Überblick

Vorlesung

- Verantwortliche
  - **Tobias Distler** Raum 0.039 `distler@cs.fau.de`
  - Jürgen Kleinöder Raum 0.043 `jk@cs.fau.de`
- Termin
  - Donnerstag, 14:15 – 15:45 Uhr
  - Raum 0.031-113
- Web-Seiten
  - Skript `https://www4.cs.fau.de/Lehre/WS19/V_MW/Vorlesung/`
  - Literatur `https://www4.cs.fau.de/Lehre/WS19/V_MW/Literatur/`
- **Fragen und Rückmeldungen sind erwünscht!**

Vorlesung

- **Grundlagen**
  - Überblick über Cloud Computing
  - Grundlagen verteilter Programmierung mit Web-Services
  - Virtualisierung als Basis für Cloud Computing
- **Stand der Kunst**
  - Infrastructure as a Service (IaaS): Eucalyptus, Windows Azure Storage
  - Verteilte Datenspeicher für Cloud-Anwendungen
    - Google File System
    - Amazon Dynamo
  - Verteilte Programmierung für datenintensive Cloud-Anwendungen
  - Energieeffiziente Datenzentren
  - Koordinierung von Cloud-Anwendungen
- **Ausblick auf (mögliche) zukünftige Entwicklungen**
  - Interoperabilität und Multi-Cloud Computing
  - Virtualisierungsbasierte Fehlertoleranz

Übung

- Verantwortliche
  - **Michael Eischer** Raum 0.045 `eischer@cs.fau.de`
  - **Laura Lawniczak** Raum 0.041 `lawniczak@cs.fau.de`
  - Tobias Distler Raum 0.039 `distler@cs.fau.de`
- Termine
  - Tafelübung Freitag, 12:15 – 13:45 Uhr, 0.031-113 (ab 18.10.)
  - Rechnerübung Mittwoch, 16:00 – 18:00 Uhr, 00.153-113 (ab 23.10.)
- Web-Seite
  - `https://www4.cs.fau.de/Lehre/WS19/V_MW/Uebung/`
- **Anmeldung**
  - Web-Anmeldesystem *Waffel*
  - `https://waffel.informatik.uni-erlangen.de`

Übung

Inhalt

- Tafel- und Rechnerübung
  - Ergänzende und vertiefende Informationen zur Vorlesung
  - Hilfestellungen zur **Bearbeitung der Übungsaufgaben**
  - Klärung von Fragen
  - Abgabe der Übungsaufgaben
- **Themen**
  - Entwicklung Cloud-basierter Web-Services
  - Einsatz einer hybriden IaaS-Cloud (OpenStack + Amazon EC2)
  - Verteilte Dateisysteme (HDFS)
  - Skalierbare Datenverarbeitung mittels MapReduce
  - Koordinierung von verteilten Cloud-Anwendungen

Prüfungen

- Informatik (**Bachelor und Master**)
  - Vertiefung „Verteilte Systeme und Betriebssysteme“
  - 5 ECTS- oder 7,5 ECTS-Modul
- Informations- und Kommunikationstechnik
  - Bachelor: „Wahlmodule aus EEI und INF“ (5 ECTS-Modul)
  - Master: „Wahlpflichtmodul aus INF“ (5 ECTS- oder 7,5 ECTS-Modul)
    - Eingebettete Systeme
    - Kommunikationsnetze
    - Übertragung und Mobilkommunikation
- Varianten
  - **5 ECTS: Vorlesung + Übung**
    - Erfolgreiche Bearbeitung aller abzugebenden Übungsaufgaben
    - Mündliche Prüfung über Vorlesungs- und Übungsstoff
  - **7,5 ECTS: Vorlesung + erweiterte Übung**
    - Erfolgreiche Bearbeitung aller abzugebenden Übungsaufgaben
    - Erfolgreiche Bearbeitung aller Zusatzsaufgaben
    - Mündliche Prüfung über Vorlesungs- und Übungsstoff

Mündliche Prüfung

- Anmeldung
  - Registrierung in *mein campus*
  - Bitte vom Prüfungsamt vorgegebenen **Anmeldezeitraum** beachten!
- Vereinbarung des Prüfungstermins
  - Gegen Ende des Semesters
  - Alle Angemeldeten erhalten eine **E-Mail mit einem Doodle-Link**
  - Doodle: Terminvorschläge für Anfang, Mitte und Ende der Semesterferien
  - **Auswahl des eigenen Prüfungstermins** in der Doodle-Umfrage
  - Erscheinen des Prüfungstermins in *mein campus* dient als Bestätigung
- Prüfung
  - Gespräch über den Stoff der Vorlesung und (erweiterten) Übung
  - Diskussion behandelter Probleme und möglicher Lösungsansätze
  - Anwendung bekannter Konzepte auf weitere Problemstellungen
  - **Verstehen ist entscheidend**, nicht das Auswendiglernen!

Überblick

Cloud Computing

- Merkmale
  - **Auslagerung von Diensten**, Berechnungen und/oder Daten
  - Verfügbarkeit **scheinbar unbegrenzter Ressourcen**
  - Einfacher universeller Zugriff
  - **Schnelle dynamische Skalierbarkeit**
- Grundlagen
  - Hochskalierbare verteilte Infrastrukturen auf Provider-Seite
  - Leistungsfähige Netzwerkanbindung auf Client-Seite
  - Geringe Kosten für Speicherplatz
- Literatur

Mache Creeger
Cloud Computing: An Overview
Queue – Distributed Computing, 7(5), 2009.

Michael Armbrust, Armando Fox, Rean Griffith, Anthony D. Joseph, Randy Katz et al.
A View of Cloud Computing
Communications of the ACM, 53(4):50–58, 2010.

Skalierbarkeit

- Häufiges Problem in der Praxis: Abschätzung der Auslastung eines Diensts und Bereitstellung entsprechender Ressourcen
  - Lastentwicklung eventuell unbekannt
  - **Ungünstiges Verhältnis zwischen Spitzen- und Durchschnittslast**
  - Starke Lastschwankungen über den Tag bzw. das Jahr hinweg
- Mögliche **Konsequenzen ungenauer Bedarfsvorhersagen**
  - Bereitstellung von zu wenigen Ressourcen (*Underprovisioning*)
  - Bereitstellung von zu vielen Ressourcen (*Overprovisioning*)
- Potentielle Vorteile durch Verlagerung von Diensten in die Cloud
  - Verfügbarkeit zusätzlicher Ressourcen im Sekunden- bzw. Minutenbereich
  - **Dynamische Skalierbarkeit in beide Richtungen**
  - Abrechnungsmodell: *Pay-as-you-go*
    - Kosten orientieren sich am tatsächlichen Ressourcenverbrauch
    - Feingranulare Abrechnung [Beispiele: Virtuelle Maschine: pro Stunde, Netzwerk: pro Megabyte]
    - **Achtung:** Dienste in der Cloud zu betreiben ist nicht automatisch günstiger!

Verfügbarkeit

- Wartung und Reparatur von Systemkomponenten
  - Aufgabe des Cloud-Anbieters
  - **Einschränkung von Verfügbarkeitsgarantien** für Cloud-Dienste
  - Nutzer hat keinen Einfluss auf Zeitpunkt und Dauer der Maßnahmen
- Technische Infrastruktur in Cloud-Datenzentren
  - Zusammenschluss einer großen Anzahl verhältnismäßig kleiner Server
  - Günstige Einkaufspreise aufgrund großer Stückzahlen
  - Konsequenzen
    - **Ausfälle einzelner Komponenten werden zum Regelfall**
    - Kompatibilitätsprobleme aufgrund heterogener Hardware
  - Realistisches Fehlerszenario: Ausfall kompletter Datenzentren
- Maßnahmen zur **Tolerierung von Fehlern**
  - Verteilung eines Diensts auf verschiedene Datenzentren
  - Replikation von Daten über mehrere Standorte

Basistechnologien

- **Web-Services**
  - Sprachunabhängige Basis für entfernte Kommunikation
  - Bereitstellung von Diensten in der Cloud
  - Schnittstelle zur Cloud-Konfigurierung
- **Virtualisierung**
  - Paralleler Betrieb mehrerer *virtueller Maschinen* auf einem Rechner
  - Höhere Auslastung einzelner Rechner [2-3% (ohne Virt.) → bis zu 80% (mit Virt.) [Creeger]]
  - Kostenersparnis durch geringeren Platzbedarf

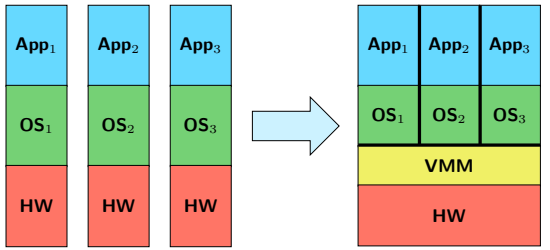

Everything as a Service

- Kategorien
  - **Software as a Service (SaaS)**
    - Bereitstellung vom Endnutzer verwendeter Dienste
    - Beispiel: Google Docs
  - **Platform as a Service (PaaS)**
    - Bereitstellung von Middleware zur Implementierung komplexer Dienste
    - Beispiel: Google AppEngine
  - **Infrastructure as a Service (IaaS)**
    - Bereitstellung von Rechen- und Speicherinfrastruktur
    - Beispiel: Amazon EC2
- In der Praxis
  - Oftmals als Schichten aufeinander aufbauend
  - Grenzen zwischen Kategorien fließend

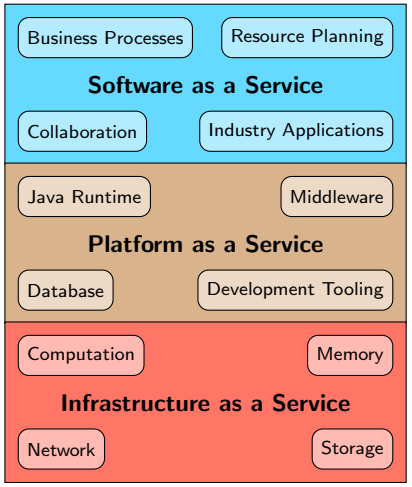

Einsatzszenarien

- **Öffentliche Cloud** (*Public Cloud*)
  - Große Unternehmen (z. B. Amazon, Microsoft, Google) stellen ihre Infrastruktur zur Verfügung
  - Cloud-Nutzer müssen selbst vergleichsweise wenige Ressourcen vorhalten
- **Private Cloud**
  - Nutzung der bereits im eigenen Unternehmen vorhandenen Infrastruktur
  - Einsatz von Virtualisierung zur flexiblen Verwaltung von Ressourcen
- **Hybride Cloud**
  - Kombination aus privater und öffentlicher Cloud
  - Mögliche Aufteilung
    - Kritische Daten verbleiben im privaten Teil der Cloud
    - Öffentliche Cloud vor allem zur Deckung von Bedarfsspitzen
- **Multi Clouds / Cloud-of-Clouds**
  - Parallele Nutzung verschiedener öffentlicher Clouds
  - Absicherung gegen den Ausfall eines Cloud-Anbieters

Limitierungen und offene Fragen

- „*Vendor Lock-In*“-Problem
  - Starke Abhängigkeit von einem einzelnen Cloud-Anbieter
  - **Erschwerter Anbieterwechsel**
  - Gründe: fehlende Standards, aufwendiger Datentransfer
- Technische Limitierungen
  - **Ineffizienter Transfer großer Datenmengen** in die bzw. aus der Cloud
    [Amazon bietet daher z. B. an, Daten per Festplatte zu transferieren: `https://aws.amazon.com/de/snowball/`]
  - Optimale Isolation von virtuellen Maschinen ist nicht immer möglich
    - Sicherheitsprobleme (z. B. Schwachstellen in der Virtualisierungssoftware)
    - Problem der *Performance Isolation*: Instabile bzw. unvorhersehbare Performanz bestimmter Operationen (z. B. Festplattenzugriffe)
- Weiterführende Aspekte
  - **Vertraulichkeit von Daten**
  - Rechtliche Fragen (Beispiele)
    - Dürfen medizinische Daten in einer öffentlichen Cloud verarbeitet werden?
    - Werden gesetzliche Bestimmungen zum Speicherort von Daten eingehalten?

Wie lässt sich Virtualisierung praktikabel realisieren?

- **Anforderungen** an ein virtualisiertes System
  - Äquivalenz
  - Ressourcenkontrolle
  - Effizienz
- **Virtualisierungsebenen**
  - Systemvirtualisierung: Virtualisierung der *Instruction Set Architecture*
  - Prozessvirtualisierung: Virtualisierung des *Application Binary Interface*

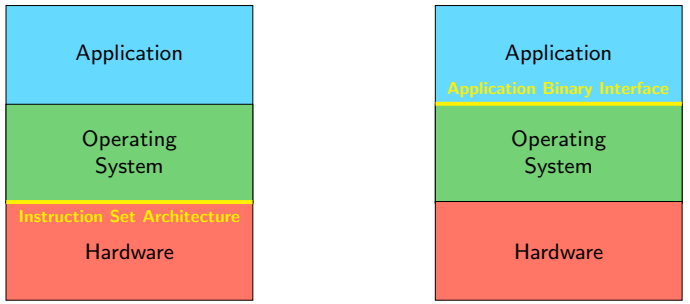

Wie wird die eigene Infrastruktur für andere nutzbar?

- **Aufbau einer Infrastruktur-Cloud**

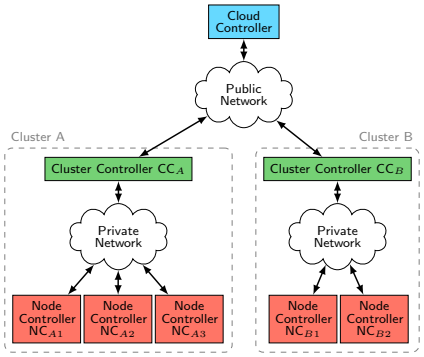

- **Aufgabenbereiche**
  - Verwaltung von physischen Maschinen
  - Verwaltung und Platzierung von virtuellen Maschinen
  - Anbindung an Datenspeicher

Wie lassen sich große Datenmengen verwalten?

- Ansatz
  - Speziell auf die jeweiligen Anforderungen zugeschnittene Systeme
  - **Enge Verzahnung mit der Anwendung**
- **Beispiel: Google**
  - Anforderungen
    - Sehr große Dateien
    - Hauptsächlich sequentielle Schreibzugriffe, kaum Modifikationen
  - *Google File System*
    - Kein Dateisystem im klassischen Sinne
    - Optimierte Auslastung der Netzwerkverbindungen
- **Beispiel: Amazon**
  - Anforderungen
    - Große Anzahl an vergleichsweise kleinen Datensätzen
    - Hohe Verfügbarkeit
  - *Amazon Dynamo*
    - Replizierter Datenspeicher für Schlüssel-Wert-Paare
    - Abgeschwächte Konsistenzgarantien

Wie lassen sich große Datenmengen verarbeiten?

- Beispiel: Google (und viele andere)
  - Anforderungen
    - **Parallele Nutzung einer großen Anzahl von Rechnern**
    - Einfache Realisierung von Anwendungen
  - *MapReduce*
    - Framework übernimmt Verteilung der Anwendung
    - Programmierer implementiert **zwei Methoden**
      - `Map`: Abbildung der Eingabedaten auf Schlüssel-Wert-Paare
      - `Reduce`: Zusammenführung der von `Map` erzeugten Schlüssel-Wert-Paare
- Koordinierung und Konfigurierung verteilter Anwendungen
  - Anforderungen
    - **Abstimmung zwischen einer großen Anzahl von Prozessen**
    - Ausfallsichere Verwaltung von Konfigurationsinformationen
  - Beispiel: *Chubby* (Google)
    - Bereitstellung als externer Koordinierungsdienst
    - Generische Schnittstelle zur Implementierung komplexer Abstraktionen