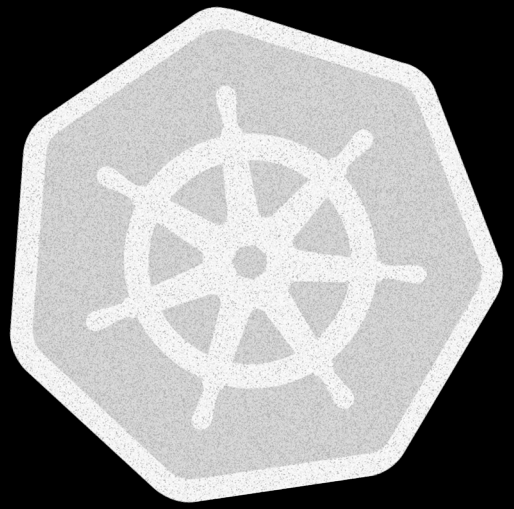

CLOUD NATIVE COMPUTING

CLOUD-NATIVE COMPUTING

Unit 05:

Container Orchestrierung

Stand: 27.03.23

PROF. DR.
NANE KRATZKE

KAPITEL 9

Container Plattformen

Nane Kratzke

Cloud-native Computing

Software Engineering von Diensten und Applikationen für die Cloud

284 Seiten. E-Book inside

€ 59,99. ISBN 978-3-446-46228-1

Weitere Informationen unter: **www.hanser-fachbuch.de** HANSER

CLOUD NATIVE COMPUTING

creative commons

CLOUD NATIVE COMPUTING

Urheberrechtshinweise

Diese Folien werden zum Zwecke einer praktikablen und pragmatischen Nutzbarkeit im Rahmen der **CCo 1.0 Lizenz** bereitgestellt.

Sie dürfen die Inhalte also kopieren, verändern, verbreiten, mit eigenen Inhalten mixen, auch zu kommerziellen Zwecken, und ohne um weitere Erlaubnis bitten zu müssen.

Eine Nennung des Autors ist nicht erforderlich (aber natürlich gern gesehen, wenn problemlos möglich).

Diese Folien sind insb. für die Lehre an Hochschulen konzipiert und machen daher vom **§51 UrhG (Zitate)** Gebrauch.

Die CCo Lizenz überträgt sich nicht auf zitierte Quellen. Hier sind bei der Nutzung natürlich die Bedingungen der entsprechenden Quellen zu beachten.

Die Quellenangaben finden sich auf den entsprechenden Folien.

INHALTSVERZEICHNIS

Überblick über Units und Themen dieses Moduls

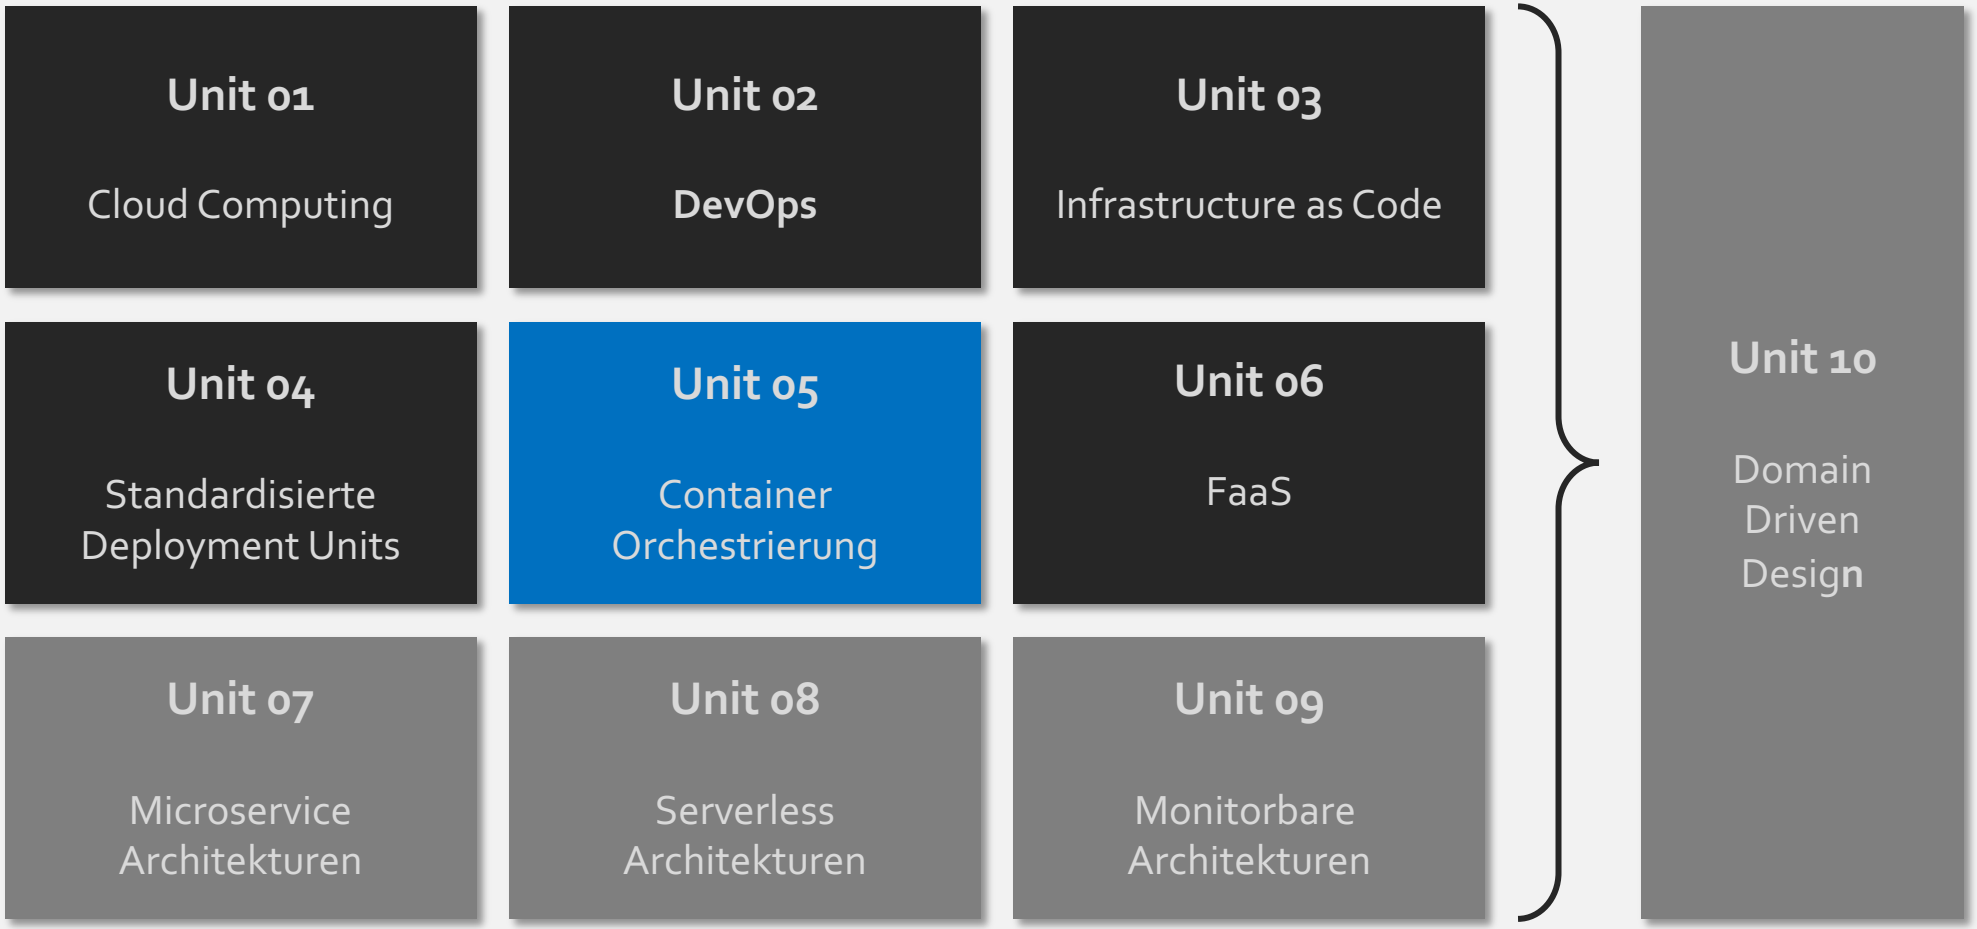

CLOUD NATIVE COMPUTING

DAS SCHICHTENMODELL DES CLOUD COMPUTINGS

Wo sind wir?

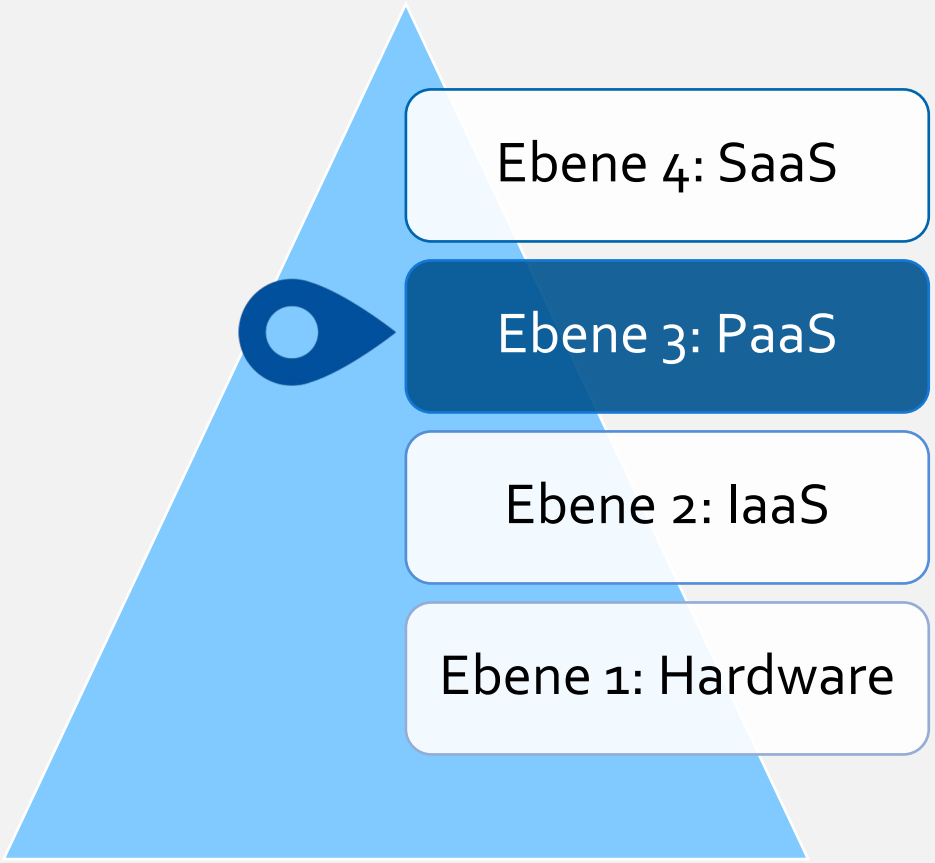

Kunden, Endnutzer
- Anpassbare Software-Dienste
- XaaS (Everything as a Service)
- Transparente Updates

Entwickler
- **Programmierschnittstellen (APIs)**
- **Plattformdienste**
- **Abstraktion der technischen Infrastruktur**

Administratoren
- Elastizität
- Virtuelle Ressourcenpools
- Technische Infrastruktur (VM, Storage, Network)

Rechenzentrum
- Rechner
- Netzwerk
- Storage

EINE KURZE GESCHICHTE DER CLOUD

Wo sind wir?

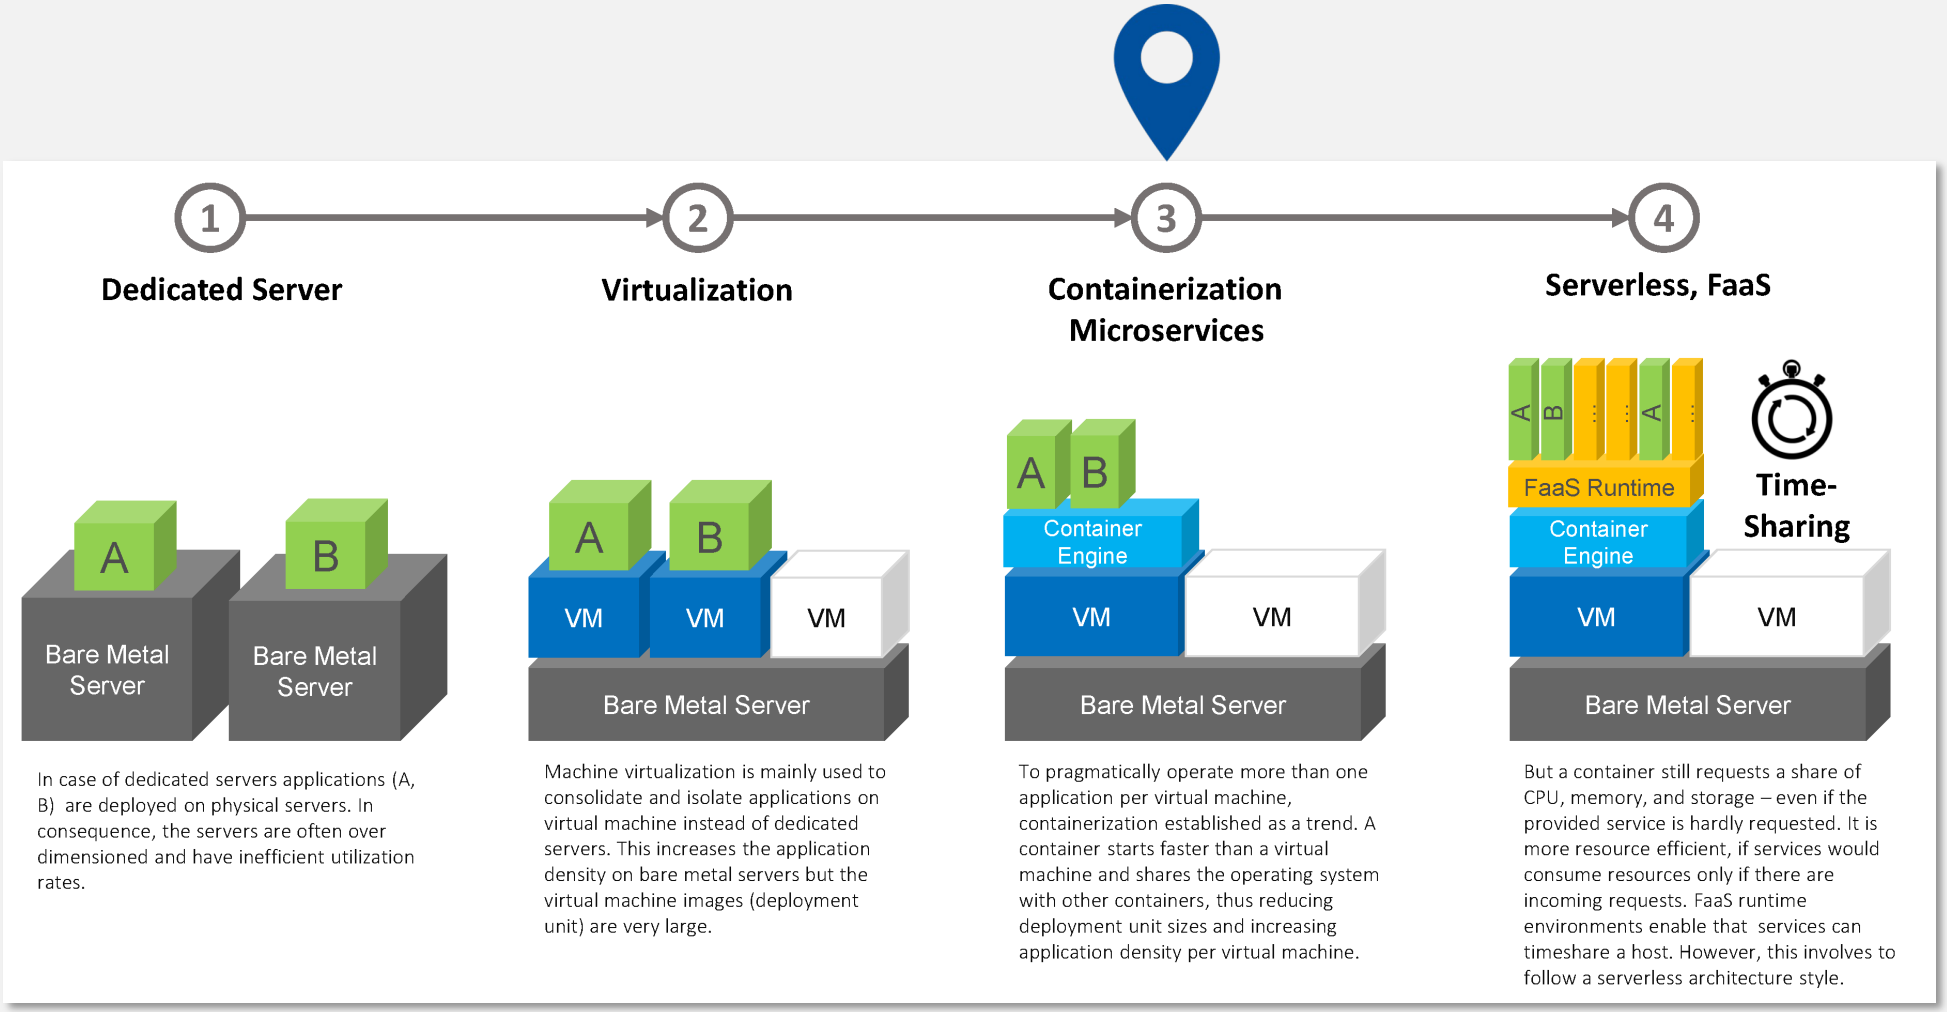

In case of dedicated servers applications (A, B) are deployed on physical servers. In consequence, the servers are often over dimensioned and have inefficient utilization rates.

Machine virtualization is mainly used to consolidate and isolate applications on virtual machine instead of dedicated servers. This increases the application density on bare metal servers but the virtual machine images (deployment unit) are very large.

To pragmatically operate more than one application per virtual machine, containerization established as a trend. A container starts faster than a virtual machine and shares the operating system with other containers, thus reducing deployment unit sizes and increasing application density per virtual machine.

But a container still requests a share of CPU, memory, and storage – even if the provided service is hardly requested. It is more resource efficient, if services would consume resources only if there are incoming requests. FaaS runtime environments enable that services can timeshare a host. However, this involves to follow a serverless architecture style.

INHALTE

Scheduling

- Scheduling Problem Definition
- Scheduling Algorithmen
- Scheduler Architekturen
- Beispiele von Cluster Schedulern: Mesos, Swarm

Orchestrierung

- Was ist Orchestrierung (in Abgrenzung zum Scheduling)?
- Was sind Blueprints?
- Container-Orchestrierungspatterns
- Überblick über bestehende Orchestrierungslösungen

Inside Kubernetes (Typ-Vertreter)

- K8S-Architektur
- K8S-Ressourcen
- Workloads, Persistenz, Isolation und Exponieren von Services

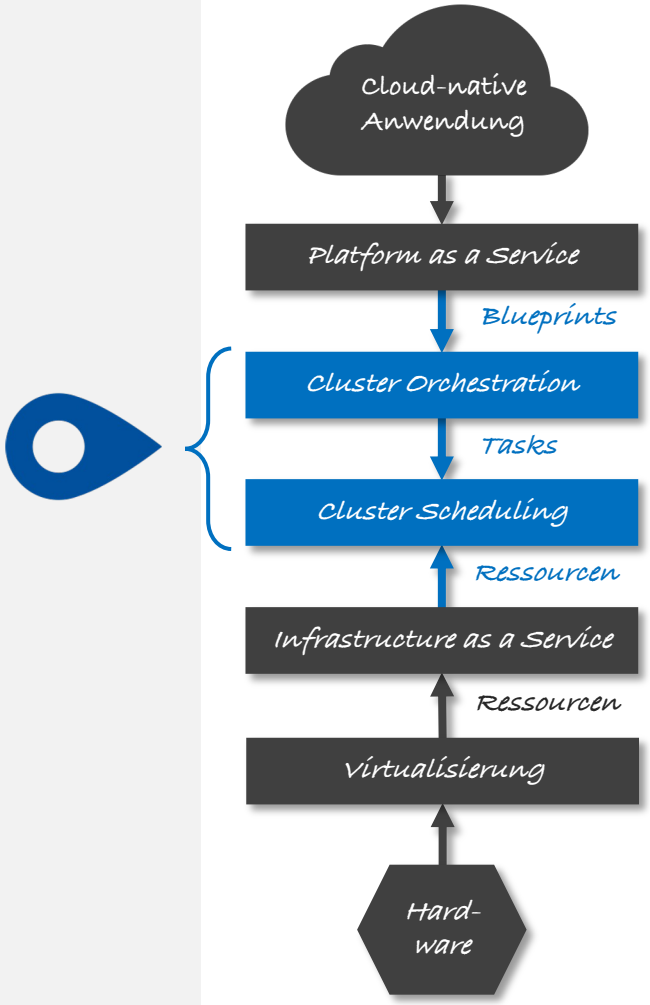

EINSTIEGSÜBUNG

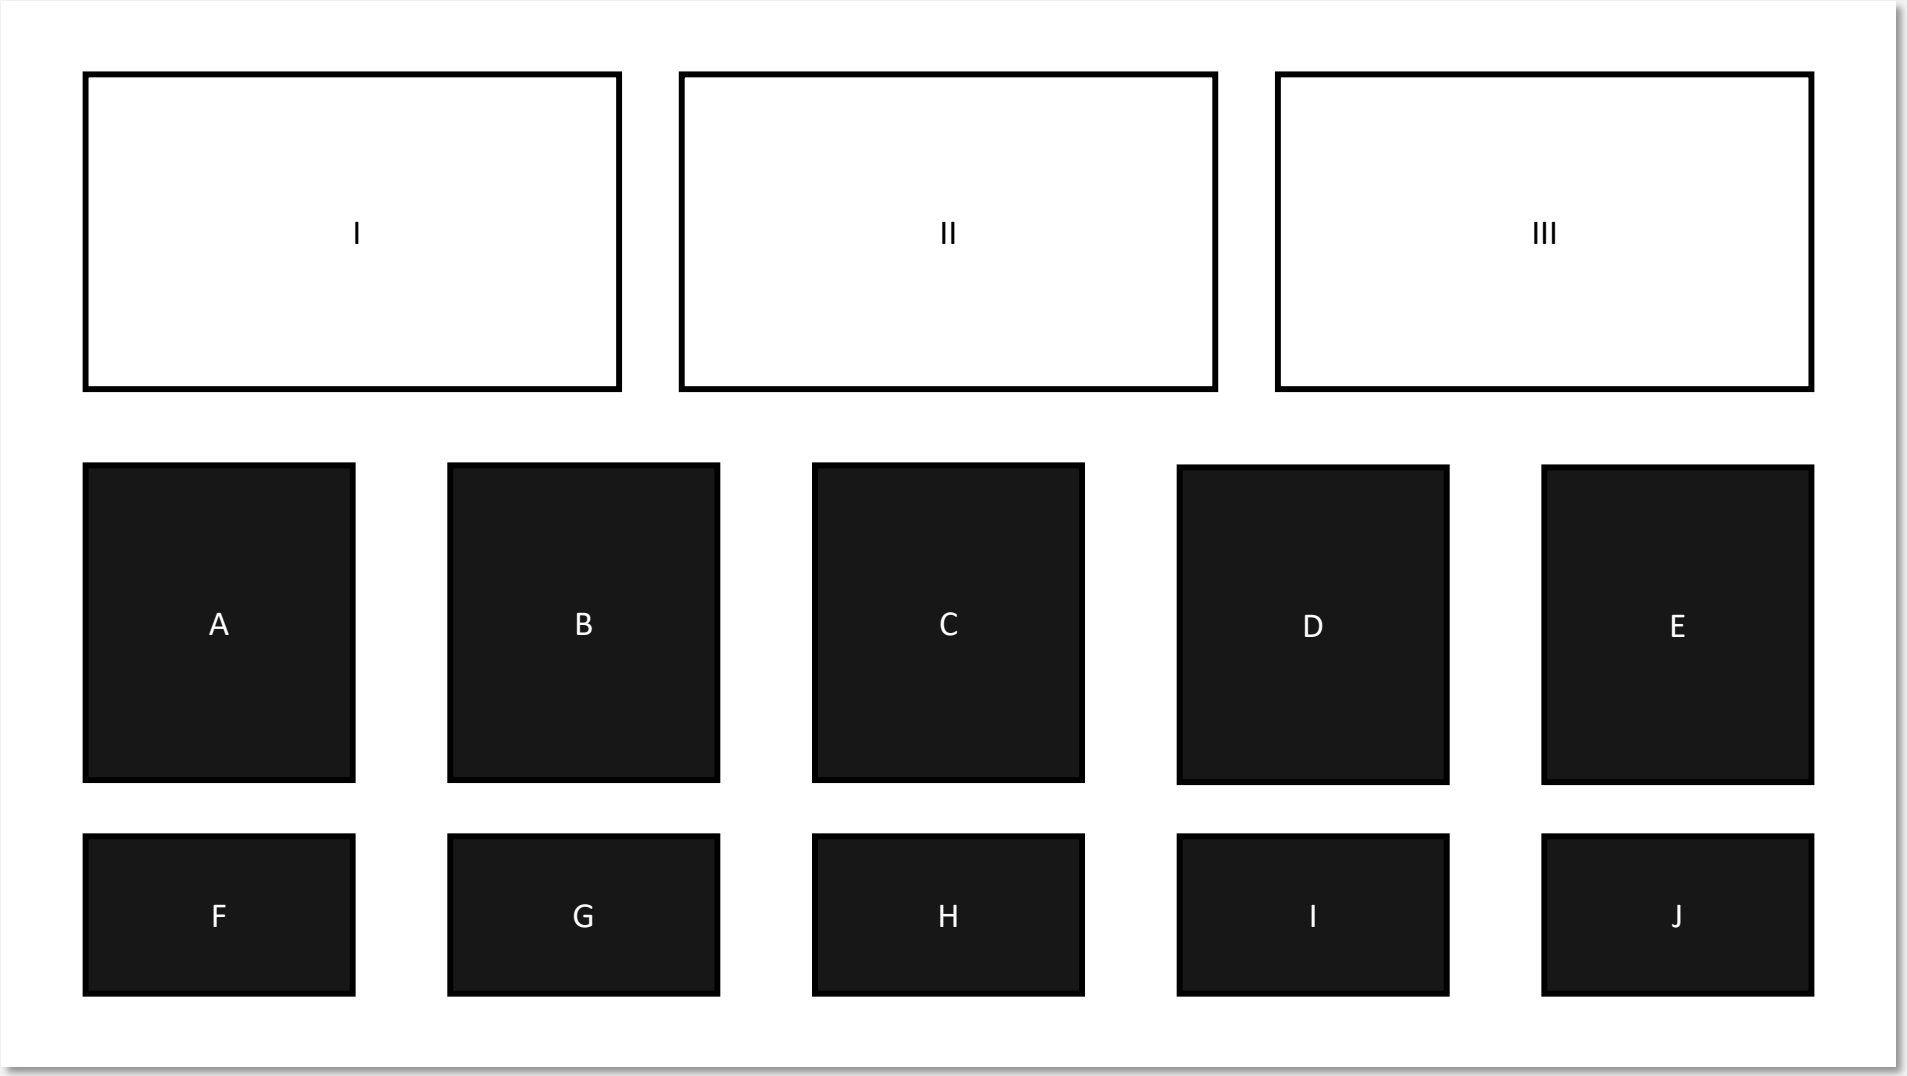

CLOUD NATIVE COMPUTING

Aufgabe:

Platzieren sie möglichst viele der schwarzen Kästen (A-J) in den weißen Kästen (I – III).

INHALTE

Scheduling

- Scheduling Problem Definition
- Scheduling Algorithmen
- Scheduler Architekturen
- Beispiele von Cluster Schedulern: Mesos, Swarm

Orchestrierung

- Was ist Orchestrierung (in Abgrenzung zum Scheduling)?
- Was sind Blueprints?
- Container-Orchestrierungspatterns
- Überblick über bestehende Orchestrierungslösungen

Inside Kubernetes (Typ-Vertreter)

- K8S-Architektur
- K8S-Ressourcen
- Workloads, Persistenz, Isolation und Exponieren von Services

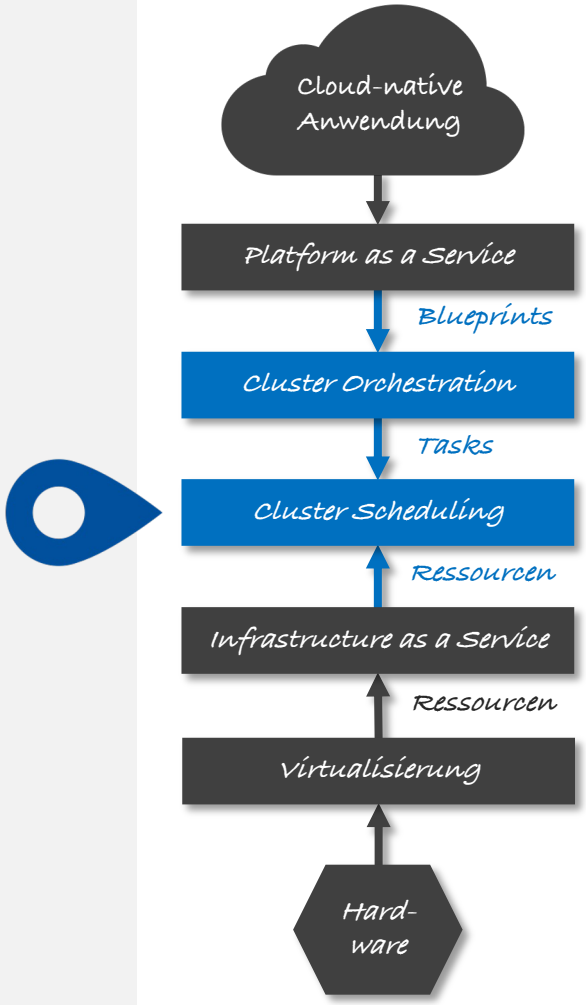

CLUSTER SCHEDULING

Das Problem

Rechenaufgaben
(Jobs/Workloads)

Wie möglichst Ressourcen-effizient und Aufgaben-angemessen zuteilen?

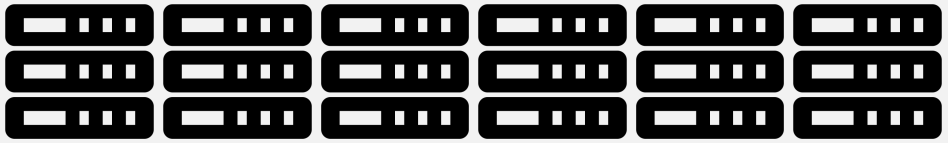

Rechenressourcen
(z.B. per IaaS oder GRID)

CLUSTER SCHEDULING

Terminologie

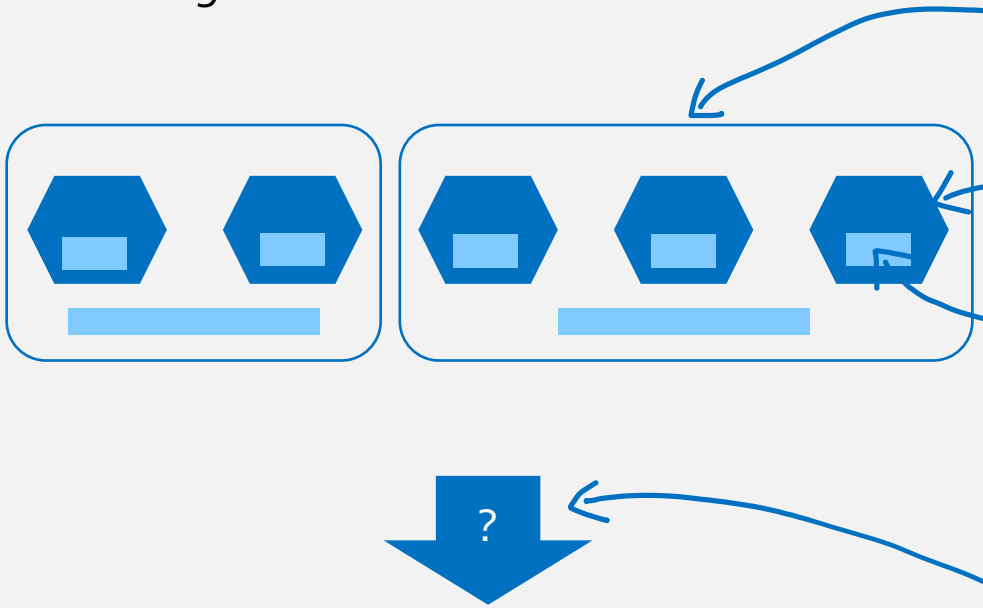

Job:
Menge an Tasks mit gemeinsamen Ausführungsziel. Die Menge an Tasks ist in der Regel als DAG mit Tasks als Knoten und Ausführungsabhängigkeiten als Kanten darstellbar.

Task:
Atomare Rechenaufgabe inkl. Ausführungsvorschrift.

Properties:
Ausführungsrelevante Eigenschaften der Jobs und Tasks

- Job: z.B. Abhängigkeiten der Tasks, Ausführungszeitpunkt
- Task: Ausführungsdauer, Priorität, Ressourcenbedarf

Scheduler:
Ausführung von Tasks auf den verfügbaren Ressourcen unter Berücksichtigung der Properties und zu optimierender Scheduling-Ziele (z.B. Fairness, Durchsatz, Ressourcenauslastung). Ein Scheduler kann präemptiv sein, also Tasks unterbrechen und neu aufsetzen.

Ressources:
Cluster an Rechnern mit CPU-, RAM-, (H/S)DD- und Netzwerkressourcen. Ein Rechner stellt seine Ressourcen temporär zur Ausführung eines oder mehrerer Tasks zur Verfügung (Slot). Die parallele Ausführung von Tasks ist isoliert zu einander.

CLUSTER SCHEDULER

Aufgaben

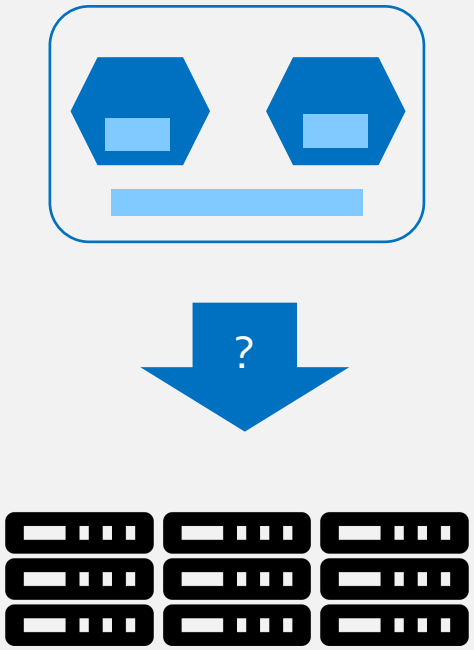

Cluster-Awareness:
Die aktuell verfügbaren Ressourcen im Cluster kennen (Knoten inkl. verfügbare CPUs, RAM, Diskspace, Netzwerkbandbreite). Dabei auch auf Elastizität reagieren (hinzufügen, entfernen von Knoten).

Job Allocation:
Zur Ausführung eines Workloads die passende Menge an Ressourcen für einen bestimmten Zeitraum bestimmen und allokieren.

Job Execution:
Einen Workload zuverlässig ausführen und dabei isolieren und überwachen.

SCHEDULING

Statische Partitionierung

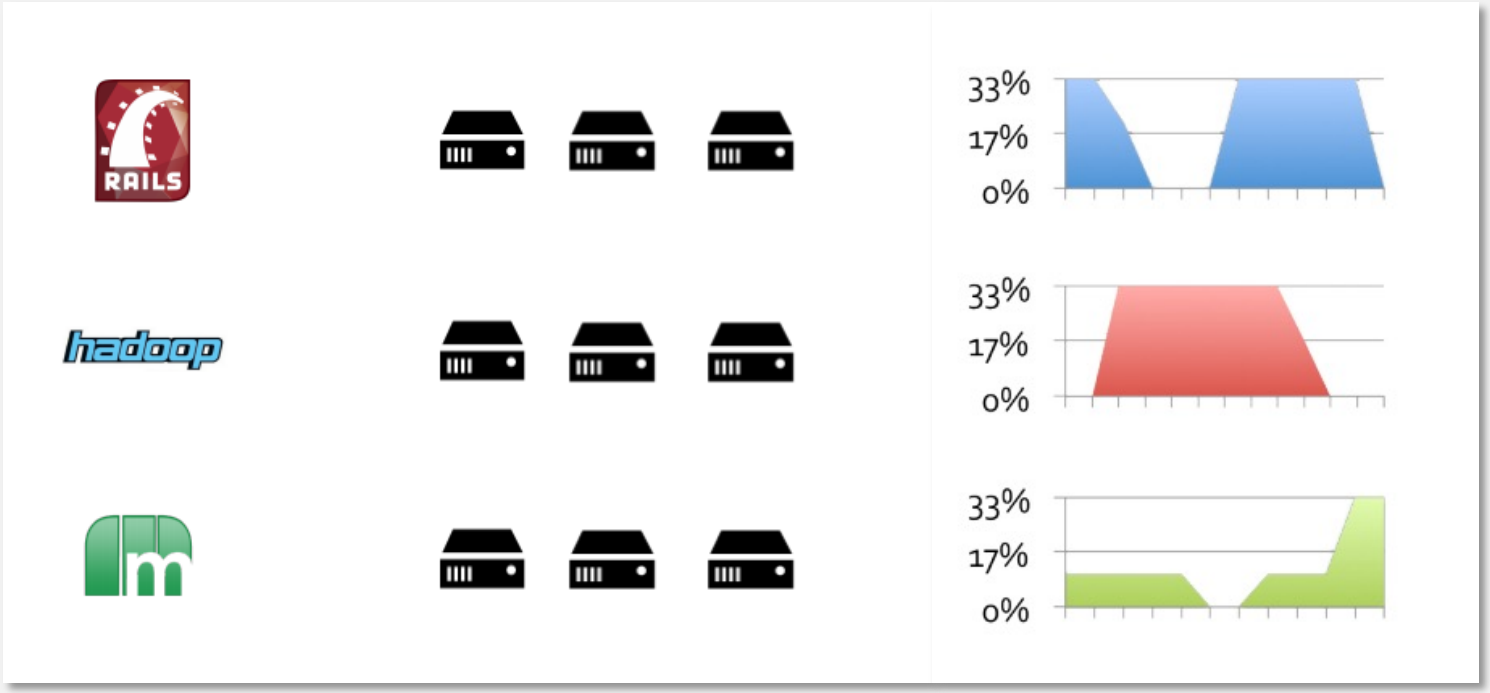

Vorteil:

- Einfach zu realisieren

Nachteil:

- Nicht flexibel bei sich ändernden Bedürfnissen
- Geringe Auslastung
- Hohe Opportunitäts-kosten

Benjamin Hindman:
„Static partioning considered harmful!"

Quelle: Benjamin Hindman, Practical Considerations for Multi-Level Schedulers (Keynote, 19th Workshop on Job Scheduling Strategies for Parallel Processing, 2015)
https://www.cs.huji.ac.il/~feit/parsched/jsspp15/p0-hindman.pdf

SCHEDULING

Hetereogenität

- In typischen Clustern sind Jobs (und deren Workload) üblicherweise sehr heterogen (Beispiel rechts).

- Charakteristische Unterschiede sind u.a.:
  - **Dauer:** Sekunden, Minuten, Stunden, Tage, unendlich
  - **Terminierung:** Sofort, später, zu einem def. Zeitpunkt
  - **Zweck:** Datenverarbeitung, Request-Handling
  - **Verbrauch:** CPU-, RAM-, HDD-, Netzwerk-dominant
  - **State:** Zustandsbehaftet, zustandslos

- Zu unterscheiden sind mindestens:
  - **Batch-Jobs:** Ausführungszeit üblicherweise im Minuten- bis Stundenbereich. Eher niedrige Priorität und gut unterbrechbar. Müssen häufig bis zu einem bestimmten Zeitpunkt abgeschlossen sein. Zustandsbehaftet.
  - **Service-Jobs:** Sollen auf unbestimmte Zeit unterbrechungsfrei laufen. Haben eine hohe Priorität und sollten nicht unterbrochen werden. Teilweise zustandslos.

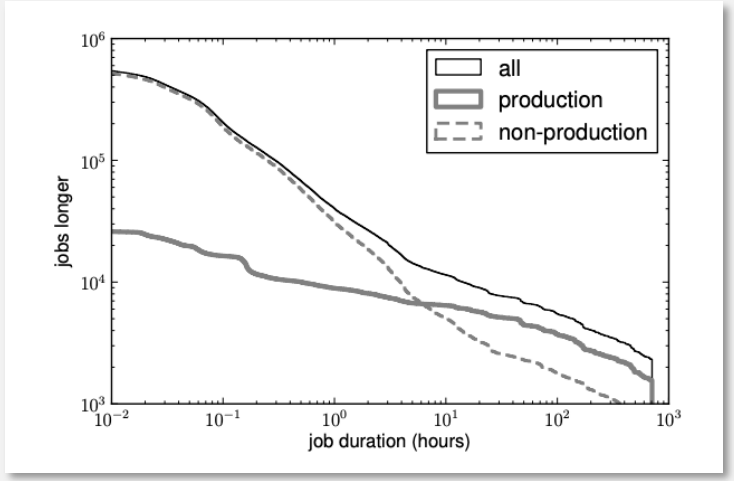

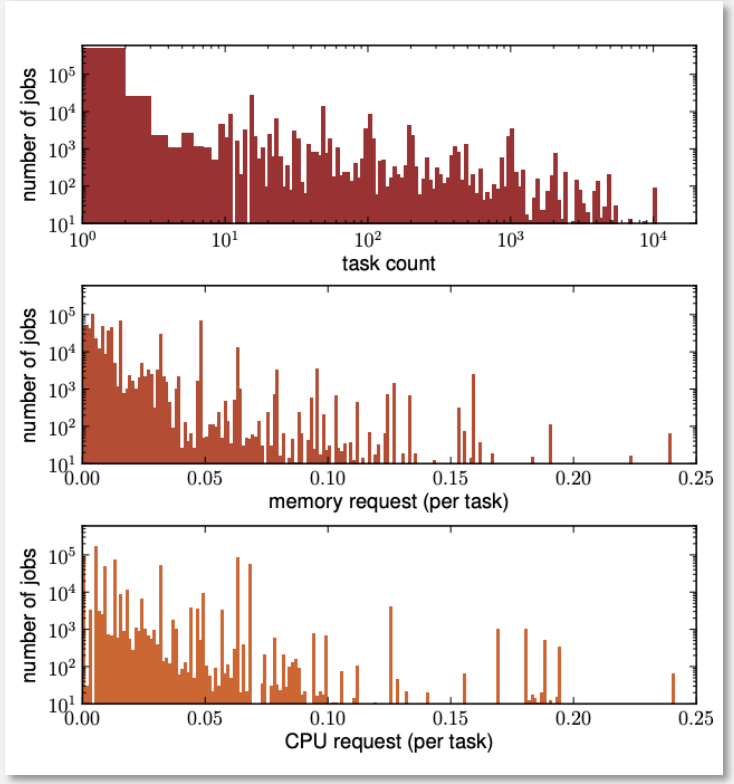

Quelle: Reiss et. al., Heterogeneity and Dynamicity of Clouds at Scale: Google Trace Analysis, 2012
https://www.pdl.cmu.edu/PDL-FTP/CloudComputing/googletrace-socc2012.pdf

CLOUD NATIVE COMPUTING

Beispiel einer Auswertung von Google Rechenzentren (Untersucht wurden 3 Plattformen mit insgesamt mehr als 10000 Knoten).

Es gibt zwar relativ viele kleine, Ressourcen-arme und kurze Jobs, aber eben nicht nur!

Cloud-Ressourcen können daher mittels dynamischer Partitionierung wesentlich effizienter genutzt werden.

„CPU and memory units are linearly scaled so that the maximum machine is 1." (siehe Quelle)

SCHEDULING

Awareness + Request → Optimierung → Placement Decision

Awareness über Jobs/Tasks (Properties) und Ressourcen

- **Ressource:** Welche Ressourcen stehen bereit, welchen Bedarf hat der Task?
- **Data:** Wo sind die Daten, die ein Task benötigt (Data locality)
- **QoS:** Welche Ausführungszeiten müssen garantiert werden?
- **Economy:** Welche Betriebskosten sind einzuhalten?
- **Priority:** Welche Priorität hat der Task?
- **Failure:** Wahrscheinlichkeit eines Ausfalls? (sind bspw. Racks für Wartung markiert?)
- **Experience:** Wie hat sich ein Task in der Vergangenheit verhalten?

Verarbeitung der Awareness-Daten im Cluster-Scheduler mittels Scheduling-Algorithmen entsprechend der jeweiligen beispielhaften Scheduling-Ziele:

Cluster-Scheduler

- **Fairness:** Kein Task soll unverhältnismäßig lange warten müssen, während ein anderer bevorzugt wird
- **Maximaler Durchsatz:** So viele Tasks pro Zeiteinheit wie möglich
- **Minimale Wartezeit:** Möglichst geringe Zeit von der Übermittlung bis zur Ausführung eines Tasks
- **Ressourcen-Auslastung:** Möglichst hohe Auslastung der verfügbaren Ressourcen
- **Zuverlässigkeit:** Ein Task wird garantiert ausgeführt
- **Minimierung der End-to-End Ausführungszeit** (z.B. durch Daten-Lokalität)

Placement Decision

- **Slot-Reservierung**
- **Slot-Stornierungen:** Im Fehlerfall, Optimierungsfalls, bei Constraint-Verletzungen

SCHEDULING

ist dummerweise eine NP-vollständige Optimierungsaufgabe

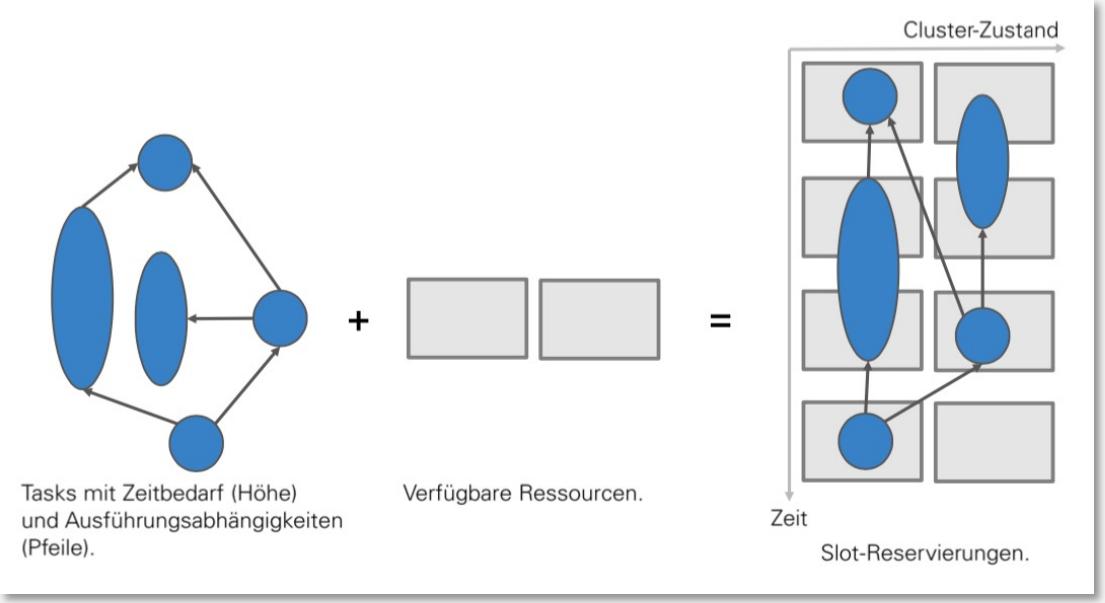

Darüber hinaus kommen Job-Anfragen üblicherweise kontinuierlich an, so dass selbst bei optimaler Allokation der Re-Organisationsaufwand pro Job unverhältnismäßig hoch werden kann.

Es ist also kein Algorithmus bekannt, der eine optimale Lösung in polynomialer Laufzeit erzeugt.

Ein Algorithmus muss für tausende Jobs und tausende Ressourcen skalieren.

Optimale Algorithmen, die den Lösungsraum komplett durchsuchen sind nicht praktikabel, da deren Entscheidungszeit zu lange dauert für große Eingabemengen (|Jobs| x |Ressourcen|).

Das Gute daran ist: Sie finden hier ein großes Feld für Forschung ;-)

SCHEDULING

Einfache Algorithmen

… optimieren das Scheduling von Tasks oft in genau einer Dimension (z.B. CPU-Auslastung) bzw. wenigen Dimensionen (CPU + RAM):

Populäre Algorithmen:

- **Binpack**
  Fit First => Hohe Auslastung von Knoten
- **Spread**
  Round Robin => Gleichmäßige Auslastung von Knoten

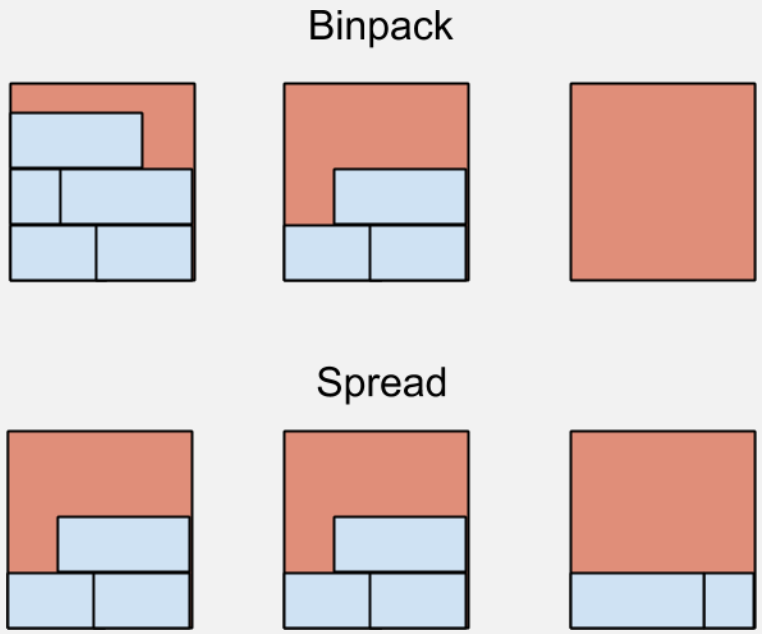

So arbeitet bspw. Docker Swarm

SCHEDULING

So arbeitet bspw. Mesos.

CLOUD NATIVE COMPUTING

Multidimensionale Algorithmen am Bsp. Dominant Resource Fairness (DRF)

Aufteilung der Ressourcen an verschiedene User (Kunden, Projekte, etc.)

Ausgangslage: Jeder User hat eine dominante Ressource, die besonders intensiv genutzt wird. Diese Ressource kann durch Beobachtung ermittelt werden.

Fairness Auffassung: Jeder User bekommt mind. 1/N aller Ressourcen der dominanten Ressourcen (equalize dominant share).

Der Scheduling Algorithmus ist also darauf ausgelegt, die dominanten Ressourcen pro User zu maximieren.

Beispiel:

Cluster mit:	9 CPU	18 GB Mem
User A Task benötigt:	1 CPU	4 GB Mem
User B Task benötigt:	3 CPU	1 GB Mem
Rel. Bedarf A Task:	1/9 CPU	**2/9 Mem**
Rel. Bedarf B Task:	**1/3 CPU**	1/18 Mem

$$a + 3b \leq 9 \quad \text{CPU constraint}$$
$$4a + b \leq 18 \quad \text{Memory constraint}$$
$$\frac{2}{9}a = \frac{b}{3} \quad \text{Equalize dominant shares}$$

Also:

$$\frac{2}{3}a = b \Rightarrow a \leq 3 \wedge a \leq 18\frac{3}{14} \approx 3.86$$
$$\Rightarrow a = 3 \wedge b = 2$$

Die Fairness kann auch noch gewichtet werden. Wenn ein Team doppelt so wichtig wäre, würde es in der Ausgangslage doppelt so viel Ressourcen bekommen.

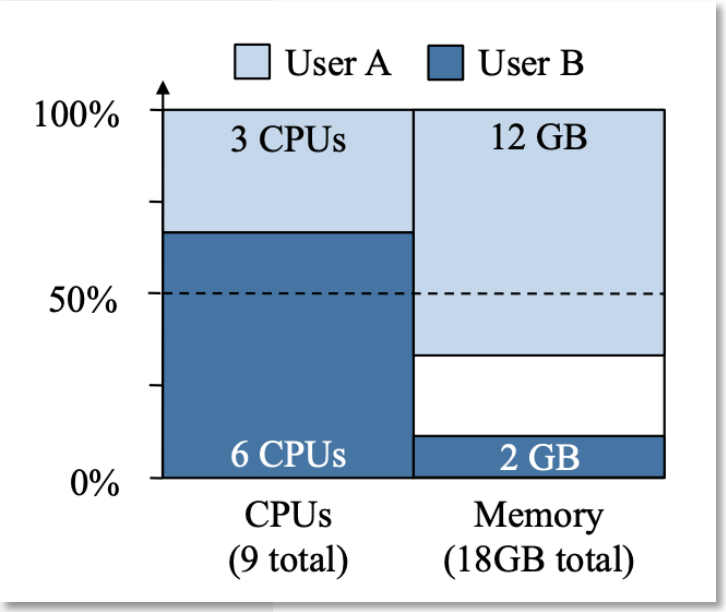

Quelle: Ali Ghodsi, Matei Zaharia, Benjamin Hindman, Andy Konwinski, Scott Shenker, and Ion Stoica. 2011. Dominant resource fairness: fair allocation of multiple resource types. https://dl.acm.org/doi/10.5555/1972457.1972490

SCHEDULING

Kapazitäts-basierte Algorithmen am Bsp. Capacity Scheduling (CS)

- Es werden Job Queues definiert und zu jeder Queue eine Kapazitätszusage in Ressourcenanteilen vom Cluster definiert.
- Fairness-Auffassung: Die minimale Kapazitätszusage wird stets eingehalten. Der Scheduling-Algorithmus stellt sicher, dass diese Fairness stets sichergestellt ist.
- Damit das Cluster dafür nicht statisch partitioniert werden muss, ist ein sog. Over-Commitment von Ressourcen erlaubt.
- Wird durch ein Over-Commitment aber eine Kapazitätszusage gefährdet, werden die over-committeten Ressourcen entzogen.
- Hierfür ist also ein präemptiver Scheduler notwendig.

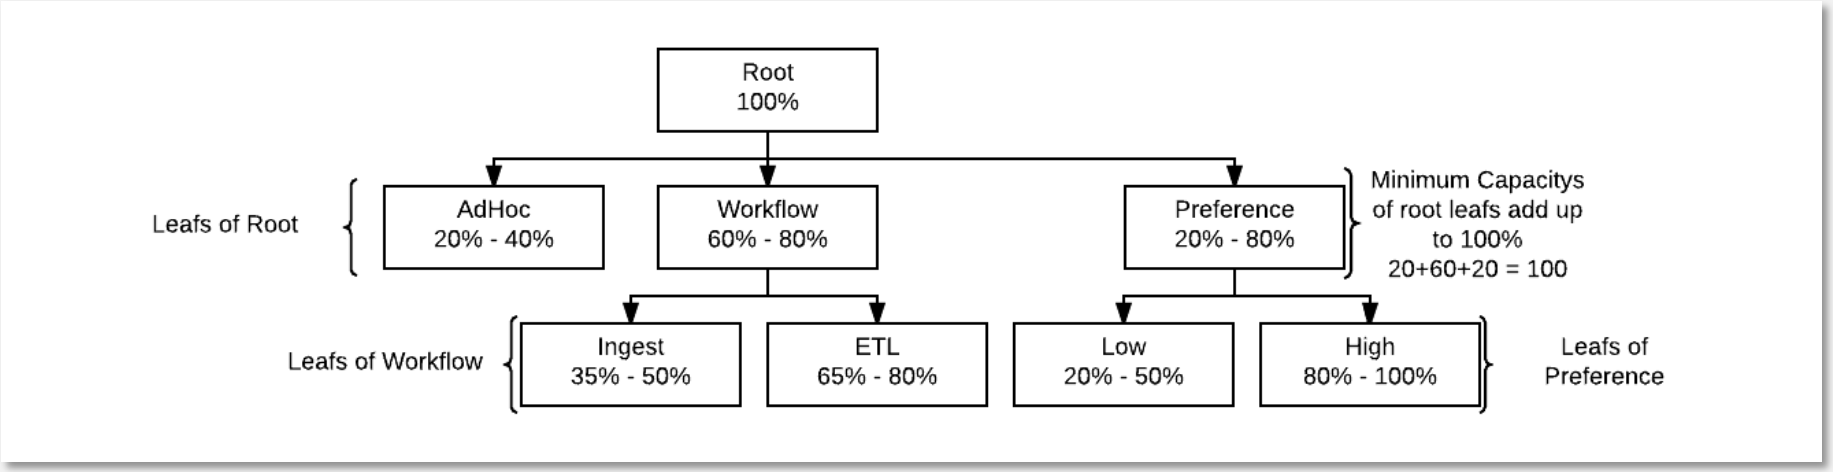

So arbeitet bspw. YARN (Yet Another Resource Negotiator) des Hadoop-Systems.

CLUSTER - SCHEDULER

The Datacenter as a Computer

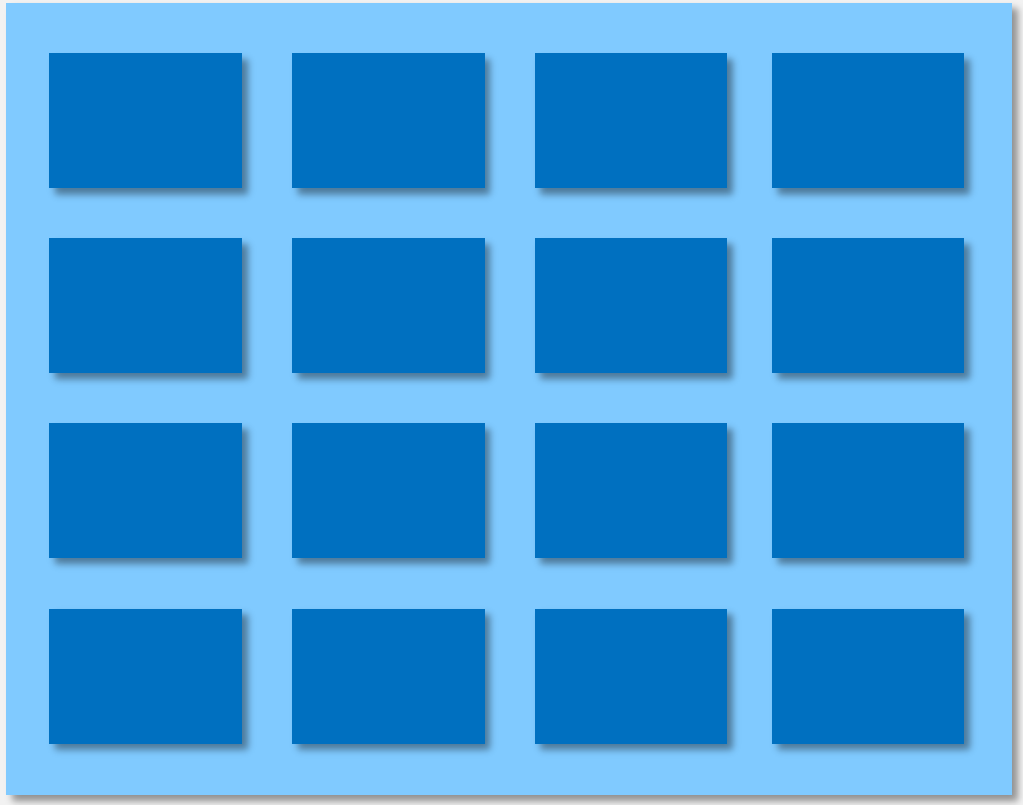

Idee:

Ein Cluster sieht von Außen aus wie ein großer Computer.

Konsequenz:

Es müssen als Fundament viele Konzepte klassischer Betriebssysteme übertragen werden (ein Cluster-Betriebssystem).

Das gilt insbesondere auch für das Scheduling.

CLUSTER - SCHEDULER

Eine konzeptionelle Architektur

Job Queue:
Eingehende Jobs zur Ausführung
Events zu eingegangen Jobs

Job Scheduler:
Jobs einplanen
Taskausführung steuern

Execution Monitor:
Taskausführung überwachen
Ressourcen überwachen

Executor:
Task ausführen
Informationen zur Ressource bereitstellen

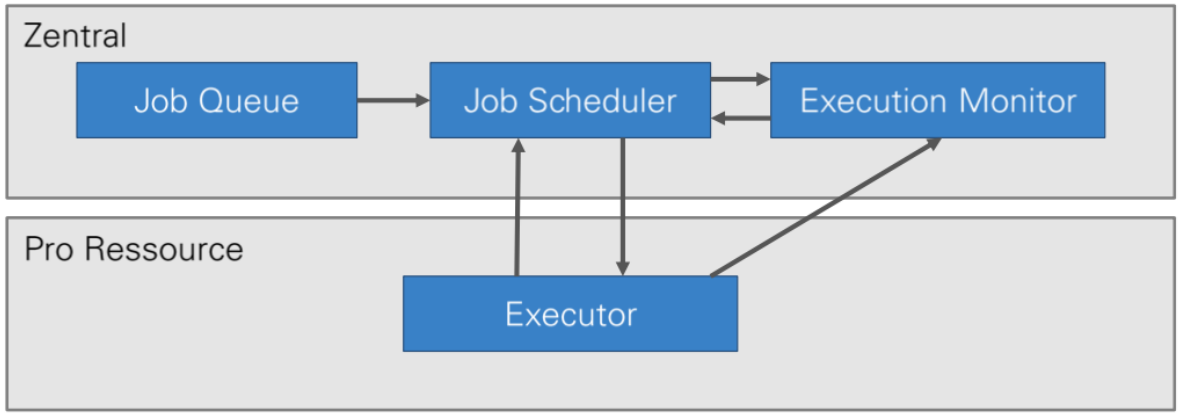

Anforderungen:

- Performance (Geringe Queueing-Time, Decision-Time, Ausführungslatenz)
- Hoch-Verfügbarkeit und Fehlertoleranz
- Skalierbarkeit bzgl. Anzahl an Jobs und verfügbaren Ressourcen

SCHEDULER ARCHITEKTUREN

Variante 1: Statische Partitionierung

Kann man kaum Scheduler nennen.

SCHEDULER ARCHITEKTUREN

Variante 2: Monolithischer Scheduler

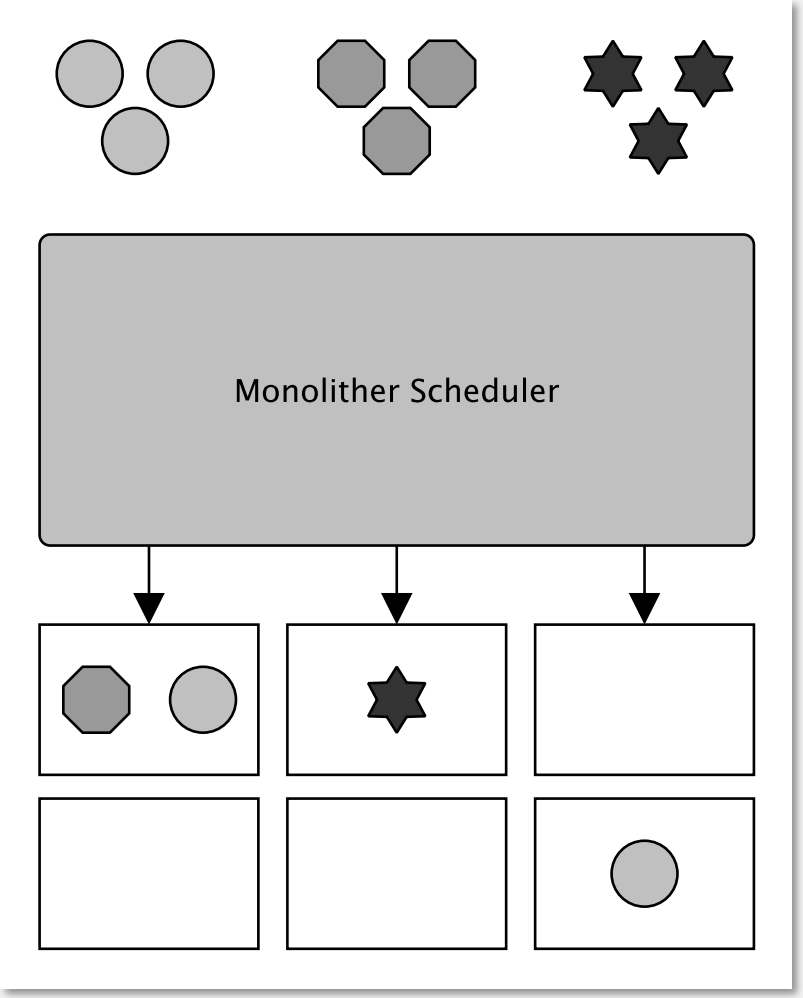

Vorteile:
Globale Optimierungsstrategien einfach möglich.

Nachteile:
Heterogenes Scheduling für heterogene Jobs schwierig.

- Komplexe und umfangreiche Implementierung notwendig
- … oder homogenes Scheduling geringer Effizienz.

Potenzielles Skalierbarkeits-Bottleneck.

Beispiele:

- *Google Borg*
- *Hadoop YARN*
- *Kubernetes*
- *Docker Swarm*

Quelle: Verma et al., Large-scale cluster management at Google with Borg, Proceedings of the European Conference on Computer Systems (EuroSys), ACM, Bordeaux, France (2015) https://storage.googleapis.com/pub-tools-public-publication-data/pdf/43438.pdf

SCHEDULER ARCHITEKTUREN

Variante 3: 2-Level Scheduler

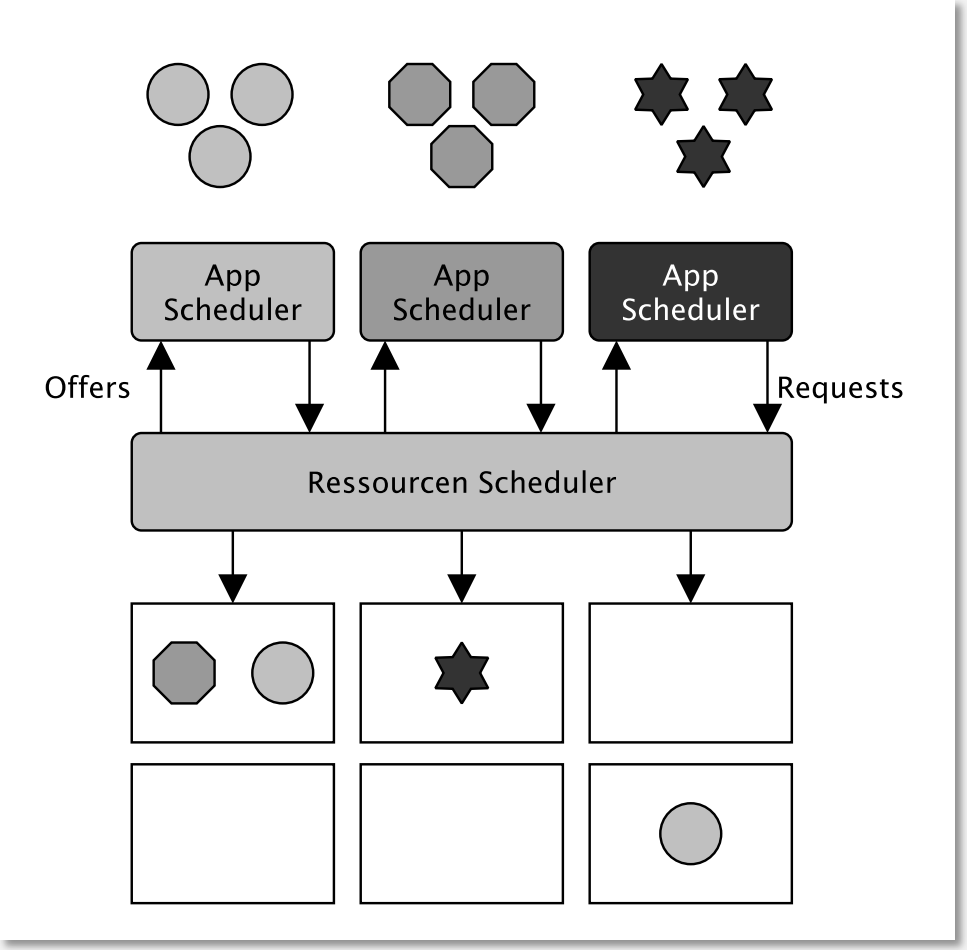

Auftrennung der Scheduling-Logik in einen Resource Scheduler und einen App Scheduler.

- Der **Resource Scheduler** kennt alle verfügbaren Ressourcen und darf diese allokieren. Er nimmt Ressourcen-Anfragen (Requests) entgegen und unterbreitet entsprechend einer Scheduling Policy Ressourcen-Angebote (Offers)
- Der **App Scheduler** nimmt Jobs entgegen und „übersetzt" diese in Ressourcen-Anfragen und wählt applikationsspezifisch die passenden Ressourcen-Angebote aus.

Offers sind eine zeitlich beschränkte Allokation von Ressourcen, die explizit angenommen werden muss.

Im Sinne der Fairness kann ein prozentualer Anteil der Ressourcen pro App Scheduler garantiert werden.

Beispiele:

- Apache Mesos

Vorteile:
Mit Mesos nachgewiesene Skalierbarkeit auf tausenden von Knoten (z.B Twitter, Airbnb, Apple Siri)

Flexible Architektur für heterogene Scheduling-Logiken

Nachteile:
App-Scheduler übergreifende Logiken nur schwer zu realisieren

Quelle: Benjamin Hindman, Andy Konwinski, Matei Zaharia, Ali Ghodsi, Anthony D. Joseph, Randy Katz, Scott Shenker, and Ion Stoica. 2011. Mesos: a platform for fine-grained resource sharing in the data center. https://people.eecs.berkeley.edu/~alig/papers/mesos.pdf

SCHEDULER ARCHITEKTUREN

Variante 4: Shared-State-Scheduler

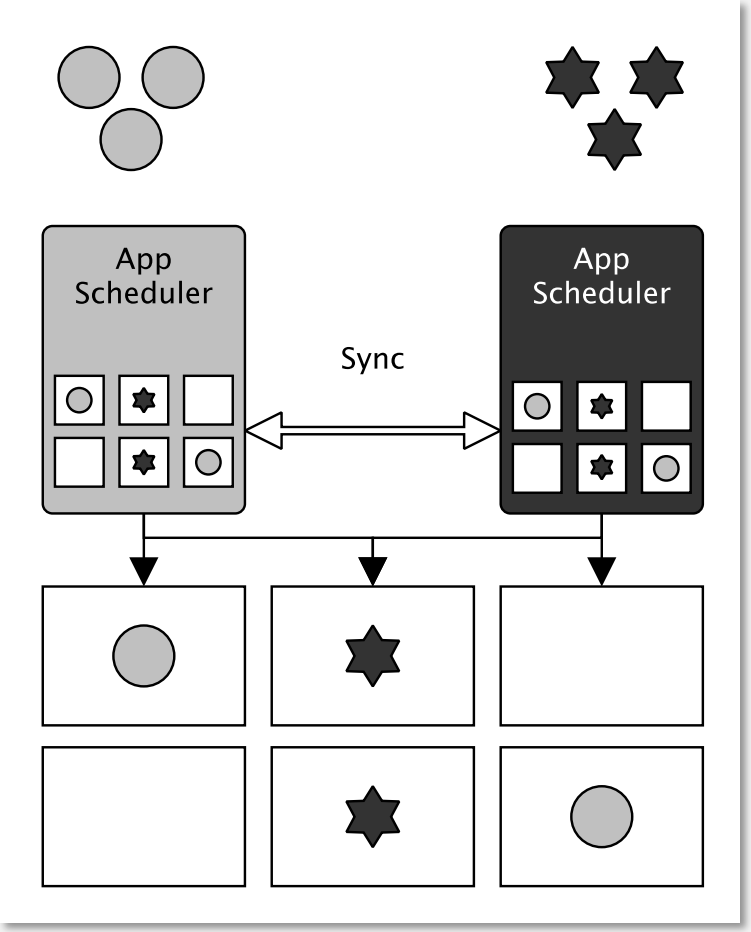

Es gibt ausschließlich applikationsspezifische Scheduler.

Die App-Scheduler synchronisieren kontinuierlich den aktuellen Zustand des Clusters (Job-Allokationen und verfügbare Ressourcen).

Jeder App-Scheduler entscheider die Platzierung von Tasks auf Basis des ihm bekannten aktuellen Cluster-Zustands.

Optimistische Strategie: Ein zentraler Koordinierungsdienst erkennt Konflikte im Scheduling und löst diese auf, in dem er Zustands-Änderungen nur für einen der beteiligten App-Scheduler erlaubt und für die anderen App-Scheduler einen Fehler meldet.

Beispiele:

- Google Omega

Vorteile:
Tendenziell geringerer Kommunikations-Overhead.

Nachteile:
Komplettes Scheduling muss pro App-Scheduler entwickelt werden.

Keine globalen Scheduling-Ziele (z.B. Fairness) möglich.

Skalierbarkeit in großen Clustern unklar, da noch nicht in der Praxis erprobt und insbesondere Auswirkung bei hoher Anzahl an Konflikte ungeklärt.

Quelle: Schwarzkopf et al. Omega: flexible, scalable schedulers for large compute clusters, SIGOPS European Conference on Computer Systems (EuroSys), ACM, Prague, Czech Republic (2013), https://storage.googleapis.com/pub-tools-public-publication-data/pdf/41684.pdf

BEISPIELE

Apache Mesos

- Entstanden an der UC Berkely im Rahmen der Arbeiten von Benjamin Hindman (1. Release 2009)
- Open Source Project unter Apache Lizenz 2.0
- Im Kern ein Cluster-Scheduler.
- Mesos ist als Cluster-Scheduler in DC/OS (Open Source Cluster-Betriebssystem) enthalten.
- 2-Level Scheduler (Dominant Ressource Fairness)
- Alle Bestandteile von Mesos können ausfallsicher ausgelegt werden.
- Wird im großen Stil bei Twitter, Apple, Microsoft, Verizon, CERN, Airbnb, … eingesetzt.
- Alle Teile sind per REST-API zugänglich.
- Task-Isolation per Docker oder eigenem Mechanismus.

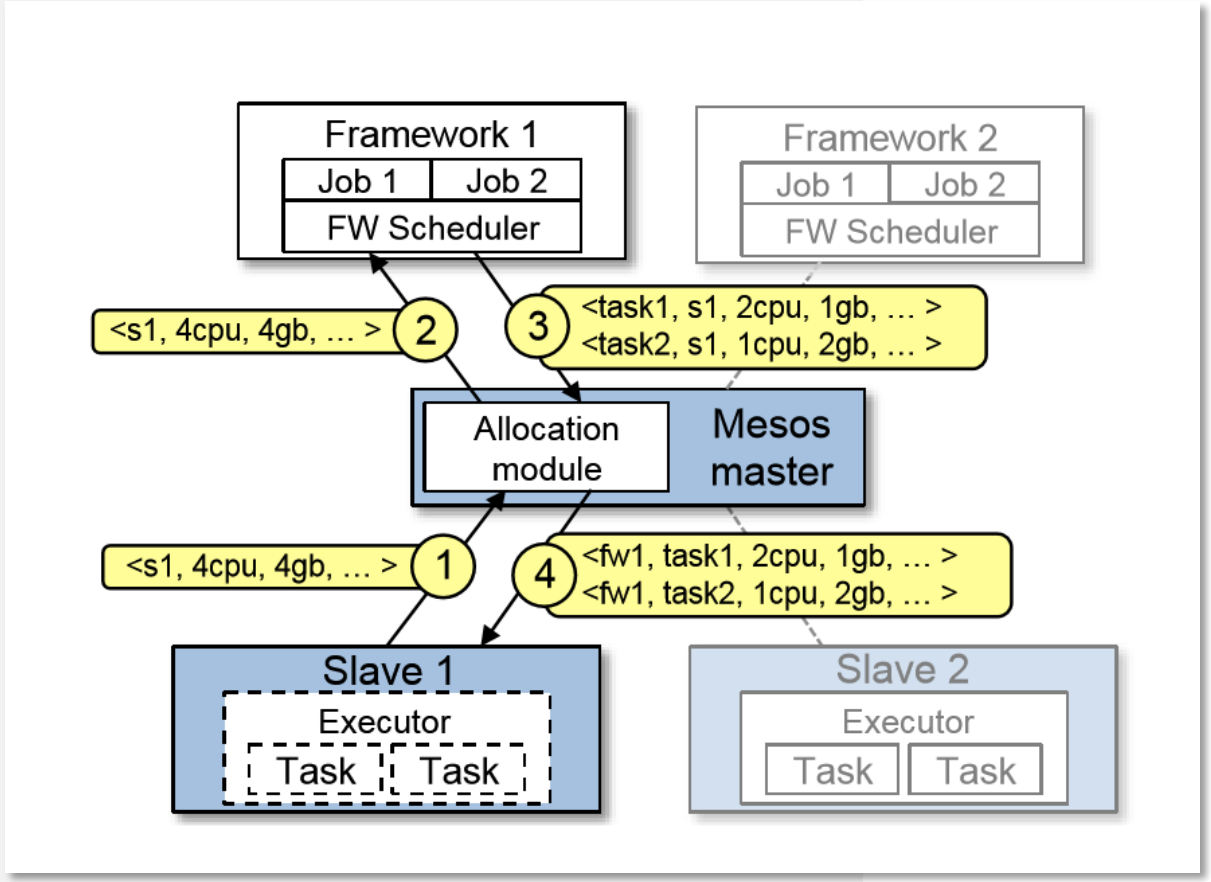

Quelle: Benjamin Hindman, Andy Konwinski, Matei Zaharia, Ali Ghodsi, Anthony D. Joseph, Randy Katz, Scott Shenker, and Ion Stoica. 2011. Mesos: a platform for fine-grained resource sharing in the data center. https://people.eecs.berkeley.edu/~alig/papers/mesos.pdf

BEISPIELE

Apache Mesos + Marathon

- Marathon ist ein 2nd-Level-Scheduler der auf die Ausführung von zustandslosen Services ausgelegt ist.
- Autor: Tobi Knaup (Ziel: Langlaufende zustandslose Services zuverlässig ausführen)
- Besitzt eigenständig Web-UI und REST-API
- Prozesse werden kontinuierlich am Leben gehalten. Terminiert ein Prozess, so wird er automatisch wieder gestartet.
- Mechanismen für Health-Checking von Services.
- Eingebauter Mechanismus für Service-Discovery und Load-Balancing.

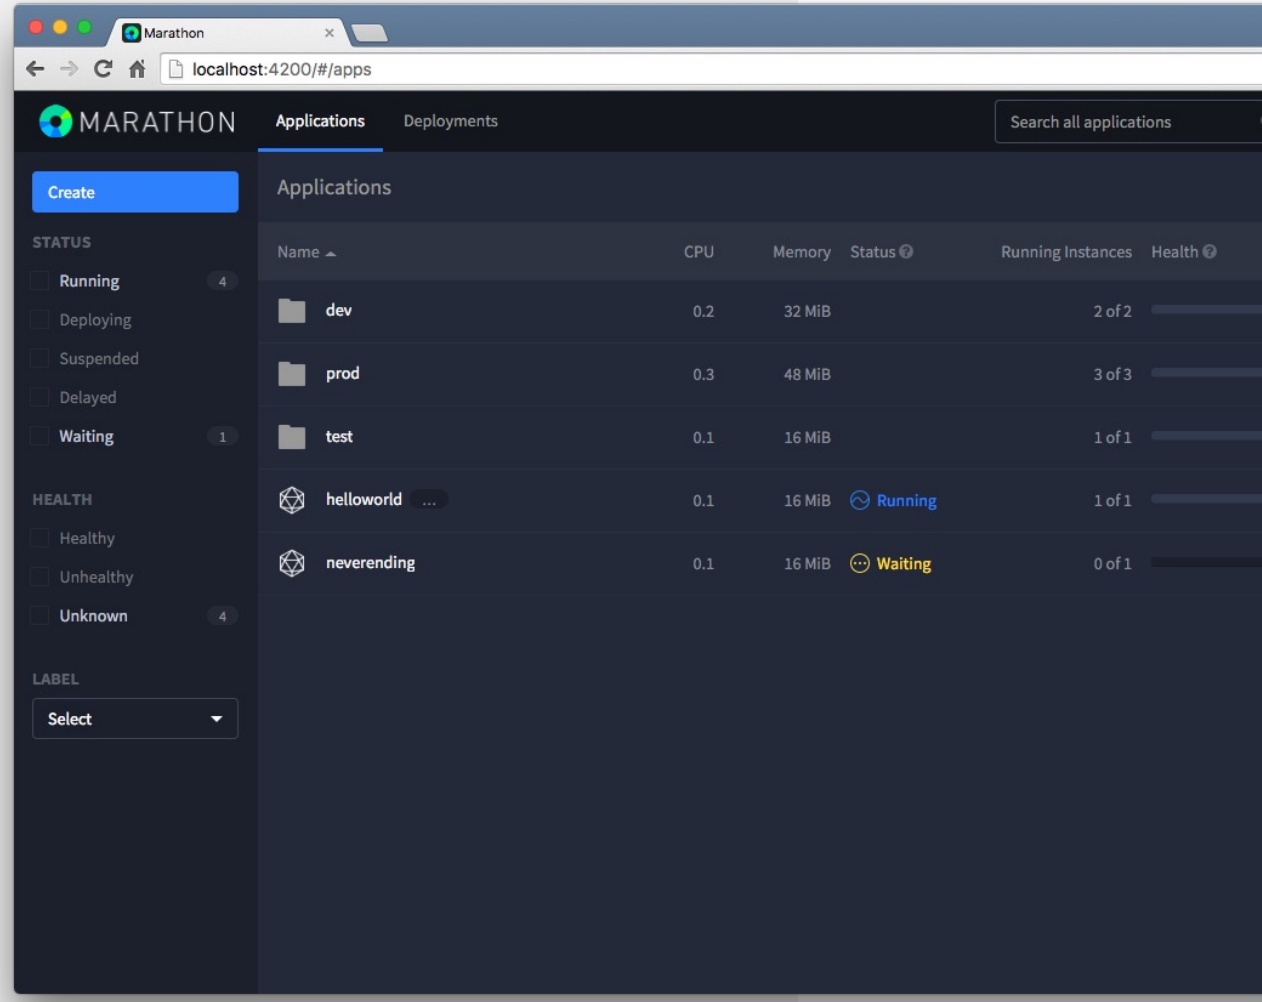

https://github.com/mesosphere/marathon

BEISPIELE

Docker Swarm

- Ein Docker Swarm besteht aus mehreren Docker Nodes, die im sogenannten Swarm Mode laufen.
- Die Nodes sind Manager, Worker, oder auch beides.
- Manager verteilen die Tasks auf die Worker.
- Die Aufgabe der Worker ist die Ausführung der Container.
- Ein Task ist ein laufender Container, der Teil eines Swarm Services ist.
- Für Services gibt man den Container, die auszuführenden Commands und bei Bedarf weitere Konfigurationen an.

Scheduling gem. Spread Strategy

- Ein Task (Container) werden gleichmäßig auf die Nodes verteilt.
- Ein Task wird einem Node zugewiesen der noch keinen Task für den Service ausführt.
- Wenn schon alle Nodes einen Task für dessen Service ausführen, wird der Node gewählt, der die wenigsten Tasks für diesen Service ausführt.
- Zusätzlich lassen sich Ressourcenbedarf und Limits angeben. Können diese auf dem eigentlich zugewiesenen Node nicht erfüllt werden, wird der nächst mögliche Node gewählt.
- Mittels Constraints und Preferences lassen sich weitere Randbedingungen für das Scheduling formulieren.

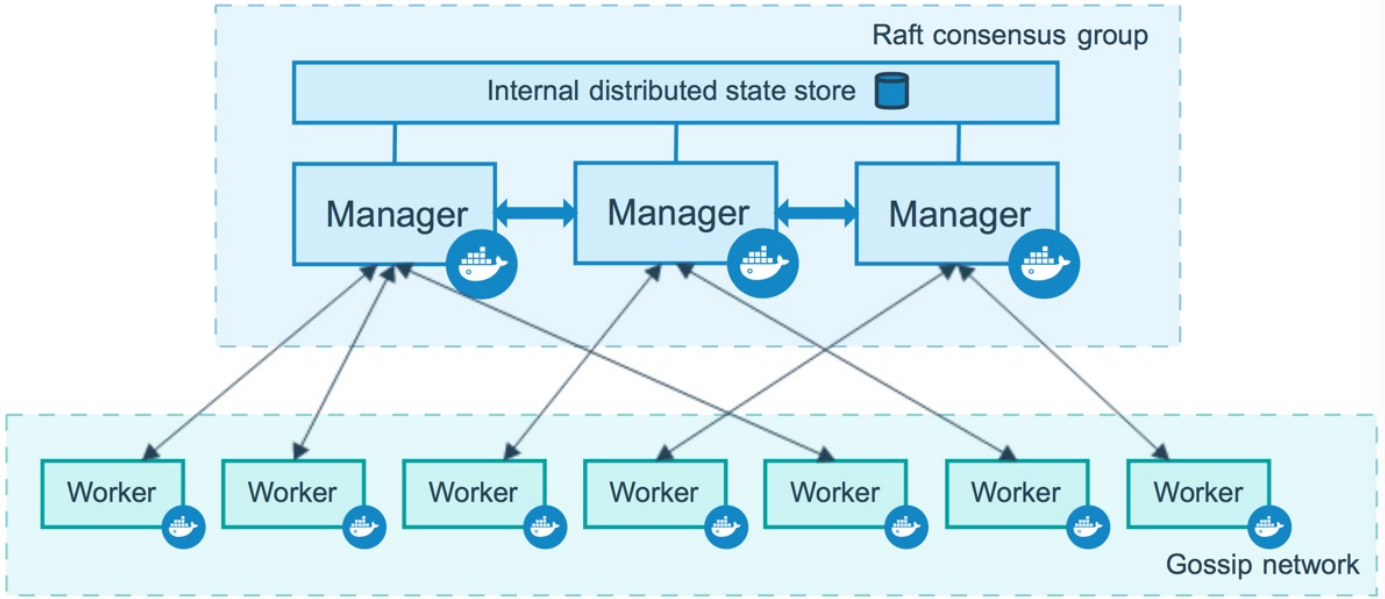

Quelle: https://docs.docker.com/engine/swarm/how-swarm-mode-works/nodes/

INHALTE

Scheduling

- Scheduling Problem Definition
- Scheduling Algorithmen
- Scheduler Architekturen
- Beispiele von Cluster Schedulern: Mesos, Swarm

Orchestrierung

- Was ist Orchestrierung (in Abgrenzung zum Scheduling)?
- Was sind Blueprints?
- Container-Orchestrierungspatterns
- Überblick über bestehende Orchestrierungslösungen

Inside Kubernetes (Typ-Vertreter)

- K8S-Architektur
- K8S-Ressourcen
- Workloads, Persistenz, Isolation und Exponieren von Services

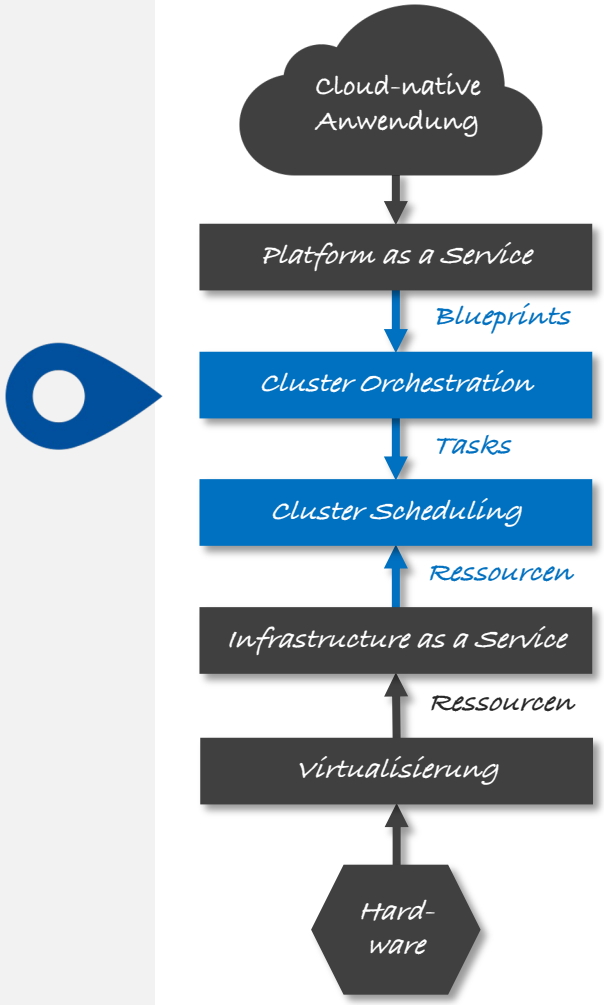

BACK TO BIG PICTURE

Orchestrierung

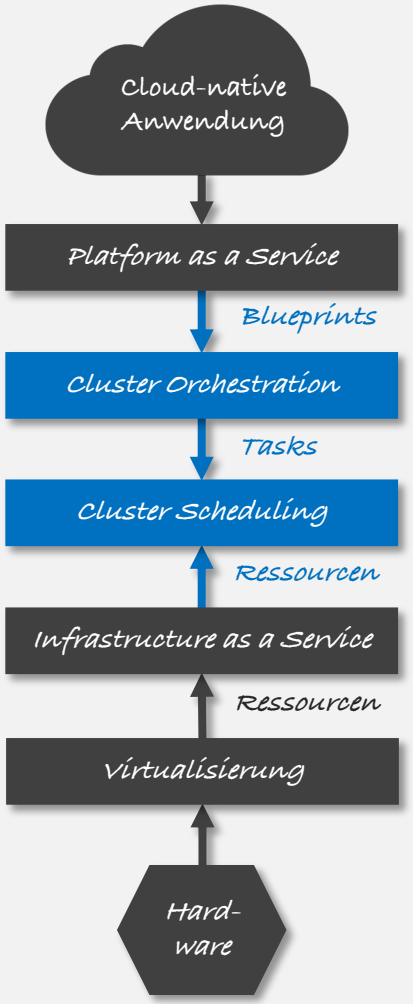

3 x NGINX Webserver + vorgelagerter HAproxy (ausfallsicher)

3 Instanzen NGINX, mind. 2 Instanzen HAproxy mit Liveness Probes

„How would you design your infrastructure if you couldn't login. Never!"

Kelsey Hightower

ORCHESTRIERUNG

Unterschiedliche DevOps-Perspektiven

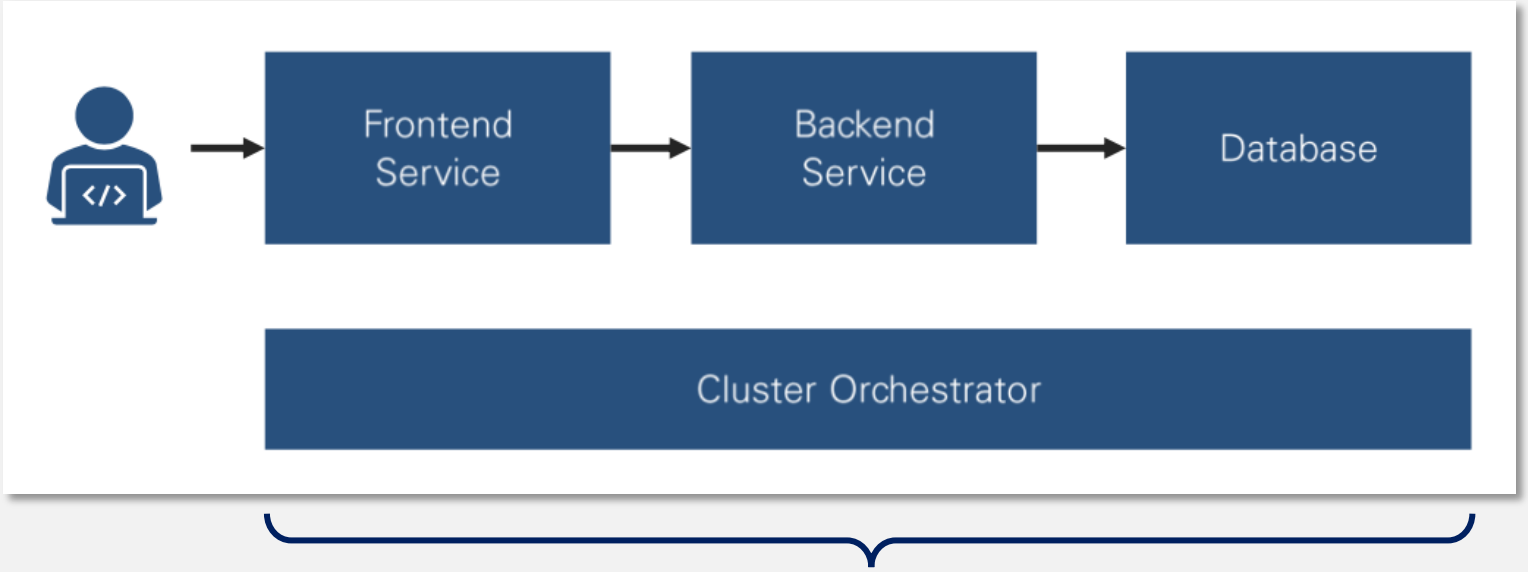

Dev-Perspektive

Anwendungen
Betriebssystem
Abhängigkeiten

Ops-Perspektive

Deployment
Networking
Service-Discovery (auch Dev)
Rescheduling

Scaling
Load Balancing
Logging + Analytics
Failure Recovery

Quelle: QAware GmbH
https://github.com/qaware/cloudcomputing

ORCHESTRIERUNG

Was ist Cluster-Orchestrierung?

Eine Anwendung, die in mehrere Betriebskomponenten aufgeteilt ist, auf mehreren Knoten laufen lassen.

Führt Abstraktionen zur Ausführung von Anwendungen mit ihren Services in einem (großen) Cluster ein.

Orchestrierung ist keine statische, einmalige Aktivität wie die Provisionierung, sondern eine dynamische, **kontinuierliche Aktivität**.

Orchestrierung hat den Anspruch, alle Standard-Betriebsprozeduren einer Anwendung zu automatisieren.

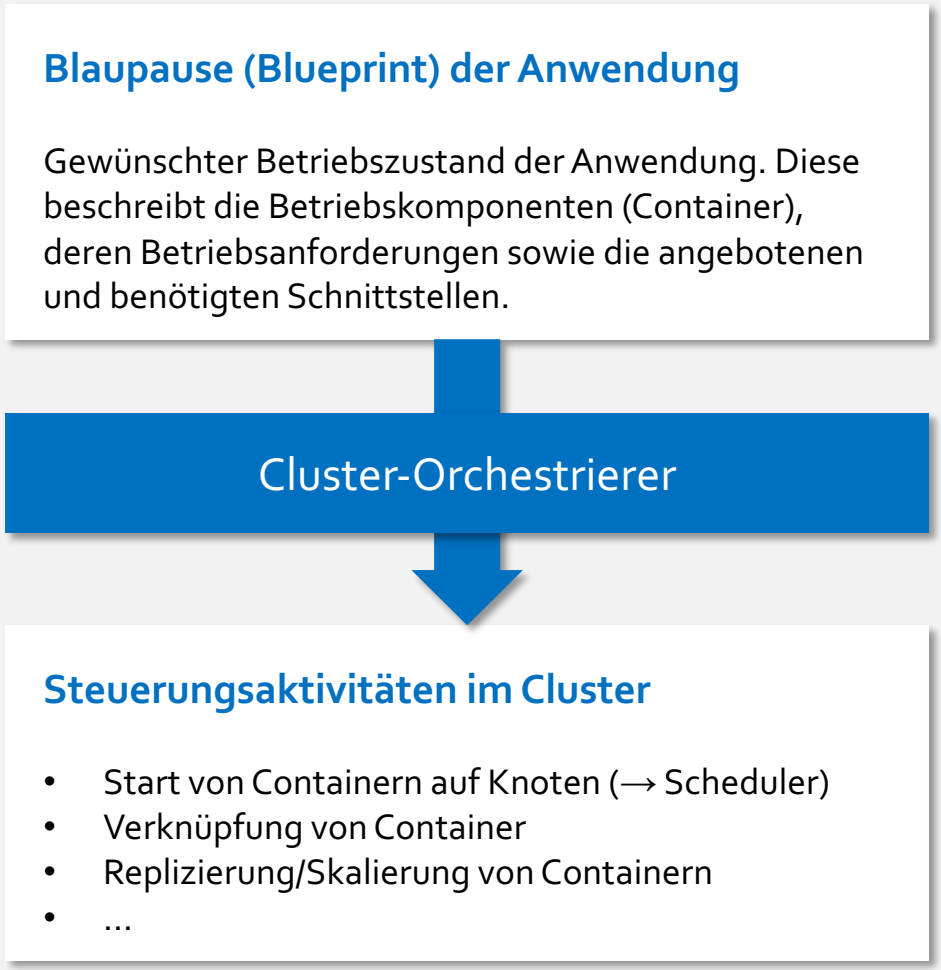

Quelle: QAware GmbH
https://github.com/qaware/cloudcomputing

CLUSTER - ORCHESTRIERER

Automatisierung von Betriebsaufgaben auf einem Cluster

- Scheduling von Containern mit Applikations-spezifischen Constraints (z.B. Affinities und Anti-Affinities)
- Aufbau von notwendigen Netzwerk-Verbindungen zwischen Containern.
- Bereitstellung von persistenten Speichern für zustandsbehaftete Container.
- (Auto-)Skalierung von Containern.
- Re-Scheduling von Containern im Fehlerfall (Auto-Healing) oder zur Ressourcen-Optimierung (→ Scheduling)
- Container-Logistik: Verwaltung, Bereitstellung und Cacheing von Container-Images.
- Package-Management: Verwaltung und Bereitstellung von Applikationen.
- Bereitstellung von Administrationsschnittstellen (Remote-API, Kommandozeile).
- Management von Services: Service Discovery, Naming, Load Balancing.
- Automatismen für Rollout-Workflows wie z.B. Canary Rollout.
- Monitoring und Diagnose von Containern und Services.
- ...

Quelle: QAware GmbH
https://github.com/qaware/cloudcomputing

CLUSTER - ORCHESTRIERER

Schnittstelle zwischen Betrieb und Entwicklung

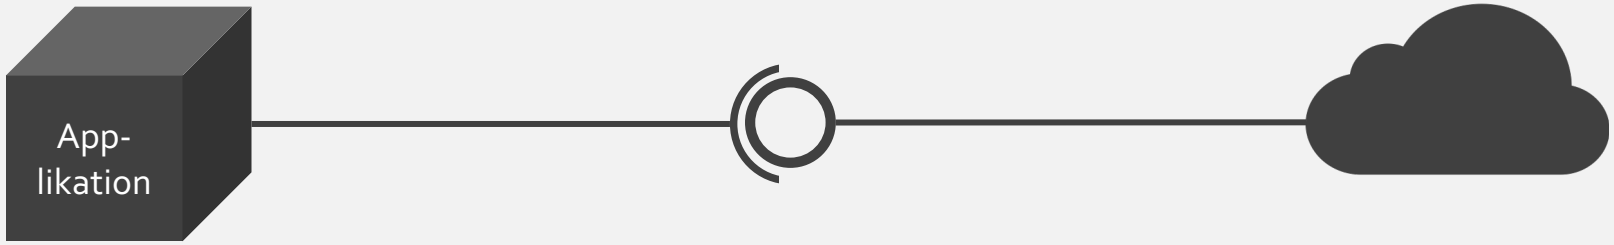

Entwicklung (Dev)

DevOps-Schnittstelle

- deploy()
- rollback()
- configure()
- scale()

Betrieb (Ops)

Quelle: QAware GmbH
https://github.com/qaware/cloudcomputing

CLUSTER - ORCHESTRIERER

Schnittstelle zwischen Betrieb und Entwicklung

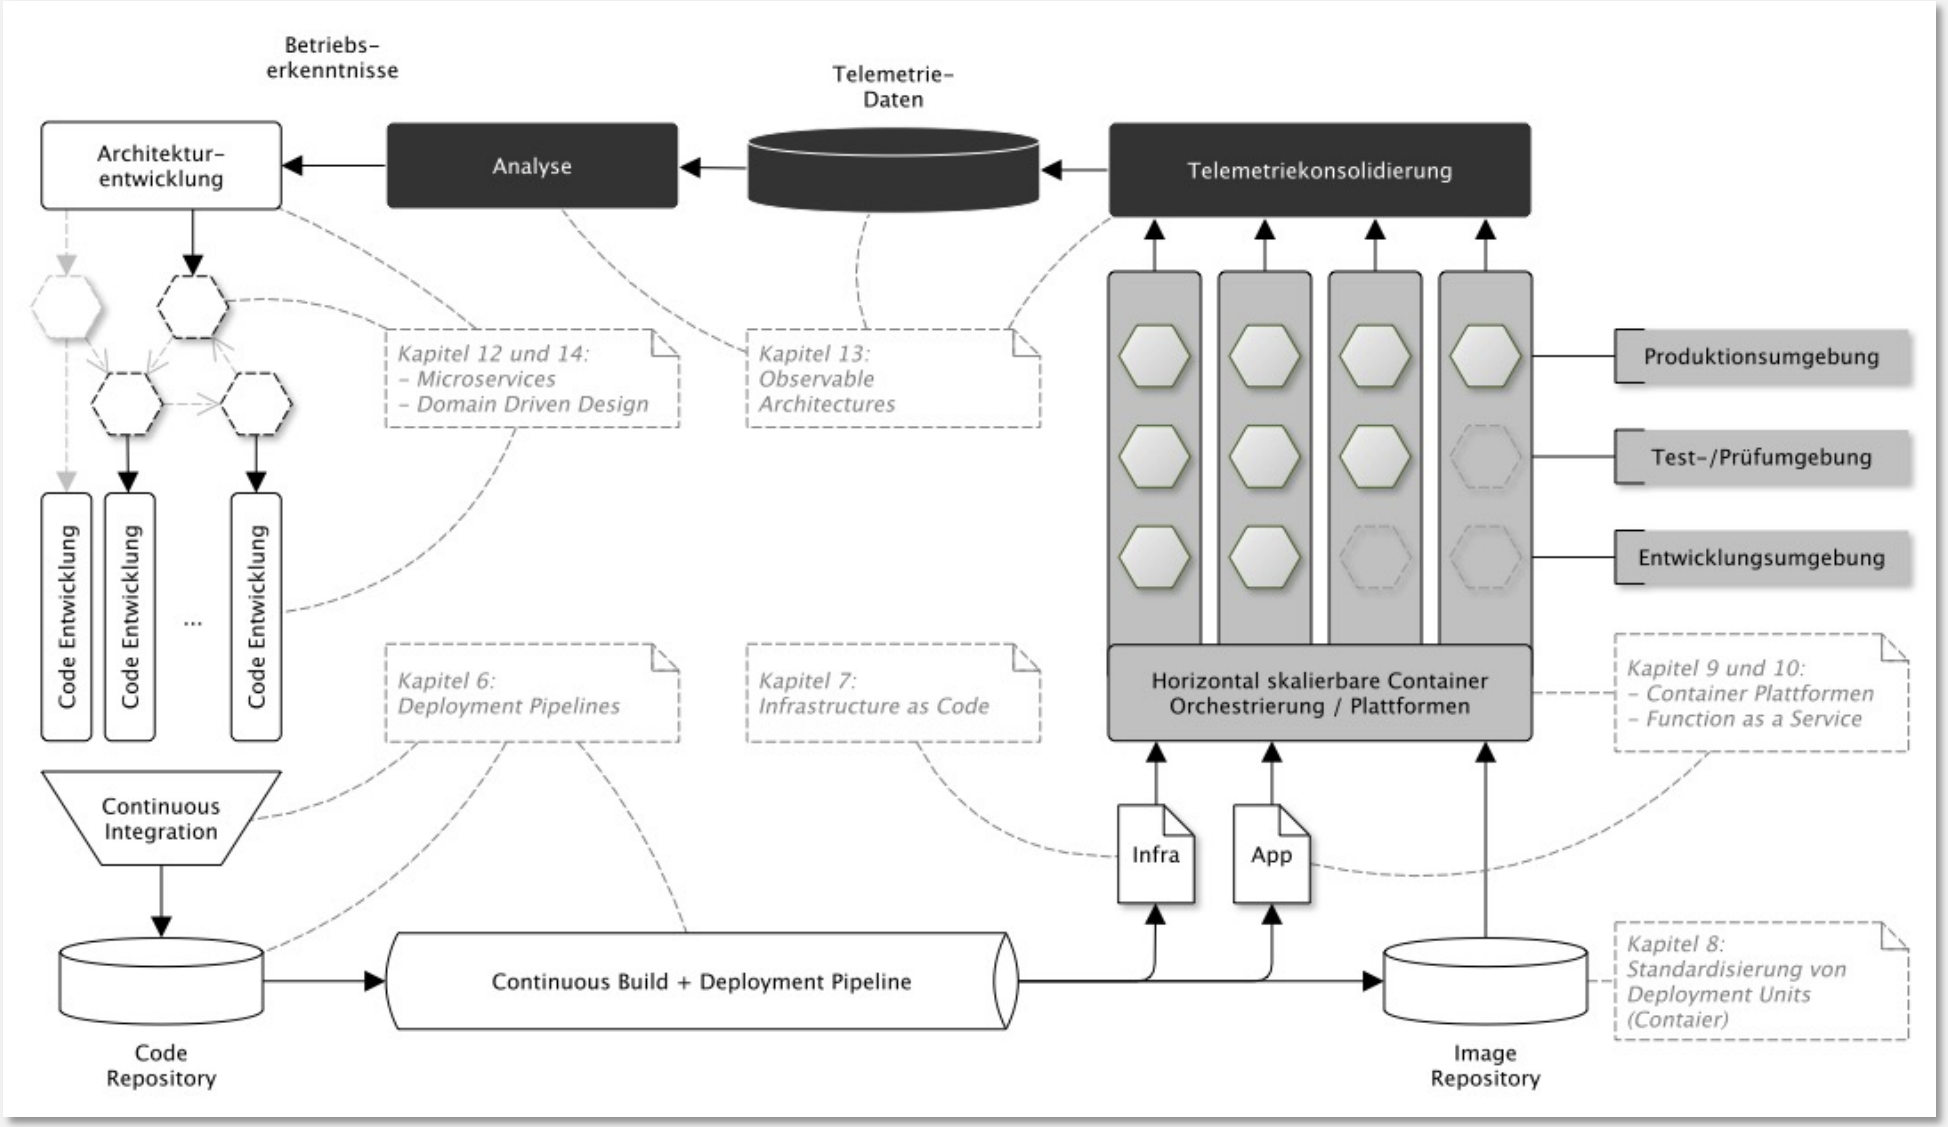

Oder etwas komplizierter.

Erinnern Sie sich an den DevOps-Cycle aus Unit 02.

BLUEPRINTS

„Konstruktionspläne" von Anwendungen (Multi-Komponenten Anwendungen)

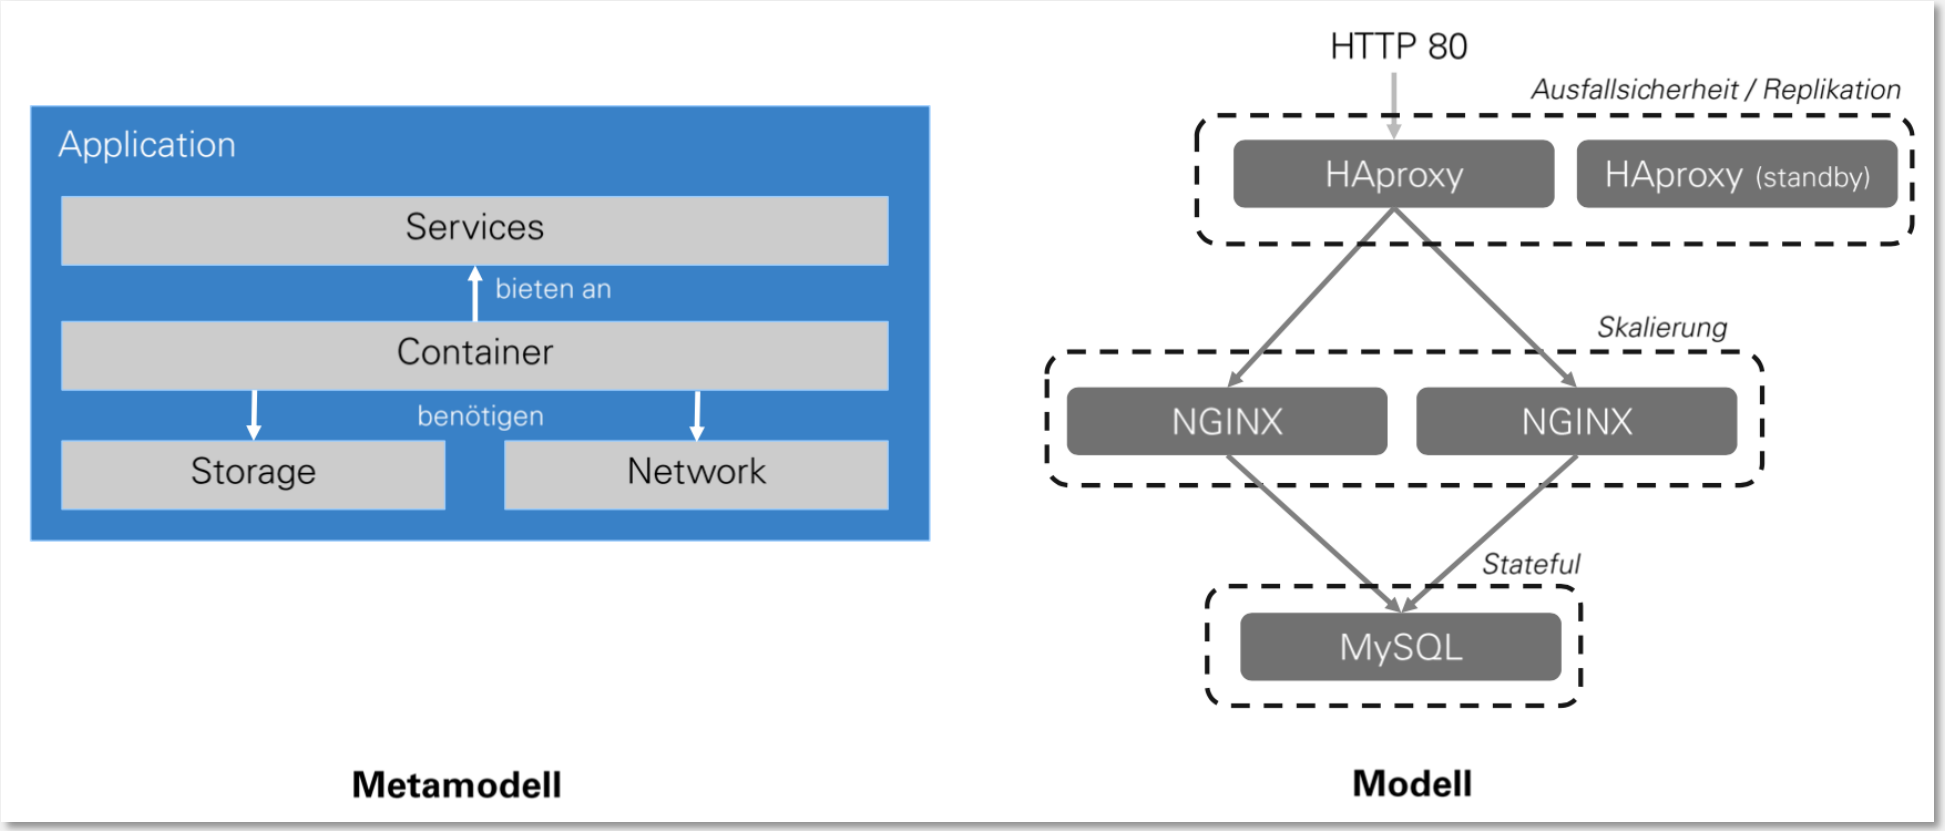

Vereinfachte Darstellung

Quelle: QAware GmbH
https://github.com/qaware/cloudcomputing

CONTAINER - ORCHESTRIERUNG

1-Level vs. 2-Level Orchestrierung

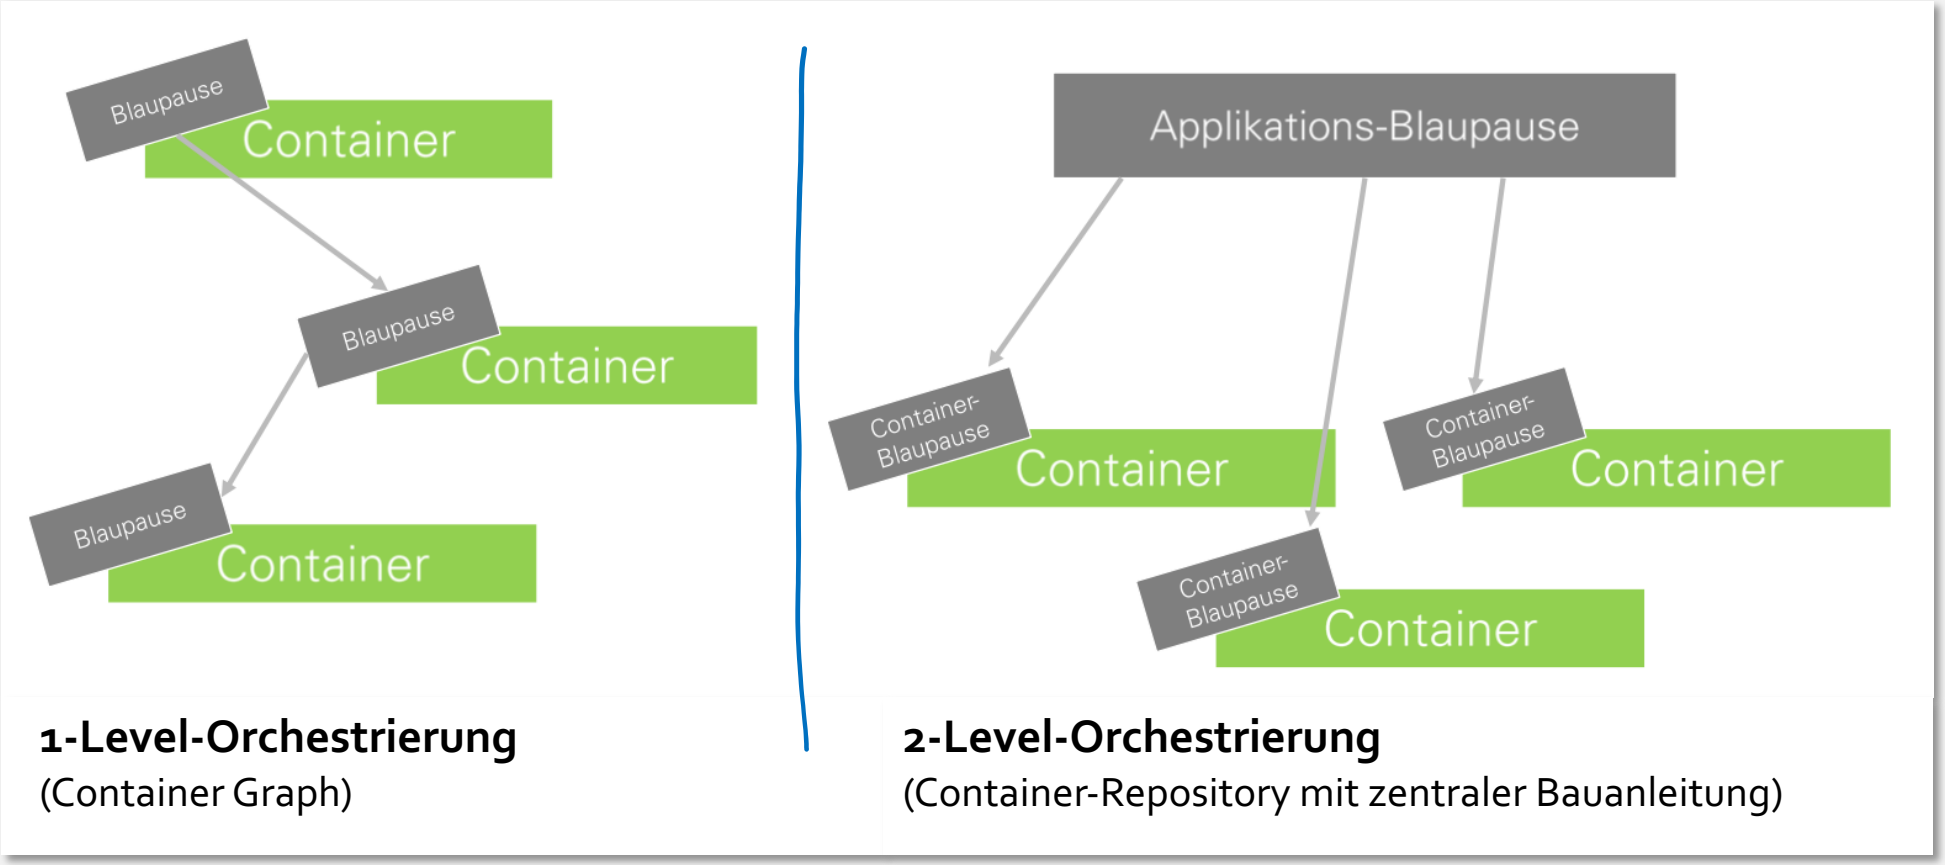

1-Level-Orchestrierung
(Container Graph)

2-Level-Orchestrierung
(Container-Repository mit zentraler Bauanleitung)

Quelle: QAware GmbH
https://github.com/qaware/cloudcomputing

CONTAINER - ORCHESTRIERUNG

1-Level vs. 2-Level Orchestrierung

```
FROM ubuntu
ENTRYPOINT nginx
EXPOSE 80


> docker run -d \
  --link nginx:nginx
```

Plain Docker

1-Level-Orchestrierung
(Container Graph)

Docker Compose

```
weba:
   image: thl/nginx
   expose: [80]

webb:
  image: thl/nginx
  expose: [80]

haproxy:
  image: thl/haproxy
  links: ["weba", "webb"]
  ports: ["80:80"]
  expose: [80]
```

```
FROM ubuntu
ENTRYPOINT nginx
EXPOSE 80
```

```
FROM ubuntu
ENTRYPOINT haproxy
EXPOSE 80
```

2-Level-Orchestrierung
(Container-Repository mit zentraler Bauanleitung)

Quelle: QAware GmbH
https://github.com/qaware/cloudcomputing

ORCHESTRIERUNGS - PATTERNS

Separations of Concerns mittels modularer Container

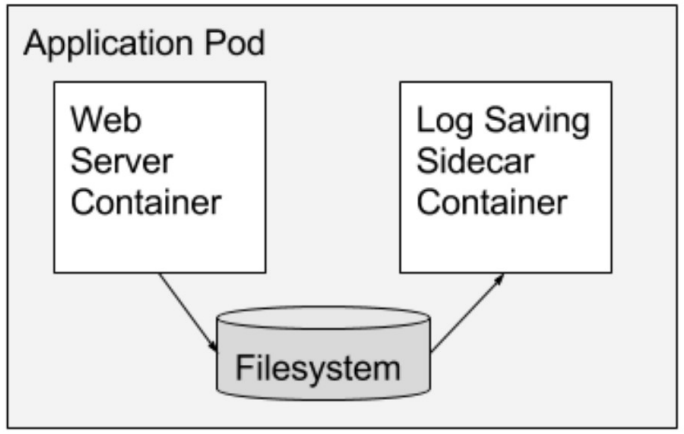

Sidecar Container

Ambassador Container

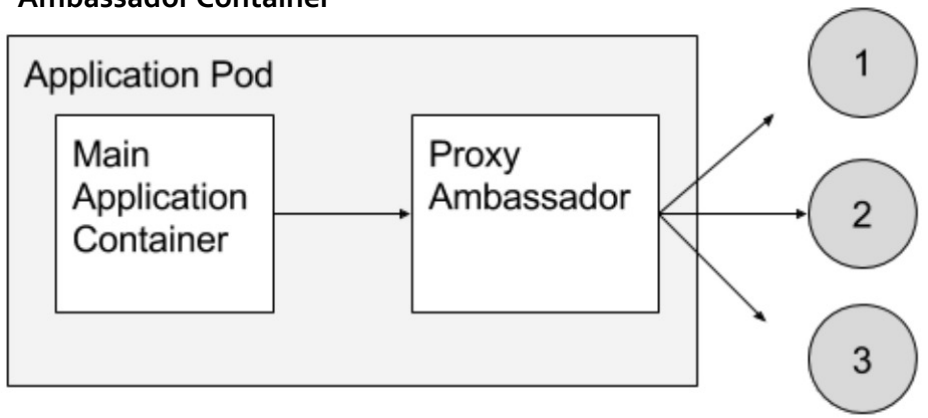

Adapter Container

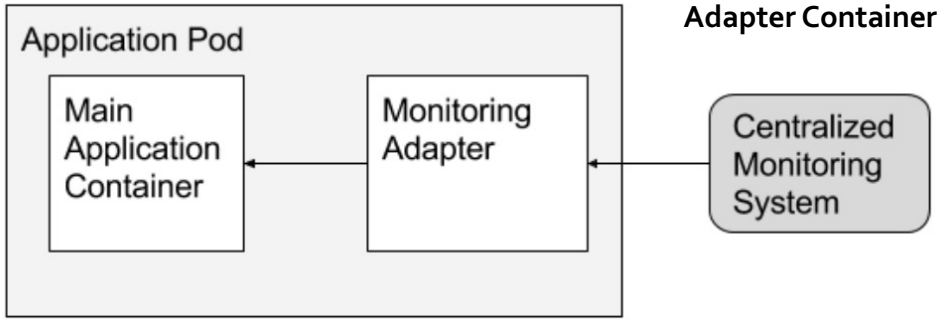

ORCHESTRIERUNGS - PATTERNS

Sidecar Container

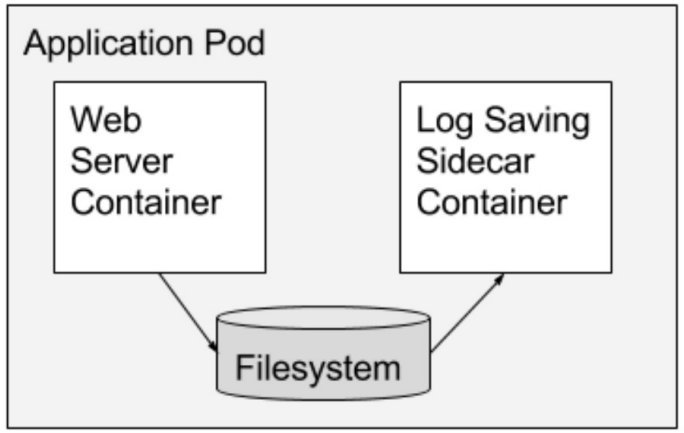

Sidecar Container

***„Sidecar containers extend and enhance the "main" container**, they take existing containers and make them better.*

As an example, consider a container that runs the Nginx web server. Add a different container that syncs the file system with a git repository, share the file system between the containers and you have built Git push-to-deploy.

But you've done it in a modular manner where the git synchronizer can be built by a different team, and can be reused across many different web servers (Apache, Python, Tomcat, etc). Because of this modularity, you only have to write and test your git synchronizer once and reuse it across numerous apps. And if someone else writes it, you don't even need to do that."

Brendan Burns

Quelle: https://kubernetes.io/blog/2015/06/the-distributed-system-toolkit-patterns/

ORCHESTRIERUNGS - PATTERNS

Ambassador Container

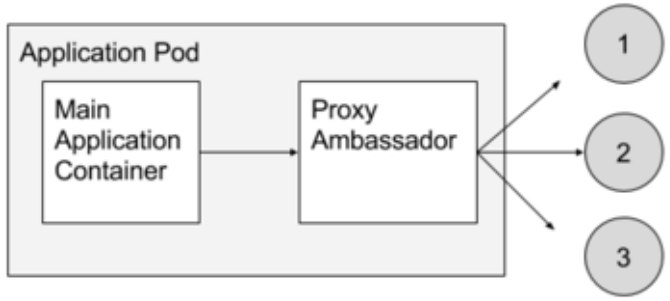

Ambassador Container

„Ambassador containers proxy a local connection to the world.

As an example, consider a Redis cluster with read-replicas and a single write master. You can create a Pod that groups your main application with a Redis ambassador container. The ambassador as a proxy is responsible for splitting reads and writes and sending them on to the appropriate servers. Because these two containers share a network namespace, they share an IP address and your application can open a connection on "localhost" and find the proxy without any service discovery. As far as your main application is concerned, it is simply connecting to a Redis server on localhost.

This is powerful, not just because of separation of concerns and the fact that different teams can easily own the components, but also because in the development environment, you can simply skip the proxy and connect directly to a Redis server that is running on localhost. "

Quelle: https://kubernetes.io/blog/2015/06/the-distributed-system-toolkit-patterns/

ORCHESTRIERUNGS - PATTERNS

Adaptor Container

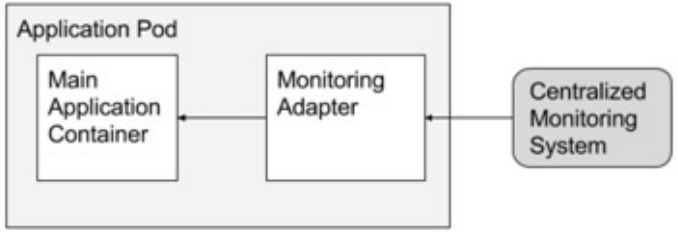

Adoptor Container

„Adapter containers standardize and normalize output.

Consider the task of monitoring N different applications. Each application may be built with a different way of exporting monitoring data. (e.g. JMX, StatsD, application specific statistics) but every monitoring system expects a consistent and uniform data model for the monitoring data it collects. By using the adapter pattern of composite containers, you can transform the heterogeneous monitoring data from different systems into a single unified representation by creating Pods that groups the application containers with adapters that know how to do the transformation.

Again because these Pods share namespaces and file systems, the coordination of these two containers is simple and straightforward.“

Quelle: https://kubernetes.io/blog/2015/06/the-distributed-system-toolkit-patterns/

CLUSTER - ORCHESTRIERER

Überblick

Apache Mesos
Marathon + Chronos

Für große Rechenzentren

Docker
Compose + Swarm

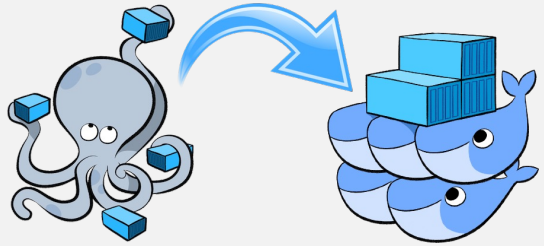

Lightweight

Kubernetes

De-facto Standard

Eher Ops-fokussiert (DC, Data Center)

Mehr Dev-fokussiert

Anmerkung:
Die Systeme sind vom Prinzip her vergleichbar. Die Zielgruppen und damit die Feature-Schwerpunkte sind nur unterschiedlich.

Aus Gründen der Praktikabilität fokussieren wir im folgenden den De-facto Standard Typvertreter Kubernetes.

INHALTE

Scheduling

- Scheduling Problem Definition
- Scheduling Algorithmen
- Scheduler Architekturen
- Beispiele von Cluster Schedulern: Mesos, Swarm

Orchestrierung

- Was ist Orchestrierung (in Abgrenzung zum Scheduling)?
- Was sind Blueprints?
- Container-Orchestrierungspatterns
- Überblick über bestehende Orchestrierungslösungen

Inside Kubernetes (Typ-Vertreter)

- K8S-Architektur
- K8S-Ressourcen
- Workloads, Persistenz, Isolation und Exponieren von Services

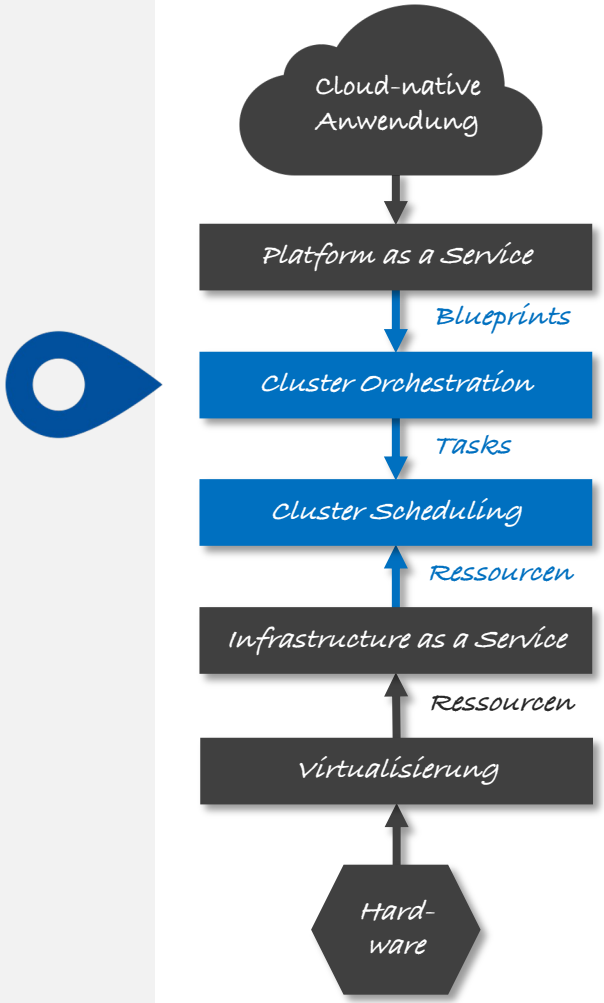

KUBERNETES

De-facto Standard für Container-Orchestierung

- Cluster-Orchestrierer für OCI-Container, der eine Reihe an Kern-Abstraktionen für den Betrieb von Anwendungen in einem großen Cluster einführt.
- Applikations-Blueprints werden über YAML- oder JSON-Dateien (sogenannte Manifests) definiert.
- Open-Source Projekt, das von Google initiiert wurde. Google will damit die jahrelange Erfahrung im Betrieb großer Cluster der Öffentlichkeit zugänglich machen und damit auch Synergien mit dem eigenen Cloud-Geschäft heben.
- Seit Juli 2015 in Version 1.0. Skaliert auf bis zu 1000 Nodes großen Clustern.
- Beiträge zur Codebasis von vielen Firmen neben Google – u.a. Mesosphere, Microsoft, Pivotal, RedHat, u.v.m.
- Zur Standardisierung der Cluster-Orchestrierung wurde die Cloud Native Computing Foundation (https://cncf.io) gegründet.
- Kubernetes ist das Lead-Projekt der CNCF.

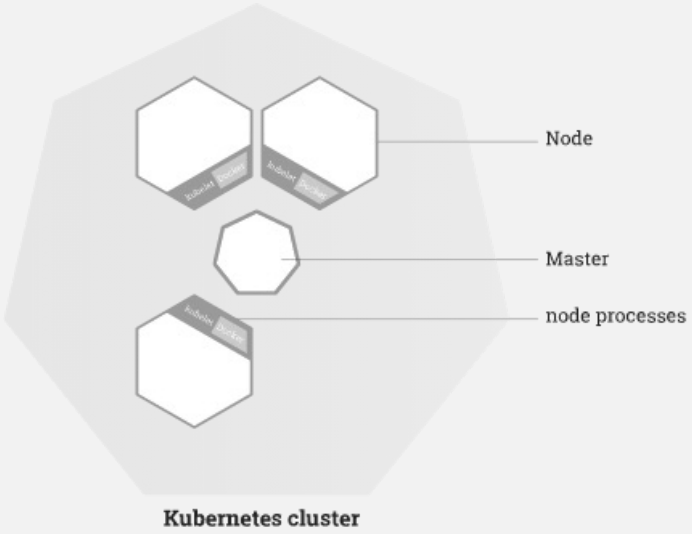

CLOUD NATIVE COMPUTING

KUBERNETES

Netzwerk- und Storage-Virtualisierung

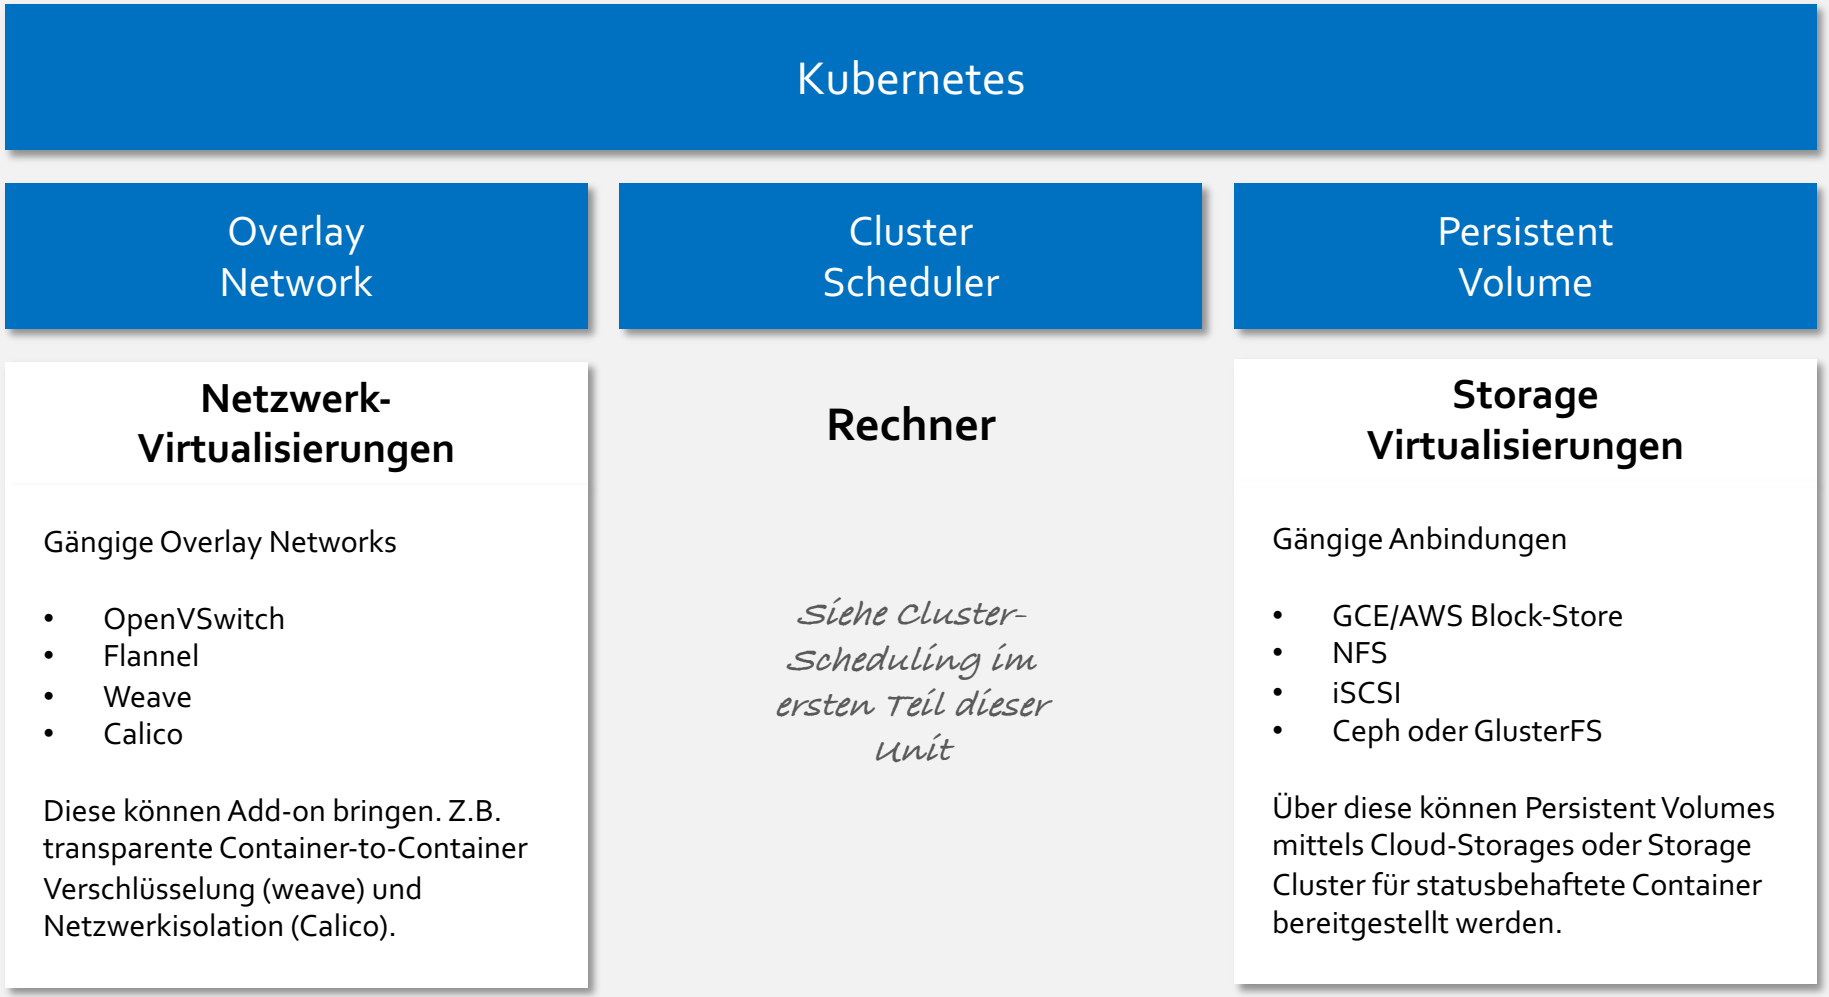

CLOUD NATIVE COMPUTING

Neben einem Cluster-Scheduler setzt Kubernetes auch noch auf Netzwerk- und Storage-Virtualisierungen auf.

KUBERNETES PLATTFORM

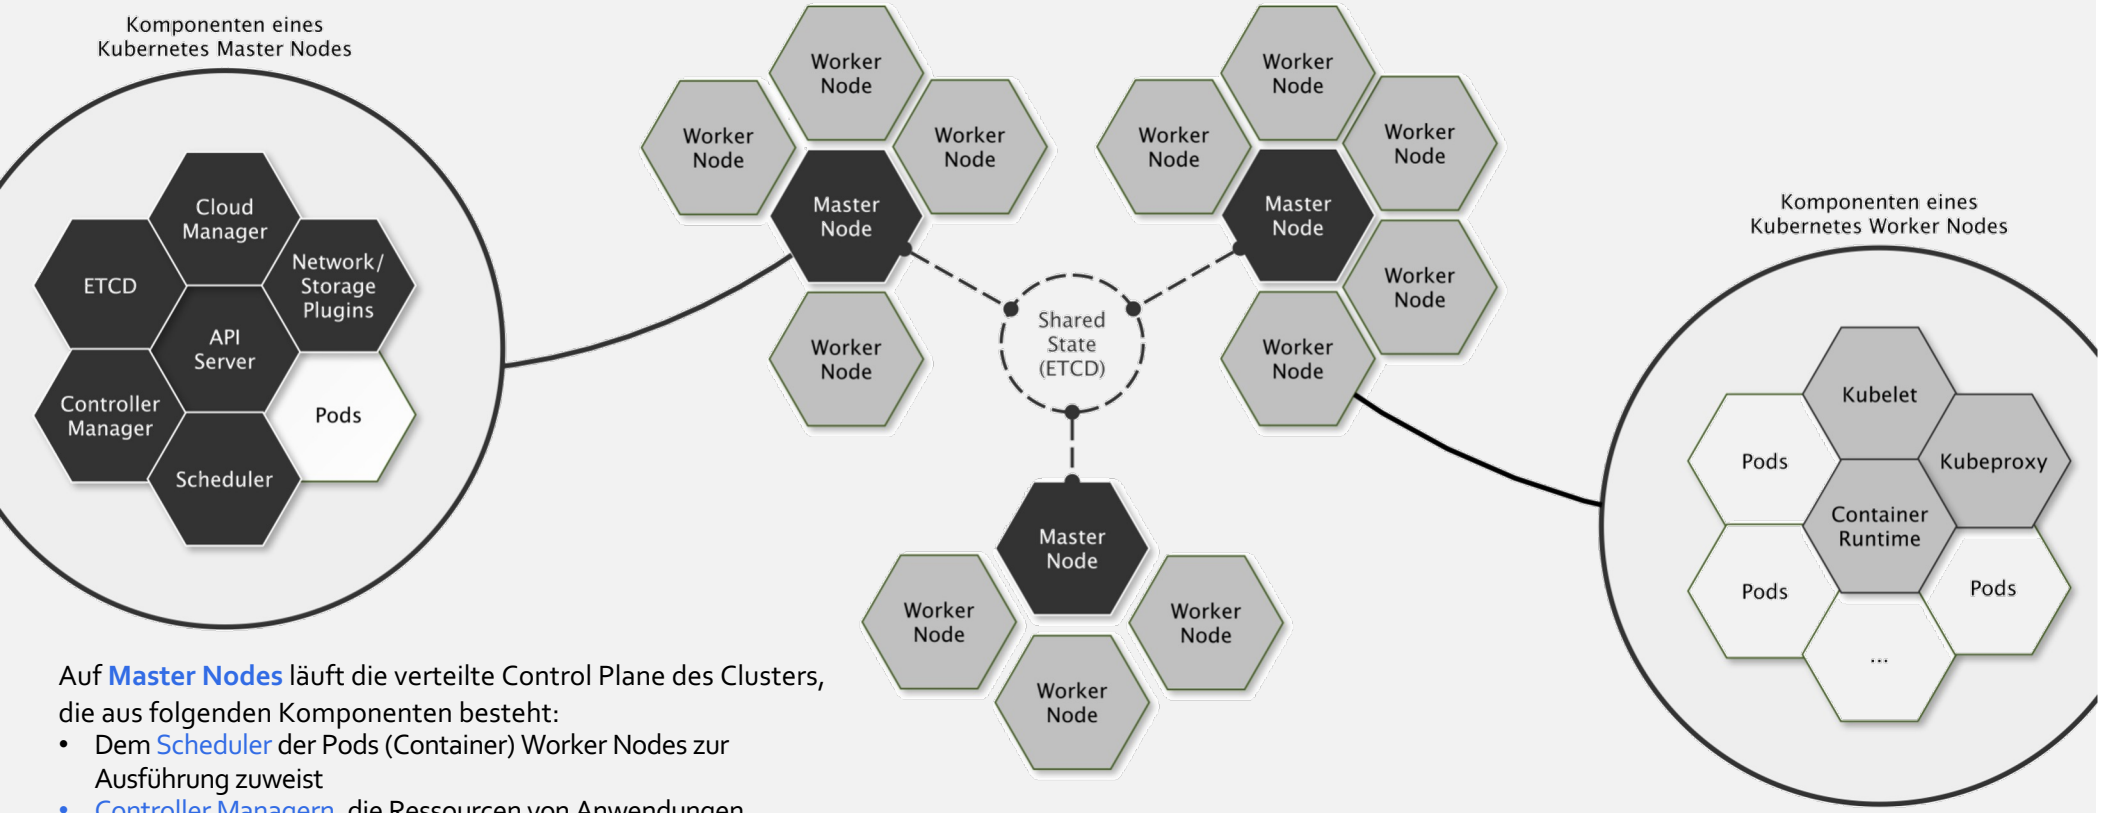

Auf **Master Nodes** läuft die verteilte Control Plane des Clusters, die aus folgenden Komponenten besteht:

- Dem Scheduler der Pods (Container) Worker Nodes zur Ausführung zuweist
- Controller Managern, die Ressourcen von Anwendungen überwachen und steuern.
- Cloud Managern, die Anbindungen an Cloud Infrastrukturen kapseln (z.B. Load Balancer Anforderungen).
- Einem verteilten und konsitenten Key-Value-Store (ETCD) um Clusterzustände hochverfügbar und konsistent zu speichern.
- Ein API-Server zur Steuerung und Verwaltung des Clusters
- Sowie weiteren Plugins, wie bspw. Network und Storage Plugins.
- Grundsätztlich können Pods auf Master Nodes ausgeführt werden (meist werden diese allerdings nur Worker Nodes zur Ausführung zugewiesen).

Worker Nodes dienen zur Ausführung von Applikationen (Pods). Die Interaktion mit der Control Plane erfolgt dabei über folgende Komponenten:

- Das Kubelet ist der primäre auf jedem Knoten laufende Node Agent, der u.a. den Knoten beim API-Server registriert.
- Kube-proxy wird als Netzwerk Proxy auf jedem Knoten ausgeführt und stellt die Kubernetes-API auf jedem Knoten bereit und ist u.a. für Weiterleitung von TCP-, UDP- und SCTP-Traffic sowie Load Balancing für Services verantwortlich.
- Um Container in Pods auszuführen, verwendet Kubernetes eine Container Runtime Environment, wie bspw. Docker, CRI-O oder containerd.

CLOUD NATIVE COMPUTING

Kubernetes (K8s) ist ein Open-Source Cluster-System zur Automatisierung der Bereitstellung, Skalierung und Verwaltung von containerisierten Anwendungen.

*Ein Kubernetes Cluster besteht aus **Master Nodes** (Control Plane) und **Worker Nodes** zur Ausführung von containerisierten Anwendungen.*

*Als Nutzer dieses Clusters interagiert man normalerweise mit dem Kommandozeilen-Programm **kubectl**. Zur Ausführung von Anwendungen erforderliche **Ressourcen** werden in sogenannten **Manifest**dateien (YAML oder JSON) definiert.*

KUBERNETES CONTROLLER

Regelkreis: Desired vs. Current State

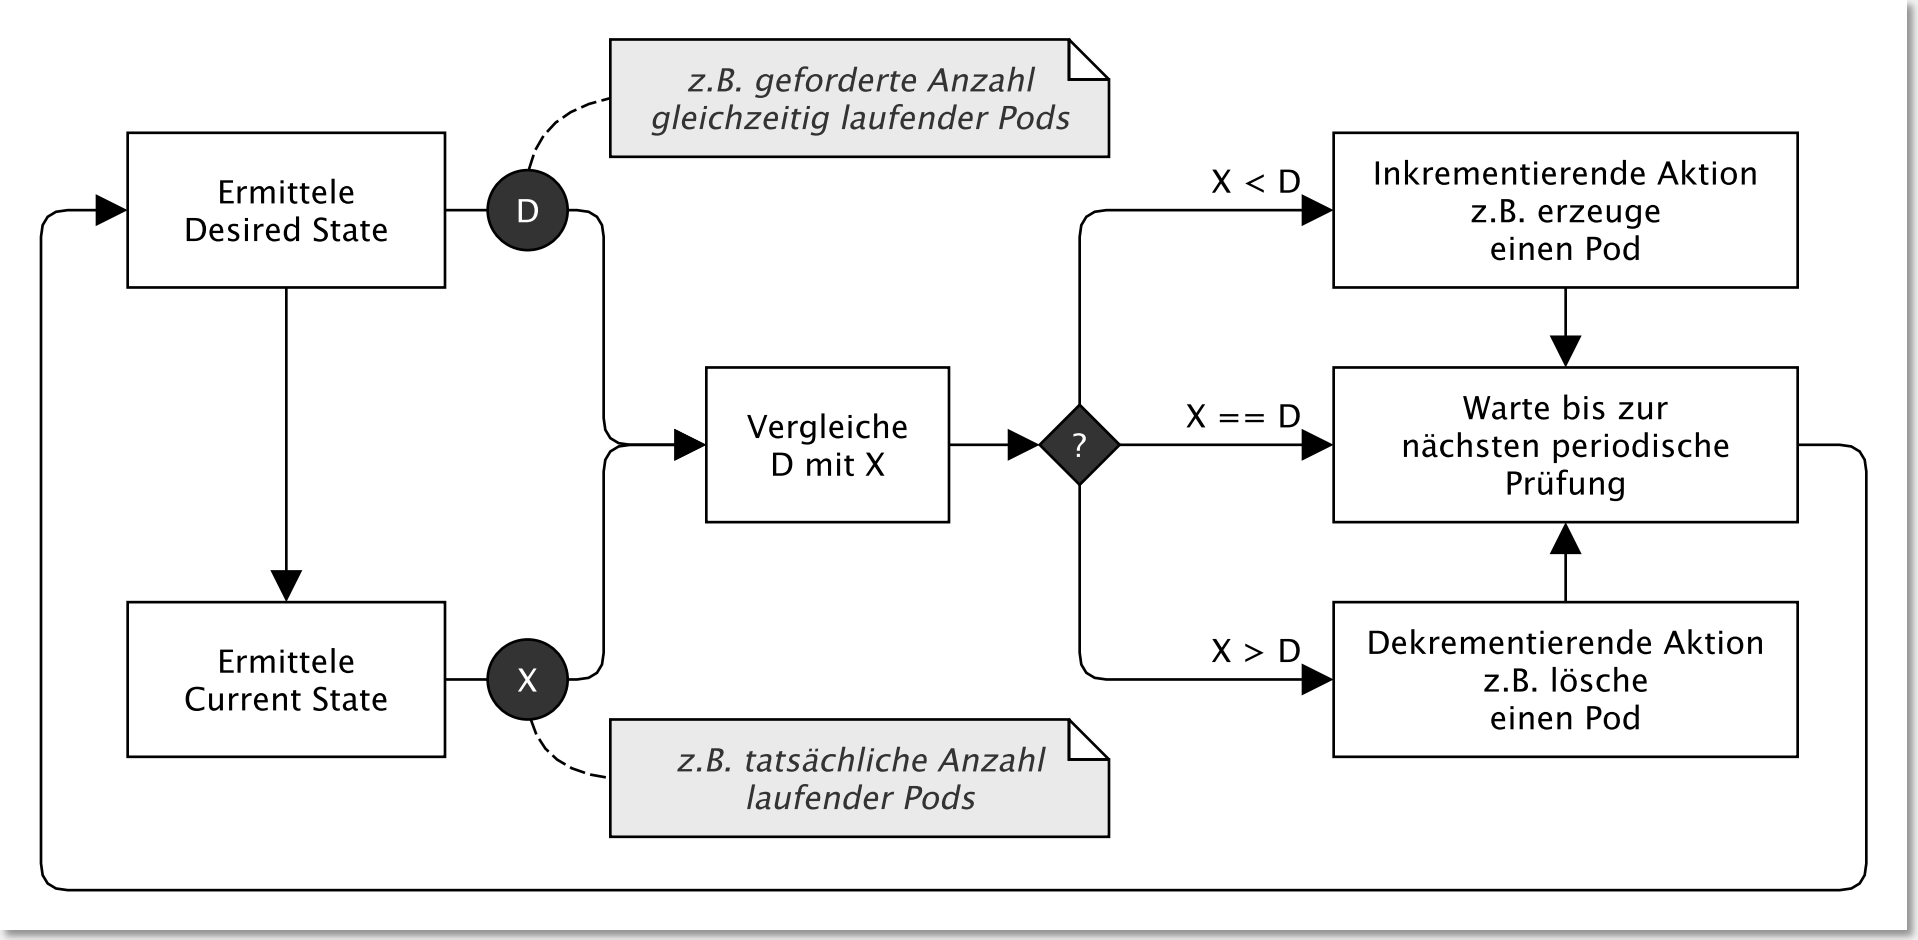

KUBERNETES CONTROL PLANE

Master(s)

API server	Scheduler	etcd	Controller manager	Cloud manager
Exposes the Kubernetes REST-API. Front end for the control plane. Horizontally scalable (see etcd).	Selects a node for pods to run them on. Factors for scheduling decisions include: • resource requirements • hardware/ software/ policy constraints • affinity and anti-affinity specifications • data locality • inter-workload interference • deadlines	Consistent and highly-available key value store for all cluster data.	Runs the following controller processes. • **Node controller** notices and responds when nodes go down. • **Replication controller** maintains the correct number of pods for every replication controller object in the system. • **Endpoints controller** populates the Endpoints object (that is, joins Services & Pods). • **Service Account & Token controllers** create default accounts and access tokens for namespaces.	Embeds cloud-specific control logic. Kind of a "Cloud" driver. The following controllers can have cloud provider dependencies: • **Node controller:** For checking if a node has been deleted. • **Route controller:** For setting up routes in the underlying cloud infrastructure • **Service controller:** managing cloud provider load balancers

CLOUD NATIVE COMPUTING

The control plane's components make global decisions about the cluster (for example, scheduling), as well as detecting and responding to cluster events (for example, restarting crashed pods).

Control plane components can be run on any machine in the cluster. However, mostly all control plane components are placed on dedicated master machines, that do not execute user containers.

KUBERNETES NODES

Nodes

kubelet	Kube-proxy	Container runtime
An agent that runs on each node in the cluster. It makes sure that containers are running in a Pod. The kubelet ensures that the containers described in those PodSpecs are running and healthy. The kubelet doesn't manage containers which were not created by Kubernetes.	kube-proxy is a network proxy that runs on each node in your cluster. kube-proxy maintains network rules on nodes. These network rules allow network communication to Pods from network sessions inside or outside of the cluster. kube-proxy uses the operating system packet filtering layer if there is one and it's available. Otherwise, kube-proxy forwards the traffic itself.	The container runtime is the software that is responsible for running containers. Kubernetes supports several container runtimes: • Docker • Containerd • CRI-O • and any implementation of the Kubernetes CRI (Container Runtime Interface).

Node components run on every node, maintaining running pods and providing the Kubernetes runtime environment.

KUBERNETES ADDONS

Funktionen, die oft als ergänzende Cluster-Ressourcen bereitgestellt werden

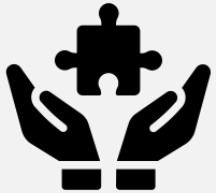

CLOUD NATIVE COMPUTING

DNS

- Ein obligatorischer DNS-Server muss DNS-Einträge für Kubernetes-Dienste bereitstellen.
- Container, die von Kubernetes gestartet werden, beziehen diesen DNS-Server automatisch in ihre DNS-Suche ein.

Web UI (Dashboard)

- Dashboard ist eine allgemeine, webbasierte Benutzeroberfläche für Kubernetes-Cluster.
- Es ermöglicht Benutzern die Verwaltung und Fehlerbehebung von Anwendungen, die im Cluster laufen, sowie des Clusters selbst.
- Mittlerweile gibt es auch Cluster-externe IDEs (wie bspw. Lens)

Container Resource Monitoring

- Ein Container Resource Monitoring zeichnet generische Zeitreihenmetriken in einer zentralen Metrik-Datenbank auf.
- Die Metrik-Datenbank bietet oft eine Analyse-/Browsing-Schnittstelle
- Bspw.: Prometheus / Grafana oder MetricBeat / ElasticSearch / Kibana

Cluster-level Logging

- Ein Protokollierungsmechanismus auf Clusterebene ist für die Weiterleitung von Containerprotokollen an eine zentralen Log-Datenbank zuständig.
- Die Log-Datenbank bietet oft eine Such-/Browsing-Schnittstelle
- Bspw.: FileBeat / ElasticSearch / Kibana

Addons verwenden Kubernetes-Ressourcen (DaemonSet, Deployment usw.) zur Implementierung solcher Clusterfunktionen.

Funktionen werden auf Clusterebene zur Verfügung gestellt (kube-system Namensraum).

Nur sehr häufige Addons werden hier beschrieben.

KUBERNETES

Überblick über die wichtigsten Kubernetes-Ressourcen

CLOUD NATIVE COMPUTING

Ausführbare Jobs/Workloads	Persistenz	Isolieren von Anwendungen mittels Namespaces	Exponieren von Anwendungen und Diensten
 **Deployments**	 **Persistent Volume Claim**	 **Quotas und Limit Ranges**	Primär Intra-Cluster  **Services**
 **(Cron-)Jobs**			
 **Daemon Sets**	 **Persistent Volume**	 **Role Based Access Model**	Primär Extra-Cluster  **Ingress**
 **Stateful Sets**			

HÄUFIG GENUTZTE K8S-RESSOURCEN

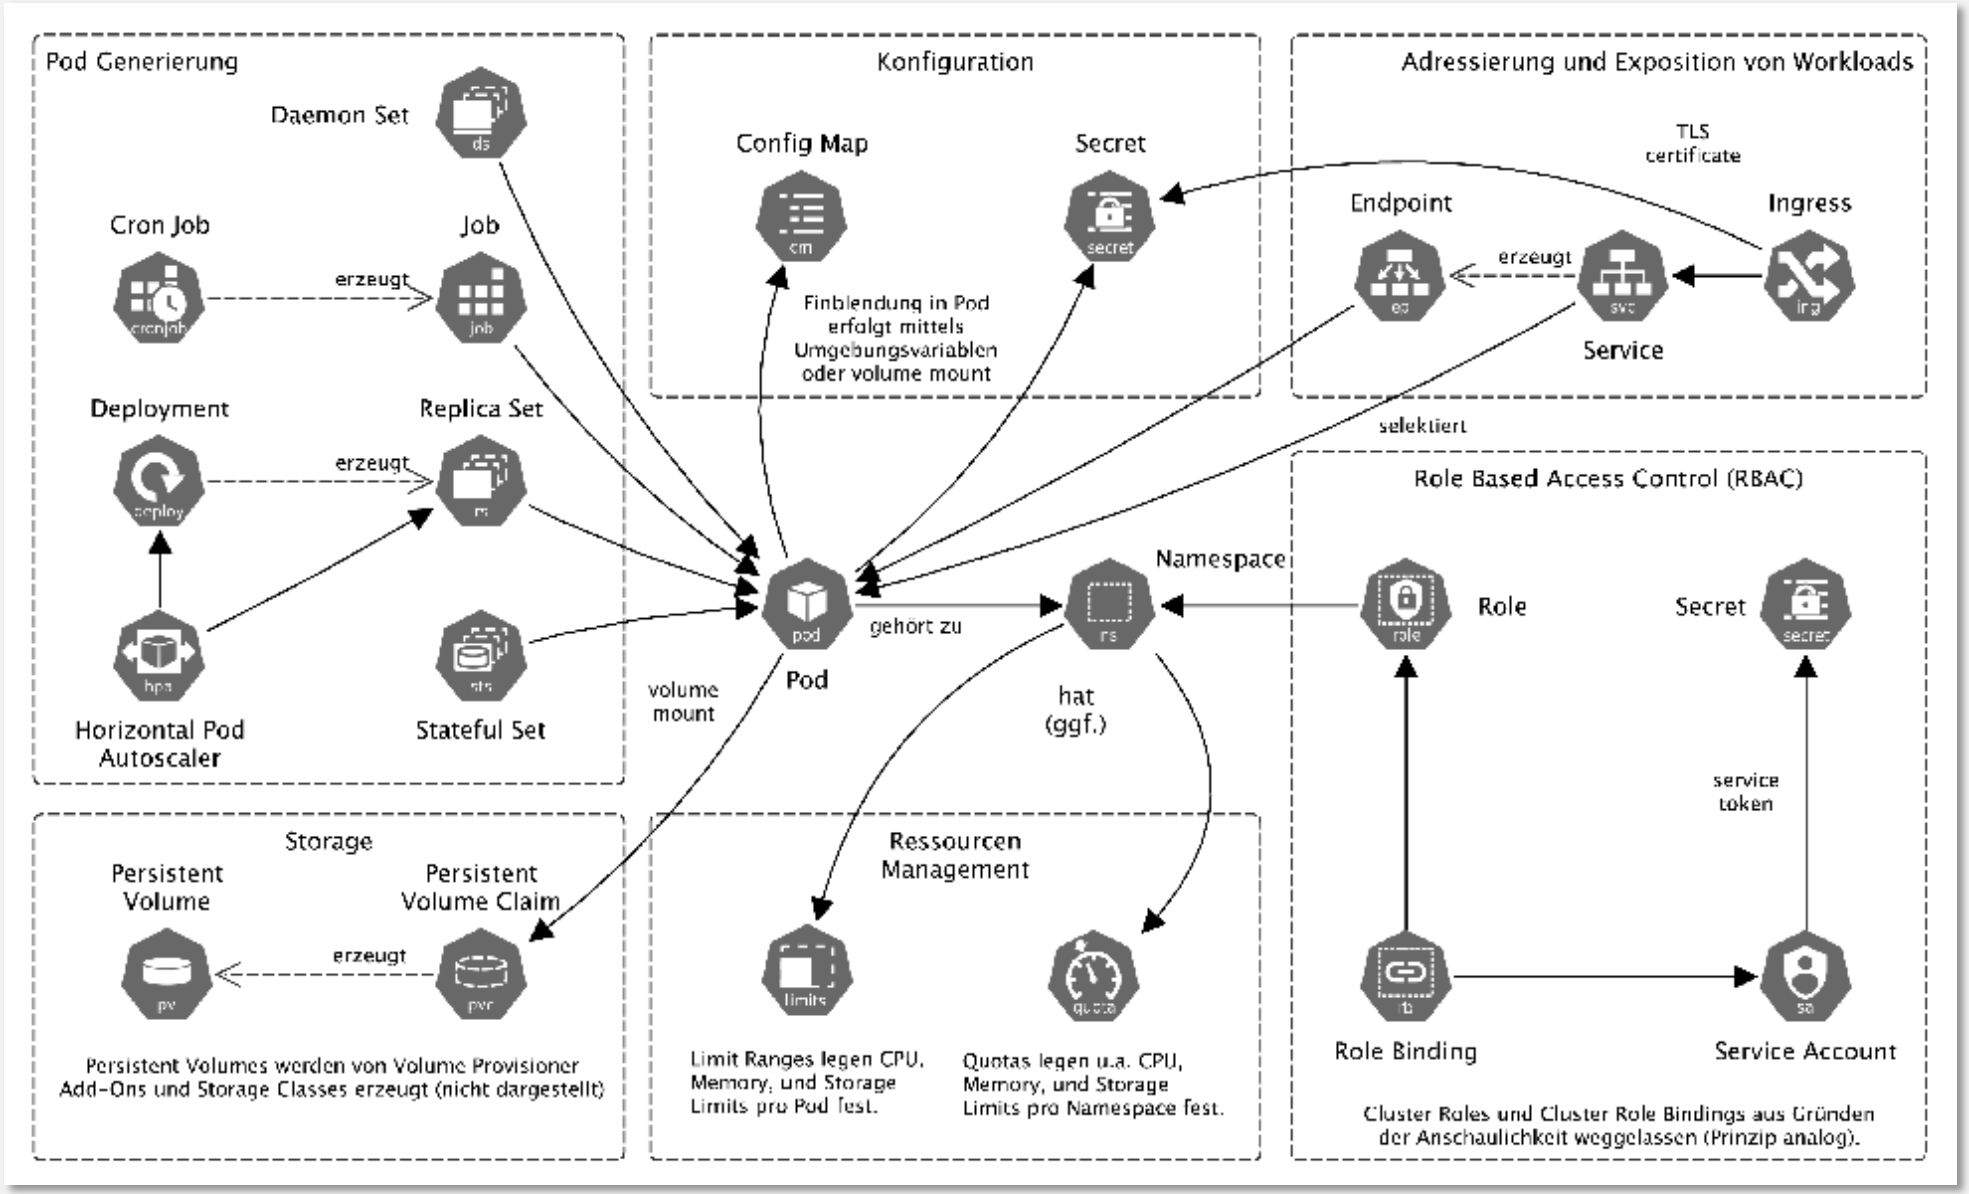

CLOUD NATIVE COMPUTING

Von Kubernetes verwaltete Ressourcen

- Pod
- Namespace
- Deployment
- Horizontal Pod Autoscaler
- Replica Set
- Stateful Set
- Daemon Set
- (Cron -) Job
- ConfigMap
- Secret
- Persistent Volume
- Persistent Volume Claim
- ServiceAccount
- (Cluster-Role Binding
- (Cluster-)Role
- Service
- Endpoint
- Ingress
- Limit Ranges
- Quota

KUBERNETES

Kern-Abstraktionen und Basis-Blueprint eines in K8S deployten Services

Config Map:
Üblicherweise Environment-spezifische Konfigurationen, die im Betrieb gesetzt werden müssen und die von Pods als Files (Konfigurationsdateien) oder Environment Variables gemounted werden können. Auf diese Weise lassen sich Environment-spezifische Konfigurationen aus Images heraushalten.

Deployment:
Drückt den gewünschten Zielzustand einer Applikationskomponente (Service) aus (z.B. lasse 5 NGINX-Container in Version 1.3 laufen).

Replica Set:
Erforderlich um den Replication Controller (RC) mit Informationen zu versorgen. Replication Controller stellen sicher, das eine spezifizierte Anzahl an Instanzen von Pods ständig laufen. RC sind auch für Reaktionen im Fehlerfall (Re-Scheduling), Skalierung und Rollouts (Canary Rollouts, Rollout Tracks, Rollbacks, ...) zuständig.

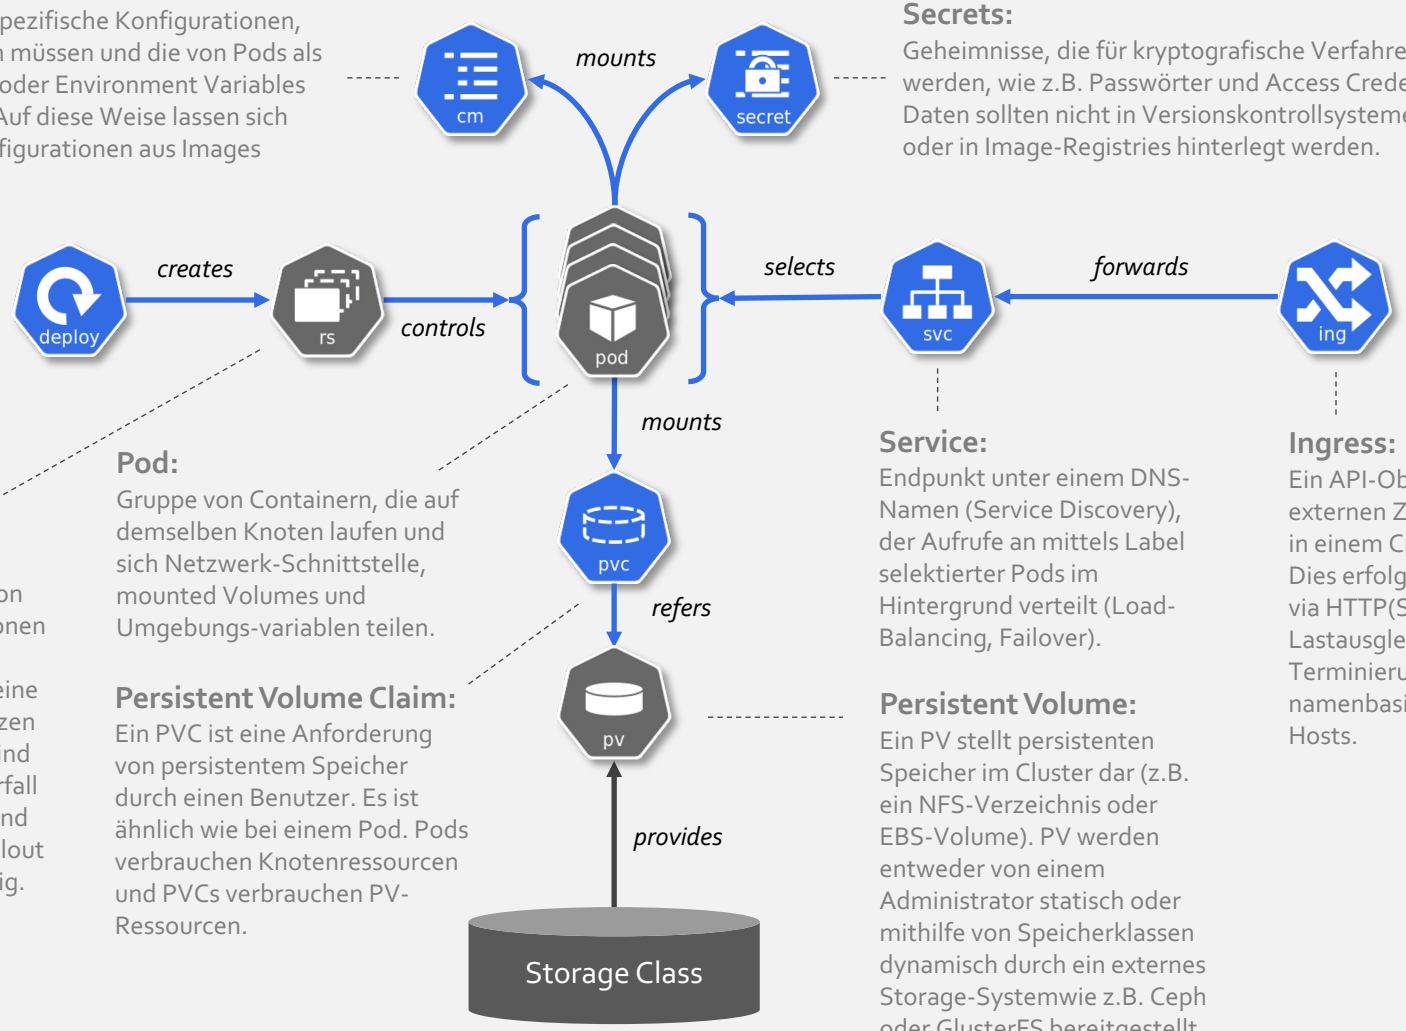

Pod:
Gruppe von Containern, die auf demselben Knoten laufen und sich Netzwerk-Schnittstelle, mounted Volumes und Umgebungs-variablen teilen.

Persistent Volume Claim:
Ein PVC ist eine Anforderung von persistentem Speicher durch einen Benutzer. Es ist ähnlich wie bei einem Pod. Pods verbrauchen Knotenressourcen und PVCs verbrauchen PV-Ressourcen.

Secrets:
Geheimnisse, die für kryptografische Verfahren benötigt werden, wie z.B. Passwörter und Access Credentials. Diese Daten sollten nicht in Versionskontrollsystemen eingecheckt oder in Image-Registries hinterlegt werden.

Service:
Endpunkt unter einem DNS-Namen (Service Discovery), der Aufrufe an mittels Label selektierter Pods im Hintergrund verteilt (Load-Balancing, Failover).

Persistent Volume:
Ein PV stellt persistenten Speicher im Cluster dar (z.B. ein NFS-Verzeichnis oder EBS-Volume). PV werden entweder von einem Administrator statisch oder mithilfe von Speicherklassen dynamisch durch ein externes Storage-Systemwie z.B. Ceph oder GlusterFS bereitgestellt.

Ingress:
Ein API-Objekt, das den externen Zugriff auf Dienste in einem Cluster ermöglicht. Dies erfolgt normalerweise via HTTP(S) und beinhaltet Lastausgleich, SSL-Terminierung und namenbasiertes virtuelle Hosts.

CLOUD NATIVE COMPUTING

Legende:

Ressource muss durch User angelegt werden.

Ressource wird üblicherweise durch K8S-interne Prozesse (meist Controller) angelegt (kann aber auch durch User oder durch Administrator angelegt werden).

KUBERNETES

Überblick über die wichtigsten Kubernetes-Ressourcen

CLOUD NATIVE COMPUTING

Ausführbare Jobs/Workloads	Persistenz	Isolieren von Anwendungen mittels Namespaces	Exponieren von Anwendungen und Diensten
Deployments	Persistent Volume Claim	Quotas und Limit Ranges	Primär Intra-Cluster: Services
(Cron-)Jobs			
Daemon Sets	Persistent Volume	Role Based Access Model	Primär Extra-Cluster: Ingress
Stateful Sets			

Hinweis:
Diverse Konzepte wie Scheduling Constraints (Requests + Limits, Node Selektoren, Affinities) sowie Health-Probes (Liveness, Readiness, Startup) werden an Deployments erläutert, lassen sich aber für die anderen K8S-Workloads analog anwenden!

DEPLOYMENTS

Ausführbare Workloads

- Ein Deployment ermöglicht deklaratives Ausbringen und Aktualisieren von Applikationen.
- Sobald die Anwendungsinstanzen erstellt wurden, überwacht ein Deployment Controller diese Instanzen kontinuierlich. Wenn der Node, der eine Instanz hostet (oder ein Pod), ausfällt oder gelöscht wird, ersetzt der Deployment Controller die Instanz durch eine Instanz auf einem anderen Node im Cluster.
- Deployment Controller überführen hierzu einen Ist-Stand in einen Soll-Stand.
- Erforderliche Maßnahmen werden automatisch abgeleitet.
- Z.B. anlegen eines neuen Replica Sets, welches schrittweise auf die Wunschanzahl an Replicas hochskaliert wird, während das bestehende Replica Set schrittweise auf Null herunterskaliert und anschließend gelöscht wird).
- Sollte ein Update fehlerhaft sein, kann es auch zurückgenommen werden.

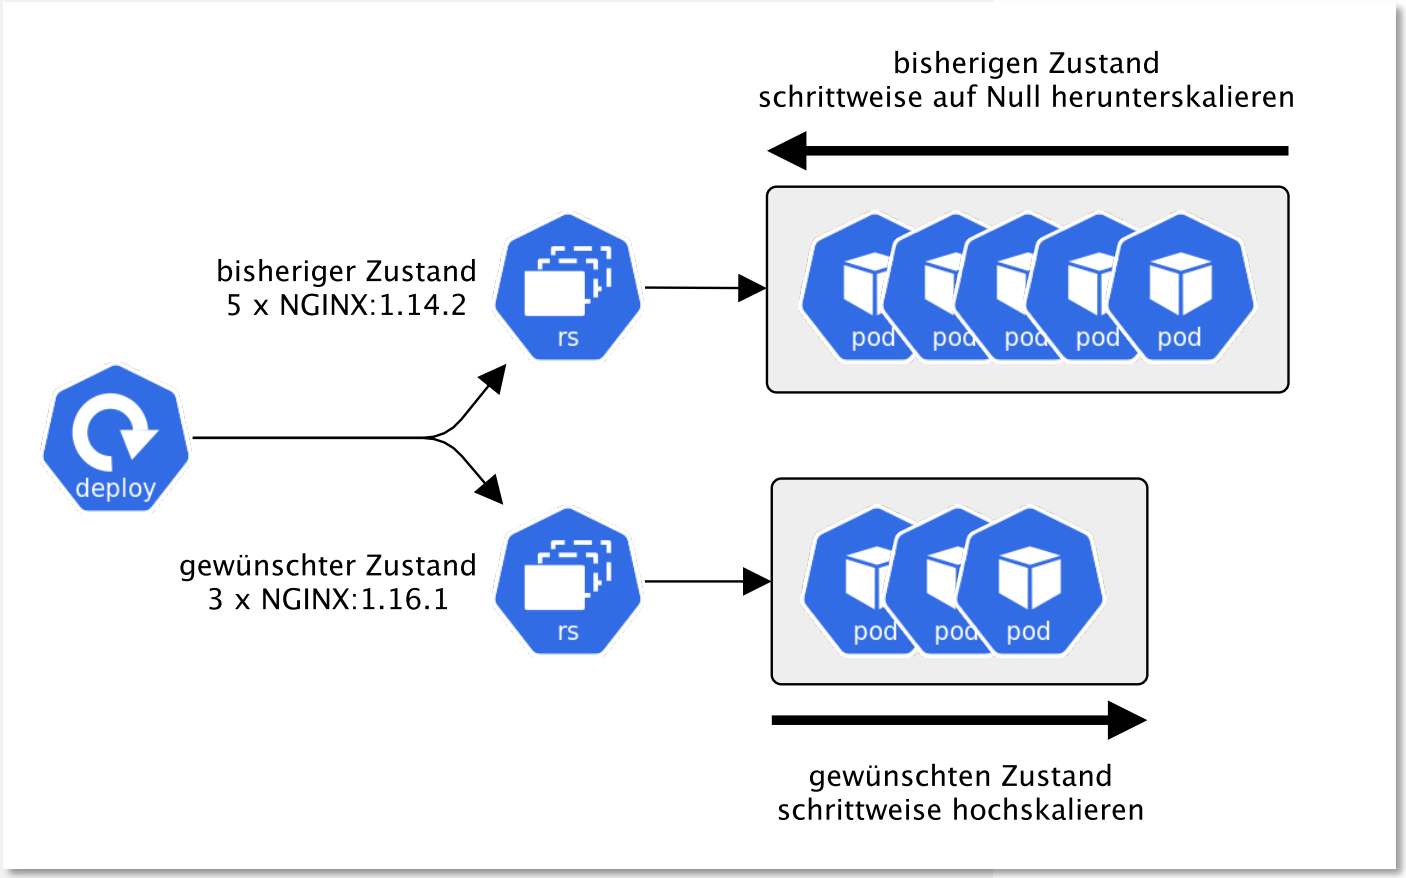

Quelle: https://kubernetes.io/docs/concepts/workloads/controllers/deployment/

DEPLOYMENTS

Ausführbare Workloads

```
# Ausbringen eines Deployments (5 x NGINX Webserver)
kubectl apply –f xample-nginx-deployment.yaml

# Update eines Images (NGINX:1.14.2 => NGINX:1.16.1) und
# Downscaling von 5 auf 3 Replicas
kubectl set image deployment.v1.apps/nginx-deployment \
        nginx=nginx:1.16.1 --record=true
kubectl scale --replicas=3 -f xample-nginx-deployment.yaml \
        --record=true

# Alle Revisionen eines Deployments auflisten
kubectl rollout history deployment.v1.apps/nginx-deployment

# Letztes Update zurücknehmen
# (bzw. auf eine spezifische Revision zurückspringen)
kubectl rollout undo deployment.v1.apps/nginx-deployment \
        [--to-revision=2]
```

Manifest: xample-nginx-deployment.yaml

```
apiVersion: apps/v1
kind: Deployment
metadata:
  name: nginx-deployment
  namespace: nane-kratzke
spec:
  replicas: 5
  selector: { matchLabels: { app: nginx }}
  template:
    metadata: { labels: { app: nginx }}
    spec:
      containers:
      - name: nginx
        image: nginx:1.14.2
        ports: [{ containerPort: 80 }]
```

SCHEDULING CONSTRAINTS

Requests und Limits

- Requests und Limits sind die Mechanismen, mit denen Kubernetes Ressourcen wie CPU und Speicher steuert.
- Requests sind das, was ein Container garantiert bekommt. Wenn ein Container eine Ressource anfordert, plant Kubernetes diese nur auf einem Knoten, der ihm diese Ressource geben kann.
- Limits stellen sicher, dass ein Container niemals einen bestimmten Wert überschreitet.
- Limits können niemals niedriger sein kann als der Request.
- **Requests und Limits werden pro Container in den Container-Specs angegeben.**
- Da Pods jedoch immer als Gruppe geplant werden, müssen Requests und Limits für alle Container eines Pods addiert werden, um einen Gesamtwert für den Pod zu erhalten.
- Um zu steuern, wie viele Ressourcen insgesamt vergeben werden können, können pro Namespace Quotas festgelegt werden.

```
apiVersion: apps/v1
kind: Deployment
metadata:
  name: nginx-deployment
  labels: {
    app: nginx
  }
spec:
  replicas: 5
  selector: { matchLabels: { app: nginx }}
  template:
    metadata: { labels: { app: nginx }}
    spec:
      containers:
      - name: nginx
        image: nginx:1.14.2
        ports: [{ containerPort: 80 }]
        ressources: {
           requests: { cpu: “100m“, memory: “100M“ }
           limits: { cpu: “1000m“, memory: “1G“ },
        }
```

Auch für die weiteren Workloads (Jobs, DaemonSets, StatefulSets) kann man Requests und Limits an den entsprechenden Container-Specs vornehmen.

Quelle: https://kubernetes.io/docs/concepts/configuration/manage-resources-containers/

SCHEDULING CONSTRAINTS

Einheiten für CPU- und Speicher-Requests und -Limits

CPU (Millicores)

- Requests und Limits für CPU-Ressourcen werden in CPU-Einheiten (Millicores) gemessen.
- Eine CPU in Kubernetes entspricht 1 vCPU / Core für Cloud-Anbieter und 1 Hyperthread auf Bare-Metal-Intel-Prozessoren.
- Bruchteile von Anforderungen sind zulässig, d.h. ein Container mit einem Request von 0.5 erhält garantiert halb so viel CPU wie einer, der 1 CPU anfordert.
- Der Ausdruck **0.1 entspricht dem Ausdruck 100m**, der üblicherweise als "einhundert Millicpu" (oder Millicores) gelesen wird.
- Eine Anforderung mit einem Dezimalpunkt wie 0,1 wird von der API in 100 m konvertiert.
- Eine Genauigkeit von weniger als 1 m ist nicht zulässig.
- Die CPU wird immer als absolute Menge angefordert, niemals als relative Menge. D.h. 0,1 ist die gleiche CPU-Menge auf einem Single-Core-, Dual-Core- oder 48-Core-Computer (die Taktrate der Prozessoren spielt dabei keine Rolle).

Memory (und Storage)

- Speicher-Requests und Speicher-Limits werden in Bytes gemessen.
- Eine Speichermenge kann als einfache Ganzzahl oder als Festkommazahl mit einem der folgenden Suffixe ausgedrückt werden:
  - E: (Exa-Byte),
  - P: (Peta-Byte),
  - T: (Terra-Byte),
  - G: (Giga-Byte),
  - M: (Mega-Byte),
  - K: (Kilo-Byte).
- Es können auch die Zweierpotenzäquivalente verwendet werden: Ei, Pi, Ti , Gi, Mi, Ki.

- Folgende Angaben bezeichnen als dieselbe Menge an Speicher!

0.25GB = 250MB = 250000KB = 250000000

Achtung:
- *1KB = 1000 Bytes*
- *1KiB = 1024 Bytes*

Beides wird im Sprachgebrauch häufig etwas ungenau als „Kilobyte" bezeichnet.

Für alle weiteren Einheiten analog!

Je größer die Einheiten, desto größer der absolute Unterschied!

*1GiB = 1024MiB = 1024 * 1024KiB = 1024 * 1024 * 1024 Bytes = 1.073.741.824 (immerhin schon fast 74MB Unterschied zu 1GB)*

SCHEDULING CONSTRAINTS

Node-Selektoren

Mittels Node-Labeln kann man Nodes kennzeichnen, um z.B. den Scheduler bestimmte Workloads nur bestimmten Nodes zuweisen zu lassen.

Z.B. könnte einen Tensorflow-Workload nur auf Nodes Sinn machen, die das Label „gpu=nvidia" haben.

Beispiel:
Es könnten Nodes des Clusters nicht vollkommen homogen aufgebaut sein, sondern es könnten Nodes mit schnellen SSD-Platten und (aus Kostengründen) Nodes mit langsameren HDD-Platten konfiguriert sein.

Aus Geschwindigkeitsgründen könnte gewollt sein, dass ein Web-Server nur auf Nodes mit SSD-Platten gesetzt wird, um geringe Auslieferungszeiten von Platte bis Browser sicherstellen zu können.

Solche Scheduling-Randbedingung lassen sich mittels eines auf Pod-Ebene angegebenen Node-Selektors realisieren.

```
# Nodes lassen sich mittels Key-Value Paaren labeln,
# z.B. so:
kubectl label nodes node-1 disktype=ssd
kubectl label nodes node-2 disktype=ssd
kubectl label nodes node-3 disktype=hdd
kubectl label nodes node-4 disktype=hdd
```

```
apiVersion: v1
kind: Pod
metadata:
  name: nginx
  labels:
    env: test
spec:
  containers:
  - name: nginx
    image: nginx
    imagePullPolicy: IfNotPresent
  nodeSelector:
    disktype: ssd
```

Man kann in K8S fast alle Ressourcen auf diese Weise labeln und selektieren!

Auch für die weiteren Workloads (Jobs, DaemonSets, StatefulSets) kann man Node-Selektorn in den entsprechenden Pod-Specs angeben.

Quelle: https://kubernetes.io/docs/concepts/scheduling-eviction/assign-pod-node/

SCHEDULING CONSTRAINTS

Affinities

- Node-Selektoren ermöglichen Pods auf Knoten mit bestimmten UND-verknüpften Labeln hart zu beschränken.
- Das Affinitätskonzept erweitert die ausdrückbaren Randbedingungen erheblich:
  - Affinitäten sind ausdrucksvoller, da sie neben exakten (UND-verknüpften) Übereinstimmungen mehr Übereinstimmungsregeln bieten.
  - Es lässt sich bspw. angeben, dass Affinitäten zwar zu präferieren, aber keine harte Anforderung sind. Wenn der Scheduler Affinitäten nicht erfüllen kann, wird der Pod in diesen „weichen" Fällen dennoch geplant.
  - Es können Affinitäten formuliert werden, die sich auf auf andere Pods (und deren Platzierung im Cluster) beziehen. So lassen sich bspw. Regeln festlegen, die vermeiden, dass Pods auf identische Nodes platziert werden (z.B. um Ausfallwahrscheinlichkeiten zu minimieren).
- Es gibt zwei Arten von Affinitäten:
  - **Knotenaffinität** ähnelt Node-Selektoren (jedoch mit den ersten beiden oben aufgeführten Vorteilen)
  - **Inter-Pod-Affinität / Anti-Affinität** wertet Pod-Labels und Pod-Platzierungen aus.

SCHEDULING CONSTRAINTS

Node Affinity

- Es gibt zwei Arten von Knotenaffinitäten
  - `requiredDuringSchedulingIgnoredDuringExecution` (harte Randbedingung, ähnlich Node-Selektor)
  - `preferredDuringSchedulingIgnoredDuringExecution` (weiche Randbedingung)
- Der Teil `IgnoredDuringExecution` bedeutet, dass der Pod nicht umgeplant wird, wenn sich zur Laufzeit Node-Labels ändern.
- `RequiredDuringExecution` würde bedeuten, dass auch Labeländerungen zur Laufzeit berücksichtigt würden. Dies wird aber aktuell vom K8S Scheduler nicht unterstützt.
- Ein Beispiel wäre Pods präferiert auf der eigenen On-Premise (`provider=on-premise`) Hardware auszuführen und nur in Overflow-Szenarien auf virtuelle Public IaaS-Maschinen (`provider=aws` oder `provider=gce` oder `provider=azure`) auszuweichen.

```
apiVersion: v1
kind: Pod
metadata:
  name: pod-with-constant-workload
spec:
  affinity:
    nodeAffinity:
      preferredDuringSchedulingIgnoredDuringExecution:
      - weight: 1
        preference:
          matchExpressions:
          - key: provider
            operator: In
            values:
            - on-premise
  containers:
  - name: constant-workload
    image: crunch:2.0
```

Auch für die weiteren Workloads (Jobs, DaemonSets, StatefulSets) kann man Node-Affinities in den entsprechenden Pod-Specs vornehmen.

Dieser Workload würde präferiert im eigenen RZ platziert werden, es sei denn, dort findet der Scheduler keinen Platz mehr!

Dann würden ggf. teurere Public Cloud Maschinen genutzt werden.

SCHEDULING CONSTRAINTS

Inter-Pod (Anti-)Affinities

- Mit Inter-Pod-(Anti-)Affinitäten lassen sich mittels Pod-Labels (und nicht anhand von Knoten-Labels) festlegen, welche Knoten für einen Pod geplant (oder vermieden) werden sollen.
- Die (Anti-)Affinitäts-Regeln haben die Form:

  Dieser Pod sollte (nicht) auf Knoten X ausgeführt werden, wenn auf Knoten X bereits ein Pod ausgeführt wird, der Regel Y erfüllt.

- Konzeptionell werden die Knoten X über eine Topologiedomäne wie Knoten, Rack, Cloud-Provider-Zone, Cloud-Provider-Region bestimmt.

```yaml
apiVersion: apps/v1
kind: Deployment
metadata: { name: redis-cache }
spec:
  selector:
    matchLabels: { app: store }
  replicas: 3
  template:
    metadata:
      labels: { app: store }
    spec:
      affinity:
        podAntiAffinity:
          requiredDuringSchedulingIgnoredDuringExecution:
          - labelSelector:
              matchExpressions:
              - key: app
                operator: In
                values: ["store"]
            topologyKey: "kubernetes.io/hostname"
      containers:
      - name: redis-server
        image: redis:3.2-alpine
```

CLOUD NATIVE COMPUTING

Dieses Beispiel platziert alle Redis Pods (In-Memory Cache) so, dass nie zwei Pods auf demselben Node landen.

Dies kann aus Gründen der gleichmäßigen Verteilung von Netzwerklasten und Ausfallsicherheit durchaus Sinn machen.

Auch für die weiteren Workloads (Jobs, DaemonSets, StatefulSets) kann man Inter-Pod-Affinities in den entsprechenden Pod-Specs vornehmen.

POD HEALTH

Liveness Probes

- Viele Anwendungen, die über einen längeren Zeitraum ausgeführt werden, enden ggf. in einen fehlerhaften Zustand (z.B. in einem seltenen Deadlock) und können nur durch einen Neustart wiederhergestellt werden.
- Kubernetes bietet sogenannte Liveness Probes, um solche Situationen zu erkennen und zu beheben.
- Mittels Liveness Probes lässt sich ein sogenannter Heart Beat realisieren (I am still alive), den die K8S Plattform kontinuierlich prüft.
- Liveness Probes können pro Container in der **Container Spec** definiert werden.
- Definiert werden können
  - Command-basierte
  - HTTP-basierte
  - oder TCP-basierte Probes
- Diese Probes werden in definierten Zeitintervallen geprüft werden. Ist die Prüfung mehrmals (definierbar über einen Schwellwert) erfolglos (d.h. Fehlerfall) wird der Container neu gestartet.

```
livenessProbe:
   httpGet:
     path: /healthz
     port: 80
   failureThreshold: 3
   periodSeconds: 10
```

HTTP-basierter Probe, Return Codes zwischen 200 und 399 werden als „Alive" interpretiert. Alles andere als „Failure".

```
livenessProbe:
   tcpSocket:
     port: 3306
   failureThreshold: 3
   periodSeconds: 10
```

TCP-basierter Probe auf Port 3306 (MySQL-Server). Ein erfolgreicher Aufbau wird dies als „Alive" interpretiert. Alles andere als „Failure".

```
livenessProbe:
   exec:
     command:
     - cat
     - /tmp/healthy
   failureThreshold: 1
   periodSeconds: 10
```

Command-basierter Probe. Hierzu wird das Command im Container ausgeführt. Exit Code 0 wird als „Alive" interpretiert. Alles andere als „Failure".

Quelle: https://kubernetes.io/docs/tasks/configure-pod-container/configure-liveness-readiness-startup-probes/

POD HEALTH

Readiness und StartUp Probes

Readiness Probe

- Manchmal können Anwendungen auch Requests nur vorübergehend nicht bedienen.
- Beispielsweise könnte eine Anwendung möglicherweise beim Start große Datenmengen oder Konfigurationsdateien laden oder nach dem Start von externen Diensten abhängig sein.
- In solchen Fällen sollte der Prozess nicht beendet werden, allerdings auch keine neuen Requests bekommen.
- Kubernetes bietet hierfür sogenannte Readiness Probes an, um solche Situationen zu erkennen und zu mildern.
- Ein Pod mit Containern, die mittels Readiness Probes melden, dass sie nicht bereit sind, empfängt keinen Datenverkehr über Kubernetes Services.
- Readiness Probes werden grundsätzlich so definiert, wie auch Liveness Probes.

```
readinessProbe:
   exec:
     command:
     - cat
     - /tmp/ready
   failureThreshold: 1
   periodSeconds: 10
```

auch HTTP und TCP-Probes möglich

StartUp Probe

- Insbesondere bei sogenannten Legacy Applikationen können für erste Initialisierungen möglicherweise zusätzliche Startzeit erforderlich sein.
- In solchen Fällen kann es schwierig sein, Parameter für die Liveness Probes einzurichten.
- Hierzu kann ein StartUp Probe eingerichtet werden. Dieser wird erst geprüft. Dieser StartUp Probe hat üblicherweise einen höheren Fehlerschwellenwert und längere Prüfperiode um die Startzeit im schlimmsten Fall abzudecken.
- Der unten stehende Startup-Probe deckt Startup-Phasen von bis zu 5 Minuten ab, und würde erst dann die Readiness- und Liveness Prüfung vornehmen.

```
startupProbe:
   tcpSocket:
       port: 3306
   failureThreshold: 10
   periodSeconds: 30
```

auch HTTP und Command-Probes möglich

Auch für die weiteren Workloads (Jobs, DaemonSets, StatefulSets) kann man Probes in den entsprechenden Container-Specs vornehmen.

POD HEALTH

Konfiguration von Probes

Allgemeine Konfiguration von Probes:

- **`initialDelaySeconds:`**
  Anzahl der Sekunden nach dem Start des Containers, bevor Liveness- oder Readiness-Tests gestartet werden.
- **`periodSeconds:`**
  Wie oft (in Sekunden) der Probe gecheckt wird.
- **`timeoutSeconds:`**
  Anzahl der Sekunden, nach denen ein Probe antworten muss.
- **`successThreshold:`**
  Minimale aufeinanderfolgende Erfolge, damit ein Probe nach einem Fehler als erfolgreich angesehen wird.
- **`failThreshold:`**
  Anzahl an Wiederholungsversuchen, bevor ein Probe als nicht bereit interpretiert wird.

Weitere Optionen für HTTP-Probes:

- **`host:`**
  Hostname, zu dem eine Verbindung hergestellt werden soll, standardmäßig die Pod-IP.
- **`schema:`**
  Schema für die Verbindung zum Host (HTTP oder HTTPS). Der Standardwert ist HTTP.
- **`path:`**
  Pfad für den Zugriff auf dem HTTP-Server.
- **`httpHeaders:`**
  Benutzerdefinierte Header, die in der Anforderung festgelegt werden sollen.
- **`port:`**
  Name oder Nummer des Ports, auf den im Container zugegriffen werden soll. Die Nummer muss im Bereich von 1 bis 65535 liegen.

CLOUD NATIVE COMPUTING

Auch für die weiteren Workloads (Jobs, DaemonSets, StatefulSets) kann man die Konfiguration von Probes in den entsprechenden Container-Specs vornehmen.

KUBERNETES

Überblick über die wichtigsten Kubernetes-Ressourcen

CLOUD NATIVE COMPUTING

Ausführbare Jobs/Workloads	Persistenz	Isolieren von Anwendungen mittels Namespaces	Exponieren von Anwendungen und Diensten
 Deployments	 Persistent Volume Claim	 Quotas und Limit Ranges	Primär Intra-Cluster  Services
 (Cron-)Jobs			
 Daemon Sets	 Persistent Volume	 Role Based Access Model	Primär Extra-Cluster  Ingress
 Stateful Sets			

JOBS

Ausführbare Workloads

Jobs sind meist länger laufende Aufgaben (z.B. das Trainieren eines neuronalen Netzes), die einmalig ausgeführt werden.

Ein Job erzeugt hierzu ein oder mehrere Pods und trägt Sorge dafür, dass eine vorgegebene Anzahl von diesen erfolgreich terminiert. Es können mehrere Pods parallel ausgeführt werden.

Wird ein Job gelöscht, werden auch alle von ihm erzeugten Pods gelöscht.

```
# Ausbringen eines Jobs
# (z.B. zur Berechnung der ersten 2000 Nachkommastellen von PI)
kubectl apply -f xample-job.yaml

# Holen des Berechnungsergebnisses
kubectl logs -l job-name=pi

# Löschen des Jobs
kubectl delete jobs/pi
```

```
apiVersion: batch/v1
kind: Job
metadata:
  name: pi
spec:
  template:
    spec:
      containers:
      - name: pi
        image: perl
        command: ["perl", "-Mbignum=bpi", "-wle", "print bpi(100)"]
      restartPolicy: Never      # Container nie neu starten!
```

Manifest: xample-job.yaml

Quelle: https://kubernetes.io/docs/concepts/workloads/controllers/job/

CRON-JOBS

Ausführbare Workloads

Cron-Jobs sind periodisch auszuführende Aufgaben (z.B. Erstellung einer Monatsabrechnung).

Die Periodizität von Jobs wird dabei nach dem gleichen Schema angegeben, dass auch von Linux/UNIX-Cron-Jobs bekannt ist (* * * * *).

Ein Cron-Job erzeugt dazu zu den so festgelegten Zeitpunkten Jobs, die wie beschrieben ausgeführt werden.

```
apiVersion: batch/v1beta1
kind: CronJob
metadata:
  name: hello
spec:
  schedule: "*/1 * * * *"
  jobTemplate:
    spec:
      template:
        metadata: { labels: { cron: job }}
        spec:
          containers:
          - name: hello
            image: busybox
            args:
              - /bin/sh
              - -c
              - date; echo Hello from the Kubernetes cluster
          restartPolicy: OnFailure
```

Manifest: xample-cron-job.yaml

Dieser Beispiel-CronJob gibt alle fünf Minuten die aktuelle Uhrzeit und eine Hallo-Nachricht aus.

Quelle: https://kubernetes.io/docs/concepts/workloads/controllers/cron-jobs/

KUBERNETES

Überblick über die wichtigsten Kubernetes-Ressourcen

CLOUD NATIVE COMPUTING

Ausführbare Jobs/Workloads	Persistenz	Isolieren von Anwendungen mittels Namespaces	Exponieren von Anwendungen und Diensten
 Deployments	 Persistent Volume Claim	 Quotas und Limit Ranges	Primär Intra-Cluster  Services
 (Cron-)Jobs			
 **Daemon Sets**	 Persistent Volume	 Role Based Access Model	Primär Extra-Cluster  Ingress
 Stateful Sets			

DAEMON SETS

Ausführbare Workloads

Ein Daemon Set stellt sicher, dass auf allen (oder ausgewählten) Nodes der Kubernetes Infrastruktur eine Kopie eines Pods läuft.

Werden Nodes dem Cluster hinzugefügt, werden so auch Pods auf diesen automatisch ausgeführt. Werden Nodes entfernt, werden entsprechende Pods durch den Garbage Collector entfernt.

Typische Anwendungsfälle sind häufig zentrale Dienste des Clusters (Kubernetes Add-Ons) wie bspw.:

- Clustered Storage Daemons pro Cluster Node
- Log Collection Daemon pro Cluster Node
- Node Monitoring Daemon pro Cluster Node
- Ingress Controller pro Cluster Node

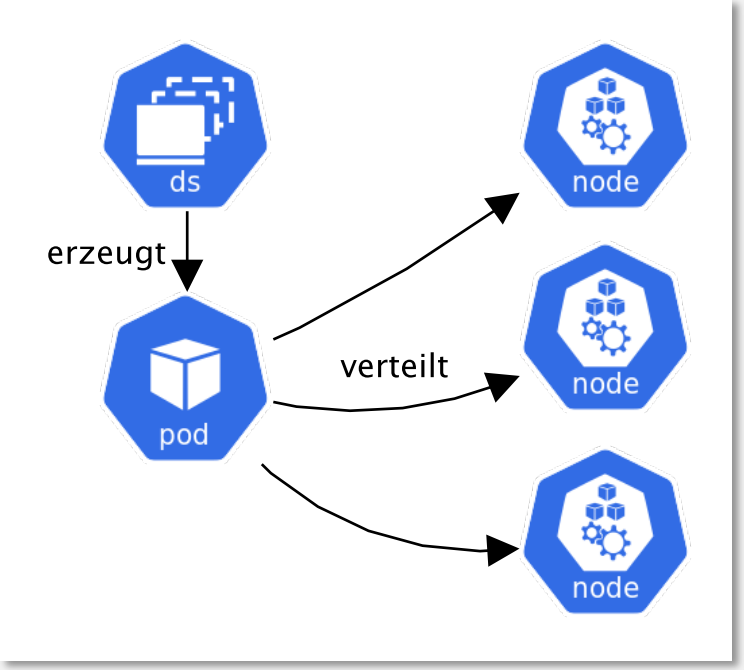

Quelle: https://kubernetes.io/docs/concepts/workloads/controllers/daemonset/

DAEMON SETS

Ausführbare Workloads

Beispiel eines DaemonSets, dass einen fluentd Log-Konsolidator Pod auf allen Nodes ausführt, um Pod Logs in einem zentralen Logging-Store zu konsolidieren und dort mittels ElasticSearch durchsuchbar zu hinterlegen (nicht Gegenstand dieses Manifests).

```
# Ausbringen einer Cluster-weiten
# Log-Aggregation auf Basis
# von fluentd
kubectl apply –f fluentd-daemon.yaml

# Löschen der Log-Aggregation
kubectl delete -f fluentd-daemon.yaml
```

```
apiVersion: apps/v1
kind: DaemonSet
metadata:
  name: fluentd-elasticsearch
  namespace: kube-system
spec:
  selector:
    matchLabels:
      name: fluentd-elasticsearch
  template:
    metadata:
      labels:
        name: fluentd-elasticsearch
    spec:
      containers:
      - name: fluentd-elasticsearch
        image: fluentd:v2.5.2
        volumeMounts:
        - name: varlog
          mountPath: /var/log
        - name: varlibdockercontainers
          mountPath: /var/lib/docker/containers
          readOnly: true
      volumes:
      - name: varlog
        hostPath:
          path: /var/log
      - name: varlibdockercontainers
        hostPath:
          path: /var/log/pods
```

Manifest: fluentd-daemon.yaml

CLOUD NATIVE COMPUTING

KUBERNETES

Überblick über die wichtigsten Kubernetes-Ressourcen

CLOUD NATIVE COMPUTING

Ausführbare Jobs/Workloads	Persistenz	Isolieren von Anwendungen mittels Namespaces	Exponieren von Anwendungen und Diensten
 Deployments	 Persistent Volume Claim	 Quotas und Limit Ranges	Primär Intra-Cluster  Services
 (Cron-)Jobs			
 Daemon Sets	 Persistent Volume	 Role Based Access Model	Primär Extra-Cluster  Ingress
 **Stateful Sets**			

STATEFUL SETS

Ausführbare Workloads

Stateful Sets dienen dem Ausbringen, Aktualisieren und Skalieren verteilter „Stateful Applications".

Solche Applikationen sind häufig Datenbanken; z.B. etcd (ein verteilter konsistenter Key-Value Store).

Dabei wird die Reihenfolge der Pod-Erzeugung und Eindeutigkeit der erzeugten Pods garantiert (Sticky Identity).

Obwohl Pods aus derselben Spec generiert werden, haben diese eine persistente Identität, die auch Reschedulings (z.B. im Rahmen von Aktualisierungen) überdauert.

Eine Besonderheit besteht bei Volume Mounts.

Stateful Sets können mittels einem ***Volume Claim Template*** pro Pod einen jeweils eigenen Volume Claim mit derselben Ordinalnummer wie der Pod erzeugen. Auf diese Weise, können Volumes bei einem Update des Pods wieder einem Pod mit derselben Ordinalnummer zugewiesen werden.

Auf diese Weise können auch Stateful Applikationen wie bspw. Datenbanken aktualisiert und skaliert werden.

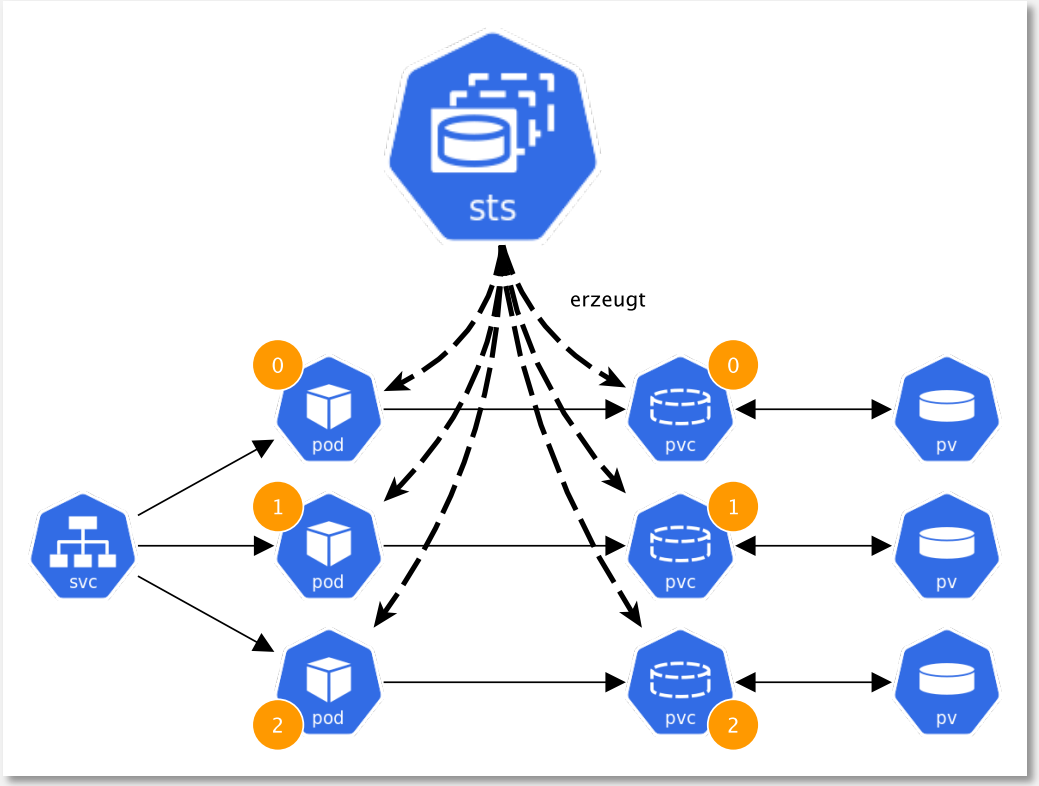

Quelle: https://kubernetes.io/docs/concepts/workloads/controllers/statefulset/

STATEFUL SETS

Ausführbare Workloads

Beispiel einer auf einem StatefulSet basierenden ETCD-Datenbank.

ETCD ist ein verteilter auf dem RAFT-Algorithmus beruhender Key-Value Store, der bspw. von Kubernetes Master-Nodes genutzt wird, um einen ausfallsicheren und konsistenten Zustand über alle Master-Nodes herzustellen und zu erhalten.

```
# Ausbringen
kubectl apply -f etcd.yaml

# Hochskalieren (wird zwei weitere Pods
# inkl. Volumes 3 + 4 erzeugen)
kubectl scale --replicas=5 -f etcd.yaml

# Runterskalieren (wird nur die
# Pods 3 + 4 löschen, aber nicht die
# Volumes 3, 4!)
kubectl scale --replicas=3 -f etcd.yaml

# Erneutes Hochskalieren (Noch bestehende
# Volumes 3 und 4 werden wieder Pod 3 und 4
# zugeordnet, Pod 5 und Vol 5 neu erzeugt!)
kubectl scale -replicas=6 -f etcd.yaml
```

Manifest: etcd.yaml

```
apiVersion: apps/v1
kind: StatefulSet
metadata:
  name: etcd
  labels: { app: etcd }
spec:
  serviceName: etcd
  replicas: 3
  selector:
    matchLabels: { app: etcd }
  template:
    metadata:
      name: etcd
      labels: { app: etcd }
    spec:
      containers:
      - name: etcd
        image: bitnami/etcd:3.4
        ports:
        - { containerPort: 2380, name: peer }
        - { containerPort: 2379, name: client }
        env:
        - { name: INITIAL_CLUSTER_SIZE, value: 3 }
        - { name: SET_NAME, value: etcd }
        - { name: ALLOW_NONE_AUTHENTICATION, value: yes}
        volumeMounts:
        - name: datadir
          mountPath: /var/run/etcd
  volumeClaimTemplates:
  - metadata: { name: datadir }
    spec:
      accessModes: ["ReadWriteOnce"]
      resources:
        requests: { storage: 1Gi }
```

CLOUD NATIVE COMPUTING

KUBERNETES

Überblick über die wichtigsten Kubernetes-Ressourcen

CLOUD NATIVE COMPUTING

Ausführbare Jobs/Workloads	Persistenz	Isolieren von Anwendungen mittels Namespaces	Exponieren von Anwendungen und Diensten
 Deployments	 **Persistent Volume Claim**	 Quotas und Limit Ranges	Primär Intra-Cluster  Services
 (Cron-)Jobs			
 Daemon Sets	 **Persistent Volume**	 Role Based Access Model	Primär Extra-Cluster  Ingress
 Stateful Sets			

PERSISTENZ

Organisation persistenten Speichers in Kubernetes

Das Verwalten von persistentem Speicher ist ein anderes Problem als das Verwalten von flüchtigen Recheninstanzen.

Das Persistenz-Subsystem von Kubernetes stellt hierzu eine API für Benutzer und Administratoren bereit, die Details zur Bereitstellung von Speicher von der Art seiner Verwendung abstrahiert.

Dies erfolgt mittels zweier API-Ressourcen namens **`PersistentVolume`** und **`PersistentVolumeClaim`**.

Persistent Volume (PV)

- Ein PV repräsentiert persistenten Speicher (Festplatte) im Cluster, der von einem Administrator bereitgestellt oder mithilfe von Speicherklassen dynamisch erzeugt wurde.
- Es ist wie ein Knoten eine normale statische Ressource des Clusters. PVs haben einen Lebenszyklus, der von einem Pod unabhängig ist.
- Dieses API-Objekt erfasst die Details der Implementierung des Speichers, sei es NFS, iSCSI oder ein Cloud-Provider-spezifisches Speichersystem.

Persistent Volume Claim (PVC)

- Ein PVC ist eine Anforderung von persistentem Speicher (Festplatte) durch einen Benutzer.
- Es ist analog einem Pod, der CPU- und Memory-Ressourcen eines Knotens benötigt. PVCs verbrauchen PV-Ressourcen.
- Mittels PVCs können bestimmte QoS-, Größen- und Zugriffsmodi von persistentem Speicher angefordert werden (z. B. können sie ReadWriteOnce, ReadOnlyMany oder ReadWriteMany bereitgestellt werden).

Für K8S gibt es u.a. die folgenden Block-Storage und Filesystem Provisioner:

- *AWS Elastic Block Store*
- *Azure File*
- *Azure Disk*
- *Ceph (FS + RBD)*
- *Cinder (OpenStack)*
- *FC (Fibre Channel)*
- *Flex Volume*
- *Flocker*
- *GCE Persistent Disk*
- *GlusterFS*
- *iSCSI*
- *Quobyte*
- *NFS*
- *Vsphere Volume*
- *Portworx Volume*
- *Scale IO*
- *Storage OS*
- *Local*
- *...*

Quelle: https://kubernetes.io/docs/concepts/storage/persistent-volumes/

PERSISTENT VOLUME

Bekanntmachung von persistentem Speicher durch den Administrator

Beispiel eines mittels NFS bereitgestellten Persistent Volumes.

Werden PVs auf diese Weise statisch dem Cluster bekannt gemacht, erfolgt dies dann normalerweise durch den Administrator. Dieser muss auch Details der Infrastruktur kennen, wie bspw. IP-Adresse des NFS-Servers, Kapazität der Platte, usw.

PVs werden daher meist nicht durch User im System angelegt.

Für User werden solche PVs meist mittels PVCs durch Storage Provisioner (Storage Classes) bereitgestellt.

```
apiVersion: v1
kind: PersistentVolume
metadata:
  name: pv0003
spec:
  capacity:
    storage: 5Gi
  volumeMode: Filesystem
  accessModes:
  - ReadWriteOnce
  mountOptions:
  - hard
  - nfsvers=4.1
  nfs:
    path: /tmp
    server: 172.17.0.2
```

PERSISTENT VOLUME CLAIM

Anforderung und Mounten von persistentem Speicher durch den User

Anforderung von persistentem Speicher

User können persistenten Speicher mittels PVCs anfordern. Hierzu muss eine Storage-Klasse angegeben werden, aus dem der Speicher bedient werden soll (auf die Angabe einer Storage Klasse kann verzichtet werden, wenn es eine Default Storage Klasse im Cluster gibt).

```
apiVersion: v1
kind: PersistentVolumeClaim
metadata:
  name: myclaim
spec:
  accessModes:["ReadWriteOnce"]
  volumeMode: Filesystem
  resources:
    requests: { storage: 8Gi }
  storageClassName: slow
```

Claims as Volumes

Pods greifen auf den so angeforderten persistenten Speicher zu, indem sie den PVC als Volume im Pod mounten. PVCs müssen sich hierzu im selben Namespace wie der Pod befinden.

Der Cluster nutzt das PVC im Namespace des Pods und verwendet es, um ein Persistent Volume zu erzeugen, welches den Anforderungen des PVC genügt. Das Persistent Volume wird dann auf dem Host und im Pod bereitgestellt.

```
apiVersion: v1
kind: Pod
metadata:
  name: mypod
spec:
  containers:
  - name: myfrontend
    image: nginx
    volumeMounts:
    - mountPath: "/var/www/html"
      name: mypd
  volumes:
  - name: mypd
    persistentVolumeClaim: { claimName: myclaim }
```

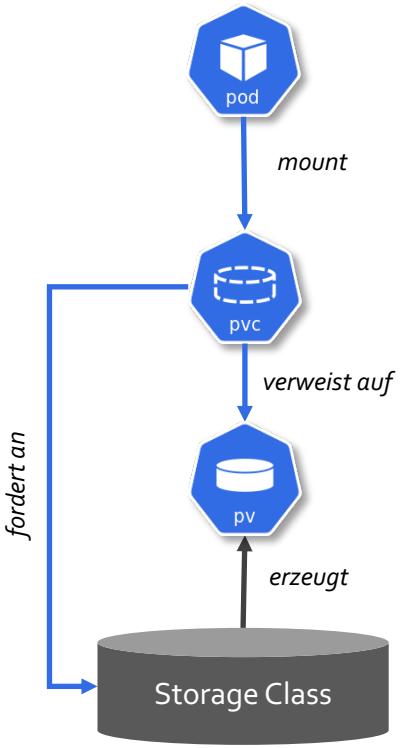

Storage Classes und Storage Provisioner werden nicht behandelt.

KUBERNETES

Überblick über die wichtigsten Kubernetes-Ressourcen

CLOUD NATIVE COMPUTING

Ausführbare Jobs/Workloads	Persistenz	Isolieren von Anwendungen mittels Namespaces	Exponieren von Anwendungen und Diensten
 Deployments	 Persistent Volume Claim	 **Quotas und Limit Ranges**	Primär Intra-Cluster  Services
 (Cron-)Jobs			
 Daemon Sets	 Persistent Volume	 **Role Based Access Model**	Primär Extra-Cluster  Ingress
 Stateful Sets			

QUOTAS UND LIMIT RANGES

Isolieren von Anwendungen mittels Namespaces

Mit Ressourcen-Kontingenten **(ResourceQuota)** kann der Ressourcenverbrauch pro Namespace beschränkt werden.

Um zu vermeiden, dass einzelne Pods oder Container alle verfügbaren Ressourcen monopolisieren, kann zusätzlich die Ressourcenzuweisung pro Container limitiert bzw. mit default Werten zugewiesen werden **(LimitRange)**.

Hierzu müssen einfach nur die entsprechenden Manifeste in einem Namespace angelegt werden.

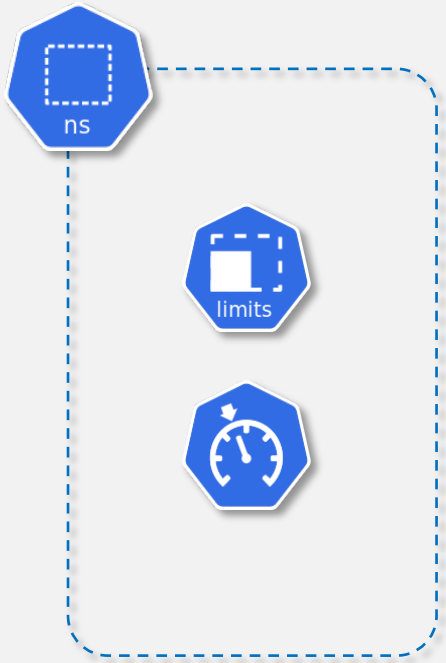

Manifest: compute-quota.yaml

```yaml
apiVersion: v1
kind: ResourceQuota
metadata:
  name: compute-resources
spec:
  hard:
    limits.cpu: "2"
    limits.memory: 2Gi
    requests.nvidia.com/gpu: 4
```

```
kubectl apply -f compute-quota.yaml -n xample
```

Manifest: cpu-limits.yaml

```yaml
apiVersion: v1
kind: LimitRange
metadata:
  name: cpu-limits
spec:
  limits:
  - type: Container
    max: { cpu: "1000m" }
    min: { cpu: "200m" }
    default: { cpu: "200m" }
```

```
kubectl apply -f cpu-limits.yaml -n xample
```

Quotas: https://kubernetes.io/docs/concepts/policy/resource-quotas/

LimitRanges: https://kubernetes.io/docs/concepts/policy/limit-range/

ROLE BASED ACCESS MODEL

Isolieren von Anwendungen mittels Namespaces

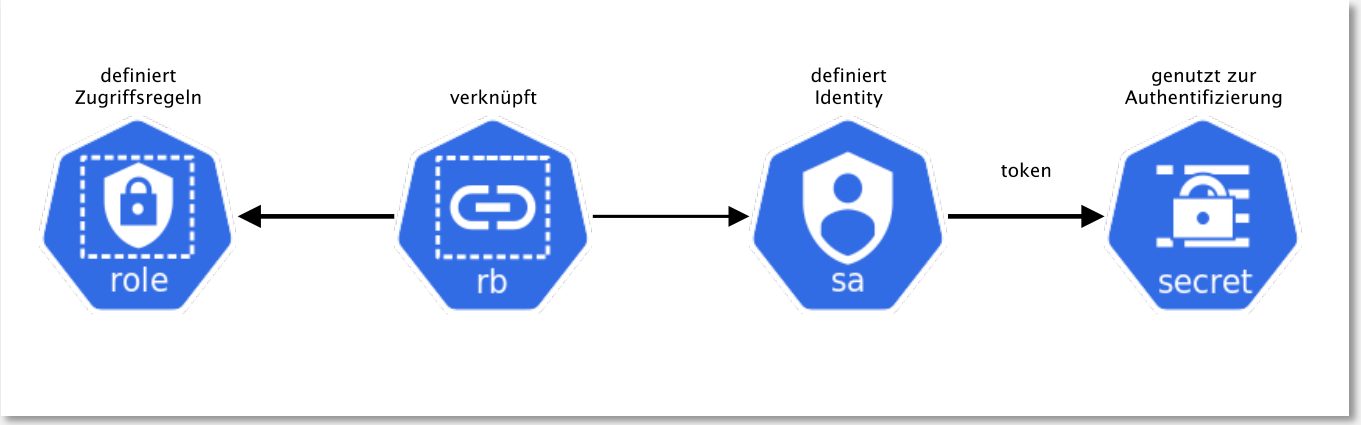

In Kubernetes können Namespaces zur Isolation von Workloads angelegt werden.

Mittels Serviceaccounts und Zugriffsregeln können innerhalb eines Namespaces komplexe Rechtesysteme realisiert werden.

Jeder per `kubectl` angelegte Namespace erhält automatisch einen default Serviceaccount mit einem generierten Access Token zur Authentifizierung. Weitere Serviceaccounts können angelegt werden.

Quelle: https://kubernetes.io/docs/reference/access-authn-authz/rbac/

CLOUD NATIVE COMPUTING

Roles weisen Rechte in einem Namespace zu (für den diese Rolle erzeugt wurde).

ClusterRoles weisen Rechte Namespace-übergreifend auf Cluster-Ebene zu.

Das Anlegen von ClusterRoles erfolgt analog zu Roles.

ROLE BASED ACCESS MODEL

CLOUD NATIVE COMPUTING

Isolieren von Anwendungen mittels Namespaces

Dieses Beispiel zeigt, wie sich Leserechte in Kubernetes dem default Serviceaccount und volle Schreibrechte dem Admin Serviceaccount zuweisen lassen.

```
# Das Erzeugen eines Namespaces (mit kubcectl) erzeugt auch
# immer automatisch einen default Serviceaccount (sa)
kubectl create namespace xample
kubectl get sa -n xample

NAME      SECRETS   AGE
default   1         6m2s

# Jedem Serviceaccount ist ein Token zur Authenifizierung
# zugeordnet (bspw. in der kubeconfig von kubectl nutzbar)
TOKEN=kubectl get sa default -o=jsonpath="{.secrets[0].name}"
kubectl get secret $TOKEN -n xample -o jsonpath="{.data.token}"

# Es können beliebig weitere Serviceaccounts in einem
# Namespace angelegt werden, z.B. ein Admin Account
kubectl create sa admin -n xample

# Anlegen von Rollen
kubectl apply -f read-role.yaml
kubectl apply -f rw-role.yaml

# Zuordnen von Rollen zu Accounts
kubectl create rolebinding read-binding --role=read-role \
  --serviceaccount=xample:default -n=xample
kubectl create rolebinding rw-binding --role=rw-role \
  --serviceaccount=xample:admin -n=xample
```

```
apiVersion: rbac.authorization.k8s.io/v1
kind: Role
metadata:
  name: read-role
rules:
- apiGroups: [""] # "" => core API group
  resources: ["*"]
  verbs: ["get", "watch", "list"]
```

Manifest: read-role.yaml

```
apiVersion: rbac.authorization.k8s.io/v1
kind: Role
metadata:
  name: rw-role
rules:
- apiGroups: ["*"]
  resources: ["*"]
  verbs: ["*"]
```

Manifest: rw-role.yaml

KUBERNETES

Überblick über die wichtigsten Kubernetes-Ressourcen

CLOUD NATIVE COMPUTING

Ausführbare Jobs/Workloads	Persistenz	Isolieren von Anwendungen mittels Namespaces	Exponieren von Anwendungen und Diensten
 Deployments	 Persistent Volume Claim	 Quotas und Limit Ranges	Primär Intra-Cluster  **Services**
 (Cron-)Jobs			
 Daemon Sets	 Persistent Volume	 Role Based Access Model	Primär Extra-Cluster  **Ingress**
 Stateful Sets			

SERVICES

Exponieren von Anwendungen und Diensten

Definieren von Diensten mittels Pod-Labels und Selektoren

Dienste ermöglichen es eine Anwendung, die auf einer Reihe von Pods ausgeführt wird, als Netzwerkdienst unter einem **DNS-Namen** verfügbar zu machen.

Hierzu werden die Pods eines Services mittels ***Selektoren*** bestimmt.

Kubernetes gibt Pods ihre eigenen **IP-Adressen** und Services einen eindeutigen **DNS-Namen**.

Pods, die über einen Service angesprochen werden unterliegen automatisch einem **Load Balancing** durch kube-proxy.

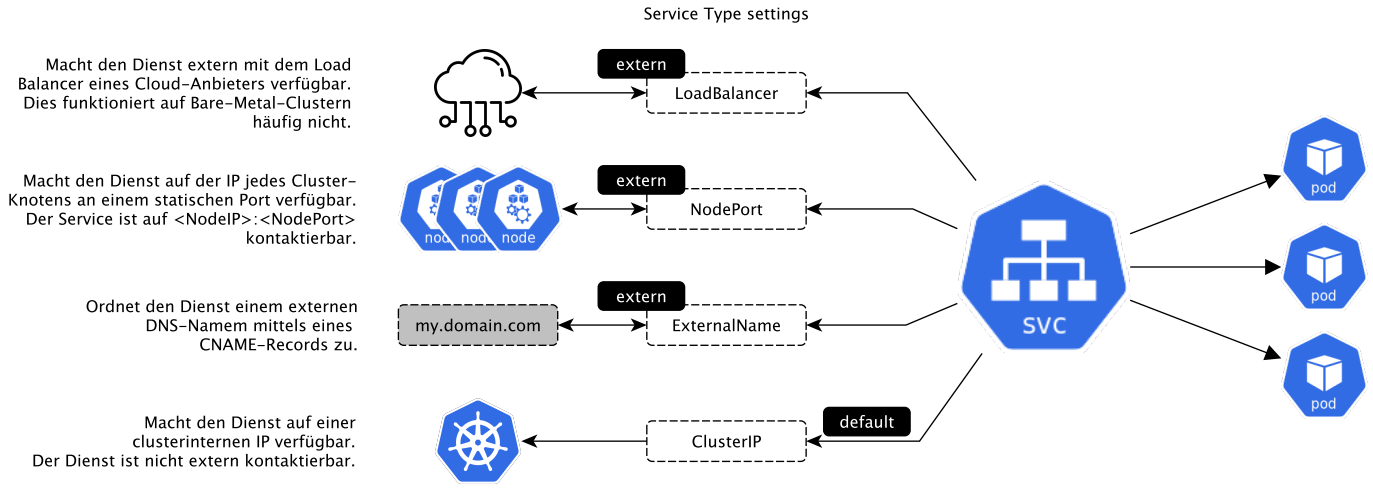

Exponieren von Diensten mittels Service Types

Dienste werden per default nur Cluster-intern bereitgestellt. Sie können aber mittels des ***serviceType*** Feldes Cluster-extern exponiert werden:

- **`Load Balancer`** bindet einen Dienst an eine Public IP eines Cloud Providers
- **`NodePort`** macht einen Service-Port auf allen IP-Adressen der Cluster Nodes bekannt.
- Mittels **`ExternalName`** können externe Dienste in den Cluster eingeblendet und wie Cluster-interne Dienste genutzt werden.

Die Exponierung mittels Loadbalancern funktioniert meist nur in Public IaaS-provisionierten Clustern.

Im bereitgestellten MicroK8S-basierten K8S-Cluster können Sie Dienste nur mittels HTTP-basierten Ingress exponieren (dazu gleich mehr).

Hintergrund: *LoadBalancer benötigen eine Public-IP-Adresse für jeden exponierten Dienst (diese sind mittlerweile recht rar für IP-V4).*

Quelle: https://kubernetes.io/docs/concepts/services-networking/service/

SERVICES

Exponieren von Anwendungen und Diensten

```yaml
apiVersion: apps/v1
kind: Deployment
metadata:
  name: nginx-deployment
  labels:
    app: nginx
spec:
  replicas: 3
  selector:
    matchLabels:
      app: nginx
  template:
    metadata:
      labels:
        app: nginx
    spec:
      containers:
      - name: nginx
        image: nginx:1.14.2
        ports:
        - containerPort: 8080
        - containerPort: 8443
```

Manifest: nginx-deployment.yaml

```yaml
apiVersion: v1
kind: Service
metadata:
  name: http-service
spec:
  selector:
    app: nginx
  ports:
  - name: http
    protocol: TCP
    port: 80
    targetPort: 8080
  - name: https
    protocol: TCP
    port: 443
    targetPort: 8443
```

Manifest: nginx-service.yaml

```
# Ausbringen des Deployments
kubectl apply -f nginx-deployment.yaml

# Ausbringen eines Services
kubectl apply -f nginx-service.yaml

# Auflisten aller Services
kubectl get svc

# Details zu einem Service
kubectl describe http-service

# Löschen eines Services
kubectl delete -f nginx-service.yaml

# Services mit der Kommandozeile erzeugen
# (funktioniert auch für andere
# Ressourcen)
kubectl create svc --help
```

INGRESS

Exponieren von Service APIs via HTTP(S)

- Ein Ingress macht HTTP- und HTTPS-Routen von außerhalb des Clusters für Dienste innerhalb des Clusters verfügbar.
- Ein Ingress kann so konfiguriert werden, dass für Dienste extern erreichbare URLs bereitgestellt (inkl. Load Balancing, SSL/TLS Termination und namenbasiertes virtuelles Hosting) angeboten werden.
- Das Routing wird hierzu durch Regeln gesteuert, die in der Ingress-Ressource definiert sind.
- Wenn Dienste mittels anderer Protokolle als HTTP(S) exponiert werden sollen, muss normalerweise ein Service vom Typ NodePort oder LoadBalancer verwendet werden.

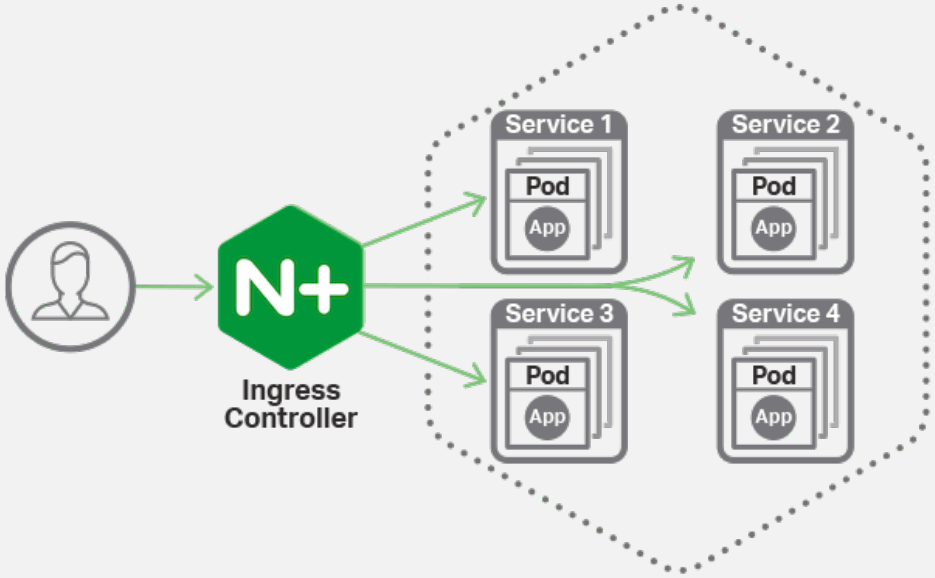

Quelle: https://kubernetes.io/docs/concepts/services-networking/ingress/

CLOUD NATIVE COMPUTING

Wieso nur HTTP(S) und nicht beliebige Protokolle?

REST-basierte APIs sind einfach eine verbreitete Art und Weise Schnittstellen zu Cloud-nativen Dienste bereitzustellen.

*Beliebige andere TCP/UDP basierte Protokolle können mittels **Load Balancern** über Services Cluster-extern bekannt gemacht werden.*

INGRESS

Exponieren von Anwendungen und Diensten

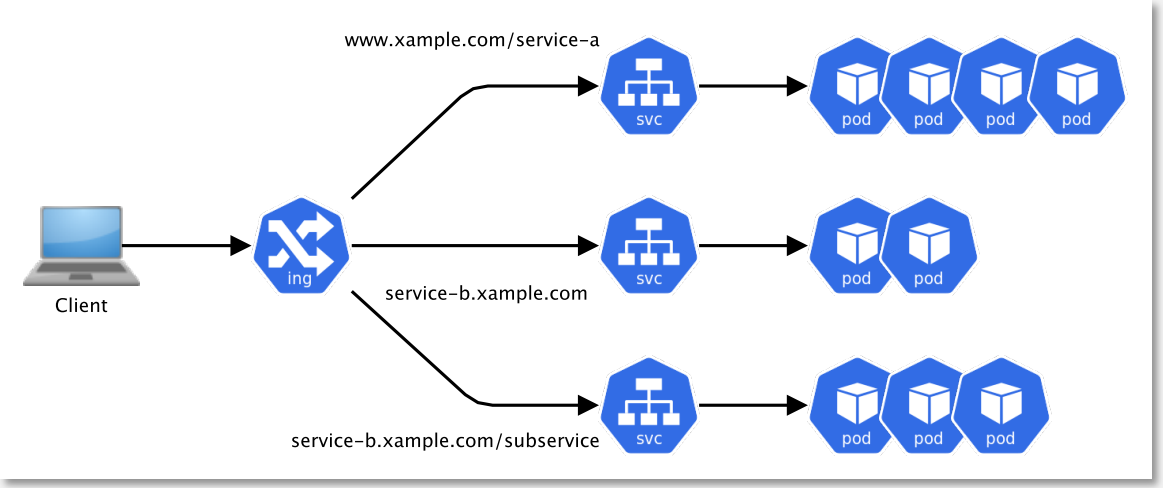

Insbesondere HTTP-basierte Dienste (z.B. REST-basierte APIs) werden meist mittels Ingress Ressourcen für Zugriffe von außerhalb des Clusters bereitgestellt.

Anders als Service-basierte NodePort oder LoadBalancer Exponierungen (die pro Exponierung jeweils eine eindeutige IP-Adresse+Portnummer Kombination benötigen) braucht ein Ingress nur eine einzige IP-Adresse und eine Portnummer, um eine Vielzahl an Diensten zu exponieren. Insbesondere Public-IP4 Adressen sind mittlerweile ein knappes Gut geworden.

Ingresse laufen ferner auf Anwendungsschicht des Netzwerkstapels (HTTP) und bieten daher Funktionen wie bspw. Cookie-gestützte Sitzungsaffinitäten und können ferner mittels TLS-Zertifikaten abgesichert werden (HTTPS).

```yaml
kind: Ingress
apiVersion: networking.k8s.io/v1
metadata:
  name: xample-ingress
  annotations:
    nginx.ingress.kubernetes.io/rewrite-target: /
spec:
  rules:
  - host: www.xample.com
    http:
      paths:
      - path: /service-A
        pathType: Prefix
        backend:
          service:
            name: service-a
            port: { number: 8080 }
 - host: service-b.xample.com
   http:
     paths:
     - path: /
       pathType: Prefix
       backend:
         service:
           name: service-b
           port: { number: 80 }
     - path: /subservice
       pathType: Prefix
       backend:
         service:
           name: service-b-subservice
           port: { number: 8888 }
```

Manifest: xample-ingress.yaml

KUBERNETES

Nur Versuch macht kluch ...

CLOUD NATIVE COMPUTING

Klonen Sie dieses Repository:

```
git clone https://git.mylab.th-luebeck.de/cloud-native/lab-k8s.git
```

Basis-Blueprint

> Ingress Controller
> Service
> Deployment
> Statesharing via REDIS
> Persistent Volume Claims

ZUM NACHLESEN

Teil I: Überblick

1. Einführung in Kubernetes
2. Erste Schritte mit Docker und Kubernetes

Teil II: Grundlagen

3. Pods: Container in Kubernetes ausführen
4. Replikationscontroller
5. Dienste: Pods finden und Ihnen kommunizieren
6. Volumes: Festplattenspeicher zur Containern hinzufügen
7. Konfigurationszuordnungen und Secrets: Anwendungen konfigurieren

9. Deployments: Anwendungen deklarativ aktualisieren
10. StatefulSets: Replizierte statusbehaftete Anwendungen bereitstellen

Teil III: Fortgeschrittene Themen

14. Die Computerressourcen eines Pods verwalten

ZUM NACHLESEN

Kapitel 9: Container-Plattformen

9.1: Scheduling

- Heterogenität von Workloads
- Scheduling-Algorithmen
- Scheduling-Architekturen

9.2: Orchestrierung

- Definition von Betriebszuständen
- Regelkreis: Desired vs. Current State

9.3: Inside Kubernetes

- Kubernetes Architektur
- Verwaltete Ressourcen und Basis-Blueprints
- Workloads
- Scheduling Constraints
- Automatische Skalierung von Workloads
- Exponieren von Workloads (Services / Ingress)
- Health Checking
- Persistenz
- Isolation von Workloads

ZUM NACHLESEN

Paper

- Ali Ghodsi, Matei Zaharia, Benjamin Hindman, Andy Konwinski, Scott Shenker, and Ion Stoica. 2011. **Dominant resource fairness: fair allocation of multiple resource types**. https://dl.acm.org/doi/10.5555/1972457.1972490
- Benjamin Hindman, Andy Konwinski, Matei Zaharia, Ali Ghodsi, Anthony D. Joseph, Randy Katz, Scott Shenker, and Ion Stoica. 2011. **Mesos: a platform for fine-grained resource sharing in the data center**. https://people.eecs.berkeley.edu/~alig/papers/mesos.pdf
- Reiss et. al., **Heterogeneity and Dynamicity of Clouds at Scale: Google Trace Analysis**, 2012 https://www.pdl.cmu.edu/PDL-FTP/CloudComputing/googletrace-socc2012.pdf
- Schwarzkopf et al. **Omega: flexible, scalable schedulers for large compute clusters**, SIGOPS European Conference on Computer Systems (EuroSys), ACM, Prague, Czech Republic (2013) https://storage.googleapis.com/pub-tools-public-publication-data/pdf/41684.pdf
- Benjamin Hindman, **Practical Considerations for Multi-Level Schedulers** (Keynote, 19th Workshop on Job Scheduling Strategies for Parallel Processing), 2015 https://www.cs.huji.ac.il/~feit/parsched/jsspp15/p0-hindman.pdf
- Verma et al., **Large-scale cluster management at Google with Borg**, Proceedings of the European Conference on Computer Systems (EuroSys), ACM, Bordeaux, France (2015) https://storage.googleapis.com/pub-tools-public-publication-data/pdf/43438.pdf
- Burns, Brendan, et al. **"Borg, omega, and kubernetes."** Queue 14.1 (2016): 70-93. https://research.google/pubs/pub44843.pdf

KONTAKT

Disclaimer

Nane Kratzke

+49 451 300-5549

nane.kratzke@th-luebeck.de

kratzke.mylab.th-luebeck.de