Überblick

Organisation

- Vorlesung
- Übung
- Prüfungen

Einführung

- Überblick
- Chancen und Limitierungen
- Herausforderungen

Vorlesung

Überblick

- Verantwortliche
  - Tobias Distler Raum 0.039 `distler@cs.fau.de`
  - Jürgen Kleinöder Raum 0.043 `jk@cs.fau.de`
- Termin
  - Mittwoch, 14:15 – 15:45 Uhr
  - Raum 0.031-113
- Web-Seiten
  - Skript `https://www4.cs.fau.de/Lehre/WS16/V_MW/Vorlesung/`
  - Literatur `https://www4.cs.fau.de/Lehre/WS16/V_MW/Literatur/`
- Fragen und Rückmeldungen sind erwünscht!

Vorlesung

Inhalt

- 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

- Verantwortliche
  - Christopher Eibel Raum 0.045 ceibel@cs.fau.de
  - Michael Eischer Raum 0.045 eischer@cs.fau.de
  - Tobias Distler Raum 0.039 distler@cs.fau.de
  - Timo Hönig Raum 0.050 thoenig@cs.fau.de
- Termine
  - Tafelübung Dienstag, 14:15 – 15:45 Uhr, 0.031-113 (ab 25.10.)
  - Rechnerübung Mittwoch, 16:00 – 18:00 Uhr, 00.153-113 (ab 26.10.)
- Web-Seite
  - https://www4.cs.fau.de/Lehre/WS16/V_MW/Uebung/
- Anmeldung
  - Web-Anmeldesystem *Waffel*
  - https://waffel.informatik.uni-erlangen.de

Übung

- 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 privaten IaaS-Cloud (OpenStack)
  - Verteilte Dateisysteme (HDFS)
  - Skalierbare Datenverarbeitung mittels MapReduce
  - Koordinierung von verteilten Cloud-Anwendungen
  - Dynamische Skalierbarkeit von Cloud-basierten Diensten in Amazon EC2

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

Überblick

Organisation
- Vorlesung
- Übung
- Prüfungen

Einführung
- Überblick
- Chancen und Limitierungen
- Herausforderungen

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 et al.
A View of Cloud Computing
Communications of the ACM, 53(4):50–58, 2010.

Basistechnologien

- Web-Services
  - Sprachunabhängige Basis für entfernte Kommunikation
  - Bereitstellung von Diensten in der Cloud
  - Schnittstelle zur Cloud-Konfiguration
- Virtualisierung
  - Paralleler Betrieb mehrerer *virtueller Maschinen* auf einem Rechner
  - Isolation von Nutzern
  - Realisierung auf unterschiedlichen Ebenen: System, Prozess,...

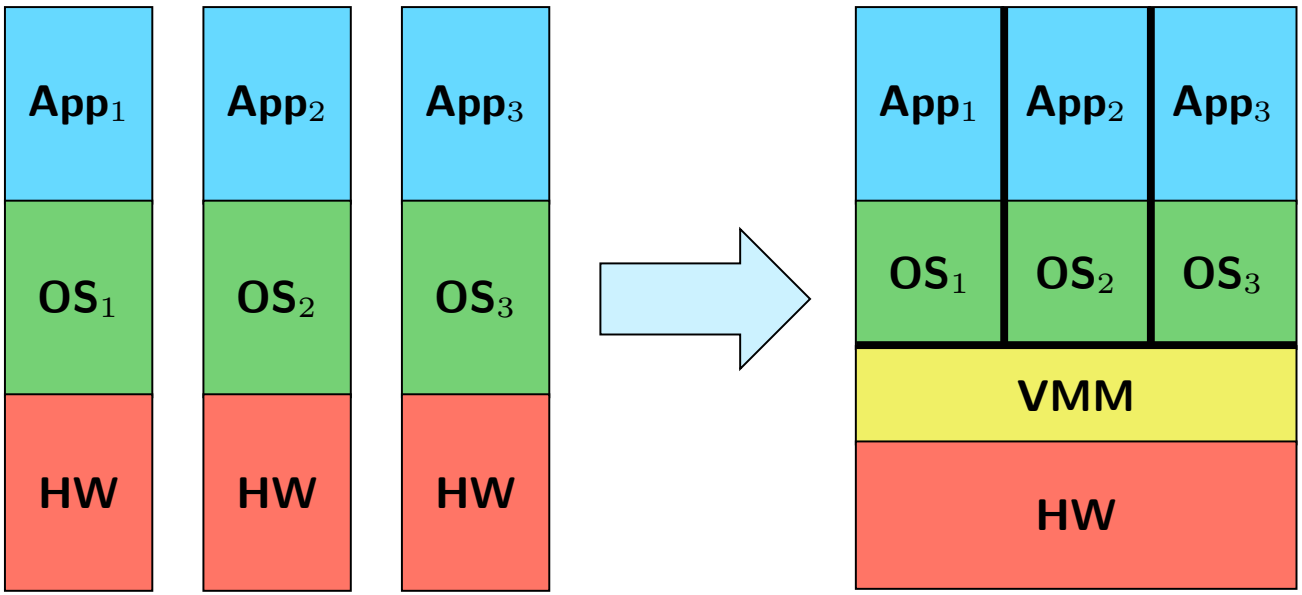

Everything as a Service

- 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

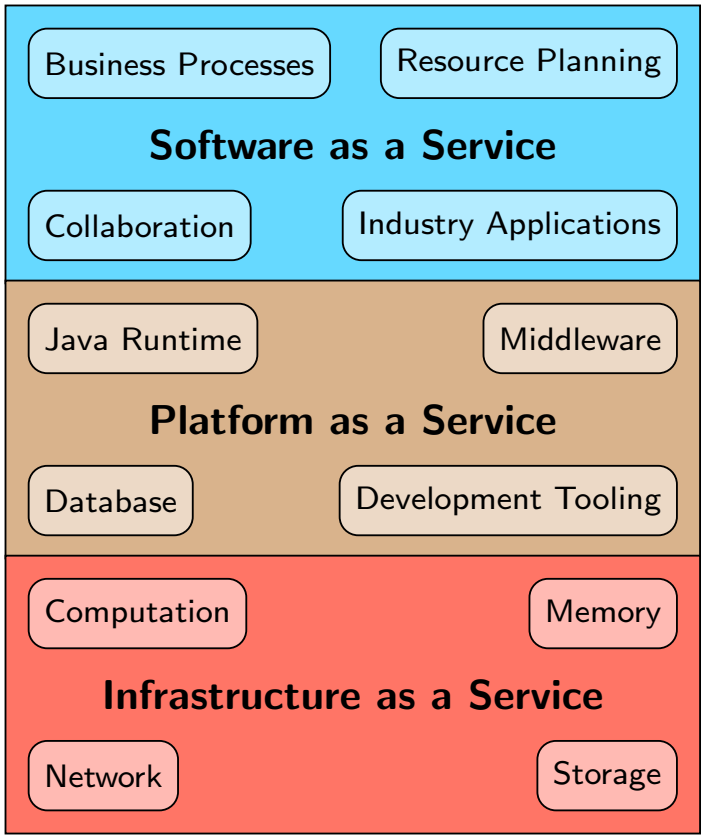

- In der Praxis
  - Oftmals als Schichten aufeinander aufbauend
  - Grenzen zwischen Kategorien fließend

Einsatzszenarien

- Öffentliche Cloud (*Public Cloud*)
  - Große Unternehmen (z. B. Amazon, Microsoft, Google) stellen anderen Firmen einen Teil ihrer 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

Wirtschaftliche Aspekte

- Cloud-Nutzer
  - Keine eigenen physischen Rechner
    - Geringerer Aufwand für Administration
    - Keine Reparaturkosten
  - Abrechnungsmodell: *Pay-as-you-go*
    - Kosten orientieren sich an tatsächlichem Ressourcenverbrauch
    - Feingranulare Abrechnung [Beispiele: Virtuelle Maschine: pro Stunde, Netzwerk: pro Megabyte]
    - Konsequenzen (Beispiele)
      * 1000 virtuellen Maschinen eine Stunde lang zu betreiben kostet genauso viel wie eine virtuelle Maschine 1000 Stunden lang zu betreiben
      * Keine Kosten für On-Demand-Dienste während der Standby-Phase, zum Beispiel im Rahmen von Garantieleistungen
  - In vielen Fällen: Verbesserte Ausfallsicherung
- Cloud-Anbieter
  - Vermietung überschüssiger Kapazitäten
  - Virtualisierung: Bereitstellung quasi unbegrenzter Ressourcen für Nutzer

Datenzentren

- Einsatz von *Commodity*-Hardware
  - Keine Spezialanfertigungen, sondern Hardware von der Stange
  - Vorteil: Günstige Einkaufspreise aufgrund großer Stückzahlen
  - Nachteile
    - Ausfälle werden zum Regelfall
    - Kompatibilitätsprobleme aufgrund heterogener Hardware
- Server-Konsolidierung durch Virtualisierung
  - Zusammenlegung von virtuellen Maschinen verschiedener Cloud-Nutzer auf demselben physischen Rechner
  - Vorteile
    - Höhere Auslastung einzelner Rechner
      [Ohne Virtualisierung: 2-3%, mit Virtualisierung: bis zu 80%. [Creeger]]
    - Kostenersparnis durch geringeren Platzbedarf
  - Nachteil: Optimale Isolation ist nicht immer erreichbar
    - Sicherheitsaspekt
    - *Performance Isolation*

Skalierbarkeit

- Problem von Firmen: Abschätzung der Auslastung ihrer für Endnutzer angebotenen Dienste und Bereitstellung entsprechender Ressourcen
  - Lastentwicklung eventuell unbekannt
  - Ungünstiges Verhältnis zwischen Spitzen- und Durchschnittslast
  - Starke Lastschwankungen
    - Über den Tag verteilt
    - Über das Jahr verteilt
- Mögliche Konsequenzen
  - Bereitstellung von zu wenigen Ressourcen (*Underprovisioning*)
  - Bereitstellung von zu vielen Ressourcen (*Overprovisioning*)
- Vorteile durch Cloud Computing
  - Verfügbarkeit neuer virtueller Maschinen im Minutenbereich
  - Dynamische Skalierbarkeit in beide Richtungen
  - Kosten orientieren sich am tatsächlichen Ressourcenverbrauch

Limitierungen und offene Fragen

- Technische Limitierungen
  - Nicht jede Anwendung lässt sich beliebig skalieren (z. B. Datenbanken)
  - Ineffizienter Transfer großer Datenmengen in die bzw. aus der Cloud
    [Amazon bietet daher die Möglichkeit Festplatten einzusenden: `http://aws.amazon.com/importexport/disk/`]
  - Instabile bzw. unvorhersehbare Performanz von schwer transparent zu isolierenden Operationen (z. B. Festplattenzugriffen)
  - Beschränkte Verfügbarkeitsgarantien durch Cloud-Anbieter
- Weiterführende Aspekte
  - Vertraulichkeit der Daten
  - Rechtliche Fragen (Beispiele)
    - Dürfen medizinische Daten in einer öffentlichen Cloud verarbeitet werden?
    - Werden gesetzliche Bestimmungen zum Speicherort von Daten eingehalten?
  - „*Vendor Lock-In*“-Problem
    - Starke Abhängigkeit von einem einzelnen Cloud-Anbieter
    - Erschwerter Anbieterwechsel
    - Gründe: fehlende Standards, aufwendiger Datentransfer

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*

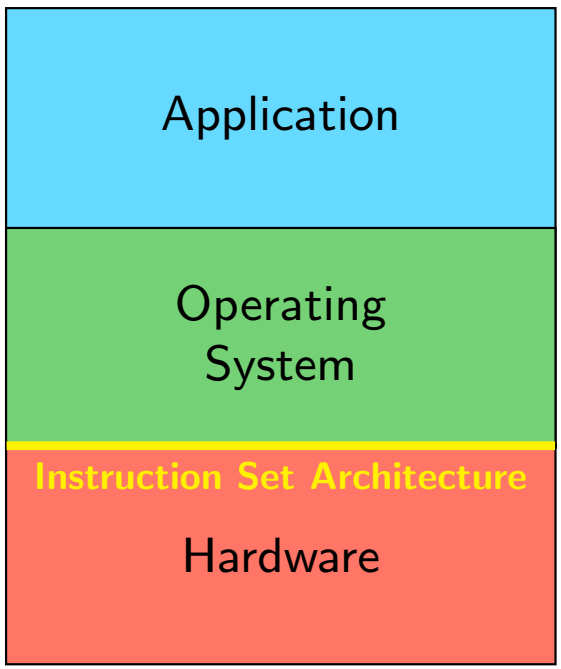

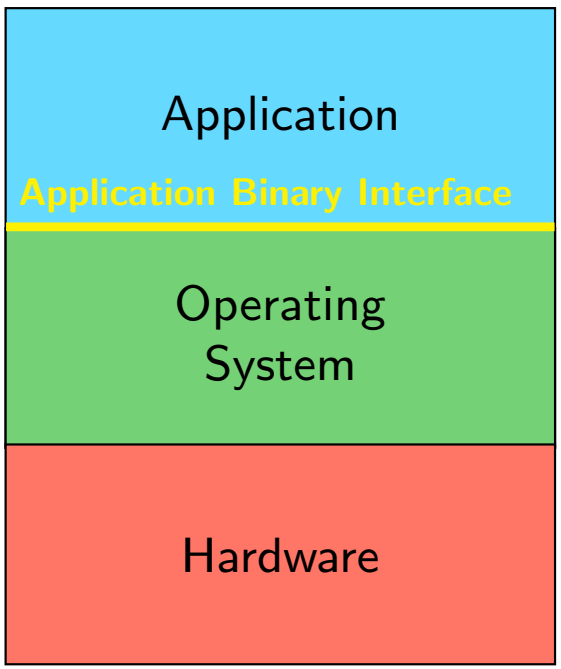

Wie wird die eigene Infrastruktur für andere nutzbar?

- Aufbau einer Infrastruktur-Cloud

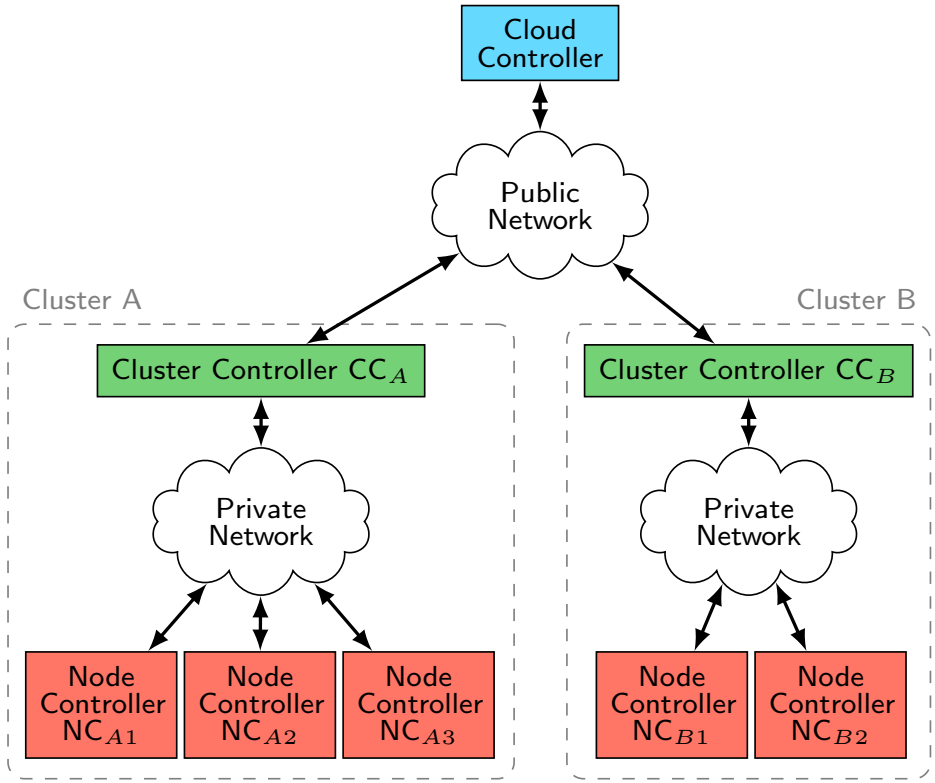

- Aufgabenbereiche
  - Verwaltung von physischen Maschinen
  - Verwaltung und Platzierung von virtuellen Maschinen
  - Anbindung an Datenspeicher

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, Yahoo,...
  - 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 Konfiguration 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