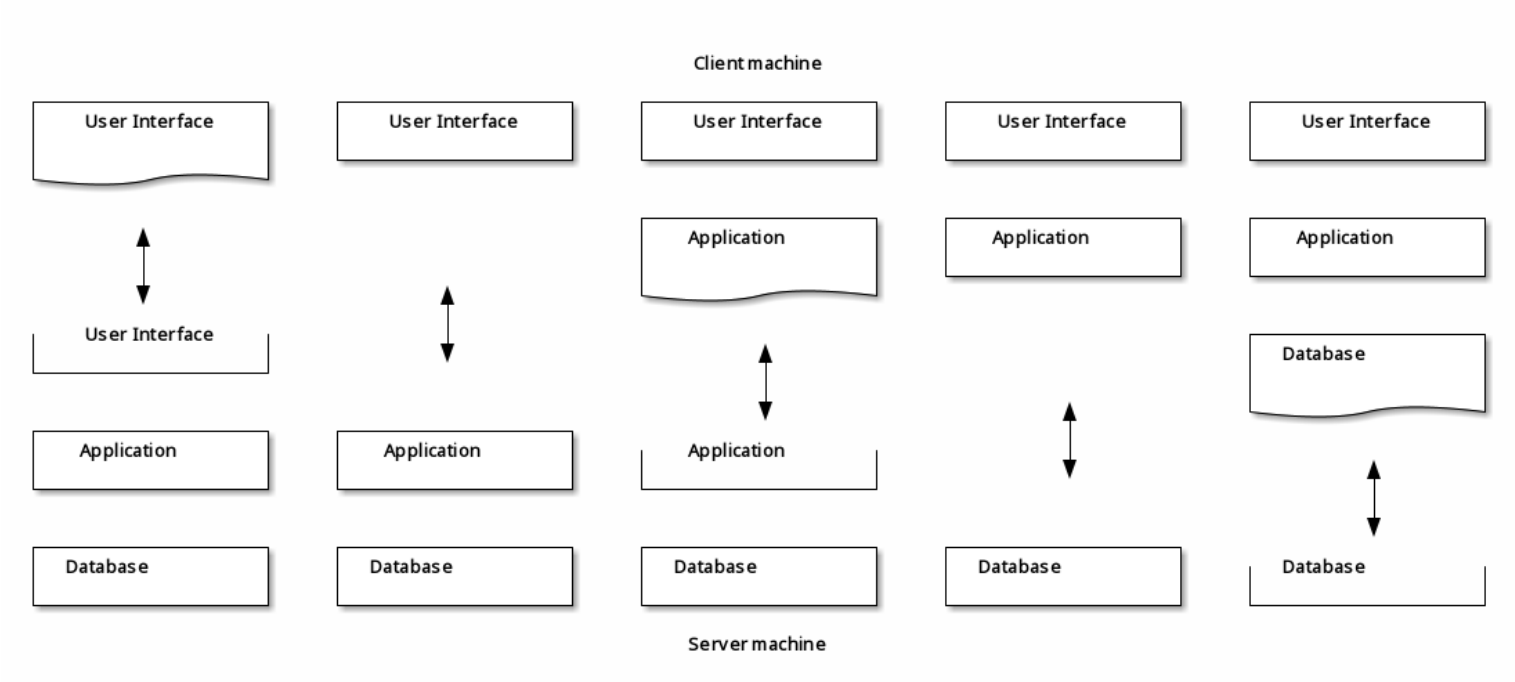

Zweischichtige Konfiguration

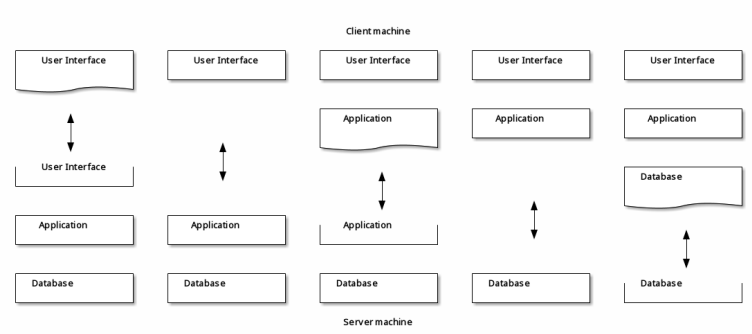

- Die Anwendungsebenen UI, Application und DB werden zwischen Client und Server aufgeteilt.
- Auf 3 Schichten erweiterbar indem die DB auf eigene Maschine ausgelagert wird.

Extrembeispiel

https://dryads-wake.1w6.org/

Wieviel Logik ist im Server? Schauen Sie nach
⇒ **F12 Hacking Key**!

Bitte schießen Sie es nicht ab. Läuft auf kleinstem mietbaren VPS :-)

Übung 1/2: Aufgabe

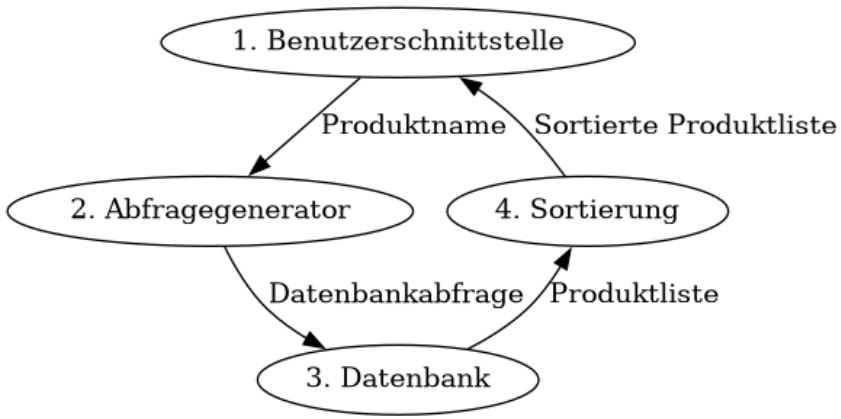

- Ordne die Komponenten 1-4 ihren Anwendungsebenen zu.
- Anwendungsebenen: Welche Komponenten sollten **auf dem Server** und welche **auf dem Client** laufen? Begründen Sie Ihre Antwort. Gruppenarbeit Randbedingungen (nächste Folie)

Übung 2/2: Randbedingungen: Latenz Client–Server

- A: 1ms (Lokaler Rechner, effizient[9])
- B: 10ms (Lokaler Rechner, effizient aber mit Compositor, Regionaler Spiele-Ping, Typische USB-Tastatur)
- C: 100ms (Lokaler Rechner[10], Spiele-Ping: 20.000km)
- D: 1s (Neue Webseite öffnen)
- E: 2.5 Minuten bis 5 Minuten (Mars) 50–100 mio km
- F: 3 Wochen (Delay Tolerant Networking — Nomaden)

[9] GVim ohne Compositor → https://pavelfatin.com/typing-with-pleasure/

[10] vscode: https://github.com/Microsoft/vscode/issues/27378

Dezentralisierte System Architekturen (p2p)

- Prozesse werden nicht nach Client und Server unterteilt; alle sind gleichgestellt.
- Overlay Network:
  - Knoten im Netz sind Prozesse.
  - Kanten im Netz sind Kommunikationswege.
- 2 Arten von Overlay Networks: Strukturiert und Unstrukturiert

Übersicht und Konzepte. Konkrete Netze im nächsten Block.

Strukturierte Overlay Networks - Beispiel Chord

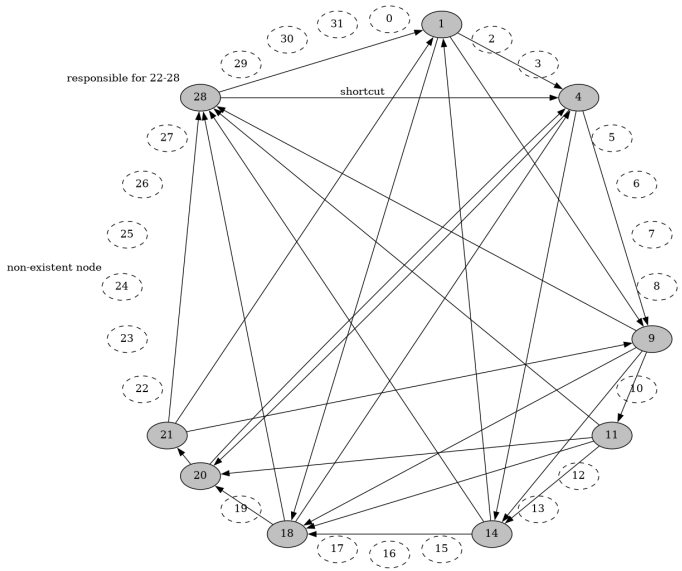

- Knoten als Ring angeordnet.
- Knoten kennt **den** Nachfolger.
- Zusätzlich Abkürzungen.
- Daten mit dem Schlüssel k auf Knoten mit der kleinsten id mit $id \geq k \rightarrow$ Nachfolger (successor).
- Suche
  - Shortcut zu $id \leq k$ (vor Key $\Rightarrow$ kennt Nachbarn),
  - Nachfolger mit $id \geq k$
- Konstruktion: kürzester Weg zwischen 2 Knoten hat Länge $O(\log N)$.

Flooding

- Algorithmus:
  - Ein Knoten erhält eine Anfrage für einen Wert.
  - Der Knoten sucht lokal nach dem Wert.
  - Findet er ihn nicht, übergibt er die Anfrage an **alle** Nachbarn.
  - Das Spiel wiederholt sich.
- Kann hohe Last erzeugen.
- Anfragen mit einer Time-To-Live (TTL).
  - z.B. maximale Anzahl von Sprüngen

Geht immer, aber selten gut.

Zusammenfassung

- Architekturstile: Layered, Object-based, Resource-based, Event-based.
- Zentralisierte Architekturen: n-Schichten.
- Dezentralisierte Architekturen: (un)strukturierte Overlay Networks
- In Realität meist Mischformen.
  - Bsp: Bittorrent verwendet zentralisierte Server (Tracker) zum Sammeln aktiver Knoten.

PAUSE

PAUSE

Prozesse: Ziele

- Sie verstehen den Unterschied zwischen Prozessen und Threads

Prozesse: Zustand

- Ein Prozess ist ein Programm in Ausführung.
- Der Zustand eines Prozesses wird im Prozesskontext gespeichert:
  - Registerwerte
  - Stackpointer
  - Programmzähler
  - Memory Maps
  - ...

Prozesse: Isolation

- Betriebssystem sorgt für Isolation zwischen Prozessen:
  - Eigene Speicherbereiche.
  - Unerlaubte Zugriffe (durch einen anderen Prozess): segfault.
- Kommunikation über Message passing.
  - Einfachste: Unix pipe.

Threads

Wie Prozesse

- Threads sind nebenläufig: führen Code unabhängig von anderen Threads aus.

Unterschiede

- Stack: Threads führen minimalen Kontext mit sich (Java: 1MiB Stack => `-Xss512k`).
- Shared Memory: Threads im gleichen Prozess können auf den gleichen Speicher zugreifen.
- Kontextwechsel, Erzeugen und Zerstören von Threads ist billiger.
- Im Kernel- oder Userspace

Lightweight Threads: fibers/goroutines/virtual threads/...

- Threads in Userspace
- Millionen von Threads, fast gratis wenn Inaktiv
- Oft explizite Kommunikation
- Skynet Benchmark: 1 Million Threads erstellen und als Baum Kommunizieren in https://github.com/atemerev/skynet
  - Eigenes Beispiel: https://github.com/atemerev/skynet/blob/master/guile-fibers/skynet.w
- Java: Project Loom: https://openjdk.java.net/projects/loom/

Lightweight Threads: Glossar

Fiber Kooperativ statt Präemptiv.

Green Thread Braucht keine OS-Unterstützung.

Coroutine Funktion mit yield statt return.

Dispatcher/Worker Modell

- Ein Thread (Dispatcher) liest eingehende Requests
- Die Request wird an Worker Thread gegeben, der die eigentliche Arbeit erledigt.

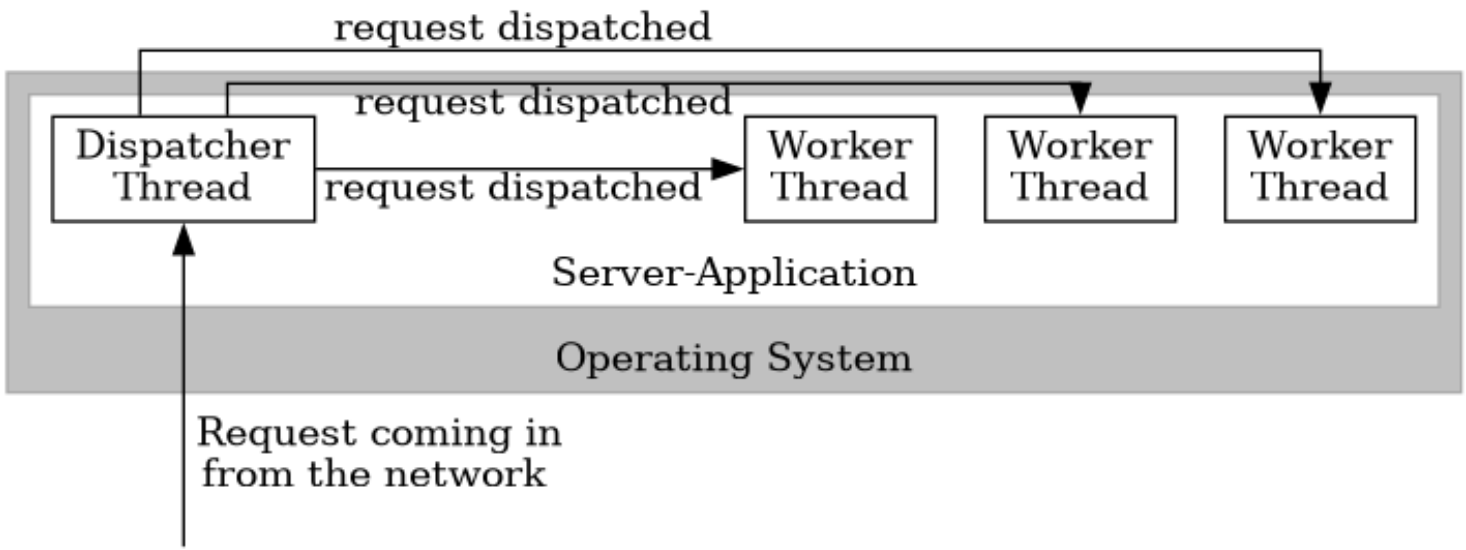

Zusammenfassung

- Prozesse werden vom OS isoliert: Messages.
- Threads teilen Speicher.
- Threads sind günstiger zu switchen.
- Threads in Kernel- oder Userspace implementiert.

Kommunikation

Interprocess communication is at the heart of all distributed systems.

Ziele

- Sie erkennen, wie Middleware als Schicht fungieren kann
- Sie kennen RPC (Remote-Procedure-Calls)
- Sie erkennen Messaging-Strukturen
- Sie können Kostenmetriken für Overlays rechnen

Synchronization points

Worauf Sie warten können.

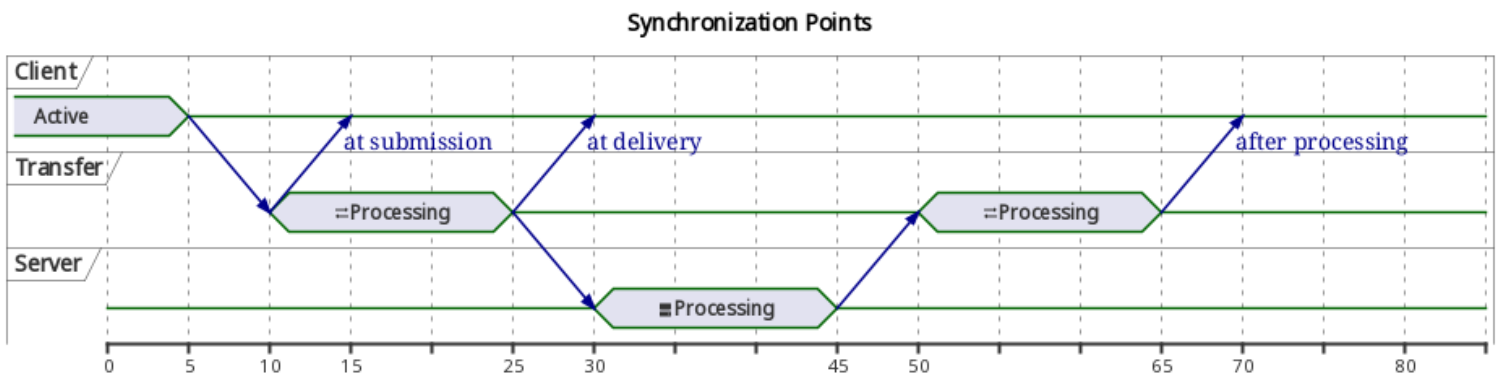

Arten der Kommunikation

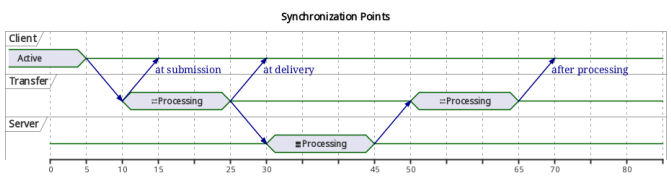

- transient vs. persistent
  - transient: Nachricht wird verworfen, falls sie nicht ausgeliefert werden kann.
  - persistent: Nachricht wird gespeichert bis sie übermittelt wurde.
- asynchronous vs. synchronous
  - asynchronous: Sender fährt nach Übergabe der Nachricht an Kommunikationsstack fort.
  - synchronous: Sender wird geblockt bis Nachricht übermittelt wurde.

Schichtmodelle

Definition von OSI:

- Schicht bietet der darüberliegenden Schicht einen Dienst an.
- Dieser Dienst wird durch eine Schnittstelle spezifiziert.
- Schichten verwenden jeweils ein Protokoll um mit der Gegenseite (auf der gleichen Schicht) zu kommunizieren.
- Beim Senden einer Nachricht wird die Nachricht an die darunterliegende Schicht gereicht.

Anschauliche Kurzbeschreibung: osi-model.com/

Middleware Schicht

- Middleware soll allgemeine Dienste und Protokolle bereitstellen:
  - Kommunikation
  - (Un)marshalling (binär $\Rightarrow$ Datenstruktur)
  - Namensprotokolle: Teilen von Ressourcen
  - Sicherheit
  - Skalierung: Replikation/Caching
- Die Implementierung eines verteilten Systems kann sich auf das Anwendungsprotokoll konzentrieren.

Middleware Schicht 2

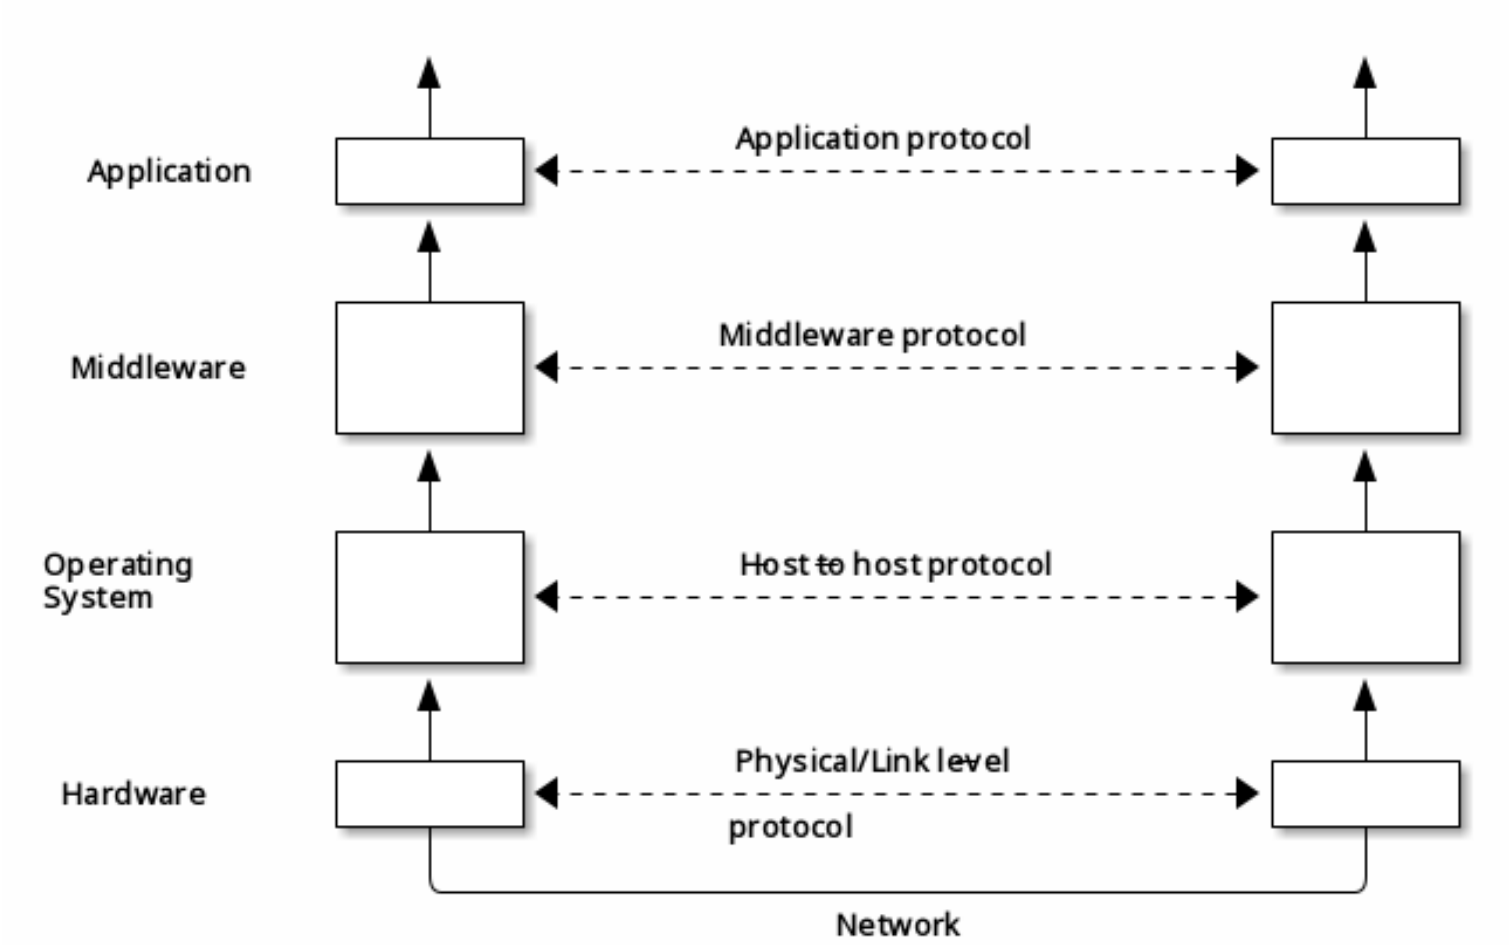

Middleware in Cadenza

Backend, physisch verteilt

- Apache Ignite shared-nothing Clustering
- Präzise Cache-invalidation durch explizite Nachrichten

Frontend, logisch verteilt

- Redux store zur Synchronisierung und für Events
- $\Rightarrow$ PATCH statt PUT/POST

Remote Procedure Call (RPC)

- Soll möglichst wie ein normaler Methodenaufruf aussehen.
- $\Rightarrow$ Zugriffstransparenz

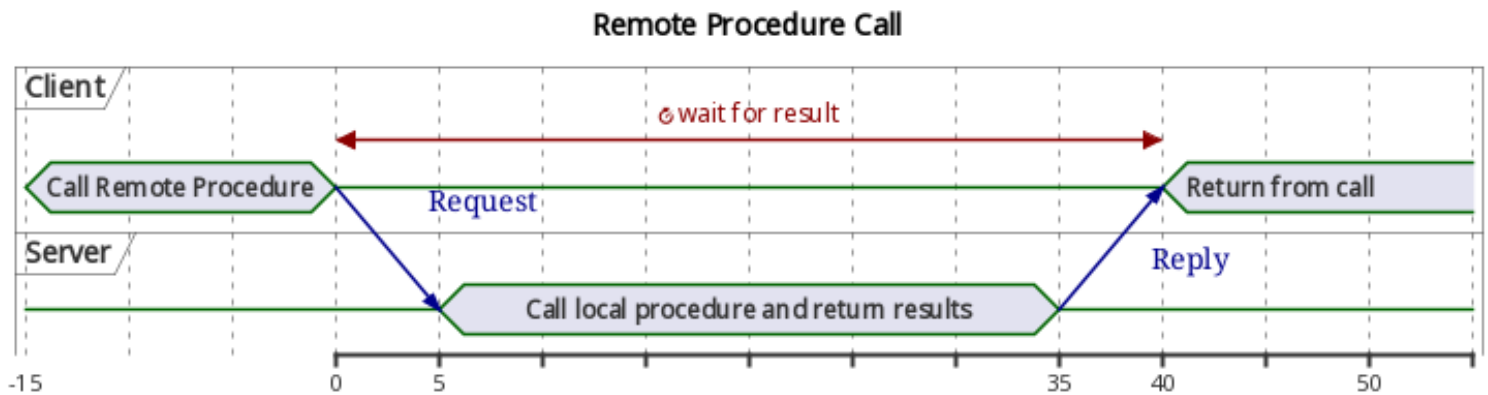

Ablauf RPC

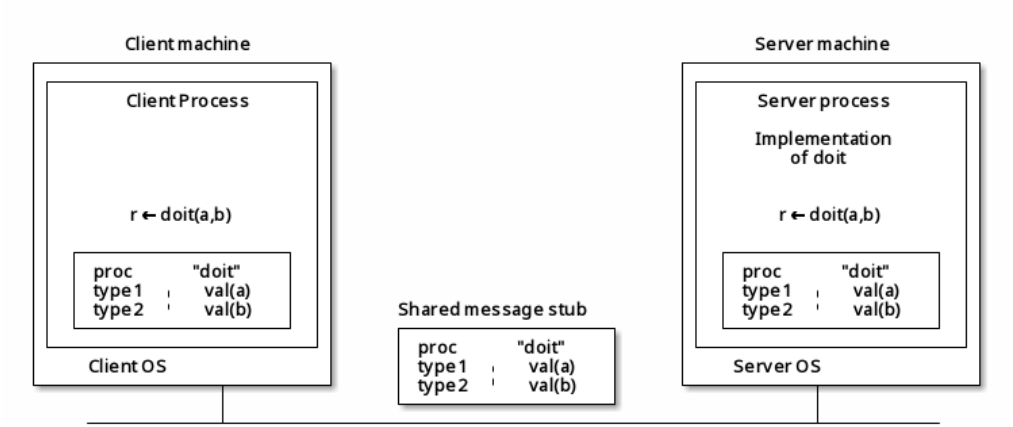

1. Client ruft stub auf.
2. Stub erstellt Nachricht.
3. Client OS sendet Nachricht.
4. Server OS ruft stub auf.
5. Stub entpackt Nachricht.
6. Stub erhält Ergebnis.
7. Stub erstellt Nachricht.
8. Server OS sendet Nachricht.
9. Client OS gibt an stub.
10. Stub entpackt Nachricht.

Parameter Marshalling

- Client und Server haben evtl. unterschiedliche Datenrepräsentation (z.B. Little vs. Big Endian)
- Parameter in Bytes umwandeln
- Auf Formate einigen
- Komplexe Datenstrukturen?
- Referenzen?
- Änderungen kommunizieren?
- Nie völlig transparent?

Referenzen

- Post-Messages zwischen iframes: Keine Referenzen
- OCap: Mögliche Referenzen als explizite Capabilities. Entrance to the rabbit hole: https://fosdem.org/2021/schedule/event/spritelygoblins/ (down the ASCII rabbit hole)

Risiko: unpassende Garantien

- Zu viel garantiert: viel Synchronisierung, langsam
- Zu wenig garantiert: Bugs

Wir kommen in einem späteren Block mit CALM und CRDTs darauf zurück.

Zusammenfassung

- Middleware als Schicht im Netzwerkmodell gesehen
- Kommunikation nach transient/persistent und asynchronous/synchronous unterschieden
- RPC ist ein entfernter Methodenaufruf
- Gibt Garantien.

PAUSE

PAUSE

Praxis: Ziele

- Sie kennen grundlegende Beispiele zum schnellen Einstieg
- Sie kennen Kostenmetriken für Overlays

Einfacher RPC Server in Python

```
from xmlrpc.server import SimpleXMLRPCServer, SimpleXMLRPCRequestHandler

server = SimpleXMLRPCServer(("localhost", 8001))

def hi():
    return "hi"

server.register_function(hi)
server.serve_forever()
```

Einfacher RPC Client in Python

```
import xmlrpc.client

s = xmlrpc.client.ServerProxy("http://localhost:8001")
print(s.hi())
```

Wireshark-Time!

Messaging mit ZeroMQ

- Sockets mit definierten Kommunikationsmustern.
- Sockets erlauben one-to-one
- ZeroMQ bietet auch many-to-one und one-to-many:
  - request-reply
  - publish-subscribe
  - pipeline

Request-Reply mit ZeroMQ - Server

```
import zmq

context = zmq.Context()
p = "tcp://127.0.0.1:8001"
s = context.socket(zmq.REP)

s.bind(p) # bind = listen here

while True:
  message = s.recv_string()
  if not "STOP" in message:
    s.send_string(message + "*")
  else:
    break
```

Request-Reply mit ZeroMQ - Client

```
import zmq

context = zmq.Context()
p = "tcp://127.0.0.1:8001"
s = context.socket(zmq.REQ)

s.connect(p)

s.send_string("hi")
message = s.recv_string()
print(message)
s.send_string("hi2")
# violate request-reply => error!
s.send_string("too hasty")
message = s.recv_string()
s.send_string("STOP")
print(message)
```

Einwurf: Was bringt mir das?

- Verständliche(-re) Muster ⇒ leichter zu kombinieren
- Kommunikations-Struktur erzwingen ⇒ Fehlererkennung

Publish-Subscribe mit ZeroMQ - Publish

```
import zmq, time

context = zmq.Context()
p = "tcp://127.0.0.1:8001"
s = context.socket(zmq.PUB)

s.bind(p)

while True:
    time.sleep(3)
    s.send_string("TIME " + time.asctime())
```

Publish-Subscribe mit ZeroMQ - Subscribe

```
import zmq

context = zmq.Context()
s = context.socket(zmq.SUB)
p = "tcp://127.0.0.1:8001"

s.connect(p)

s.setsockopt_string(zmq.SUBSCRIBE, "TIME")

for i in range(5):
    time = s.recv_string()
    print(time)
```

Publish-Subscribe mit ZeroMQ

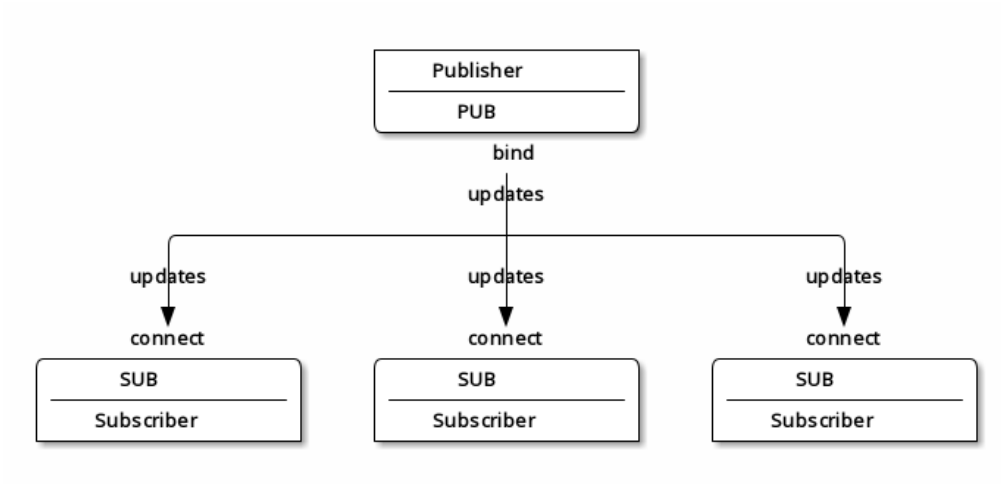

- Implementiert Multicast
- Subscribers bekommen nur Messages entsprechend ihrer Subscription.

Pipeline mit ZeroMQ - Producer

```
import zmq, time

context = zmq.Context()
s = context.socket(zmq.PUSH)
p = "tcp://127.0.0.1:8001"

s.bind(p)

for i in range(100):
    s.send_string(str(i))
    time.sleep(0.1)
```

Pipeline mit ZeroMQ - Consumer

```
import zmq, time

context = zmq.Context()
s = context.socket(zmq.PULL)
p = "tcp://127.0.0.1:8001"

s.connect(p)

while True:
    message = s.recv_string()
    print(message)
    time.sleep(int(message) * 0.01)
```

Pipeline mit ZeroMQ

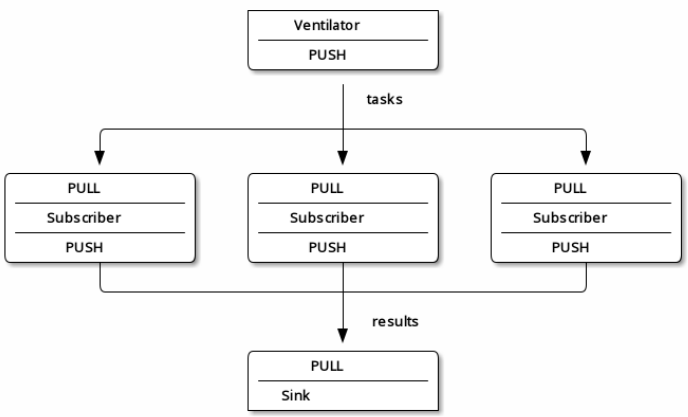

- Erlaubt Verteilung von Arbeit auf mehrere Consumer
- Im Gegensatz zu Publish-Subscribe wird jede Message nur an einen Consumer weitergegeben

Message-oriented persistent communication

- „message-queuing systems“ oder „Message-Oriented Middleware (MOM)“
- **Persistente** asynchrone Kommunikation.
- Sender und Empfänger müssen nicht gleichzeitig aktiv sein.
- Wie E-Mail.

Allgemeiner Aufbau

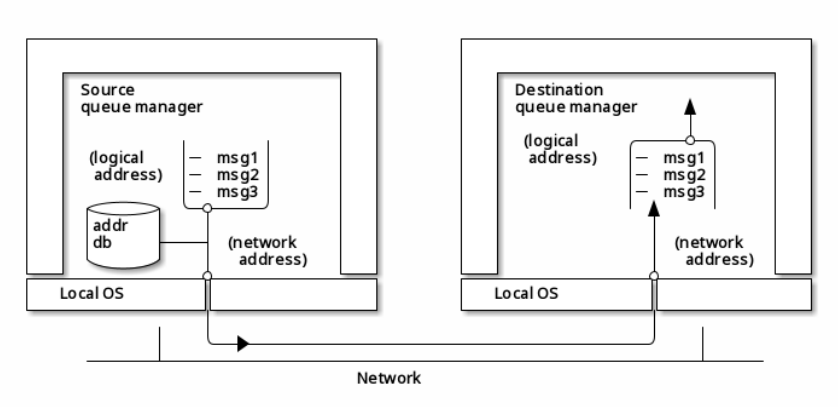

- Prozess hat einen lokalen Queue-Manager.
- Queue Manager verwaltet die Queue für den Prozess.
- Prozess kann in die lokale Queue Messages einstellen und entnehmen.
- Messages addressiert.
- Adressdatenbank im Queue-Manager.

Message Broker

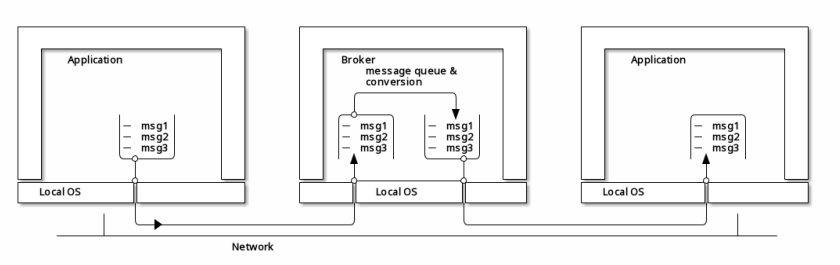

- bestehende Systeme integrieren
- Für jedes System eigenes Messageformat
- Nachricht von Prozess A an B muss Bs Protokoll nutzen
- Konvertierung von Nachrichten durch Komponente

Kostenmetriken für Multicast

Den Preis der Abstraktion quantifizieren.

Multicast in der Anwendungsschicht

- Ziel: Daten an mehrere Empfänger
- Multicast auf IP Ebene zwischen ISPs selten umgesetzt
  $\Rightarrow$ Multicast **in der Anwendungsschicht**
  $\Rightarrow$ Abstraktions-Overhead
- Overlay Netzwerk
  - Oft Baum: Pfade sind eindeutig
  - Mesh-Strukturen benötigen Routing

Metriken für Multicast mit Overlay

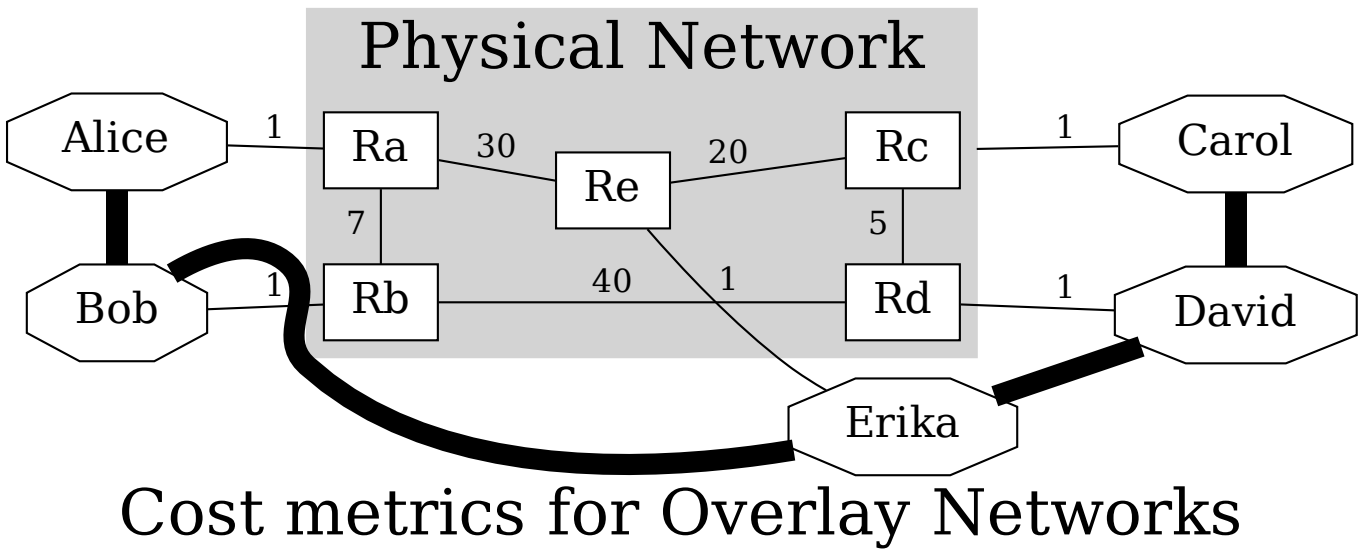

- Kosten für physische Verbindungen sind gegeben.

Link Stress für Multicast mit Overlay

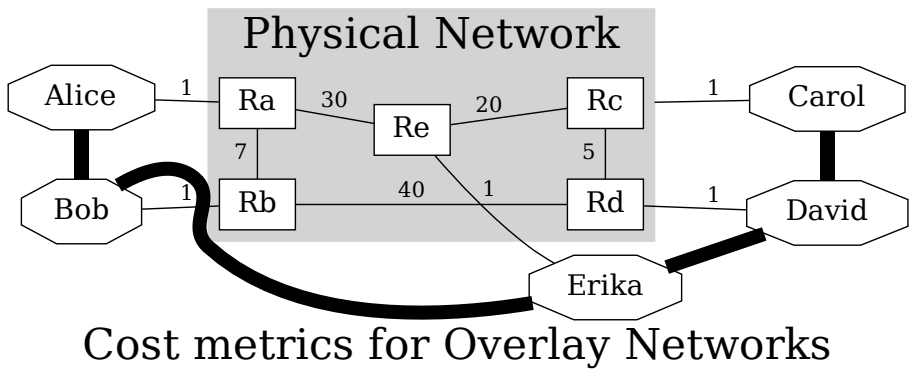

Cost metrics for Overlay Networks

Link Stress: Anzahl wiederholter Nutzungen einzelner Verbindungen.

Beispiel Link Stress von Alice zu Erika: (B, Rb), (Ra, Rb) mit Link Stress jeweils 2.

Stretch für Multicast mit Overlay

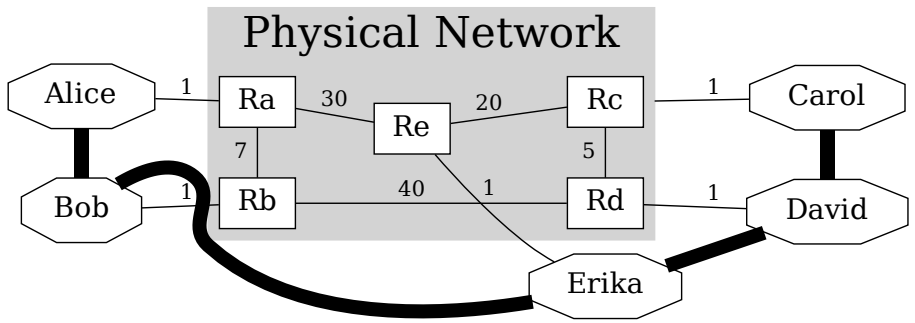

Cost metrics for Overlay Networks

Stretch: Verhältnis aggregierter Kosten auf dem Weg im Overlay und dem optimalen Kommunikationsweg.

Beispiel Stretch von Alice zu Erika: Overlay $= 1 + 7 + 1 + 1 + 7 + 30 + 1 = 48$, Optimal $= 1 + 30 + 1 = 32$ –> Stretch $48/32$

Übung

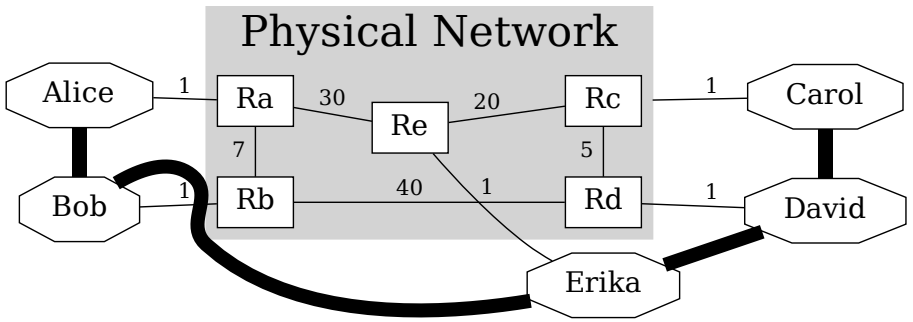

Cost metrics for Overlay Networks

Berechne Link Stress und Stretch für die Verbindung Erika zu Carol.

- Link Stress: (Rd, D) (Rc, Rd) mit Link Stress jeweils 2
- Stretch: $1 + 20 + 5 + 1 + 1 + 5 + 1 = 34$, $1 + 20 + 1 = 22$ –> 34/22

Zusammenfassung

- Messaging erlaubt entkoppelte Kommunikation
- ZeroMQ bietet die Kommunikationsmuster:
  - Request-Reply
  - Publish-Subscribe
  - Pipeline
- Multicast:
  - Wird auf Anwendungsebene umgesetzt
- Link Stress und Stretch als Metriken für Overlay Netzwerke

Gesamtzusammenfassung 1

- Sammlung autonomer Knoten, die als ein kohärentes System erscheinen.
- **Ziele**: Resourcen, Verteilungstransparenz, Skalierbarkeit
- **Skalierung**: Größe, Geographie, Administration
- Latenz, Partitionierung, Replikation, Caching
- **Fallacies!**
- Cluster, Grid, Cloud, Ubiquitous, Mobile, DIS, Sensornetze

Gesamtzusammenfassung 2

- **Architektur**: Layered, Object, Resource, Event
- Schichten und Overlay Netze
- Prozesse sind isoliert, Threads teilen Speicher.
- **Middleware** als Schicht: Übernimmt Verteilung, gibt Garantien.
- **Messaging**: Request-Reply, Pub-Sub, Pipeline.
- **Overlay** metriken: Link Stress und Stretch

Fallacies of distributed Systems

1. reliable
2. secure
3. homogeneous
4. topology
5. latency
6. bandwidth
7. transport cost
8. administrator

1. hard disk
2. power
3. IP
4. constant factors
5. APIs
6. text

Fin

Viel Erfolg in den nächsten Wochen!

Verweise

Ghosh, S. (2015). *Distributed Systems - An Algorithmic Approach*. Computer & Information Science. Chapman & Hall/CRC, 2 edition.

Steen, M. v. and Tanenbaum, A. S. (2017). *Distributed Systems*. CreateSpace Independent Publishing Platform; 3.01 edition (February 1, 2017), 3 edition.

Bilder: