

Dockerbank

Container-basiertes Deployment von biomedizinischen IT-Lösungen
Rahmenbedingungen & Best Practices beim
Betrieb von Containerlösungen

Dr. med. Thomas Ganslandt¹

¹ *Universitätsklinikum Erlangen*

Aspekte des technischen Betriebs

- ▶ Ablage von Nutzdaten
- ▶ Backup von Containern und Nutzdaten
- ▶ Debugging & Monitoring laufender Container

Konzeptionelle Aspekte

- ▶ Benennung und Versionierung
- ▶ Architektur der Dienste

Sicherheits- & rechtliche Aspekte

- ▶ Images als "Black Box"?
- ▶ Lizenzrechtliche Einschränkungen

Ablage von Nutzdaten (1)

Begriffsbestimmung "Nutzdaten"

- ▶ Daten, die im laufenden Betrieb des Containers entstehen und persistent verfügbar sein sollen
 - ▶ Datensätze in Datenbanken
 - ▶ Dateien mit Nutzdaten
 - ▶ Logdateien, die von dauerhafter Relevanz sind (z.B. Audit-Trails)


- ▶ nicht gemeint sind dagegen...
 - ▶ die eigentliche Software des Services
 - ▶ temporäre Dateien von Services des Containers
 - ▶ Konfigurationsdateien, die bei der Generierung des Images erzeugt wurden
 - ▶ Logdateien von vorübergehender Relevanz

Ablage von Nutzdaten (2)

Ziel: Trennung von Applikation & Nutzdaten

- ▶ Persistenz: Erhaltung der Nutzdaten bei Neuaufsetzen des Containers
- ▶ Unabhängigkeit: bei Update/Austausch des Applikationscontainers
- ▶ Skalierbarkeit: mehrere App-Container mit gemeinsamen Nutzdaten
- ▶ Datenschutz: Hochladen eigener Nutzdaten in Images vermeiden

Ablage von Nutzdaten (3)



▶ Optionen zur Ablage der Nutzdaten

- ▶ im Applikationscontainer
- ▶ in separatem Datencontainer ("Volume Container")
- ▶ im Dateisystem des Hosts ("Volume")
- ▶ auf externer Speicherplattform (SAN, NAS)
- ▶ in separat betriebener Datenbank

▶ "Aufräumen" nicht vergessen

- ▶ Datencontainer werden (bewusst) nicht automatisch mit dem App-Container gelöscht
- ▶ Datencontainer sollten deshalb sinnvoll benannt werden

Backup von Containern & Nutzdaten (1)

Notwendigkeit

- ▶ Nutzdaten sind ohne Frage zu sichern
- ▶ bei den Containern dagegen abzuwägen
 - ▶ können aus DockerHub/privatem Repository jederzeit wiederhergestellt werden
 - ▶ Deployment sollte dazu inklusive nötiger Konfiguration automatisiert sein
- ▶ Disaster Recovery
 - ▶ vollständige Sicherung des Hosts (z.B. Image) inkl. enthaltener Container & Nutzdaten
 - ▶ ermöglicht schnelle Wiederherstellung des Betriebs nach Totalausfall

Backup von Containern & Nutzdaten (2)

Technische Umsetzung: je nach Ablageort

- ▶ reguläre Sicherungsmechanismen
 - ▶ für Dateien im Host-Filesystem
 - ▶ für Dateien auf externen Speichersystemen (SAN, NAS)

- ▶ Docker-spezifische Mechanismen
 - ▶ Sichern eines aktiven Datencontainers
 - wird in einen zweiten Container "eingehängt" und von dort in ein .tar-Archiv gesichert
 - ▶ Export eines Containers in eine Datei
 - zuvor "Fixierung" des aktuellen Dateistands (commit) erforderlich
 - ▶ Pushen eines Images nach DockerHub/privates Repository
 - Cave: versehentlicher Einschluss von Nutz-/Konfigurationsdaten möglich

- ▶ Datenkonsistenz beachten
 - ▶ wie bei jedem Backup
 - ▶ z.B. read-only-Mode einer Datenbank während der Sicherung aktivieren
 - ▶ z.B. Nutzung eines SQL-Dumps statt Sicherung der Rohdateien

Debugging primär für Container-Entwicklung & -Konfiguration

- ▶ Kapselung im Container erschwert Zugriff auf laufende Prozesse

- ▶ Zugriff von "außen"
 - ▶ docker logs: zeigt STDOUT-Meldungen der Applikation im Container
 - ▶ docker attach: hängt sich live an den Container und zeigt laufende STDOUT-Meldungen
 - ▶ docker inspect: zeigt Konfiguration des Containers, insbesondere Umgebungsvariablen und freigegebene Ports
 - ▶ docker top: zeigt laufende Prozesse im Container
 - ▶ docker stats: zeigt Übersicht aller laufenden Container

- ▶ Zugriff von "innen"
 - ▶ docker exec: führt beliebige Befehle im laufenden Container aus
 - z.B. auch eine interaktive Shell, mit der das Dateisystem und interne Logdateien betrachtet sowie weitere Befehle ausgeführt werden können
 - ▶ nsenter ("namespace enter"): gibt Shell-Zugriff auf laufenden Container

Monitoring zur Überwachung "fertiger" Installationen

- ▶ Laufzeitverhalten, Ressourcenverbrauch, Stabilität
- ▶ Herausforderung durch Vielzahl verschiedener oder auch identischer Container, die auf einem oder mehreren Hosts/Clouds laufen
- ▶ manuelles Auslesen von Logs & Statistiken unzureichend

Werkzeuge zur Aggregation & Visualisierung

- ▶ CAdvisor: sammelt & visualisiert docker stats-Angaben
- ▶ Graylog: fragt STDOUT/-ERR ab & bietet aggregierte Sicht
- ▶ Prometheus: Abfrage & Visualisierung verschiedener Daten, Alerting
- ▶ Scout, DataDog: kommerzielle Angebote (zentral gehosted)

Größere Management-Plattformen: z.B. Kubernetes

Benennung und Versionierung

Images

- ▶ Vergabe von "Tags" zur Kennzeichnung von Versionen
 - ▶ z.B. Postgres mit Tag 9.1, 9.2, ... 9.6
 - ▶ spezielles Tag "latest" für jeweils aktuellste Version
- ▶ erlaubt Einbindung ausgewählter Versionsstände
 - ▶ z.B. einer älteren Version, wenn dies für eine Applikation benötigt wird
 - ▶ z.B. immer der aktuellsten ("latest") Version
- ▶ teilweise auch zur Kennzeichnung von Varianten (z.B. php-apache, php-cli)

Container

- ▶ Vergabe eines Namens beim Instanzieren aus dem Image
 - ▶ hilft, Container
- ▶ Vergabe von "Labels" zur Kennzeichnung von Eigenschaften
 - ▶ z.B. für alle Datencontainer, Applikationsserver, ...
 - ▶ hilft, Log- & Sensordaten beim Monitoring zu strukturieren

Kernkonzept Microservices

- ▶ Container sollen im Idealfall nur genau einen Dienst (=1 Prozess) anbieten
- ▶ Wie soll mit der nötigen Infrastruktur umgegangen werden?
 - ▶ z.B. Datenbankserver - würde bei klassischer VM ggf. im gleich Gast installiert
- ▶ Nutzung separater "Infrastruktur"-Container
 - ▶ z.B. für die Datenbank
 - ▶ Infrastruktur kann von mehreren Diensten gemeinsam genutzt oder getrennt je Dienst betrieben werden

Orchestrierung

- ▶ Nutzung von docker compose, um alle für einen Dienst nötigen Container parallel aufzusetzen und inkl. Konfiguration zu starten
- ▶ Bündelung von Containern zu "pods" in Kubernetes, um komplexe Dienste gemeinsam managen zu können

Sicherheit: Container als "Black Box"?

Images als Summe vieler Layers

- ▶ unklar, wer dazu beigetragen hat
 - ▶ wurden aktuelle Releasestände verwendet?
 - ▶ wurden Empfehlungen für die sichere Konfiguration beachtet?
 - ▶ wurde ggf. absichtlich oder versehentlich Schadsoftware eingeschleust?
- ▶ aber: wo liegt der Unterschied zu regulären Softwaredistributionen?
 - ▶ werden von größeren Teams zusammengestellt
 - ▶ nutzen verschiedenste Infrastrukturpakete und Bibliotheken

Vorteile des Container-Ansatzes

- ▶ Kapselung der Dienste innerhalb des Hosts sowie untereinander
 - ▶ nicht explizit freigegebene Ports sind automatisch gesperrt
 - ▶ kein Zugriff aus dem Container auf Dateien des Hosts oder anderer Container
- ▶ zunehmende Verfügbarkeit von "official" Images verbreiteter Tools
- ▶ Möglichkeit einer "Kuratierung" biomedizinischer Container

Containerisierung kann im Konflikt zu Lizenzen stehen

- ▶ z.B. darf der Sourcecode von REDCap nur direkt an Lizenznehmer weitergegeben werden
 - ▶ die Veröffentlichung eines REDCap-Images auf DockerHub ist damit unzulässig
 - ▶ ein Dockerfile, das den Container auf Basis lokal vorliegenden Sourcecodes generiert, ist dagegen möglich
- ▶ z.B. darf die Testversion der Oracle-Datenbank (XE) nur direkt über die Oracle-Homepage distribuiert werden
 - ▶ Images, die offenbar von Privatpersonen erstellt wurden, sind trotzdem auf DockerHub zu finden

Empfehlung

- ▶ Lizenzvorgaben bei der Containerisierung einer Applikation beachten
 - ▶ betrifft ggf. auch genutzte Infrastrukturdienste
 - ▶ Alternativen wie die Bereitstellung von Dockerfiles prüfen
 - ▶ ggf. muss auf Produkte verzichtet werden, deren Lizenz inkompatibel ist

Vielen Dank für Ihre Aufmerksamkeit!

thomas.ganslandt@uk-erlangen.de