BeOne stuttgart

WENN ICH DAS NUR VORHER GEWUSST HÄTTE!

Kubernetes für Entwickler

Dr. Stefan Schlott (BeOne Stuttgart GmbH)

ABOUT.TXT

Stefan Schlott, BeOne Stuttgart GmbH

Java-Entwickler, statische-Sprachen-Fan, Linux-Jünger

Seit jeher begeistert für Security und Privacy

Herr der Container (im Projekt)

KUBERNETES!

Oh brave new world...

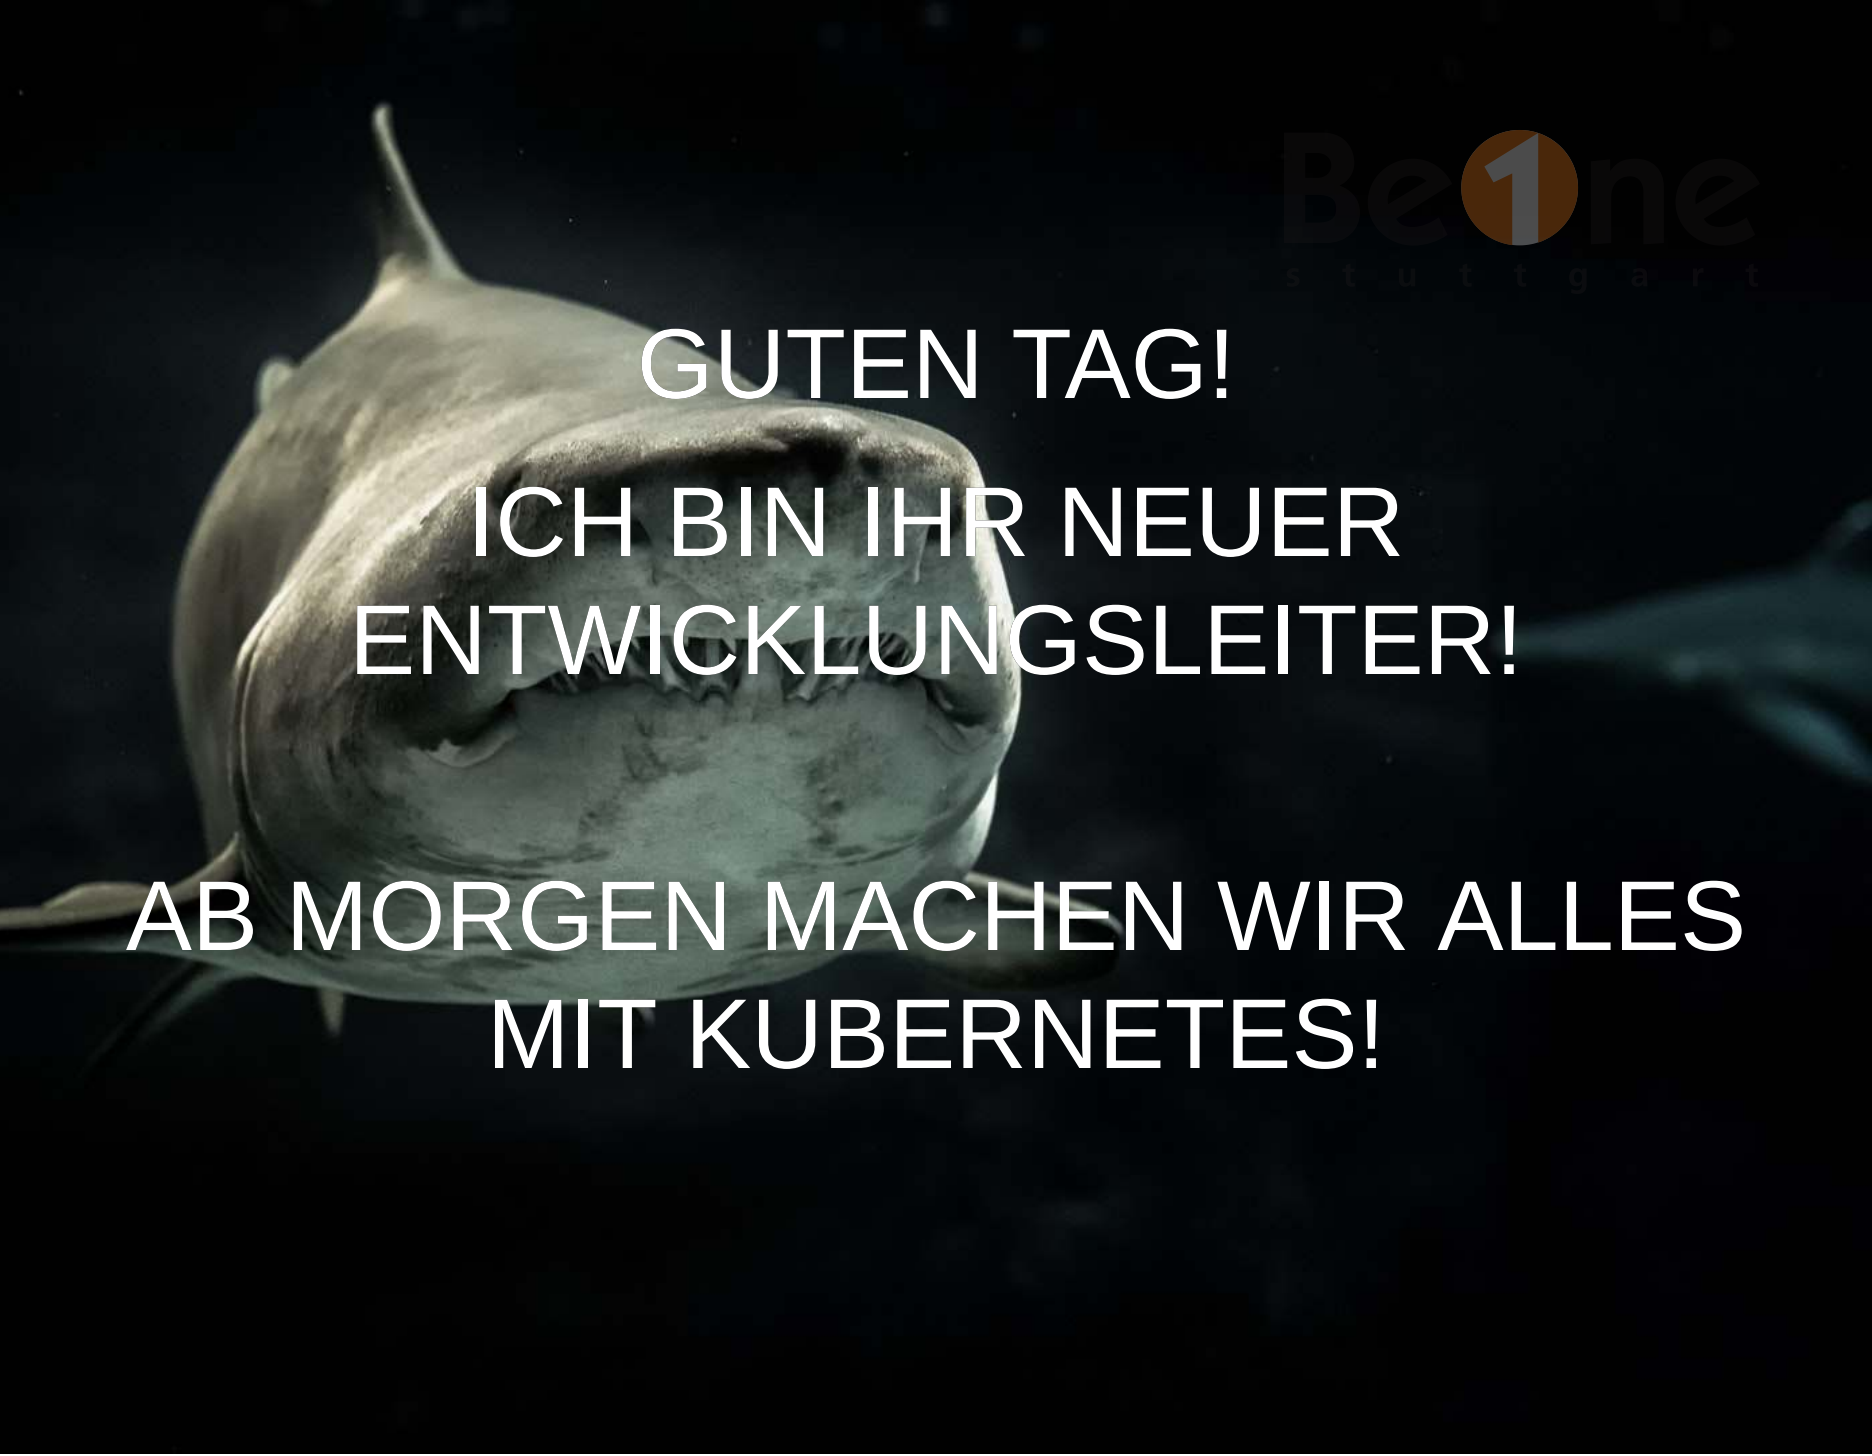
GUTEN TAG!
ICH BIN IHR NEUER ENTWICKLUNGSLEITER!
AB MORGEN MACHEN WIR ALLES MIT KUBERNETES!

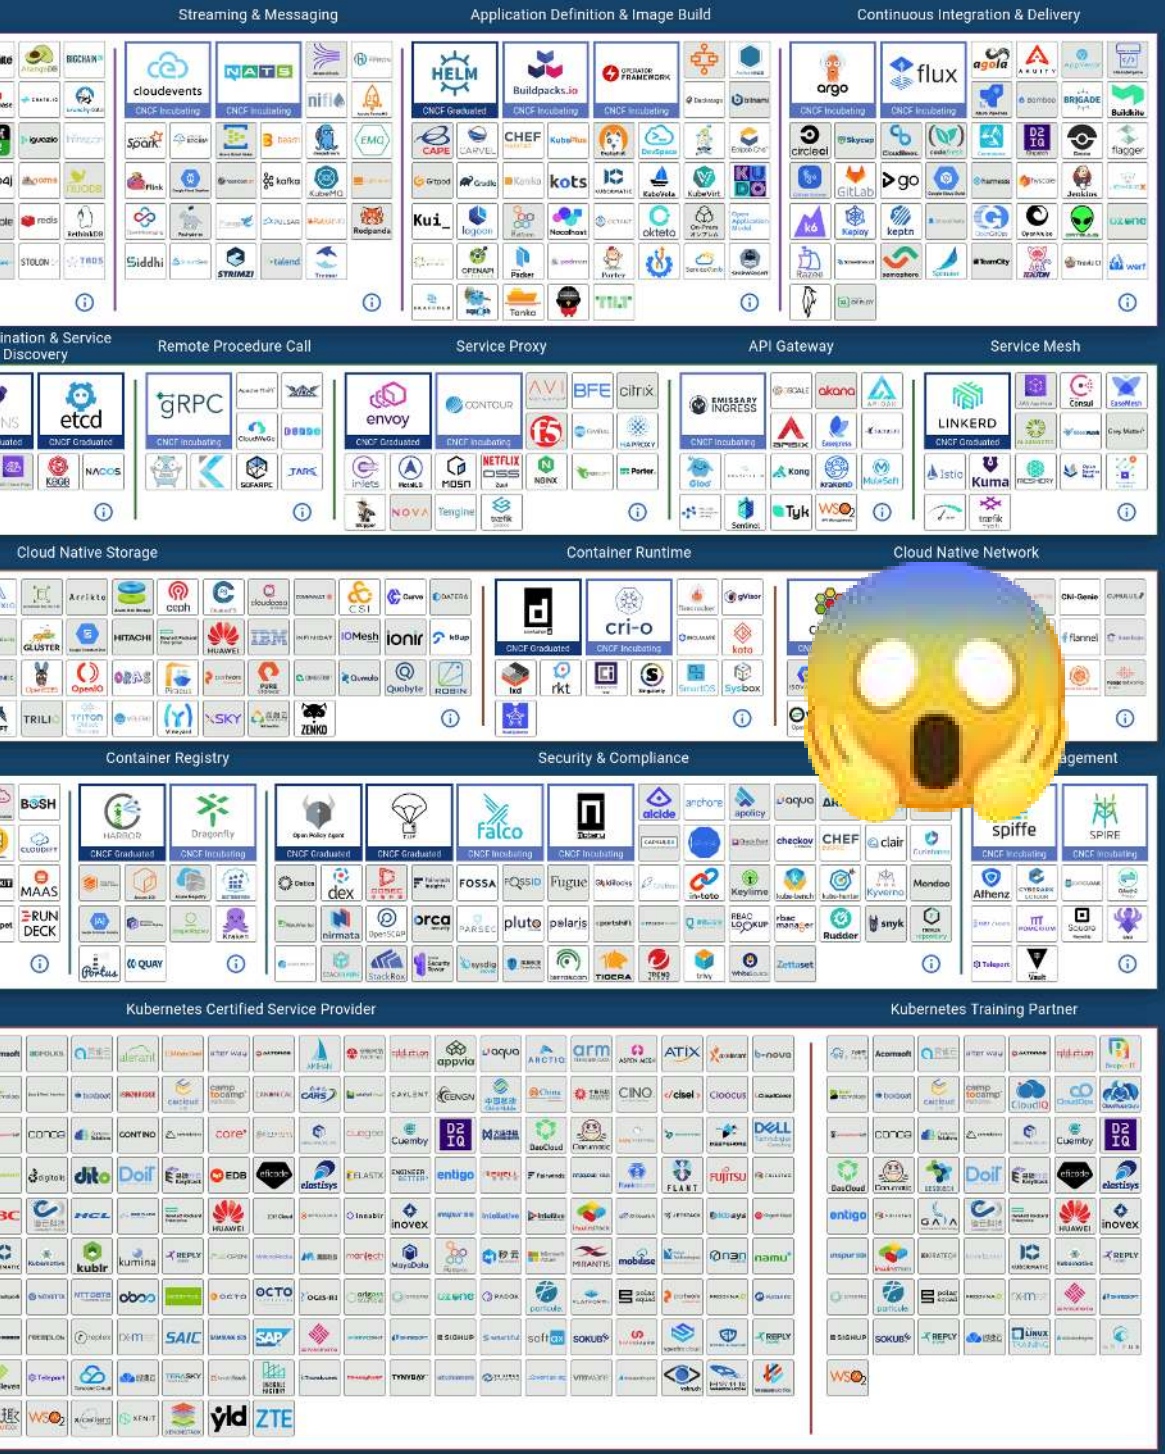
Streaming & Messaging
Application Definition & Image Build
Continuous Integration & Delivery
cloudevents
NATS
HELM
Buildpacks.io
argo
flux
Remote Procedure Call
Service Proxy
API Gateway
Service Mesh
etcd
gRPC
envoy
CONTOUR
EMISSARY INGRESS
LINKERD
Cloud Native Storage
Container Runtime
Cloud Native Network
cri-o
Container Registry
Security & Compliance
HARBOR
Dragonfly
Falco
spiffe
SPIRE
Kubernetes Certified Service Provider
Kubernetes Training Partner

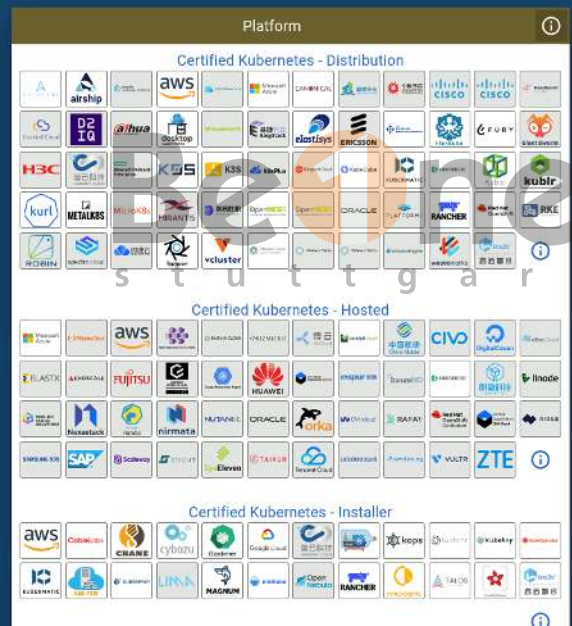
Platform
Certified Kubernetes - Distribution
Certified Kubernetes - Hosted
Certified Kubernetes - Installer
PaaS/Container Service

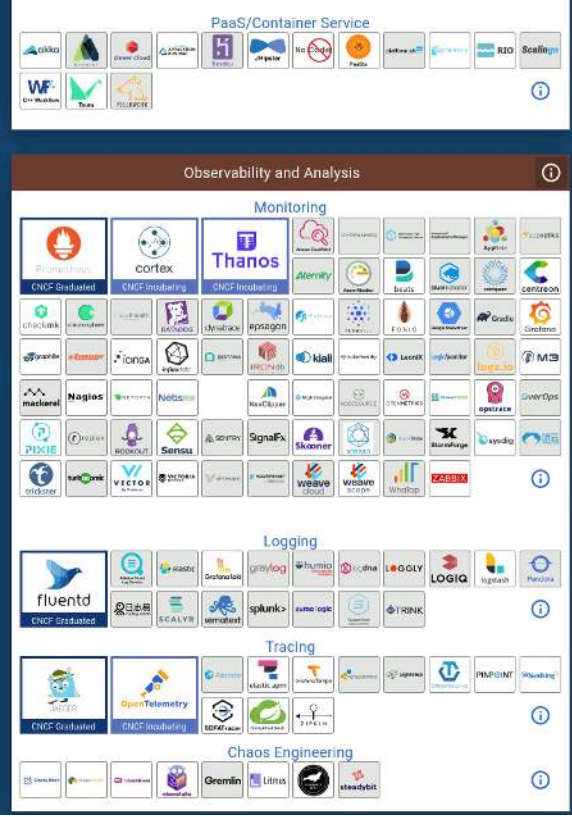
Observability and Analysis
Monitoring
Thanos
cortex
Logging
fluentd
Tracing
OpenTelemetry
Chaos Engineering

KEINE SORGE!

Sie müssen nur ihre bestehende Anwendung in einen Container packen, das ist alles!

KUBERNETES IN A NUTSHELL

Ein kurzer Überblick

ZUSTÄNDIGKEITS-MATRJOSCHKA

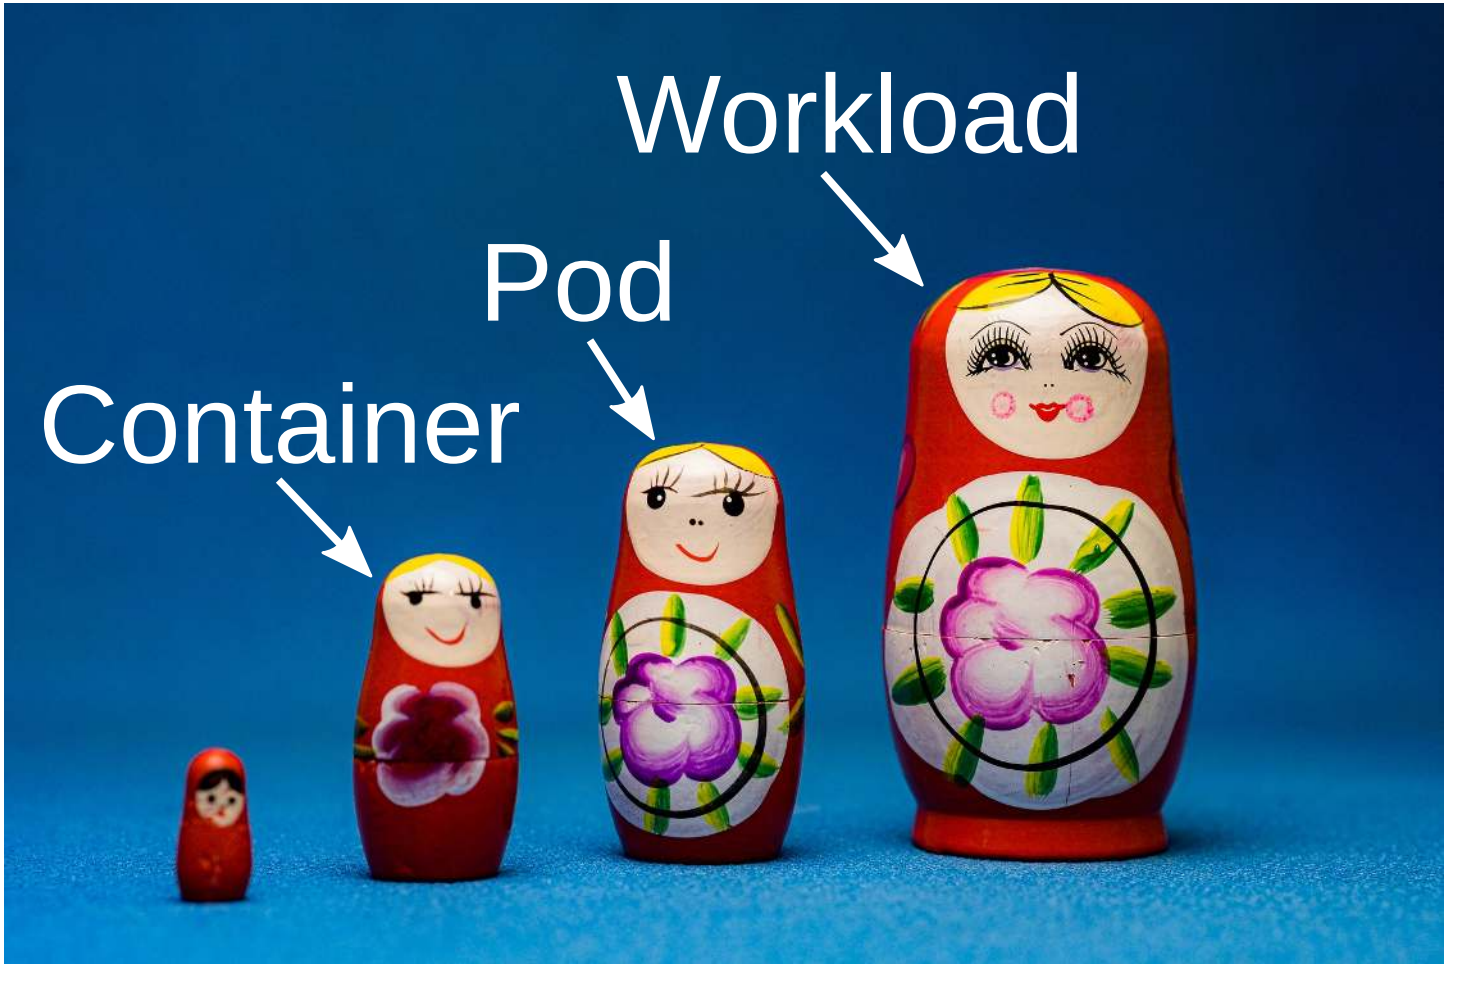

Be One
stuttgart

WAS IST WAS?

Container: Hoffentlich klar :-)

Pods: Ein oder mehrere Container. „Atomare Einheit“ in Kubernetes

Workload: Verwaltet Pods
Übliche Workloads: Deployment, StatefulSet

Be One
stuttgart

WER MANAGT WAS?

Node → Container (Restarts, etc.)

Scheduler → Pods (Zuteilung auf Nodes)

Cluster Controller → Workloads (Skalierung, Rolling Updates, Neue Pods bei Ausfall von Node, etc.)

TYPISCHE WORKLOADS

DEPLOYMENT

Stateless

Einfacher zu handlen

STATEFULSET

1:1-Verknüpfung mit Pod-individuellem Storage

Be One stuttgart

SERVICES

„Kleber“ zwischen (Gruppen von) Pods und einem (DNS-)Namen

Abstrahiert über „mehrere einer Sorte“ o.ä.

Ansprechbar als Hostname

Mapping: Hostname + Port + Protokoll → Port im Container

Be One stuttgart

LABELS

Kubernetes Object:

```yaml
apiVersion: apps/v1
kind: Deployment
metadata:
  name: foobar
  labels:
    app: foobar
    networking/ingress-allow: true
spec:
  ...
```

SELECTORS

Selector wählt Ziel von Regeln

z.B. Service:

```
apiVersion: v1
kind: Service
metadata:
  name: foobar-service
spec:
  type: ClusterIP
  ports:
    - ...
  selector:
    app: foobar
```

Service zeigt auf alle Pods mit dem Label `app=foobar`

PODS

Der große Container-Zirkus

Be One
stuttgart

PODS

Kleinste von Kubernetes gemanagte Einheit

Ein oder mehrere Container

Laufen auf derselben Node

Selbe IP-Adresse (selber Network-Namespace)

Auch IPC / Shared Memory zwischen Containern möglich

Gemeinsames Nutzen von Volumes

MODULBAUKASTEN

Jeder Pod: „Macht ein Ding“

→ nur eine Anwendung, etc.
→ Skalierung, Redundanz, ...: Anderer Mechanismus!

Also warum mehrere Container?

Teilfunktionen separat - und ggfs an mehreren Stellen wiederverwenden

Be One stuttgart

BEISPIEL: PROMETHEUS

„Hauptanwendung”: nginx

Gewünscht: Statistiken per Prometheus exportieren

„Klassischer Weg“: nginx-Container „ableiten“ und Prometheus-Exporter dazubauen

„The Pod way“: Zweiter App-Container mit dem Prometheus-Exporter

Be One
stuttgart

INIT-CONTAINER

Naming: Init-Container vs App-Container

Container, die vor dem Start der App-Container ausgeführt werden

Der Reihe nach

Ohne Timeouts, erzwungene Restarts, etc.

Beispiel: Liquibase-Datenbank-Migrationen durchführen

DEBUGGING

In Container verbinden: `kubectl exec -it` *`podname`* `/bin/sh`

Port Forwarding: `kubectl port-forward` *`podname`* *`localport`*`:`*`remoteport`*

Ephemeral Containers ohne Namespace-Grenze
(Kubernetes 1.23, beta)

`kubectl debug -it` *`podname`* `--image=busybox --target=`*`containername`*

RESSOURCEN-LIMITS

Was ist „normal“ in meiner Anwendung?

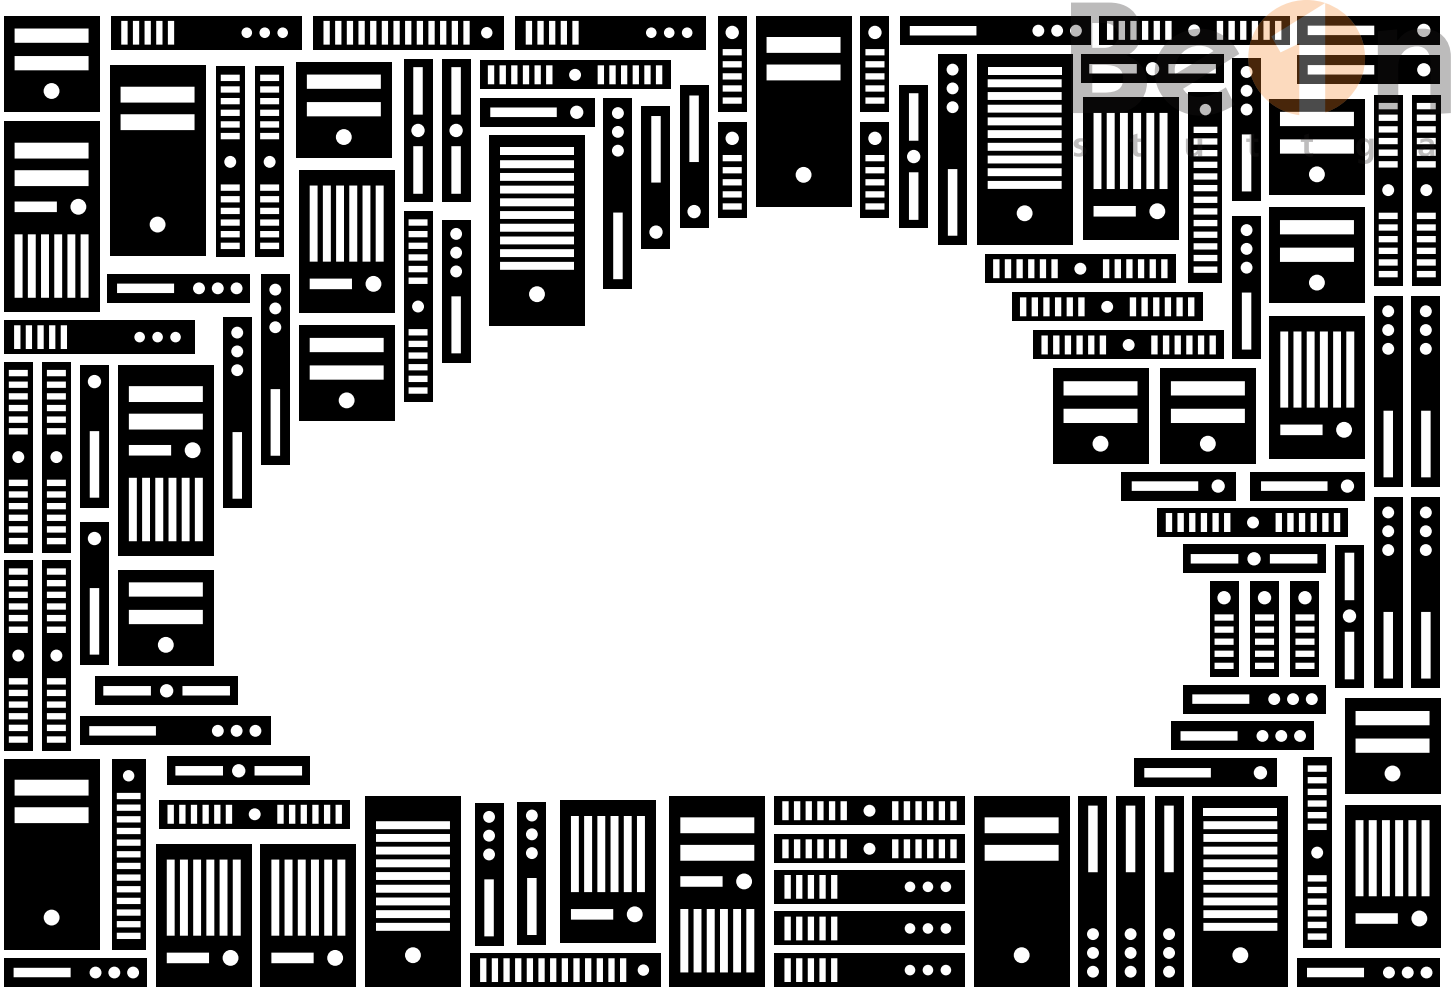

There is NO CLOUD, just other people's computers

Bild: CC-by-sa FSFE

Be One
stuttgart

REQUESTS UND LIMITS

...für RAM und CPU

Requests: Mindestgarantie für einen Pod
Kapazitäts-Disposition für Admins
Indikator für Kubernetes (Scheduler, Autoscaler)

Limits: Maximalverbrauch
Schutz vor Amok-laufenden Anwendungen

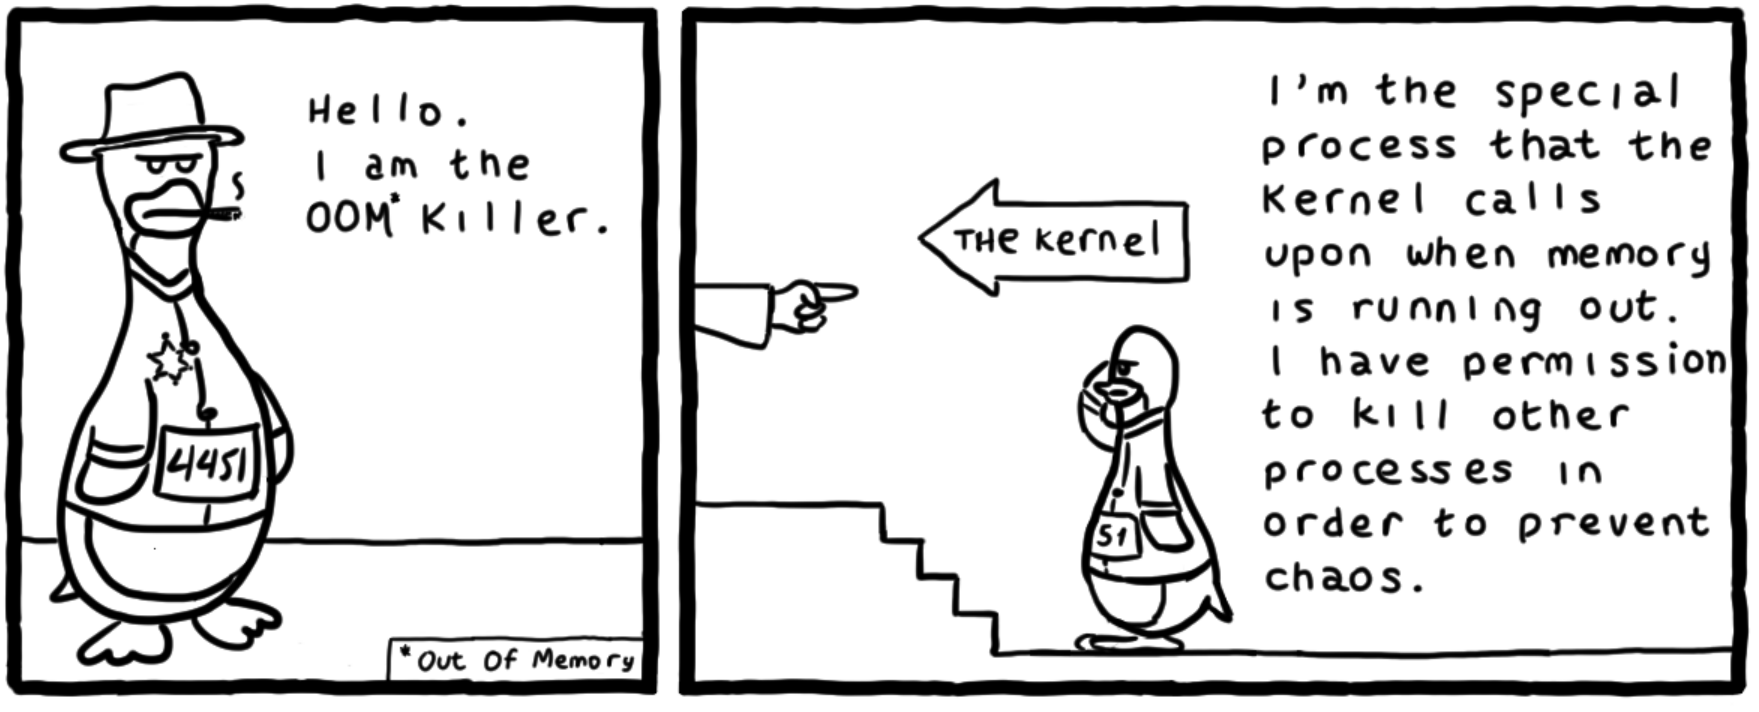

JAVA UND DER FREIE SPEICHER

Vor Java 8u181: Berücksichtigt cgroup nicht (JRE bestimmt Heapgröße auf Basis des gesamten RAMs der Node) ↯

Ohne -Xmx und -Xms: JRE bestimmt initiale und maximale Heapgröße selbst

Aber: Größen müssen auf Request/Limit abgestimmt sein!

Be One
stuttgart

HEAPGRÖSSE ≠ LIMIT

-Xms / -Xmx → Initiale / Maximale Heapgröße

Kubernetes-Resourcen: *Gesamter* RAM-Bedarf:

Heap, weiterer Speicherbedarf des JRE, aber auch z.B. tmpfs

→ Anwendung kennen, entsprechende Zugabe

LIMIT ≠ GARANTIE

Eine Node kann weniger RAM als das Containerlimit haben!

→ -Xms = -Xmx = Request (minus Zuschlag)

→ Request = Limit

→ Anwendungsverhalten „kennen“, horizontal skalieren

QUOTAS

Maximalwert für Summe aller Requests/Limits *in einem Namespace*

(z.B. vom Admin vorgegeben um „gierige Teams“ auszubremsen)

Vorsicht bei Rolling Updates:
Nicht bis zum Anschlag ausreizen!

LEBEN UND STERBEN IM CLUSTER

Die großen Fragen im Leben eines Containers

PROBES

„Statusabfragen“ an den Pod
(genauer: Die App-Container)

Verschiedene Möglichkeiten: Kommando ausführen, TCP-Connect, HTTP-Request, ...

Initial Delay und Interval

Success- und Failure Threshold

Be One
stuttgart

READINESS PROBE

Liefert Information, ob Pod Daten verarbeiten kann

Wenn Failure Threshold überschritten: Keine Zustellung von Requests, etc.

→ Backpressure-Mechanismus, Überlastschutz

Be One
stuttgart

LIVENESS PROBE

Liefert Information, ob Pod korrekt funktioniert

Pod-Neustart, wenn Failure Threshold überschritten

→ „Selbstheilung“ im Cluster

STARTUP PROBE

„Initial Delay dynamisch” für Liveness-Probe

Nach positivem Test der Startup-Probe: Wechsel zur Liveness-Probe

Anwendungsbeispiel: Selber Endpoint wie Liveness-Probe, aber deutlich höherer Failure Threshold

→ Init-Container vs. Startup-Probe

GRACEFUL SHUTDOWN

Chance für Anwendung, sich sauber herunterzufahren:

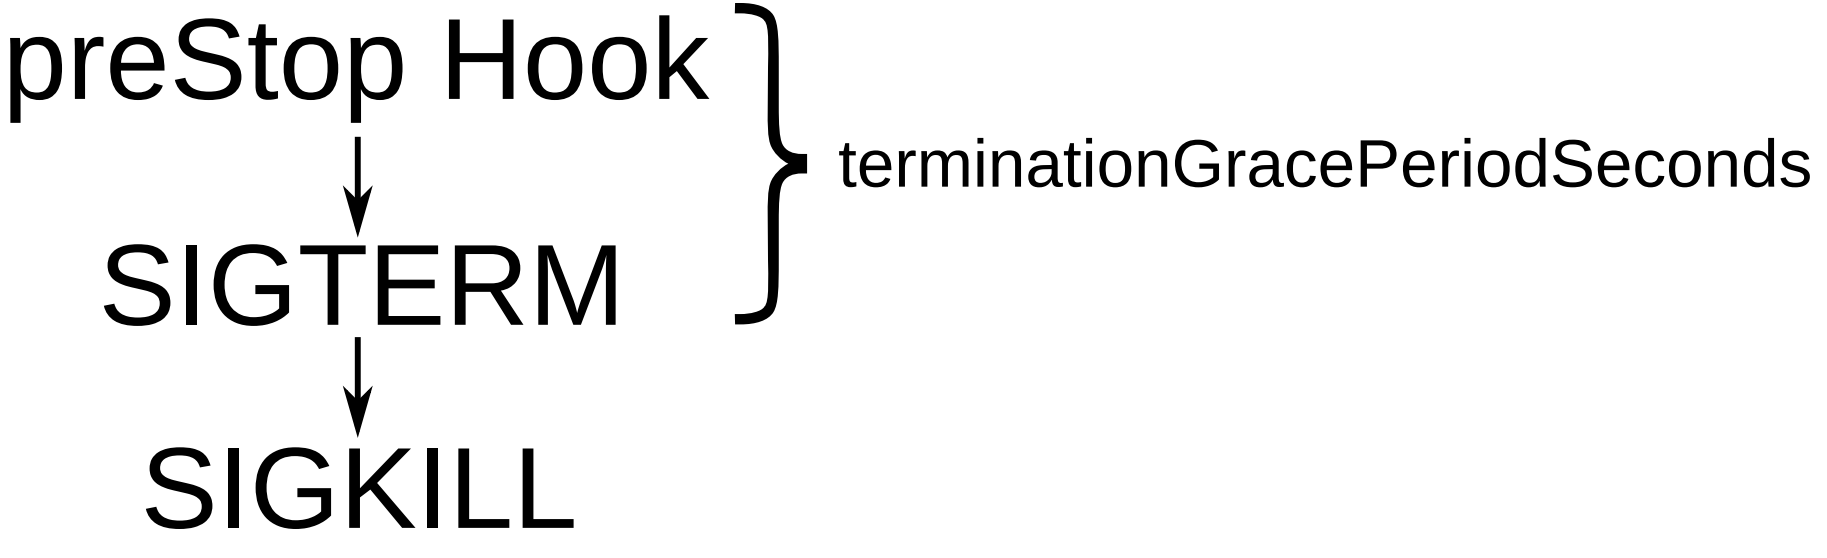

SHUTDOWN: SIGNALE

SIGTERM: „Höfliche Aufforderung“ an Anwendung

Kann von der Anwendung abgefangen und behandelt werden

Wird an ENTRYPOINT-Prozess geschickt
(Vorsicht bei Shellskripten - Weiterreichen des Signals?)

SIGKILL: Sofortiges Beenden des Prozess

ROLLING UPDATES

Kingt cool, aber...

Be One stuttgart

ROLLING UPDATES

Idee: Zero Downtime

Tuning-Parameter: maxUnavailable und maxSurge

→ Update beginnt durch Stoppen von maxUnavailable alten Pods und Sarten von maxSurge neuen Pods

Be One
stuttgart

FEHLERBILDER

Geht doch! vs Wo ist mein neues Feature!

Unerschiedliche Stände laufen gleichzeitig

Schemakompatibilität
(Datenkbank-Schema, REST-APIs, etc)

AUTOSCALING

Wenn die Hölle losbricht

GRUNDFUNKTION

Controller passt Anzahl Replicas an Metriken an (innerhalb von gegebenem Minimum und Maximum)

Durchschnitt der Metrik vs gewünschter Zielwert = Skalierungsfaktor

Relative Zielwerte: Basierend auf Resource Request

FEHLERBILD CPU-INTENSIVER STARTUP

Gut gemeint: Anwendung meldet sich „ready“, macht im Hintergrund noch Dinge

→ Autoscaler detektiert hohe CPU-Last
Startet weitere Pods

→ Wieder CPU-intensiver Start, Durchschnitt steigt weiter, weitere Pods...

FAZIT

FAZIT

Ganz ohne Rücksicht der Anwendung geht's nicht.
Architektur-Impact:

Splitten in Container (Init-Container!)

Endpoints für Probes

Graceful Shutdown

Informierte Entscheidung bzgl. Rolling Updates

stefan.schlott@beone-stuttgart.de
@_skyr @skyr@chaos.social