QCon 全球软件开发大会
INTERNATIONAL SOFTWARE DEVELOPMENT CONFERENCE

BEIJING 2017

容器技术在千万用户级企业的实践及网络方案优化

SPEAKER /王翱宇

主办方 Geekbang. 极客邦科技 InfoQ

自我介绍 - 王翱宇

- 谐云科技CEO & 联合创始人
- 来自浙江大学SEL实验室，曾就职于美国道富银行，浙大网新。
- 2005年毕业于浙江大学计算机学院

SEL

Zhejiang University

2016

谐云科技
HARMONYCLOUD

演讲内容简介

- 研究方向和产品定位
- 落地案例介绍
- 容器落地方案
  - 多集群方案
  - CI/CD
  - 应用迁移
  - 网络改造与优化

SEL实验室与容器技术书籍

SEL

Zhejiang University

2011

成立于2011年

40+浙大博士/硕士

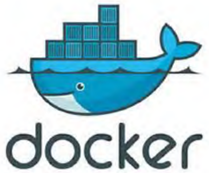

专注开源
PaaS/CaaS技术

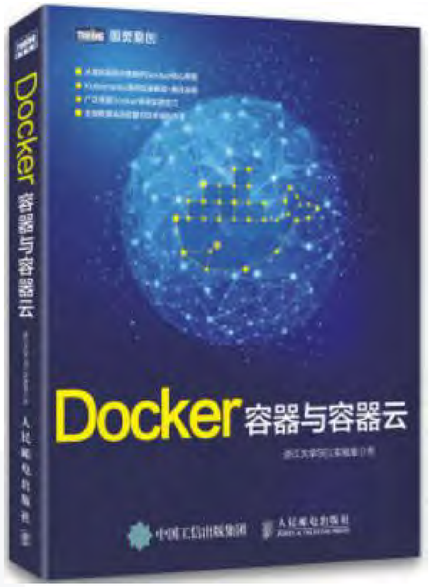

2015

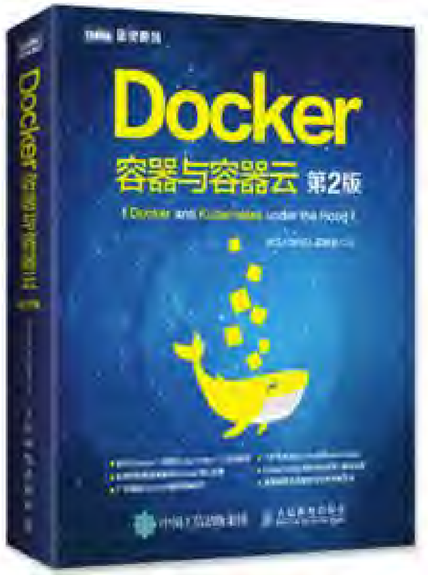

2016

积极参与贡献社区

- 贡献了493个Patch到Kubernetes，总共142万行代码
- 2个Kubernetes feature maintainer

Contribution by companies

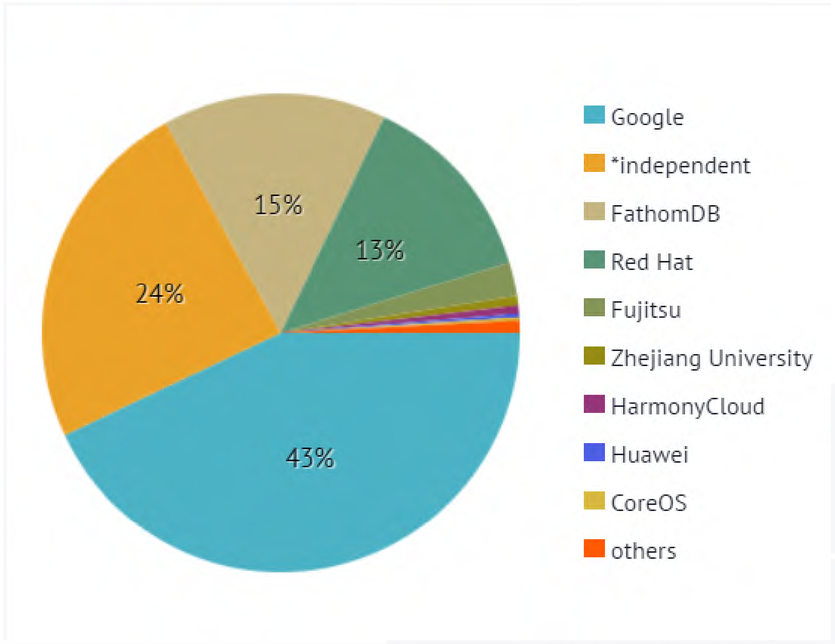

#	Company	Lines of code
1	Google	51550613
	*independent	28806338
2	FathomDB	18119611
3	Red Hat	15711748
4	Fujitsu	2755657
5	Zhejiang University	764824
6	HarmonyCloud	657697
7	Huawei	295721
8	CoreOS	253536
9	Intel	223840

IT向云端迁移的趋势与挑战

企业IT架构演进

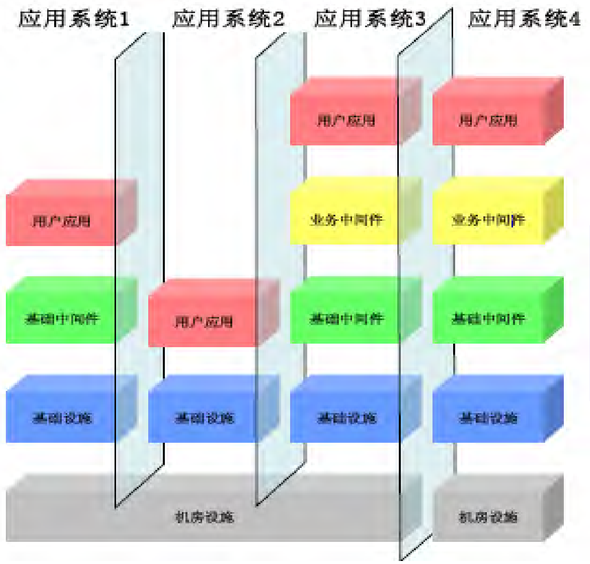

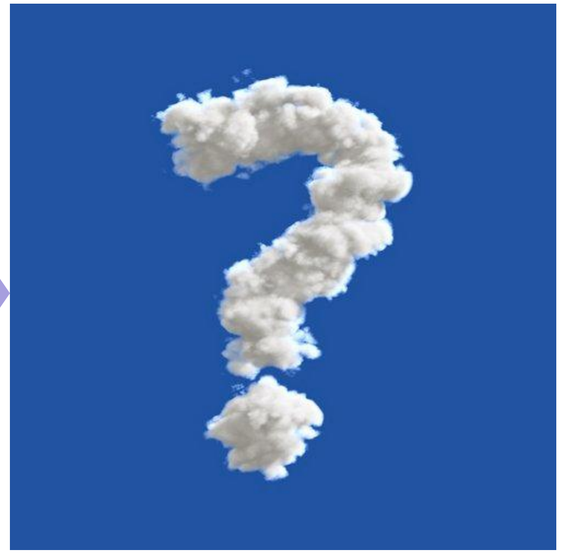

竖井化、巨石型应用式IT系统架构

虚拟化？云平台化？

一个好的云平台

01

保障业务长期稳定、高效的运行

02

快速响应业务上线

03

灵活的资源池，根据客户业务量进行应用调度

04

容错，及时甚至预测性地发现、定位、诊断故障，自我修复的能力

落地案例-业务介绍

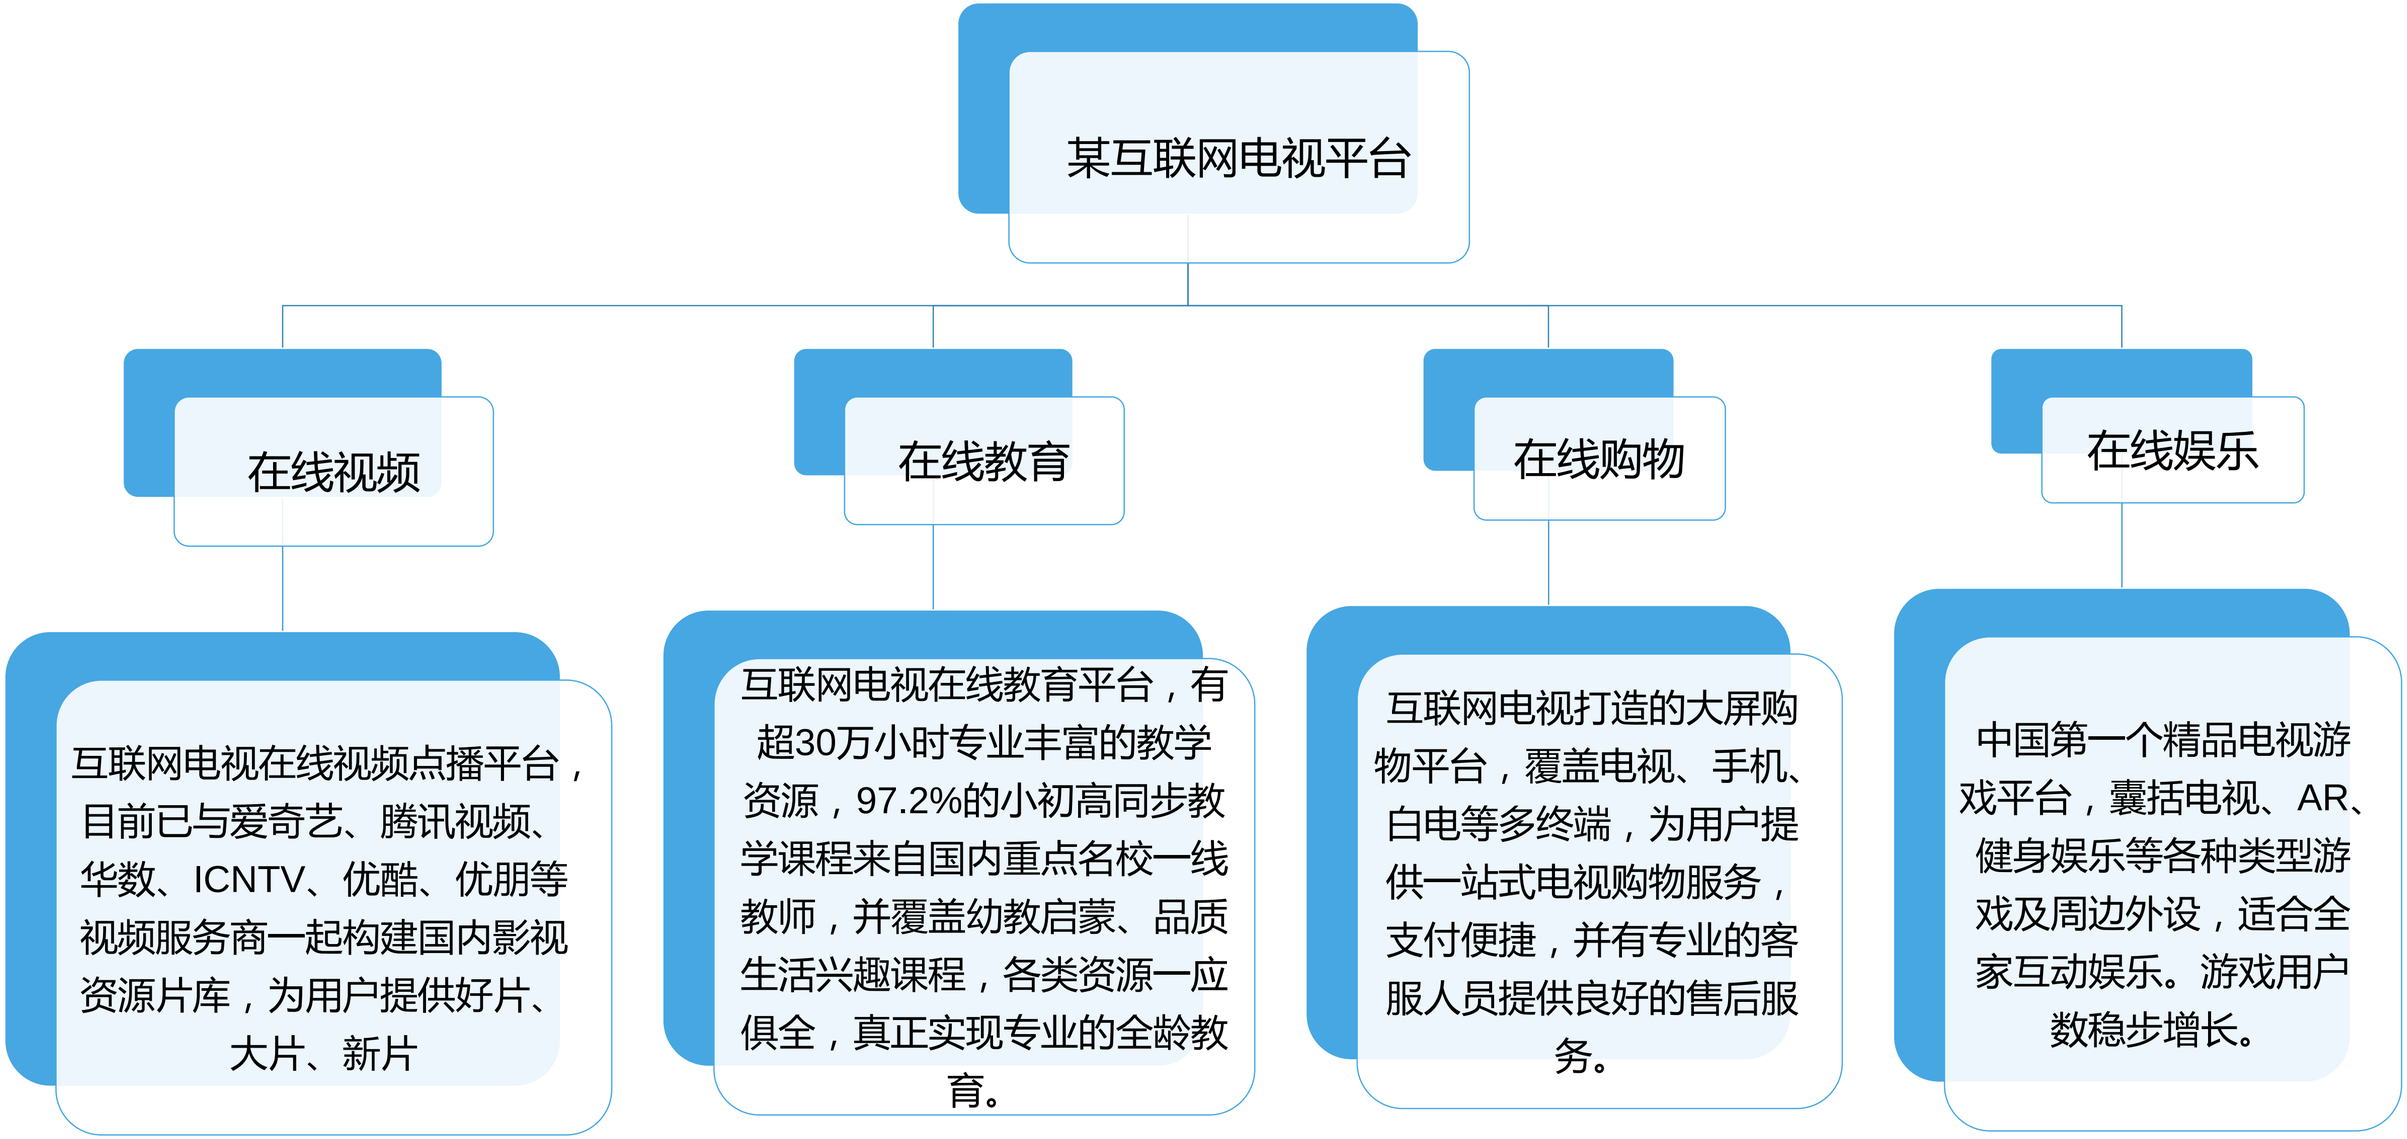
某互联网电视平台
在线视频
互联网电视在线视频点播平台，目前已与爱奇艺、腾讯视频、华数、ICNTV、优酷、优朋等视频服务商一起构建国内影视资源片库，为用户提供好片、大片、新片
在线教育
互联网电视在线教育平台，有超30万小时专业丰富的教学资源，97.2%的小初高同步教学课程来自国内重点名校一线教师，并覆盖幼教启蒙、品质生活兴趣课程，各类资源一应俱全，真正实现专业的全龄教育。
在线购物
互联网电视打造的大屏购物平台，覆盖电视、手机、白电等多终端，为用户提供一站式电视购物服务，支付便捷，并有专业的客服人员提供良好的售后服务。
在线娱乐
中国第一个精品电视游戏平台，囊括电视、AR、健身娱乐等各种类型游戏及周边外设，适合全家互动娱乐。游戏用户数稳步增长。

落地案例-业务介绍

国内最大的开放智能终端云平台

服务超过**3300万**智能电视和智能家具用户

平台对终端和服务开放

服务稳定性达到**99.99%**

互联网

终端

全球最大的互联网电视运营商

截至2017年3月底

该客户互联网电视用户数突破**2541万**

国内**2138万**海外**403万**

最丰富的运营服务内容

视频内容超过**100万**小时

国内最大的电视端教育资源库

国内应用数量最多的应用商店

用户

服务

国内最活跃的线上智能终端用户社群

国内互联网电视用户日活跃DAU超**44.80%**

国内最活跃的用户社群

基于K8S的容器管理平台 - 观云台

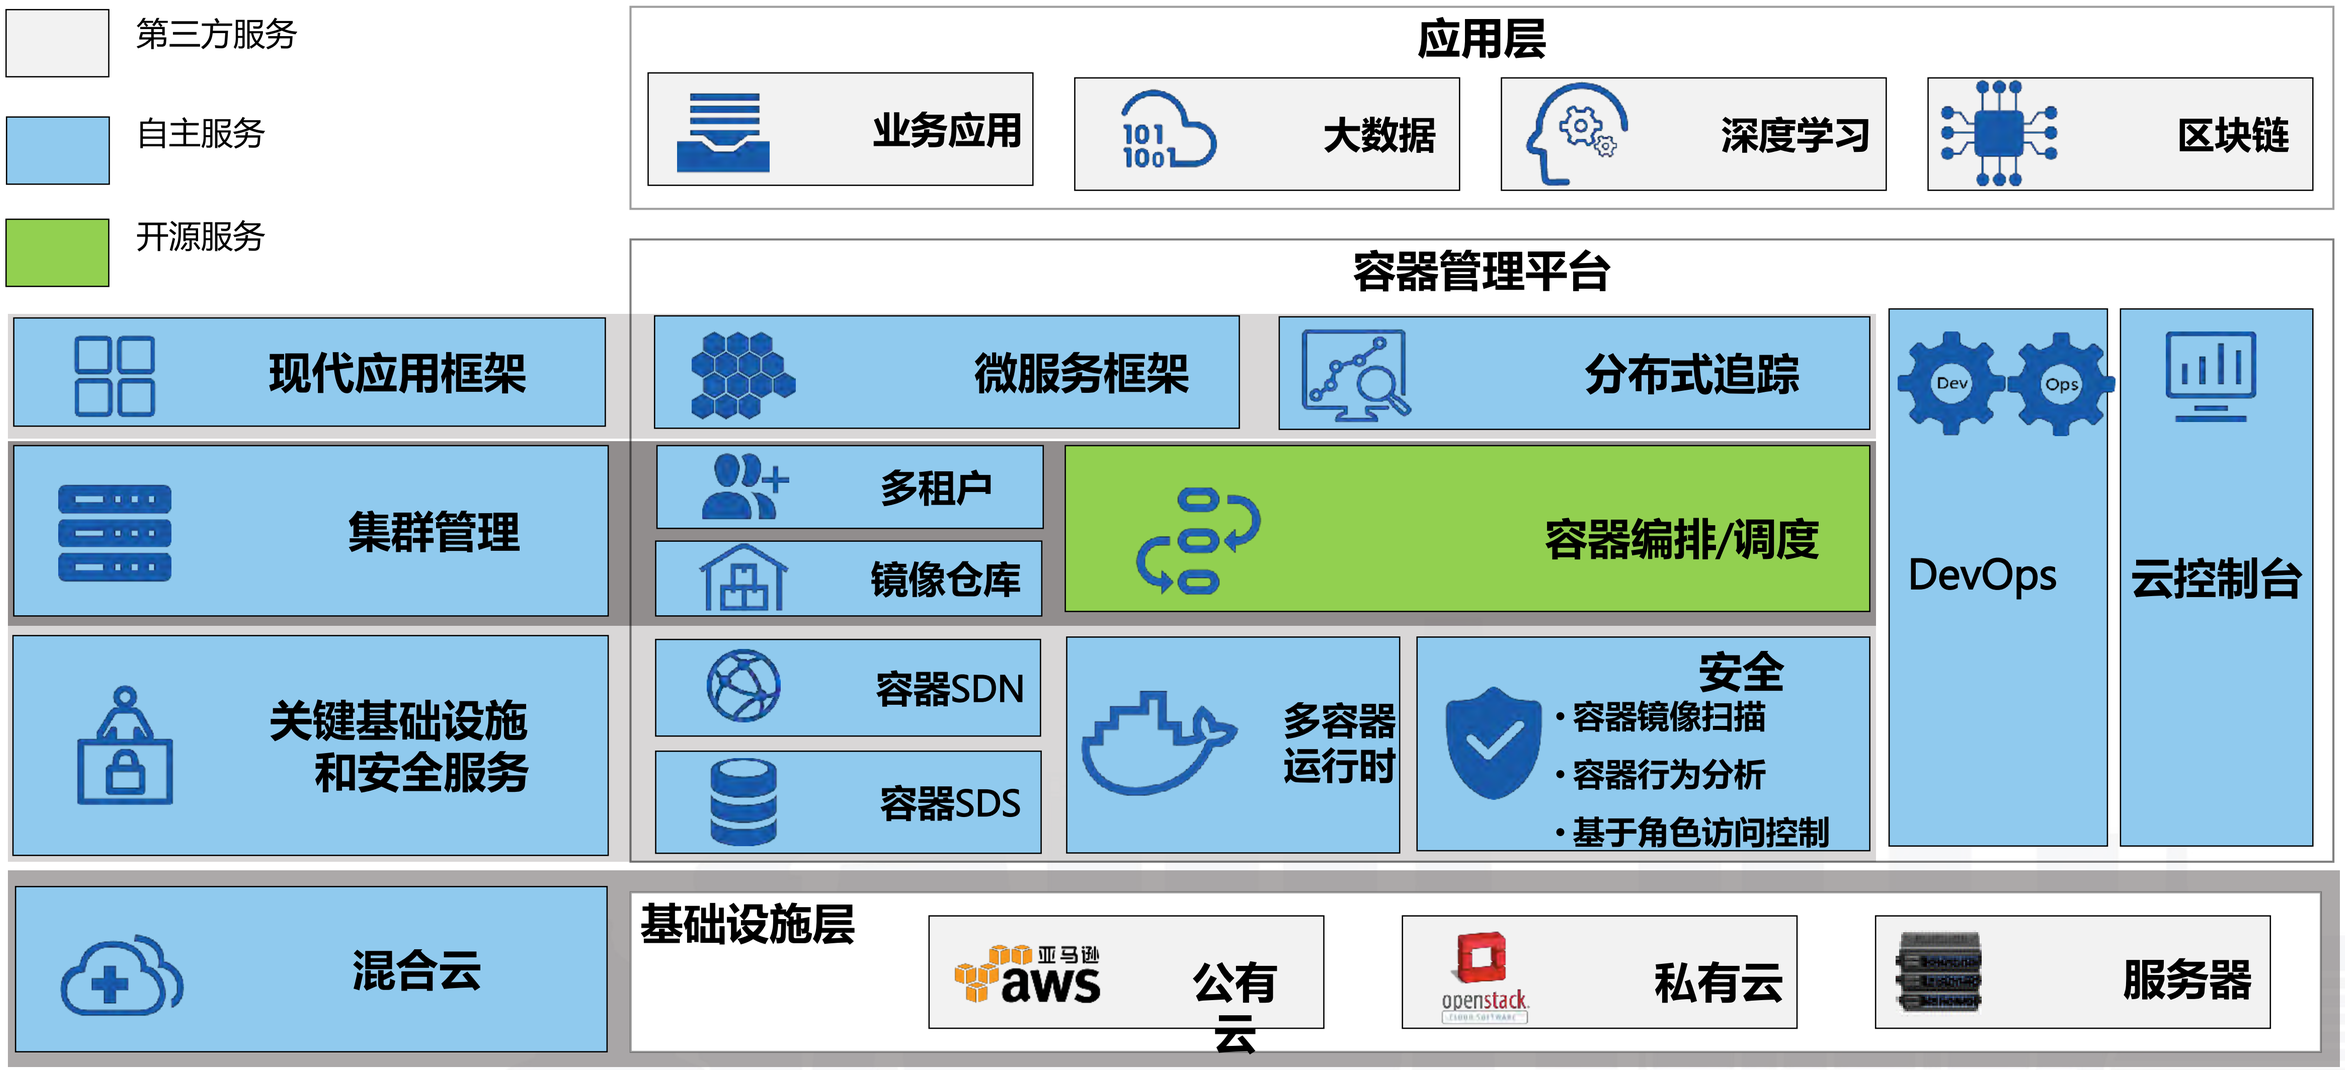

多集群方案

K8S集群高可用

keepalived子进程崩溃？

第一种策略：主节点挂掉以后立即将虚拟IP漂移到备用节点，由备用节点提供服务。当主节点恢复时，虚拟IP重新漂移到主节点，由主节点提供服务；

第二种策略：主节点挂了以后尝试拉起挂掉的服务，尝试N次，如果服务拉起失败，则漂移虚拟IP到备用节点，由备用节点提供服务，主节点恢复以后，并不马上漂移虚拟IP，继续由备用节点提供服务。

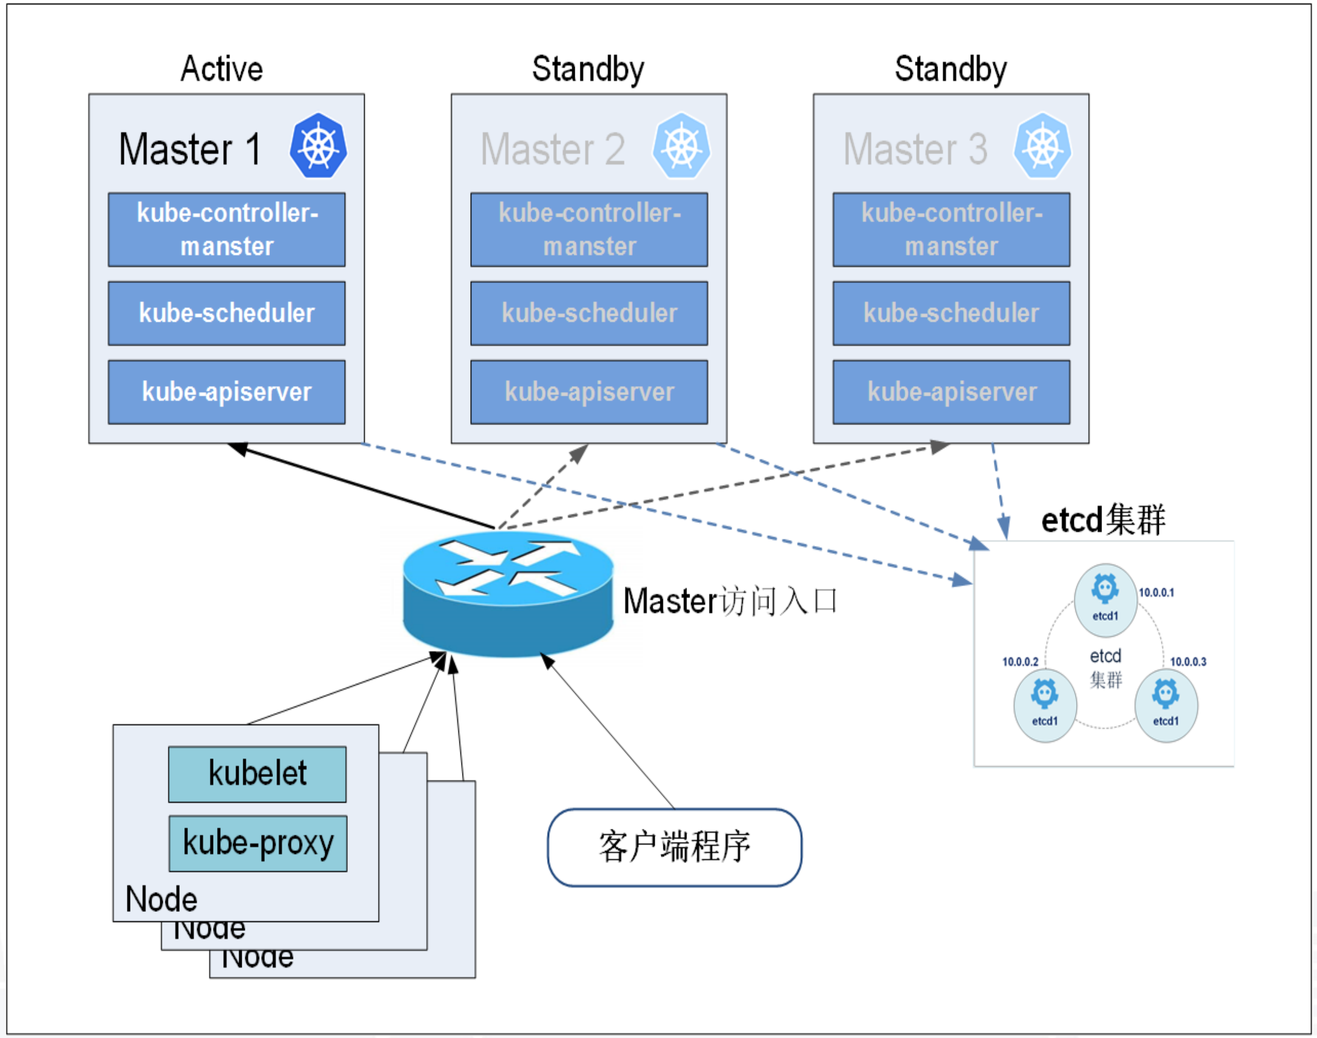

多集群架构

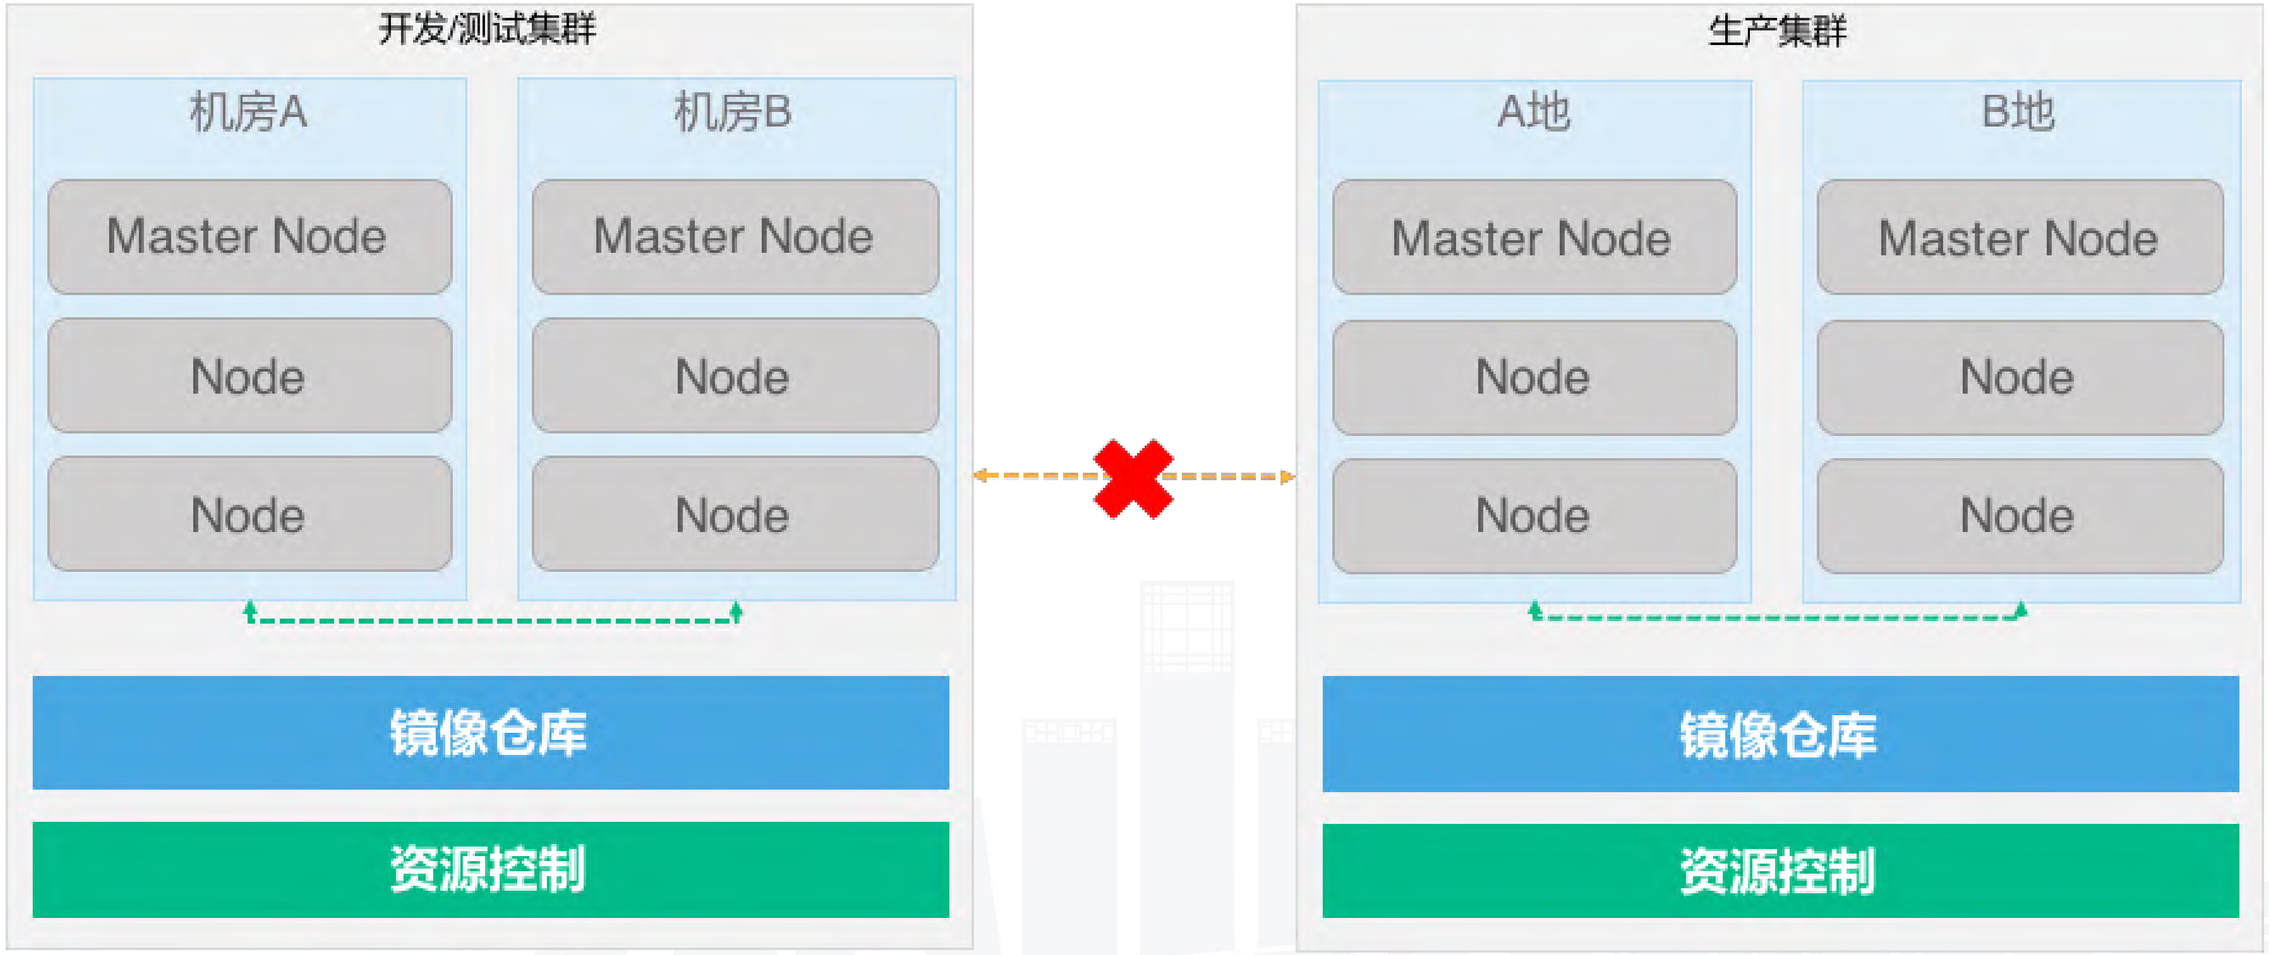
开发/测试集群
机房A
机房B
Master Node
Master Node
Node
Node
Node
Node
镜像仓库
资源控制
生产集群
A地
B地
Master Node
Master Node
Node
Node
Node
Node
镜像仓库
资源控制

跨数据中心单集群

跨数据中心单集群

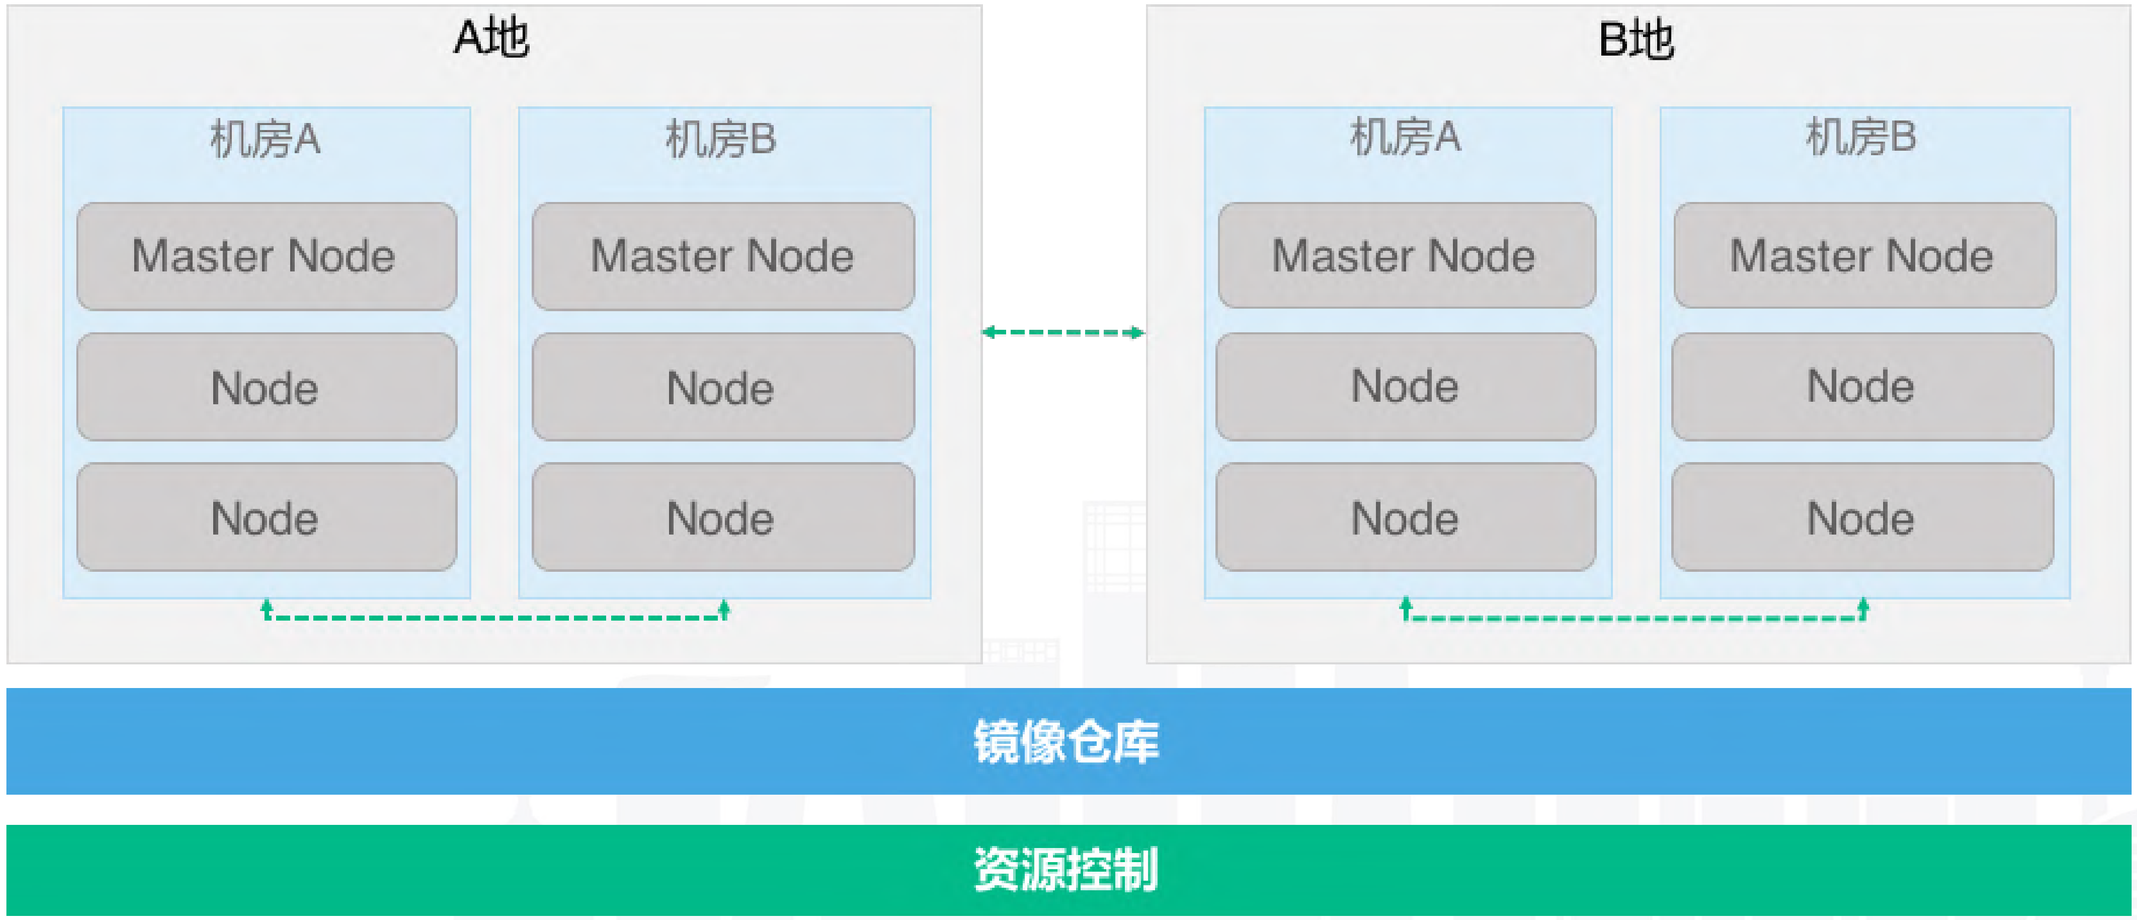

CI/CD

持续集成持续部署

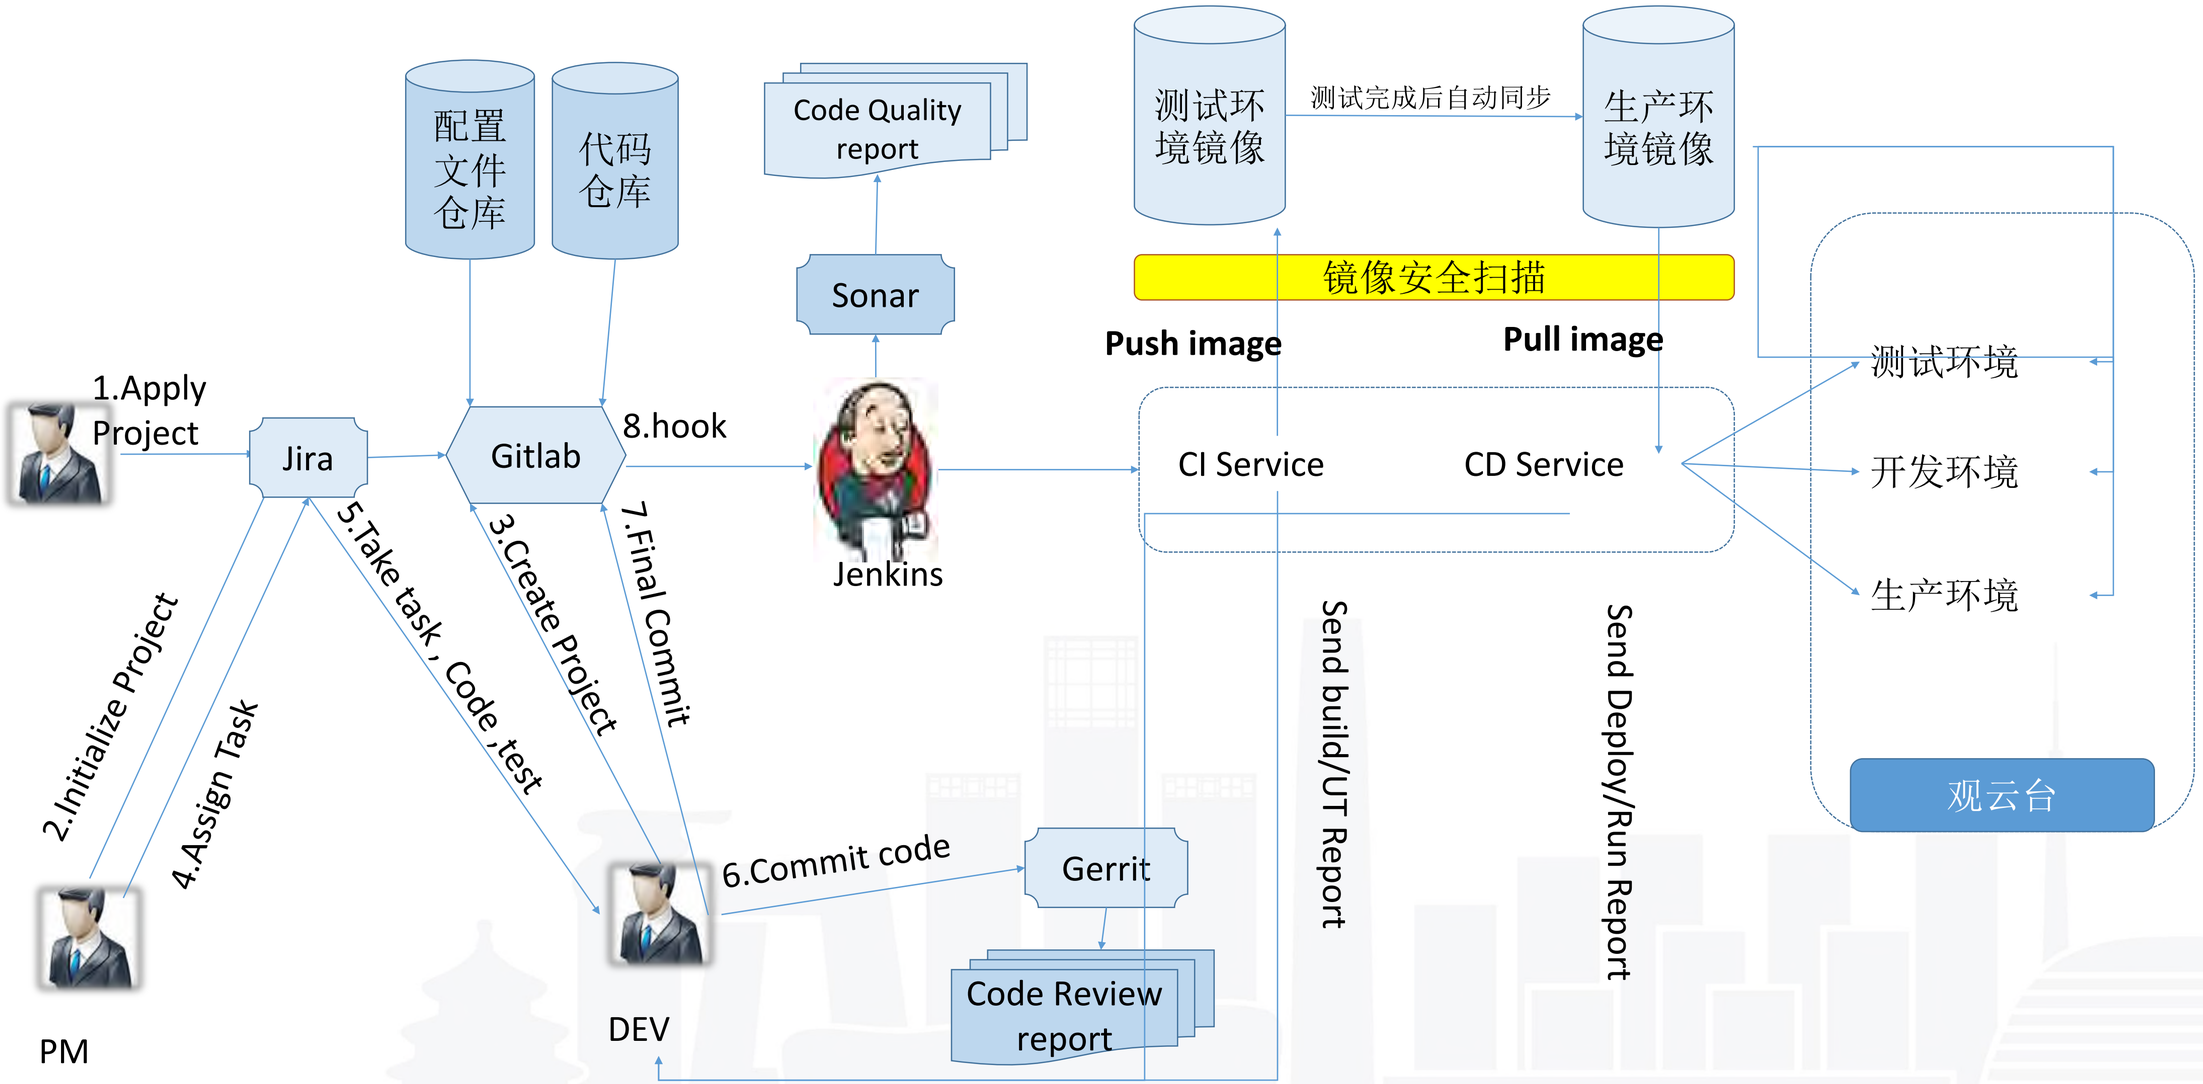
配置文件仓库
代码仓库
Code Quality report
Sonar
测试环境镜像
测试完成后自动同步
生产环境镜像
镜像安全扫描
Push image
Pull image
1.Apply Project
Jira
Gitlab
8.hook
Jenkins
CI Service
CD Service
测试环境
开发环境
生产环境
观云台
2.Initialize Project
4.Assign Task
5.Take task , Code ,test
3.Create Project
7.Final Commit
6.Commit code
Gerrit
Code Review report
Send build/UT Report
Send Deploy/Run Report
PM
DEV

镜像仓库同步

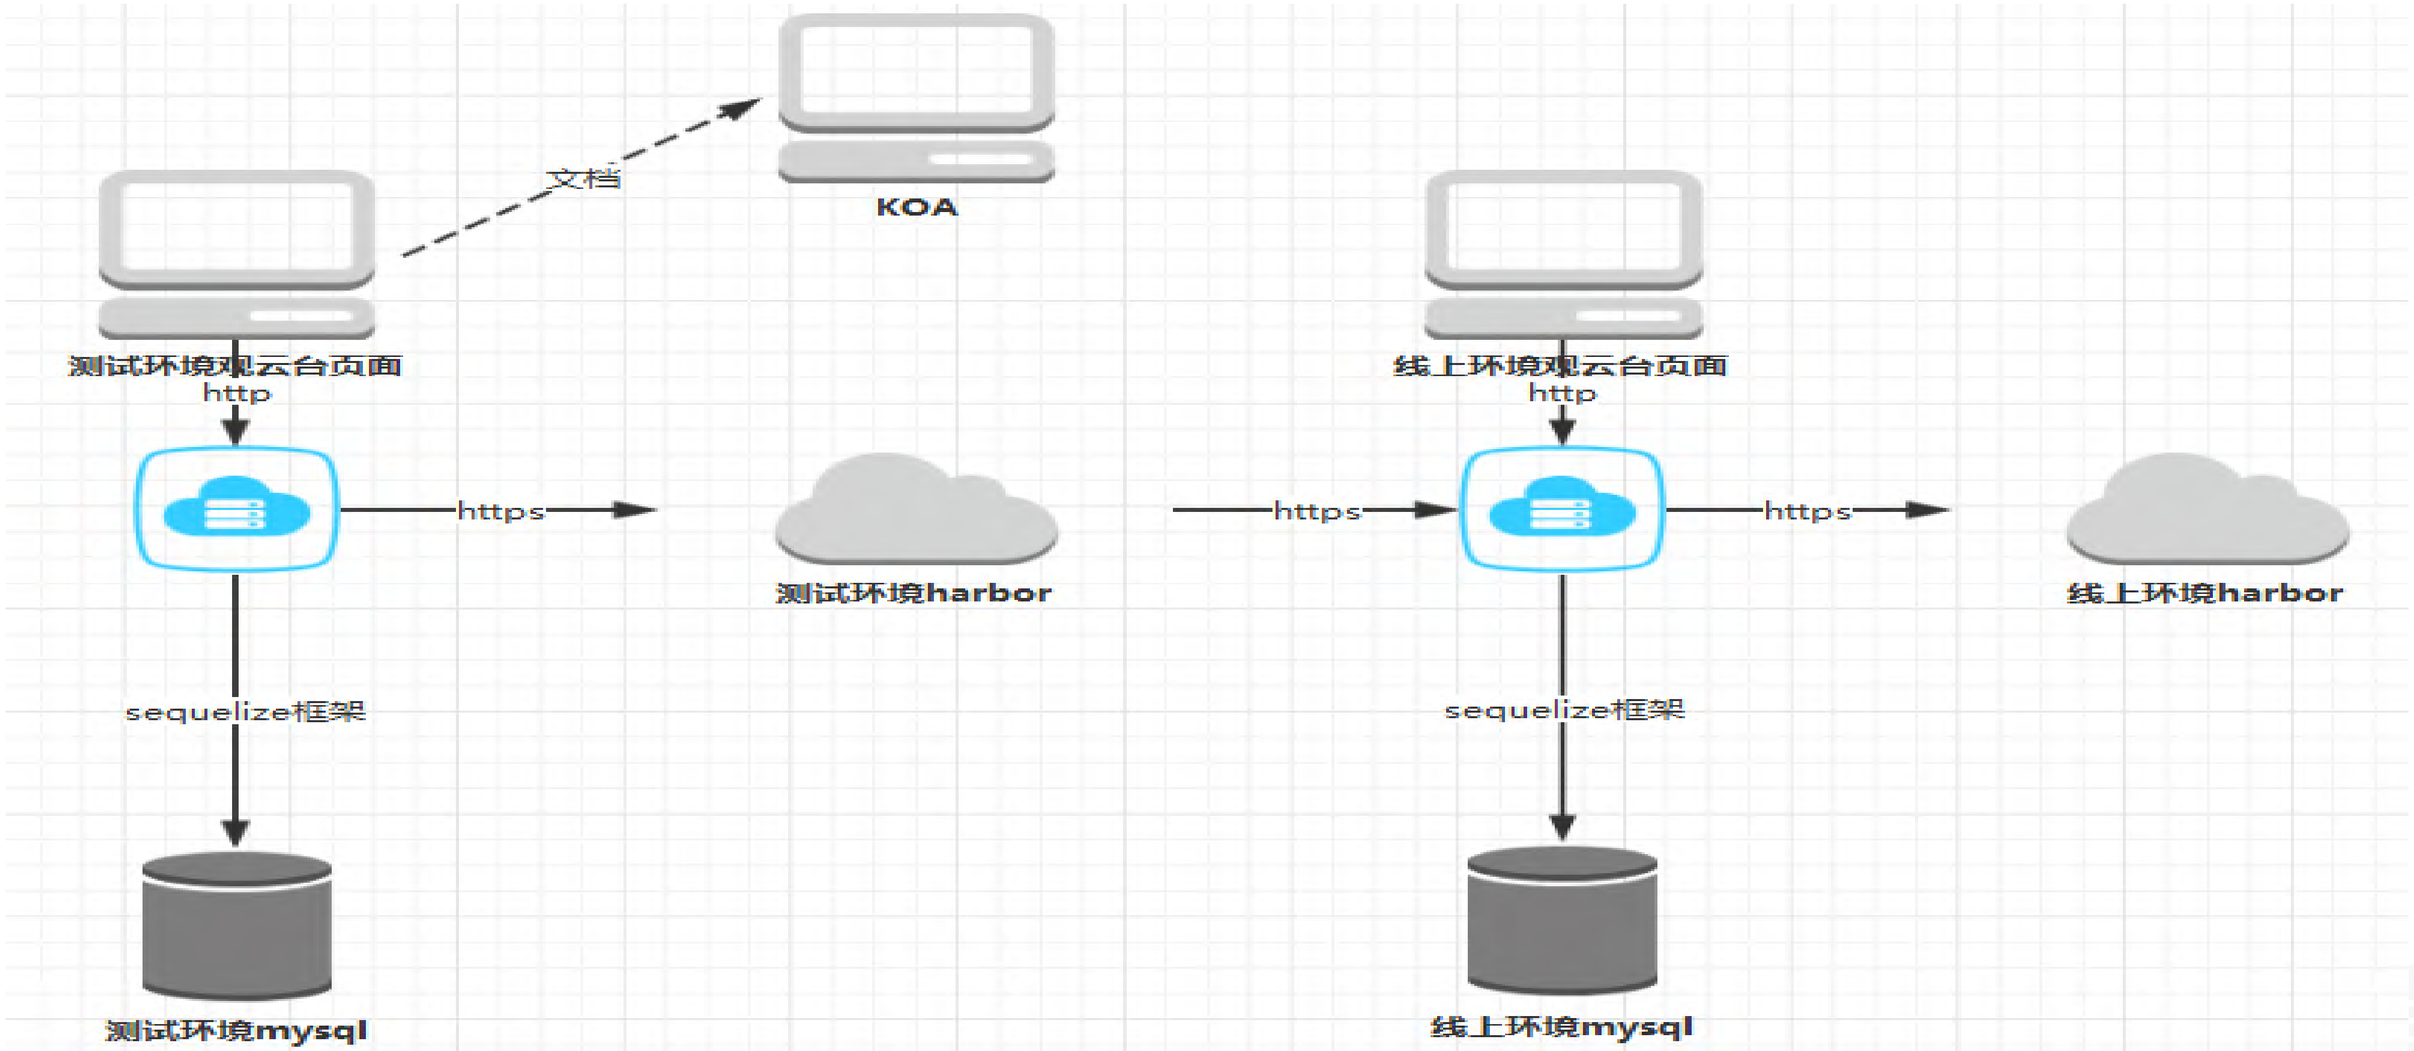
文档
KOA
测试环境观云台页面
http
https
测试环境harbor
sequelize框架
测试环境mysql
线上环境观云台页面
http
https
https
线上环境harbor
sequelize框架
线上环境mysql

配置中心

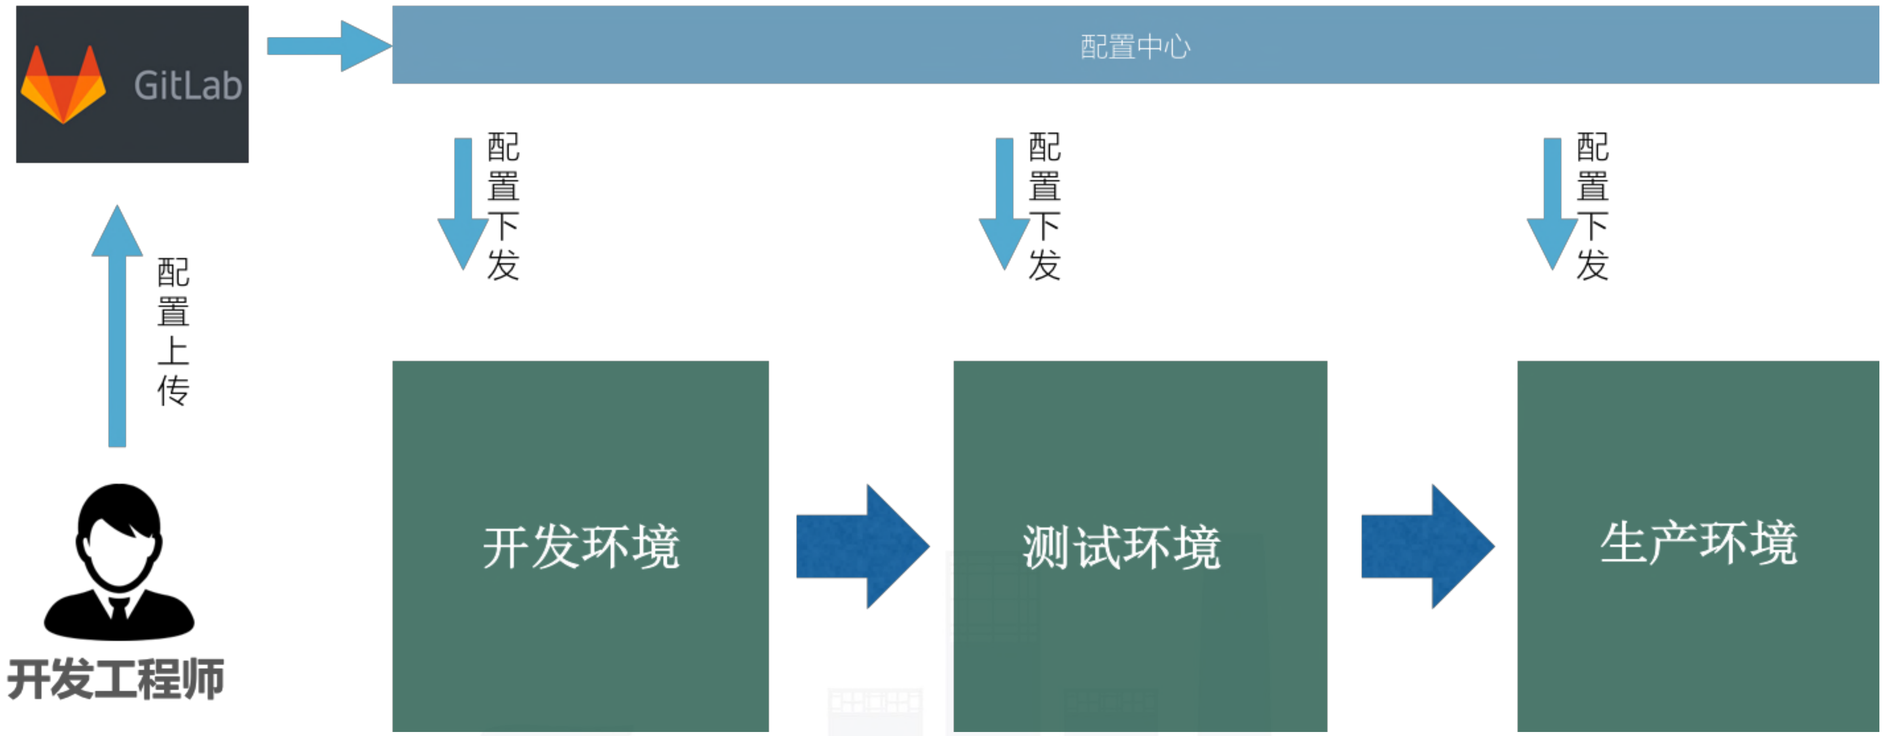

应用迁移

应用迁移改造

应用类型	特征	收益	改造
无状态应用	普通的web应用程序	快速部署 弹性伸缩 自动容错 高利用率	容器化,配置分离
有状态应用	采用Redis或Memcached共享用户状态	快速部署 快速扩容 可能提升利用率	做无状态改造
本地持久化应用	生成本地文件	快速部署 (可能需同步数据)	需要分布式存储支持
服务注册调用	解耦配置依赖	自动化部署，配置	服务发现

应用迁移改造

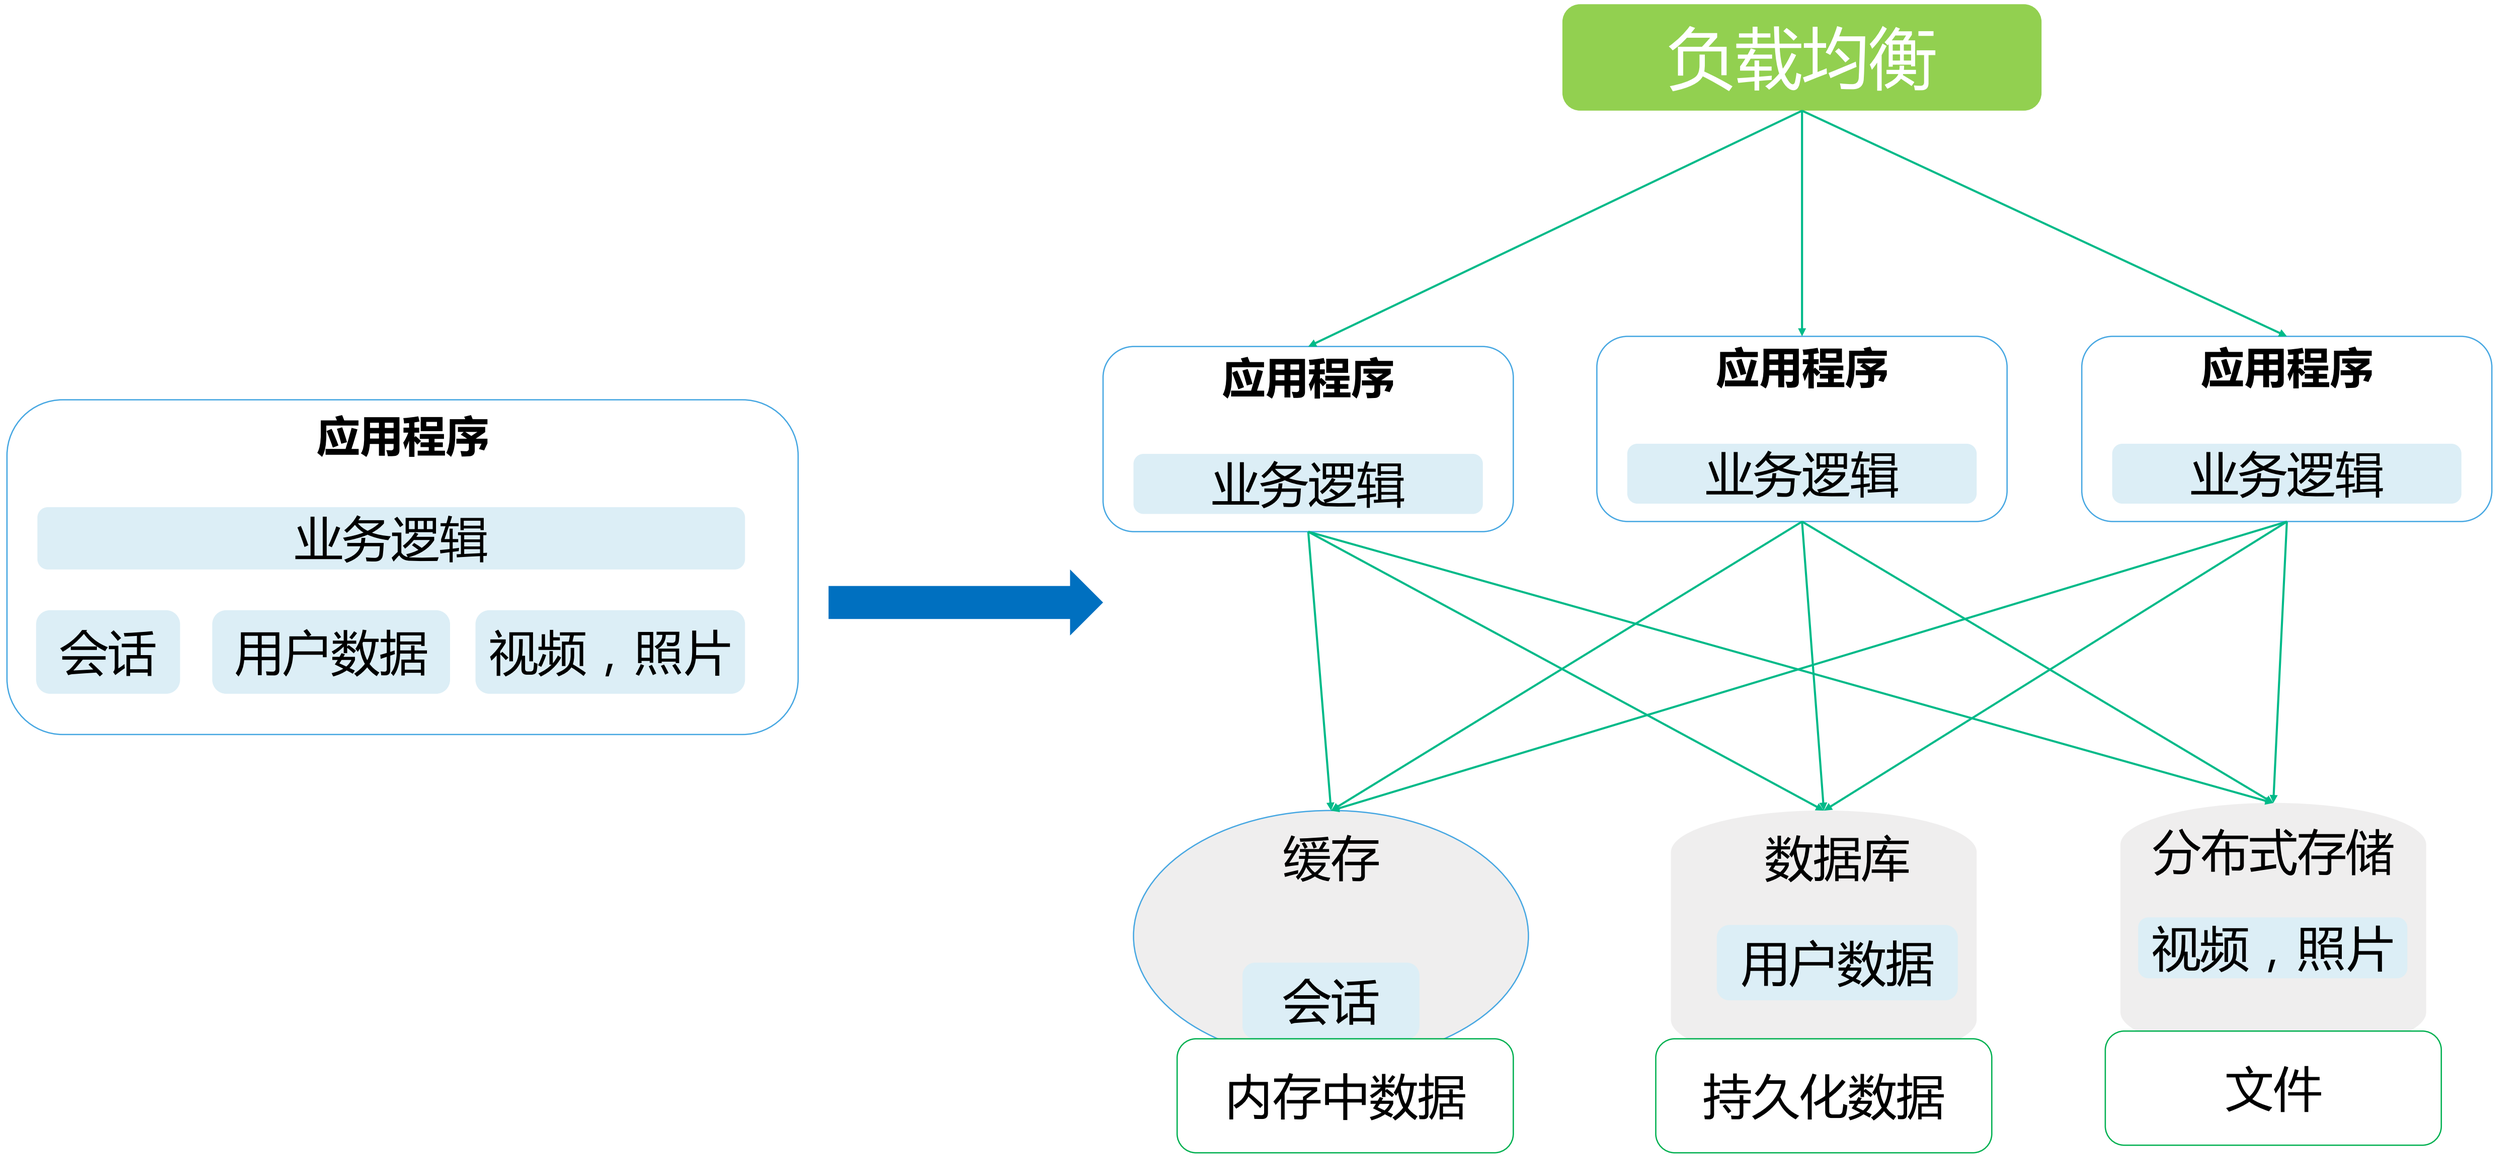
应用程序
业务逻辑
会话
用户数据
视频，照片
负载均衡
应用程序
业务逻辑
应用程序
业务逻辑
应用程序
业务逻辑
缓存
会话
内存中数据
数据库
用户数据
持久化数据
分布式存储
视频，照片
文件

微服务化及服务管理改造前

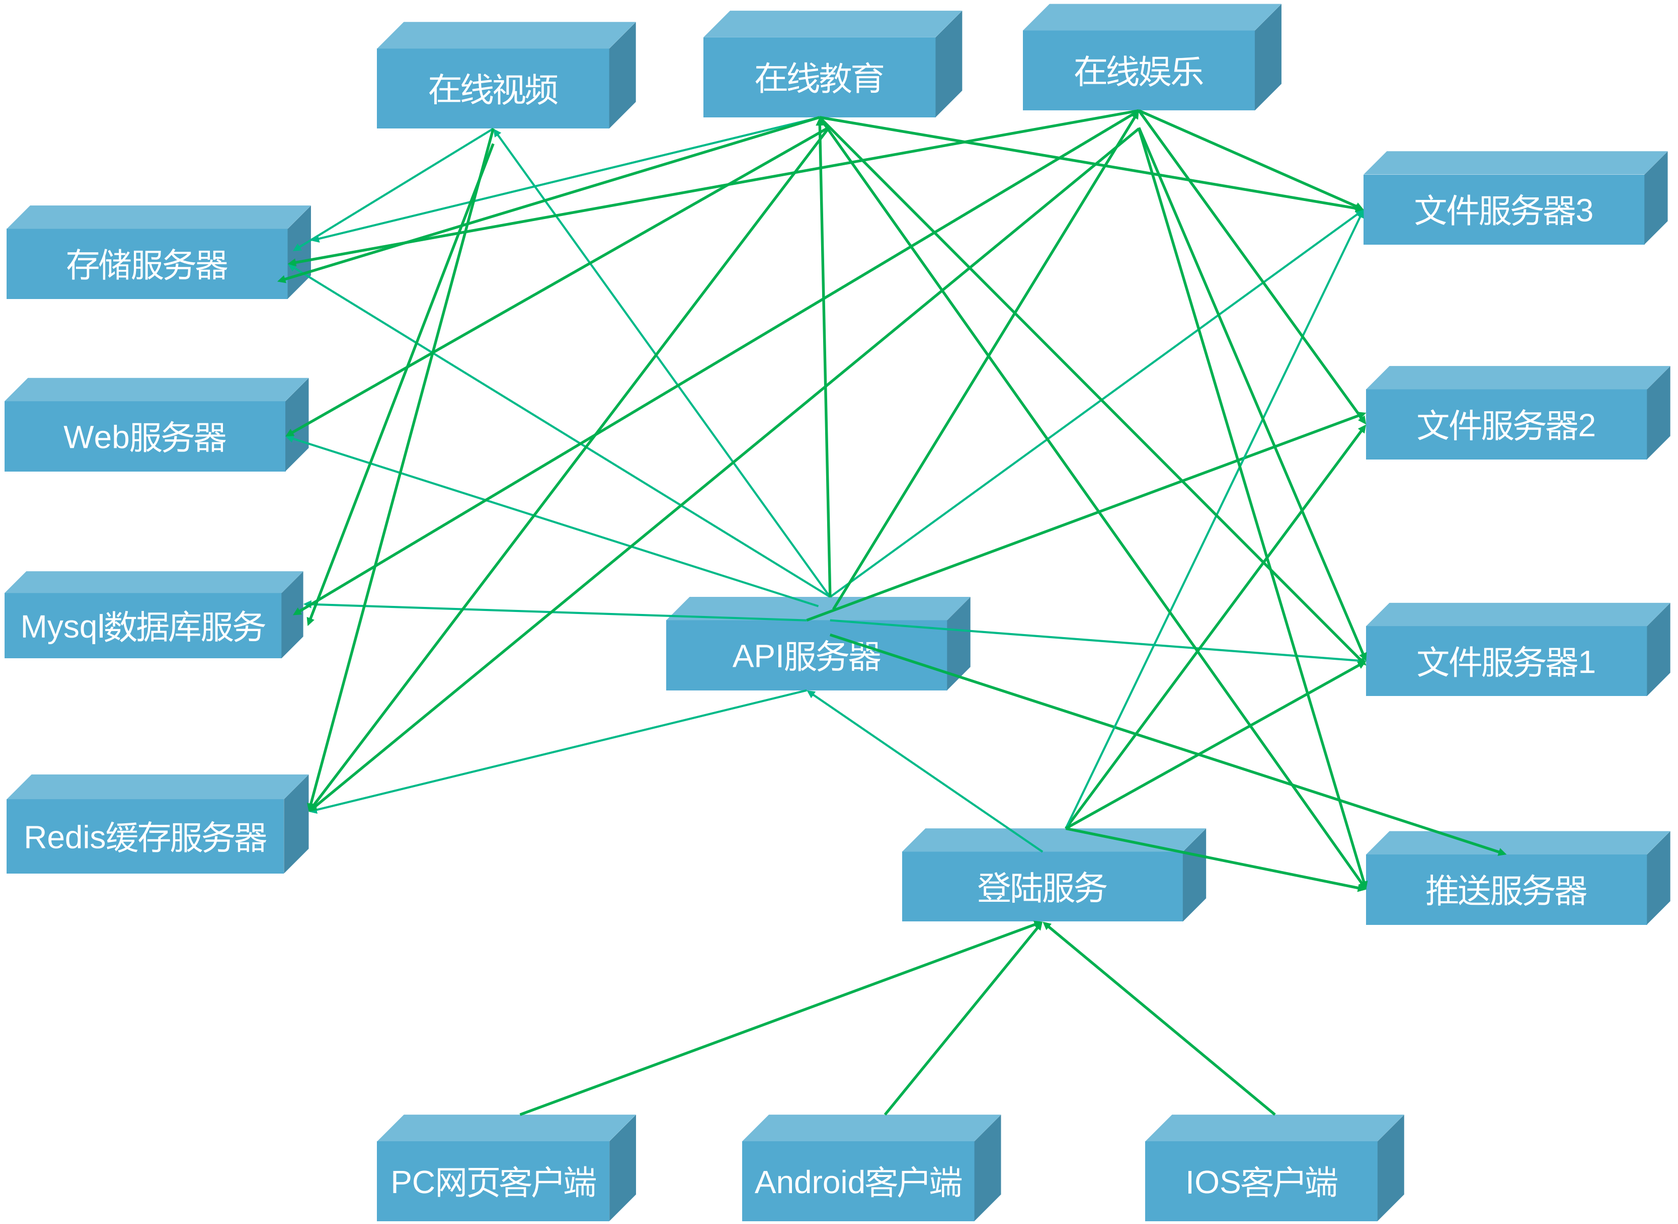

微服务化及服务管理改造后

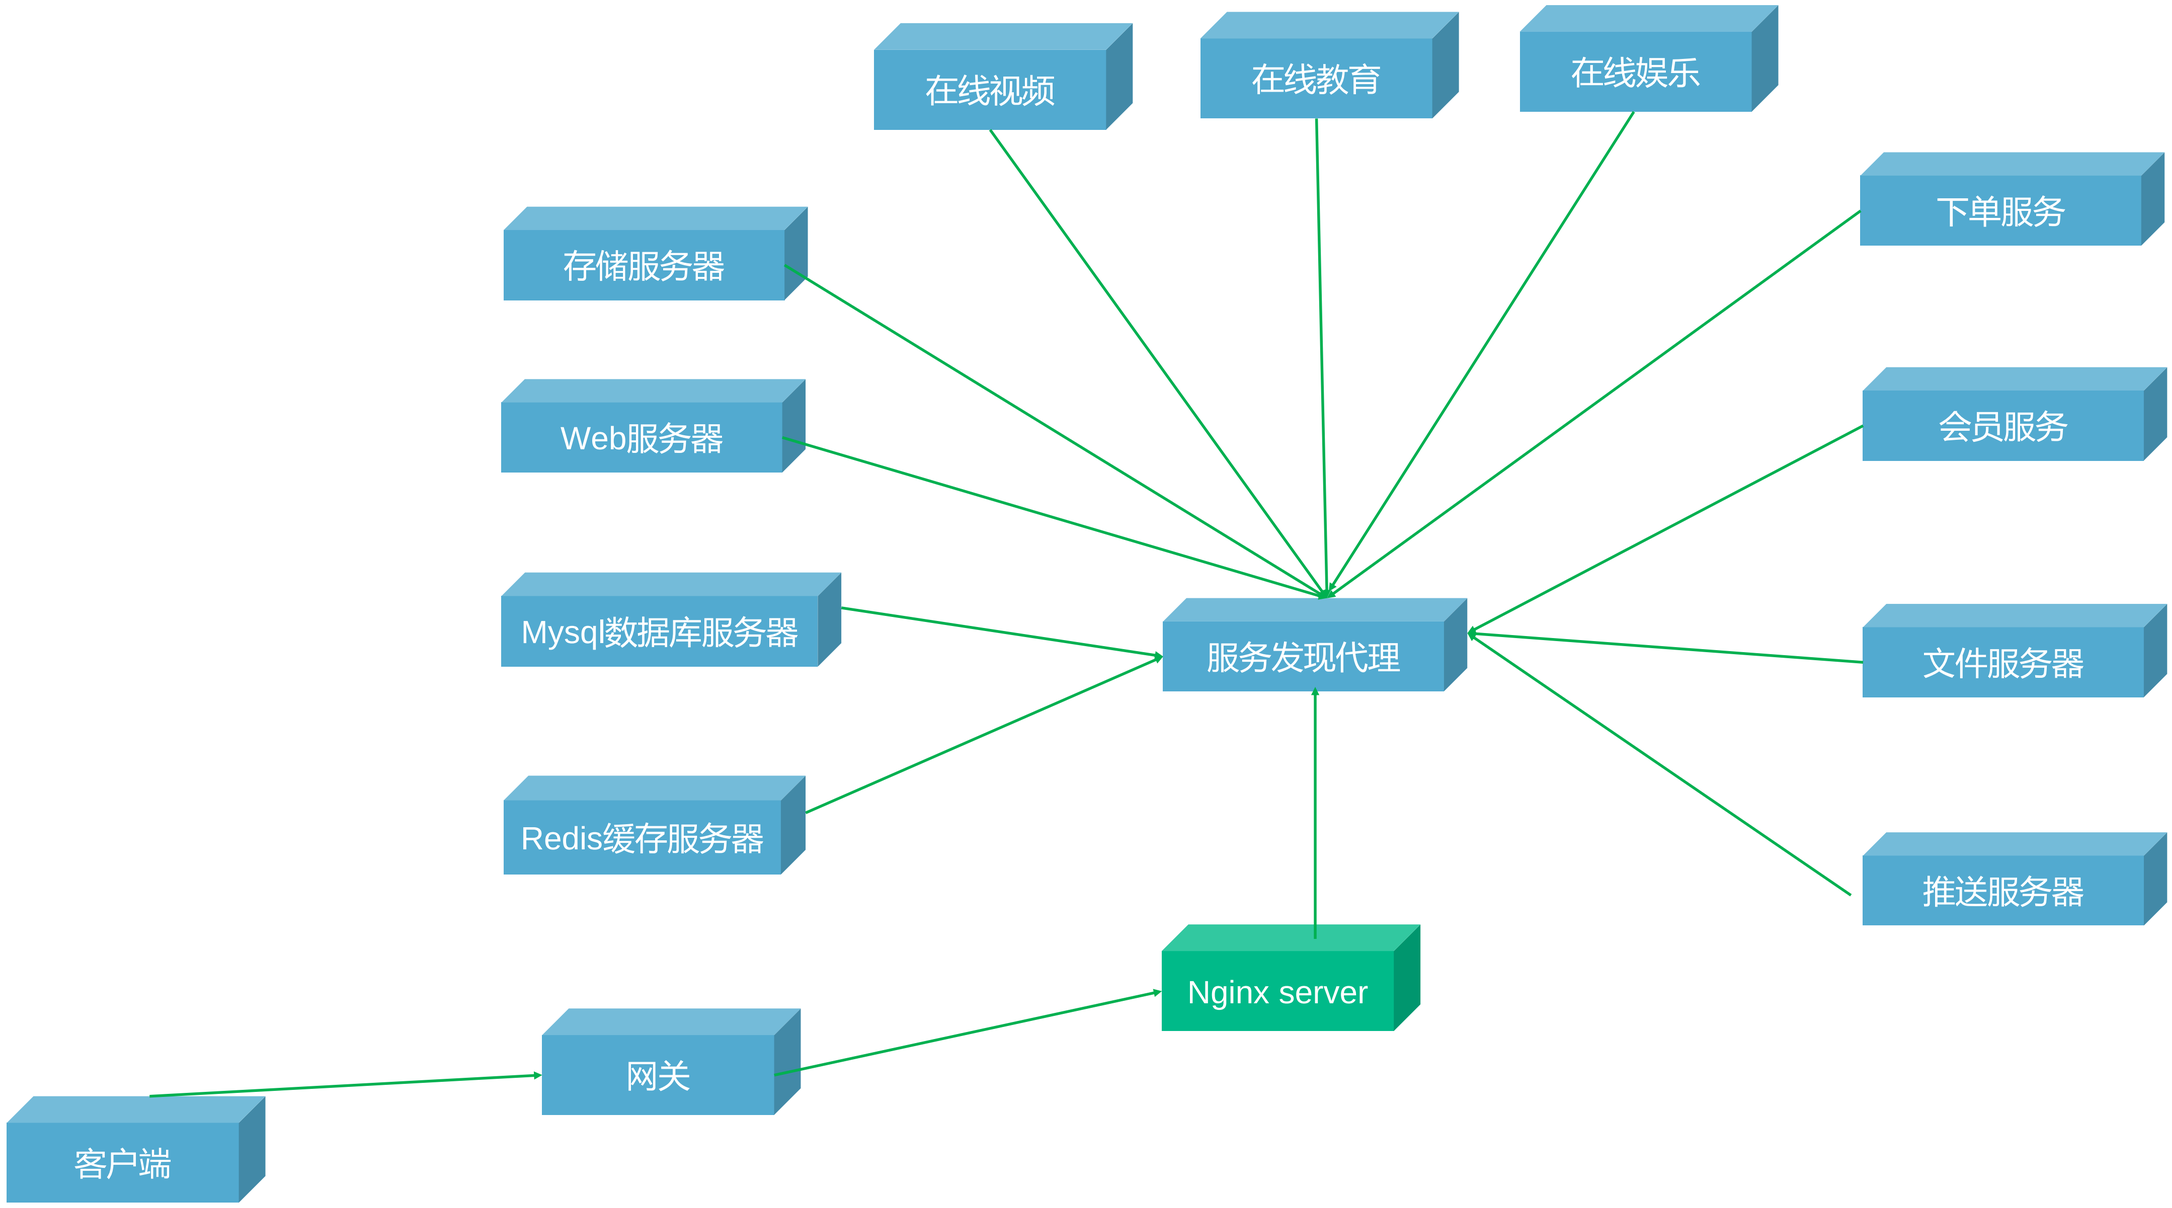

日志过滤收集

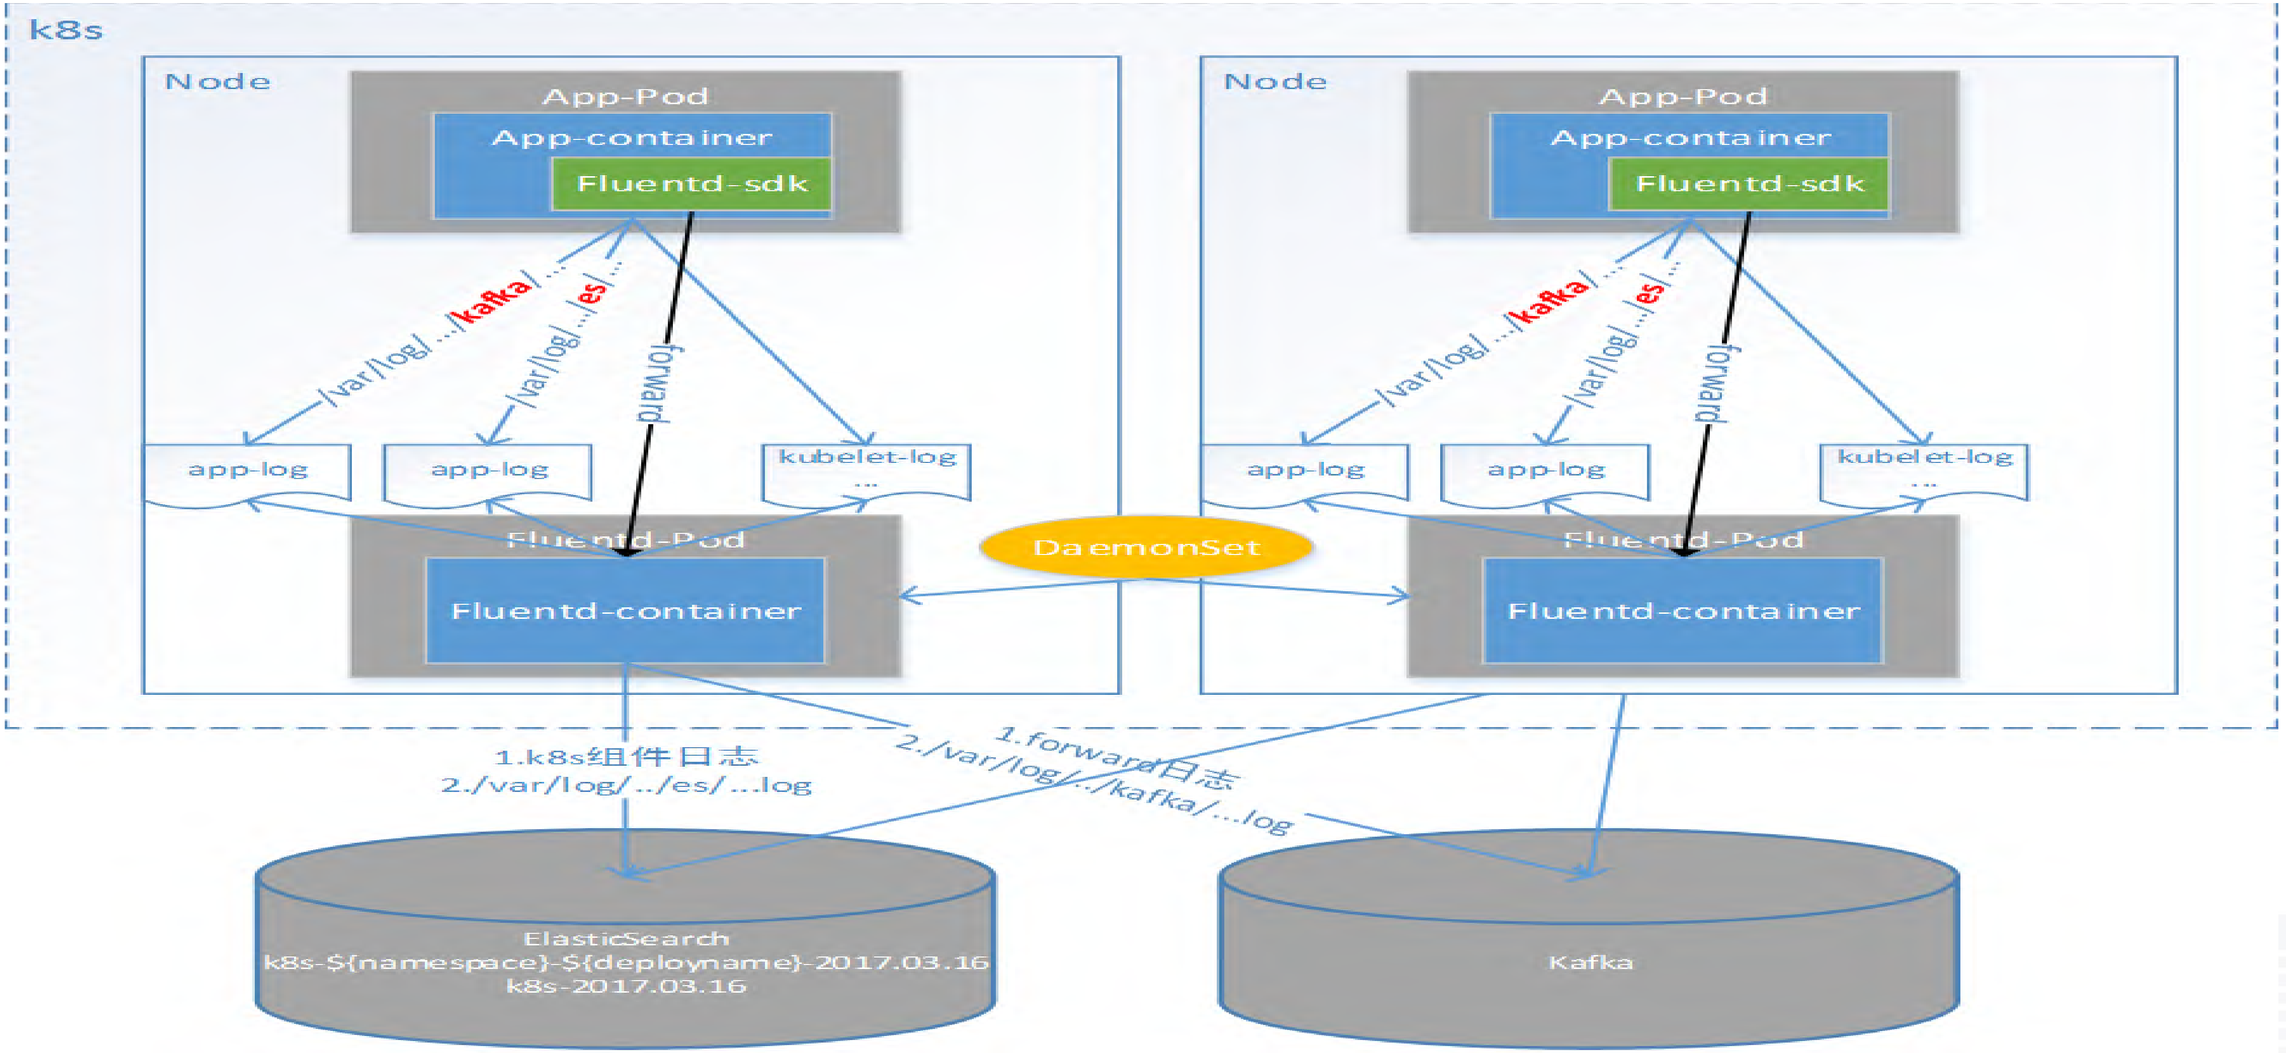
k8s
Node
App-Pod
App-container
Fluentd-sdk
/var/log/.../kafka/...
/var/log/.../es/...
forward
app-log
app-log
kubelet-log
...
Fluentd-Pod
Fluentd-container
DaemonSet
Node
App-Pod
App-container
Fluentd-sdk
/var/log/.../kafka/...
/var/log/.../es/...
forward
app-log
app-log
kubelet-log
...
Fluentd-Pod
Fluentd-container
1.k8s组件日志
2./var/log/../es/...log
1.forward日志
2./var/log/../kafka/...log
ElasticSearch
k8s-${namespace}-${deployname}-2017.03.16
k8s-2017.03.16
Kafka

应用拓扑自发现

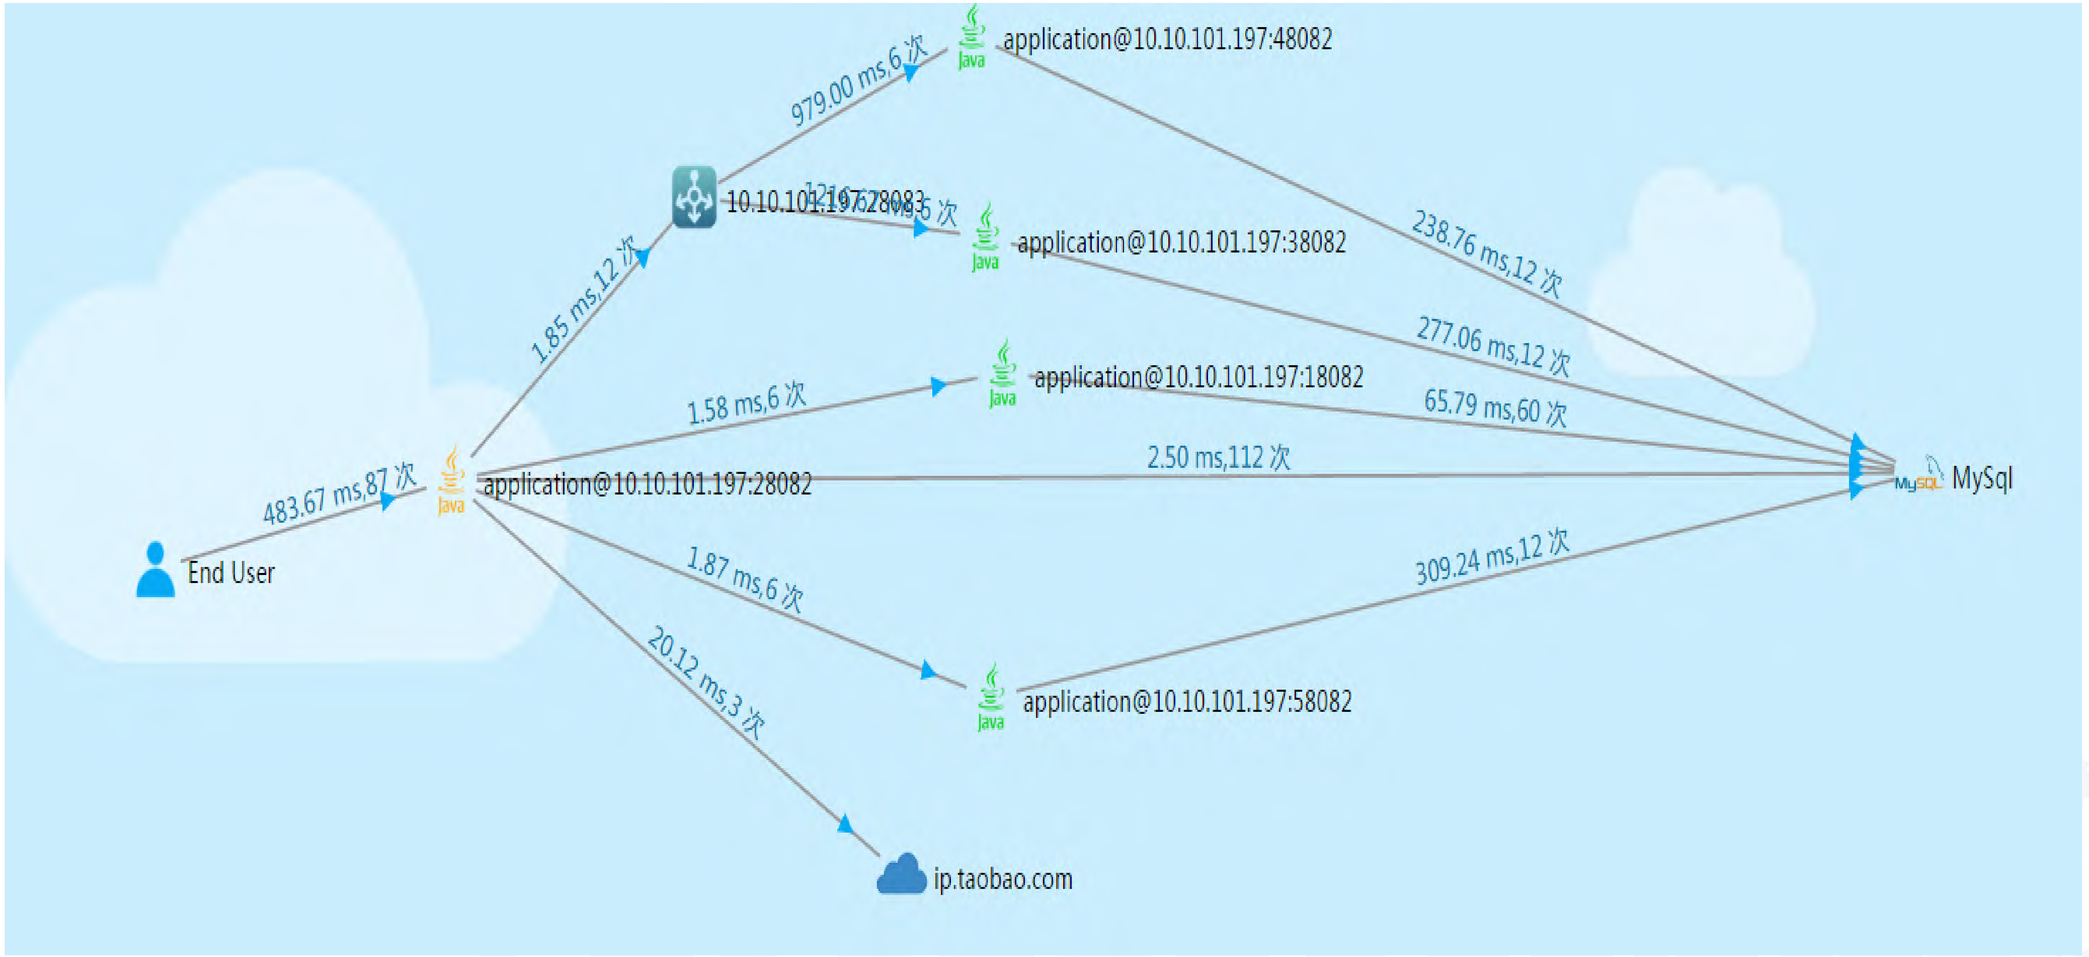

自动构建应用拓扑，发现全链路性能瓶颈，重现业务场景，快速定位问题

基于业务指标的弹性伸缩

标准弹性指标

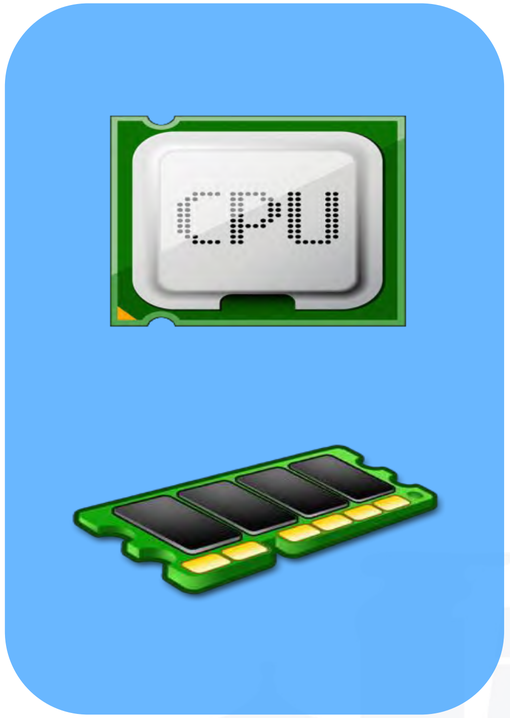

基于业务弹性指标

在线视频移动端监控

崩溃

网络错误

卡顿...

- 崩溃
- ANR
- 网络监控
  - 网络错误
  - 网络性能
- 劫持监控
- 慢动作&慢交互监控
- 各机型综合监控

监控后台优化

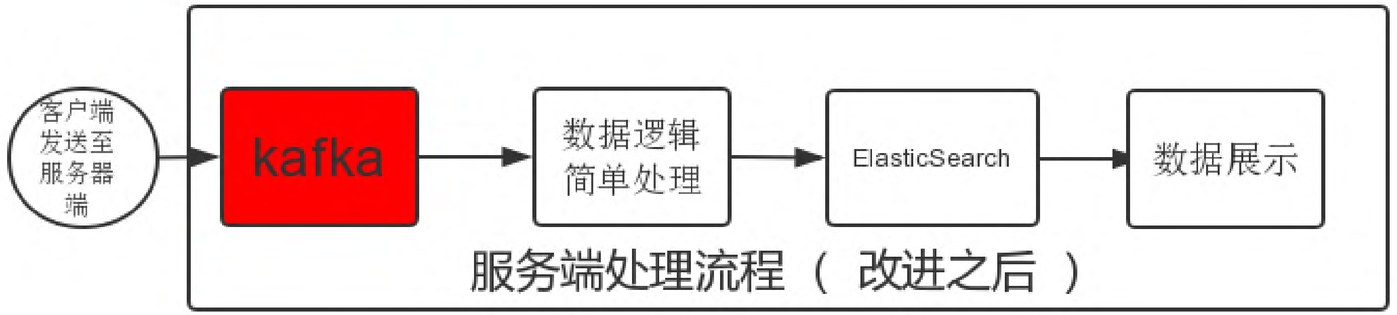

延后数据处理
降低每次请求处理延时
TPS翻倍

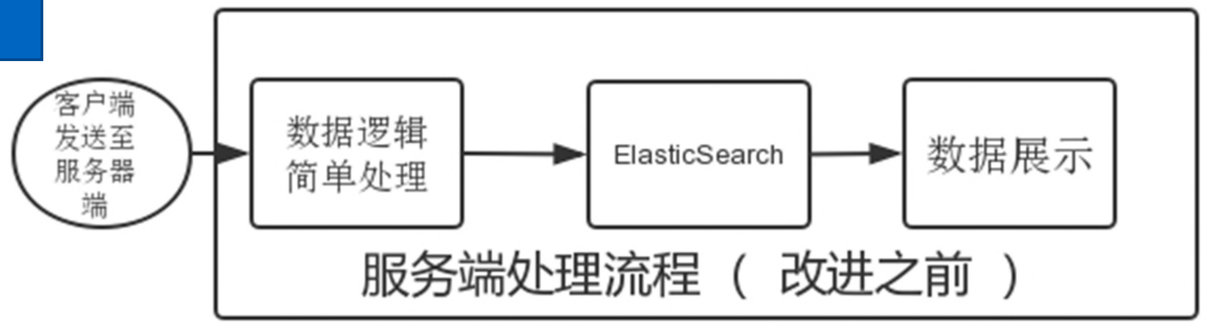

网络方案选择及优化

K8S容器网络方案对比

网络方案功能对比

方案	技术	多节点	多租户	高可用	高级网络功能	社区支持	适用场景
隧道方案	Flannel	支持	不支持	不支持	不支持	一般	无依赖
	OVS	支持	不支持	支持	支持	一般	无依赖
	Neutron	支持	支持	支持	支持	较好	无依赖
路由方案	Calico	支持	支持	支持	部分支持	较好	大二层

网络方案性能对比

网络类型	延迟(ms)	带宽(Mb/s)	Nginx(QPS/延迟)
物理	0.244842	942	11439.61/4.019
Neutron VXLAN	0.747789	907	9065.38/5.515
Flannel VXLAN	0.727158	910	10031.23/4.886
Calico	0.267684	941	11004.44/4.428
OVS VXLAN	0.35475	917	10457.32/4.864

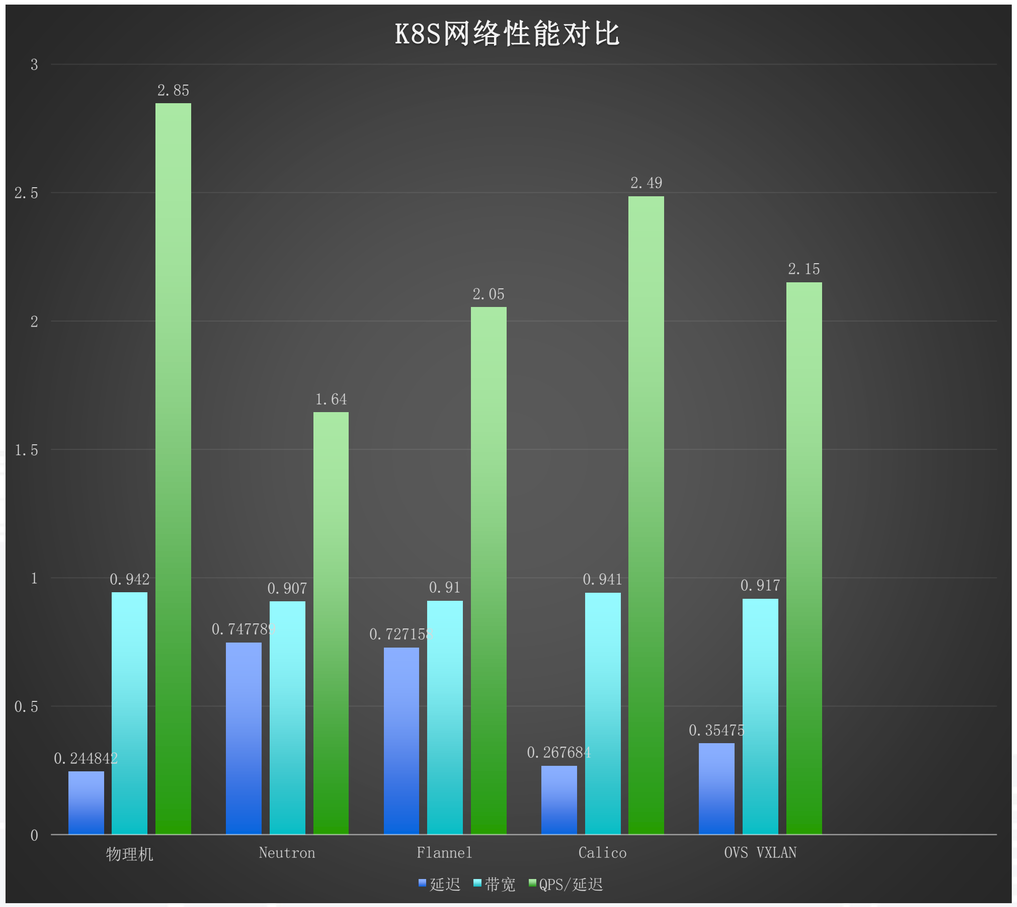

网络方案改造

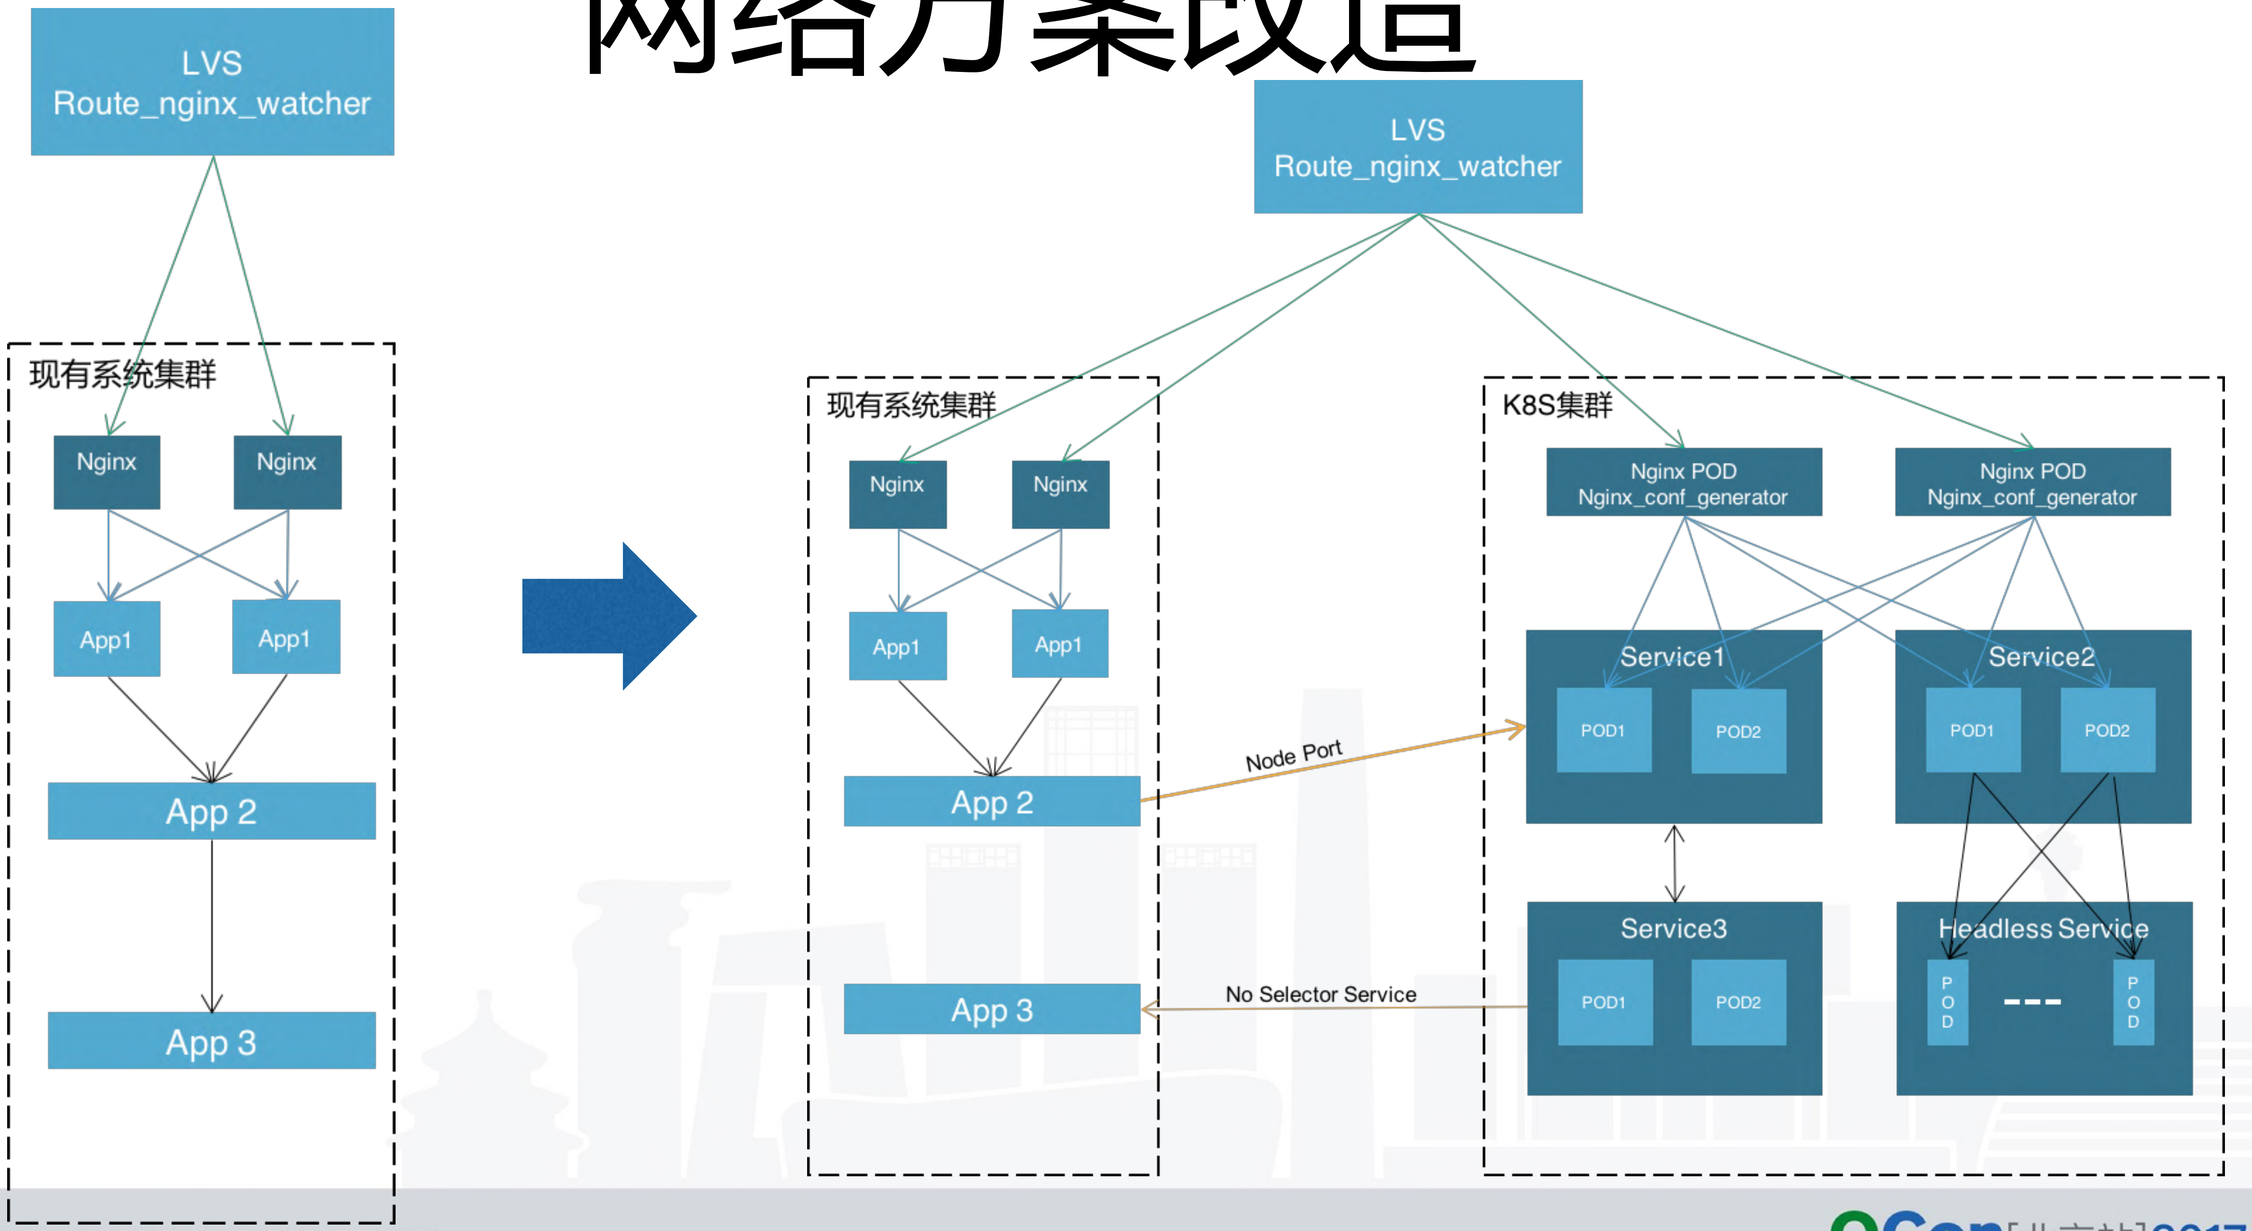
LVS
Route_nginx_watcher
现有系统集群
Nginx
Nginx
App1
App1
App 2
App 3
LVS
Route_nginx_watcher
现有系统集群
Nginx
Nginx
App1
App1
App 2
App 3
Node Port
No Selector Service
K8S集群
Nginx POD
Nginx_conf_generator
Nginx POD
Nginx_conf_generator
Service1
POD1
POD2
Service2
POD1
POD2
Service3
POD1
POD2
Headless Service
POD

POD

集群内外通信

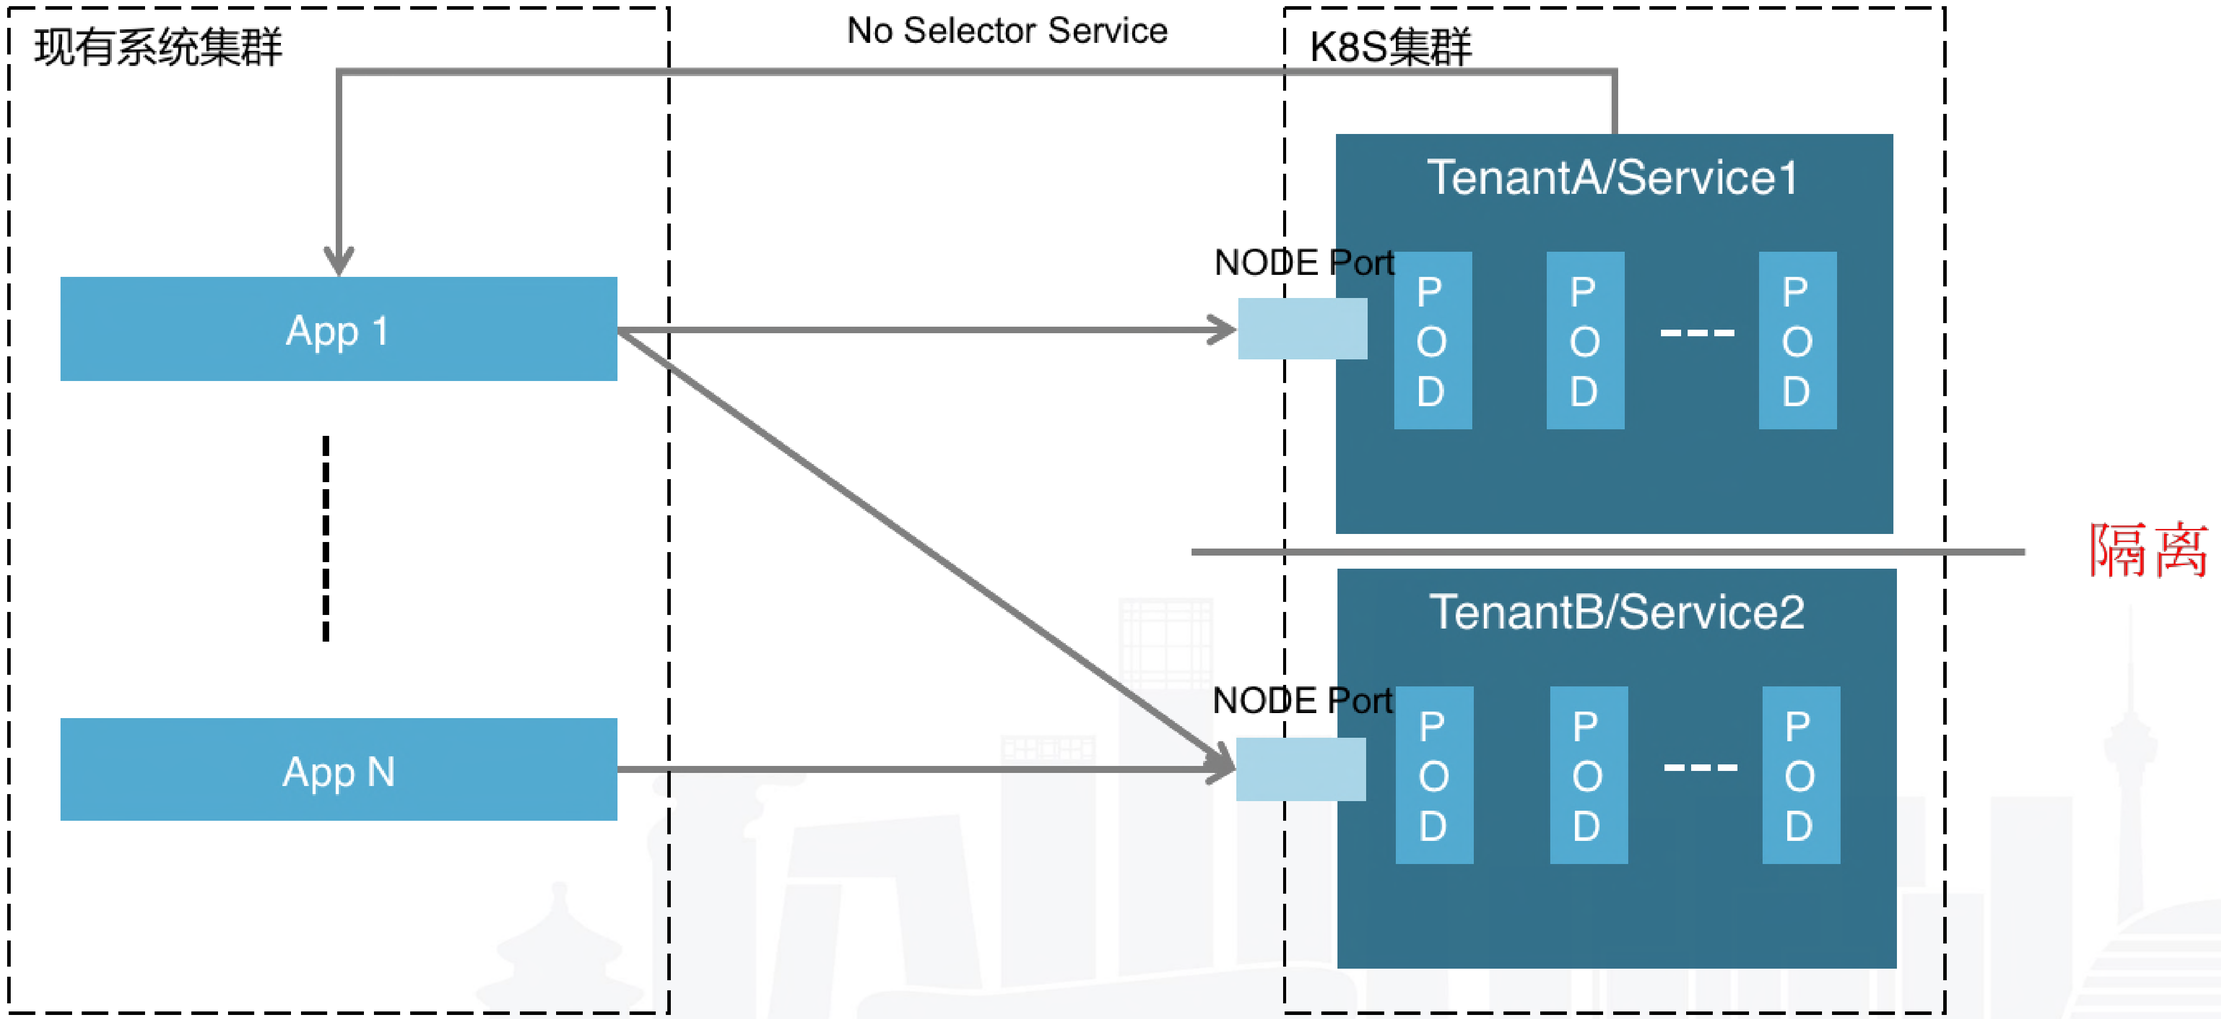
现有系统集群
No Selector Service
K8S集群
TenantA/Service1
NODE Port
POD
POD

POD
App 1
隔离
TenantB/Service2
NODE Port
POD
POD

POD
App N

客户端负载均衡

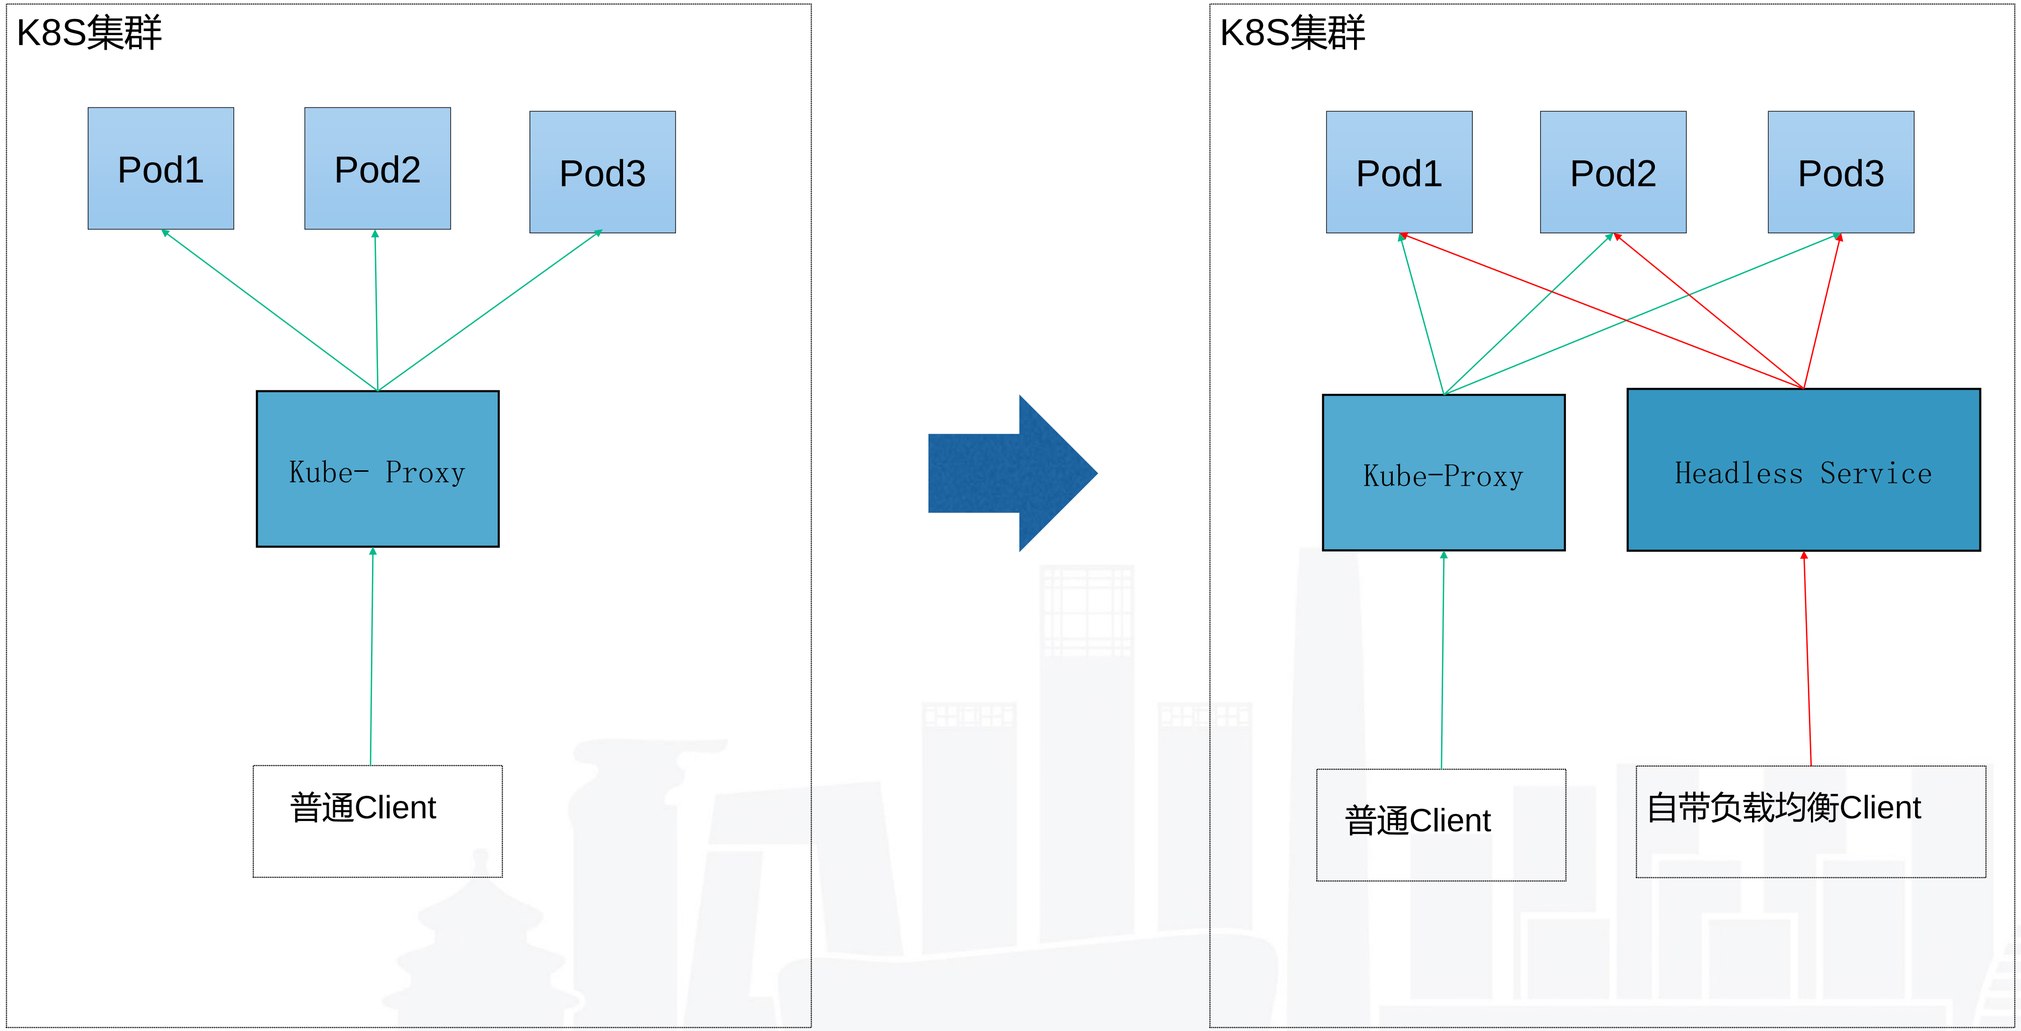
K8S集群
Pod1
Pod2
Pod3
Kube- Proxy
普通Client
K8S集群
Pod1
Pod2
Pod3
Kube-Proxy
Headless Service
普通Client
自带负载均衡Client

对外服务负载均衡优化

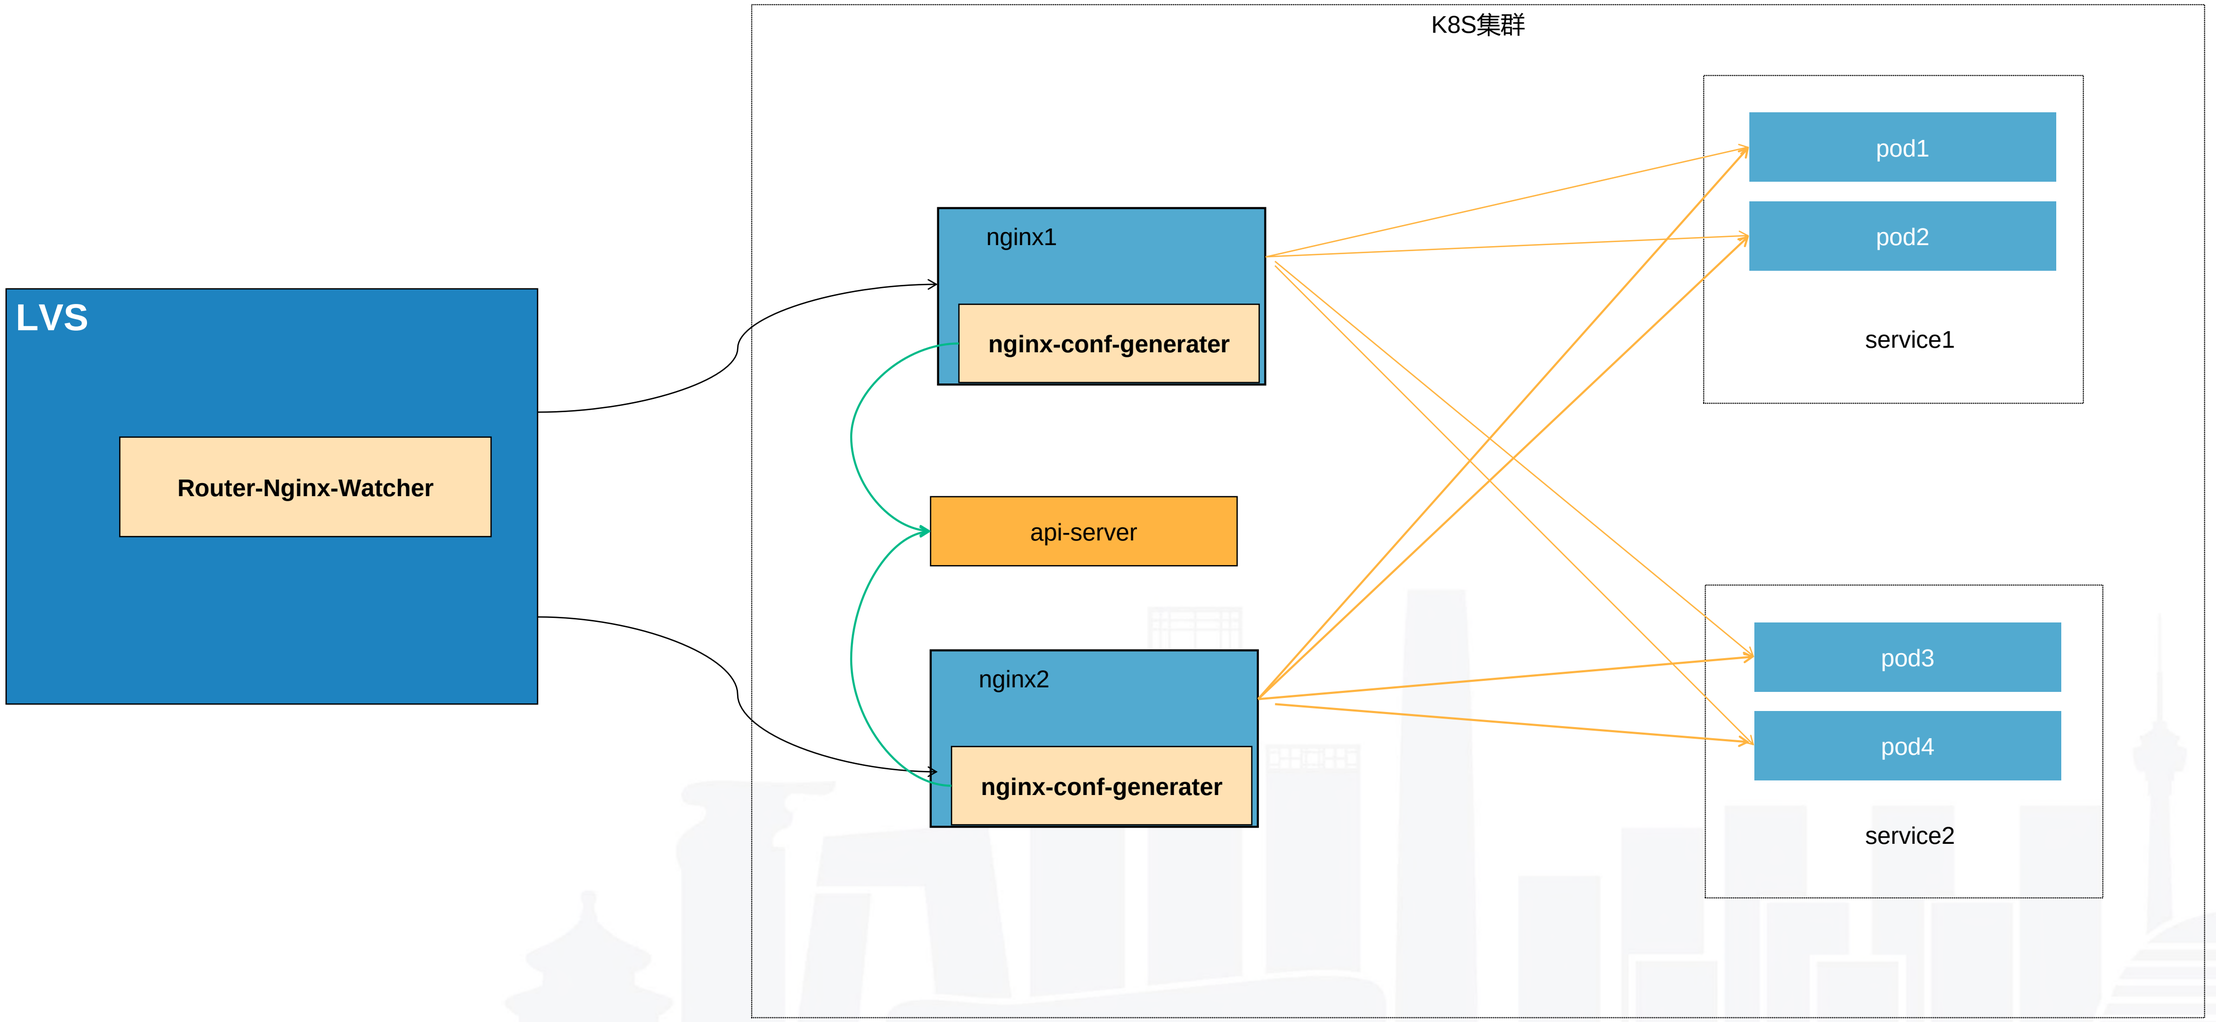
K8S集群
LVS
Router-Nginx-Watcher
nginx1
nginx-conf-generater
api-server
nginx2
nginx-conf-generater
pod1
pod2
service1
pod3
pod4
service2

Calico网络方案实践

方案难点分析

1.nginx流量出去的时候源ip会被realserver改为LVS的VIP，所以会被felix-FORWARD链给drop掉。需要添加source 为VIP的规则。

```
Chain felix-FORWARD (1 references)
 pkts bytes target     prot opt in     out     source               destination
    0     0 RETURN     all  --  *      *       10.10.102.67         0.0.0.0/0
    0     0 RETURN     all  --  *      *       10.10.102.66         0.0.0.0/0
    0     0 DROP       all  --  cali+  *       0.0.0.0/0            0.0.0.0/0           ctstate INVALID
    0     0 DROP       all  --  *      cali+   0.0.0.0/0            0.0.0.0/0           ctstate INVALID
    0     0 ACCEPT     all  --  cali+  *       0.0.0.0/0            0.0.0.0/0           ctstate RELATED,ESTABLISHED
    0     0 ACCEPT     all  --  *      cali+   0.0.0.0/0            0.0.0.0/0           ctstate RELATED,ESTABLISHED
    0     0 felix-FROM-ENDPOINT  all  --  cali+  *       0.0.0.0/0            0.0.0.0/0
    0     0 felix-TO-ENDPOINT  all  --  *      cali+   0.0.0.0/0            0.0.0.0/0
    0     0 ACCEPT     all  --  cali+  *       0.0.0.0/0            0.0.0.0/0
    0     0 ACCEPT     all  --  *      cali+   0.0.0.0/0            0.0.0.0/0
```

2.关闭nginx的interface的反向路由 /proc/sys/net/ipv4/conf/X/rp_filter=0

3.nginx-conf-generater容器从api-server定时获取nginx代理的upstream的pod的变化，并更新对应的nginx 配置文件。

隔离更好的Neutron方案

Neutron网络方案实践

Neutron与K8S集成方案

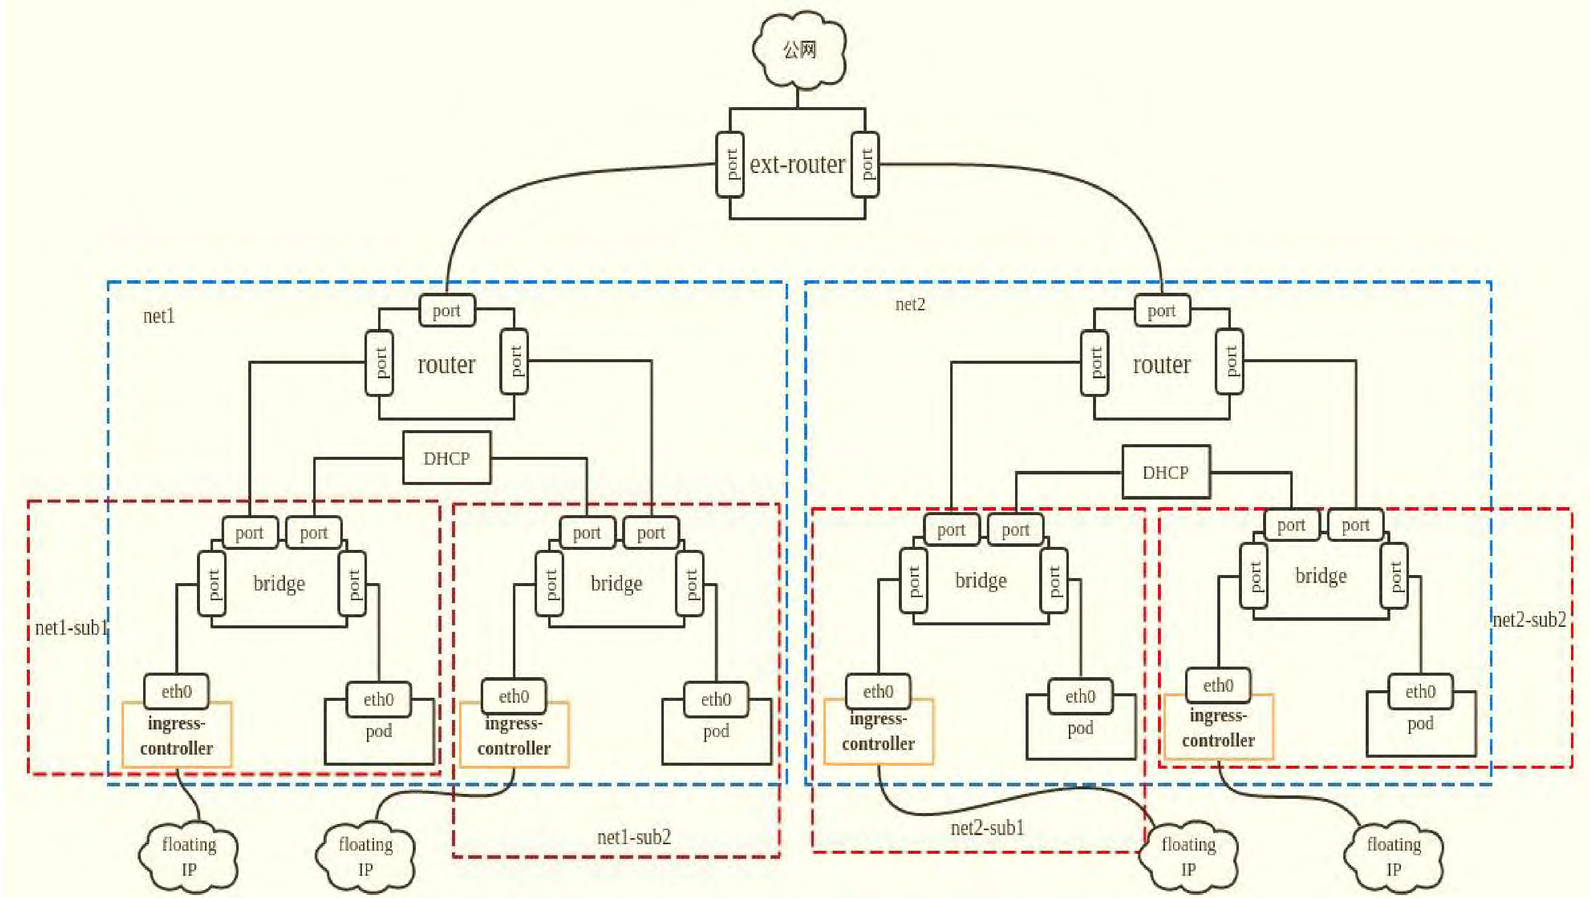

Neutron网络方案实践

Neutron与K8S集成组件

- Neutron CNI

负责在创建/删除POD过程中给POD分配Neutron的Port和IP

- Neutron-Proxy

负责监听K8S Service创建信息，并在对应的Neutron网络路由器中写入对应规则

- Ingress-Controller

是一个具有TCP/HTTP代理功能的POD，每个子网在创建过程中自动回创建这个POD，同时通过Floating IP对外提供服务

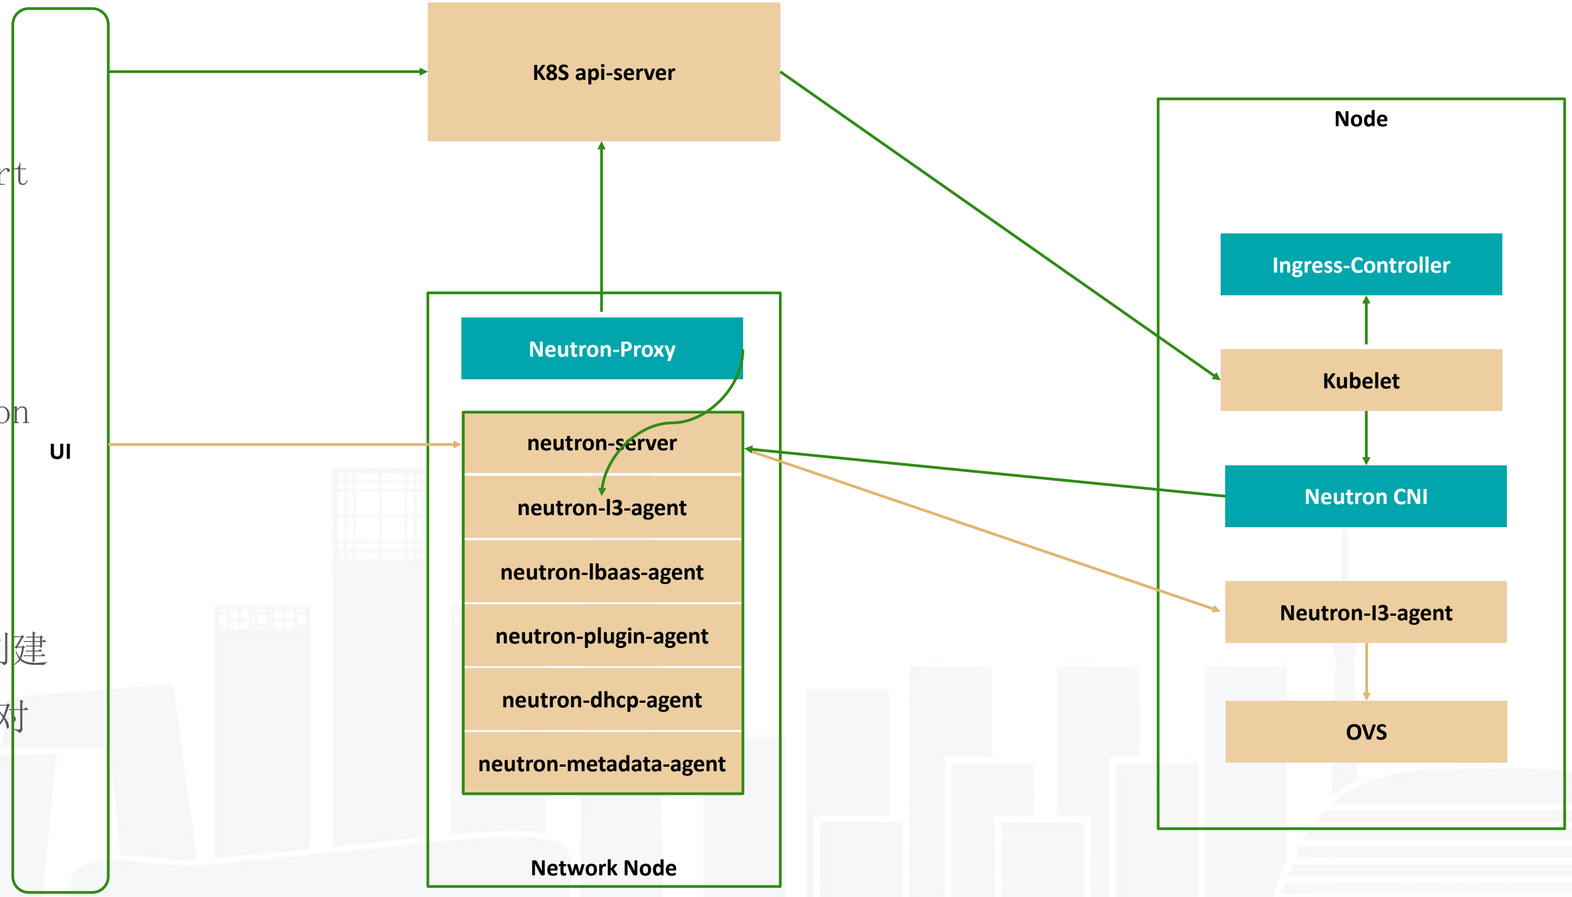

某互联网电视私有容器云平台

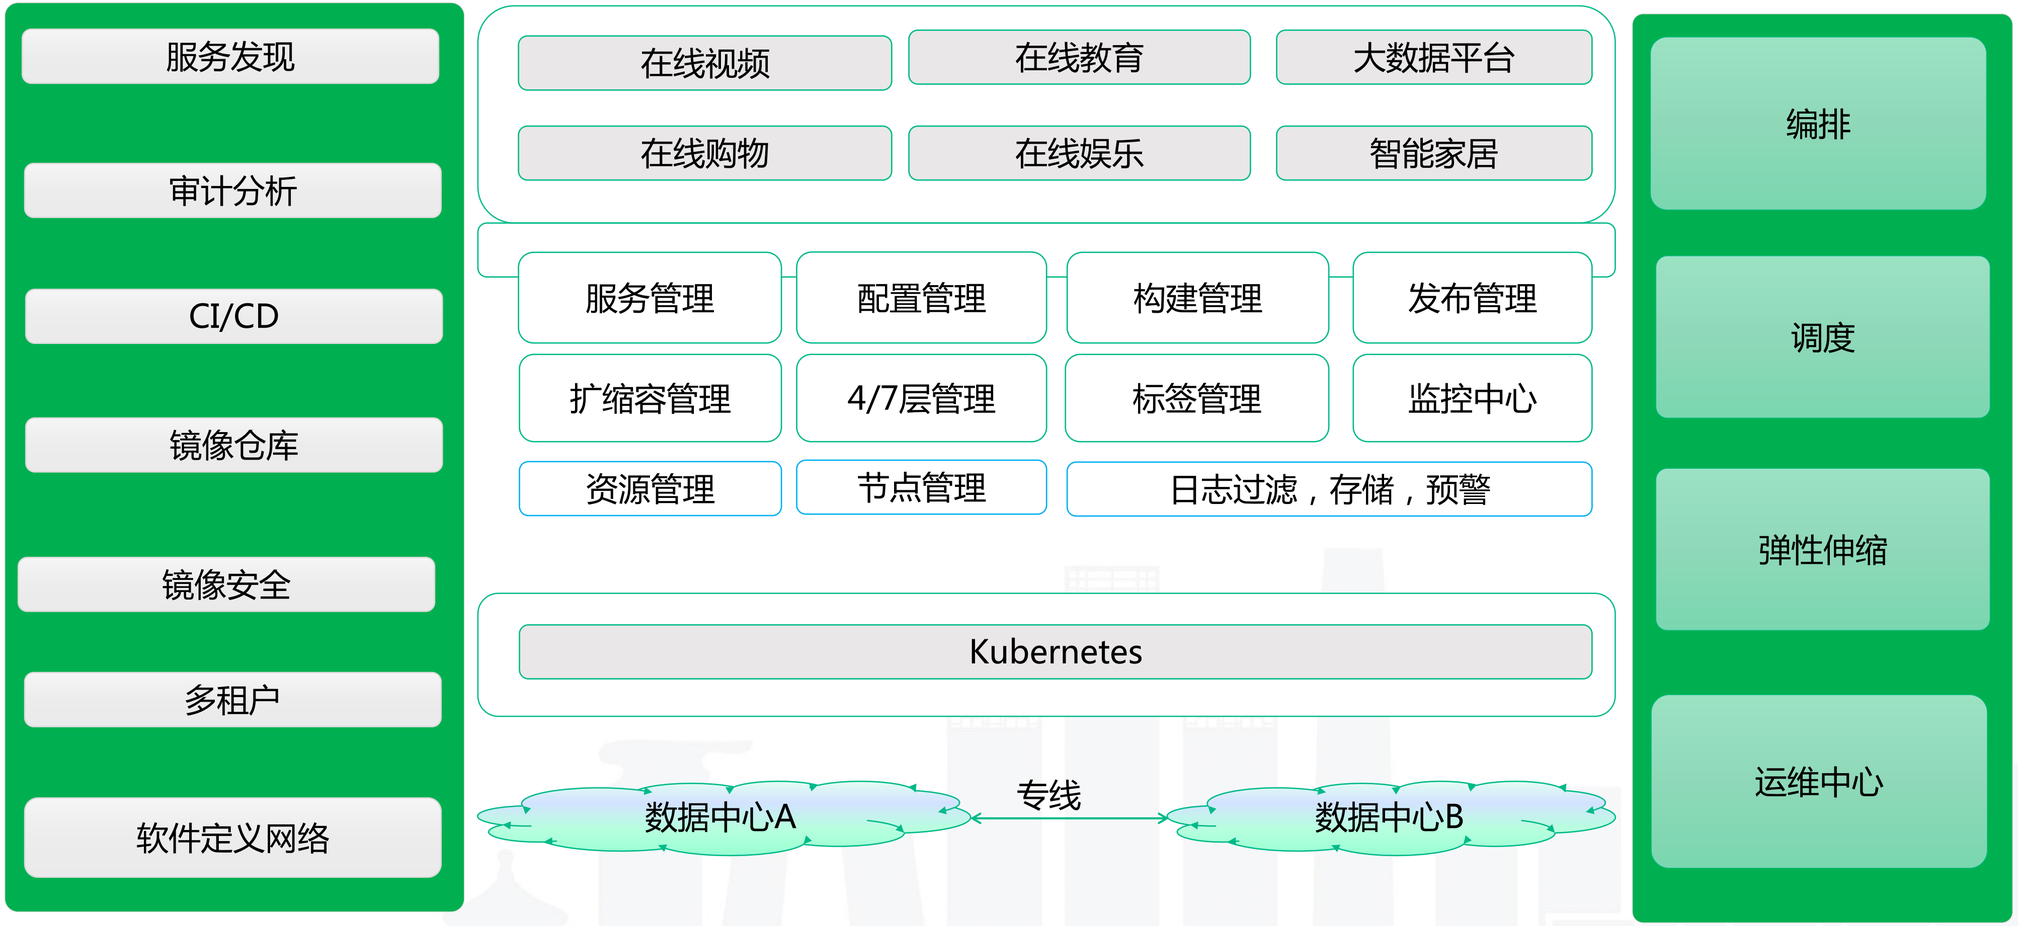

总结

- 分享了容器技术基于观云台落地的过程包括多集群搭建，CI/CD对接，应用迁移和网络的改造对接，落地对接现有方案，过程平滑。
- 效果：
  - 基于物理机，节约了成本和资源
  - 加快了应用发布的速度
  - 提升了弹性伸缩的能力
  - 提升了应用监控的水平
- 展望：持续优化

关注QCon微信公众号，
获得更多干货！

Thanks!

INTERNATIONAL SOFTWARE DEVELOPMENT CONFERENCE

主办方 Geekbang. 极客邦科技 InfoQ