
WOTA
51CTO
World Of Tech 2017
全球架构与运维技术峰会
2017年4月14日-15日 北京富力万丽酒店
ARCHITECTURE

出品人及主持人：

李庆丰

新浪微博研发中心
研发总监

容器技术实践

微博混合云DCP平台介绍与业务上云实践

付稳 @it_fuwen

WOTA

51CTO

付稳

新浪微博
技术专家

分享主题：

新浪微博混合云DCP平台介绍与业务上云实践

分享主要内容

- 一、背景、挑战
- 二、Weibo DCP设计与实现
- 三、基础设施
- 四、弹性调度
- 五、春晚实战与总结

一、背景、挑战

微博业务挑战

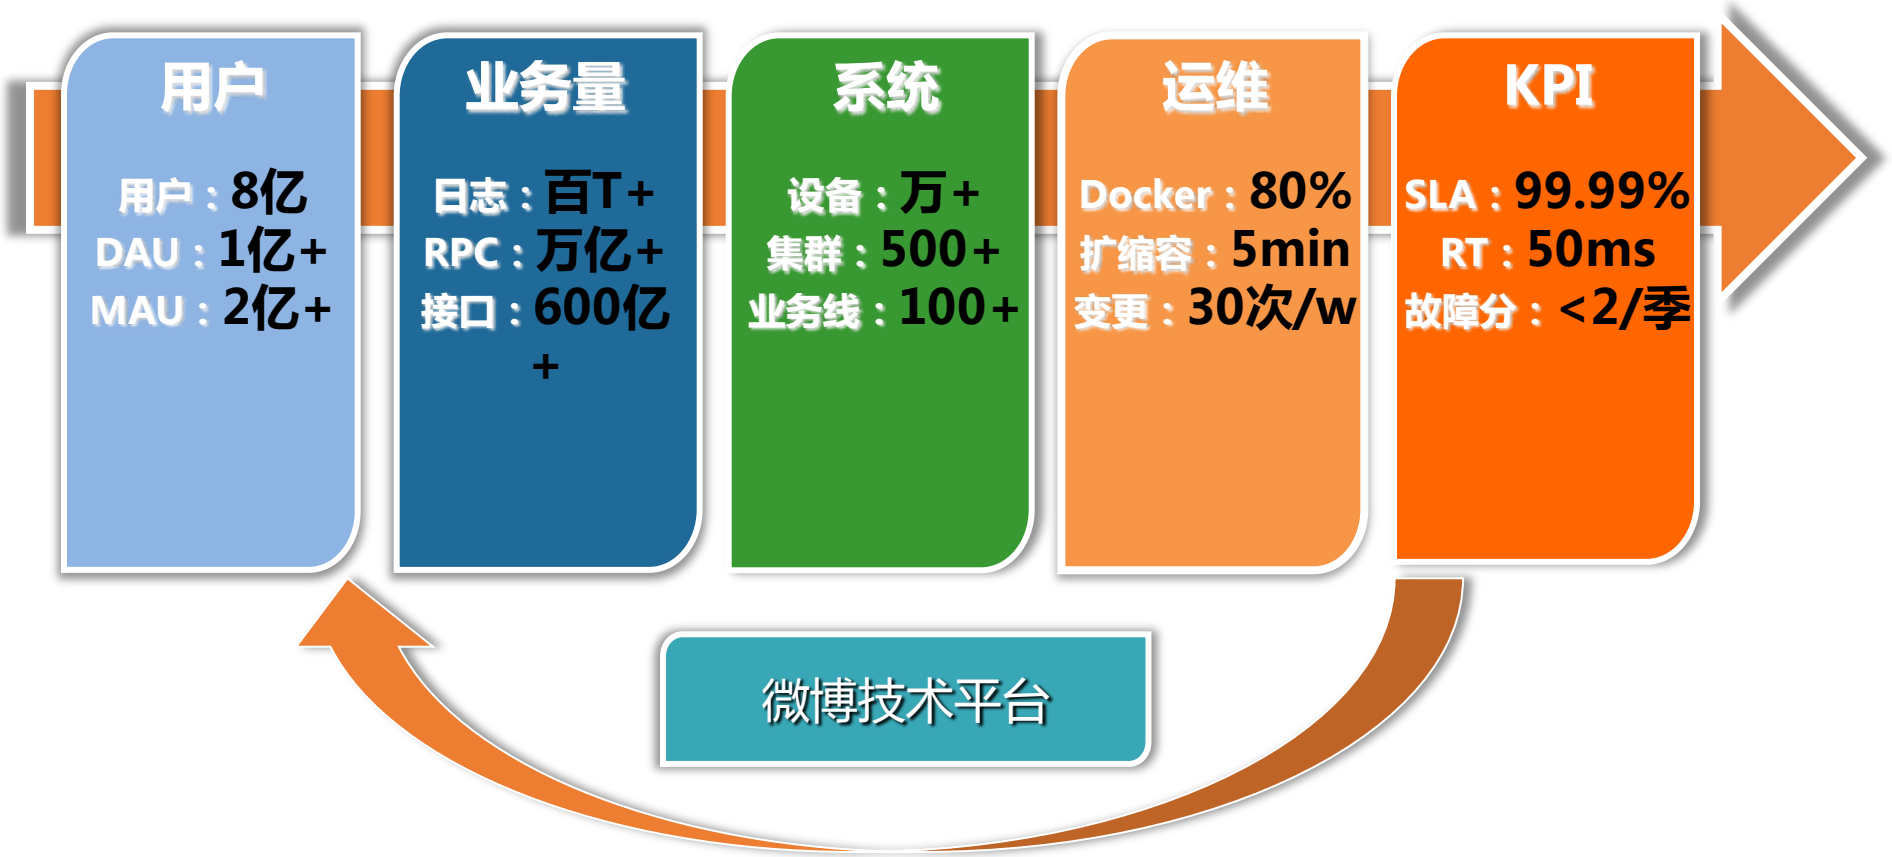

十亿级PV、千亿级数据、2000台以上的服务器规模、20个以上的大小服务模块、百亿级数据HBase存储、千台以上的Docker混合云集群，持续不断的技术挑战；

微博业务现状

- 春晚峰值流量应对
  - 机架位不足，上千台服务器库存不足
  - 千万级采购成本巨大
  - 采购周期长，运行三个月只为一晚
- 白百合、李晨娱乐事件等热点突发峰值应对
  - 突发性强无预期、无准备
  - PUSH常规化，短时间大量设备扩容需求

明星“出轨、在一起！”

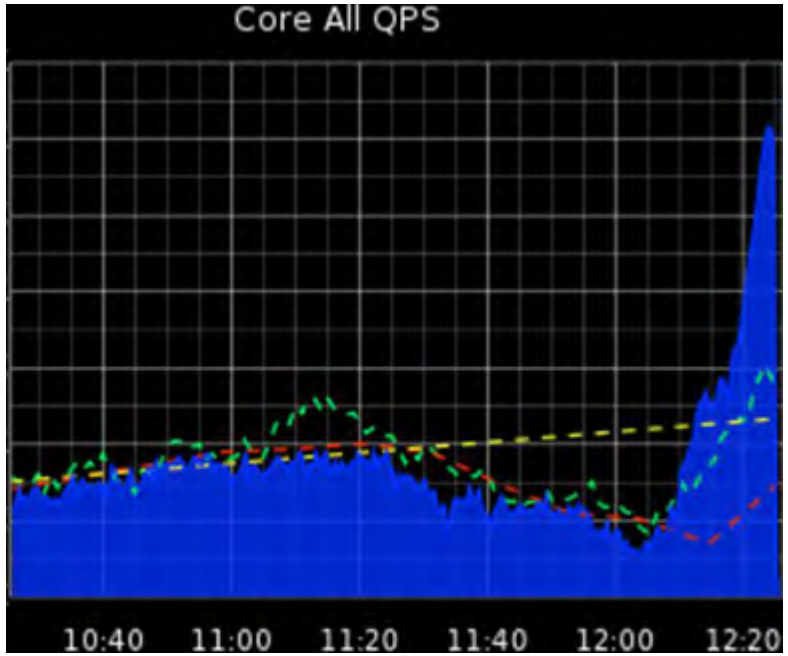

如何10分钟内完成1000节点扩容能力？

服务扩缩容流程繁琐

项目评审 设备申请 → 入CMDB → 装机 上架 → 初始化 → 服务部署 → 报修 下架

微博业务现状与解决

弹性快速扩缩容

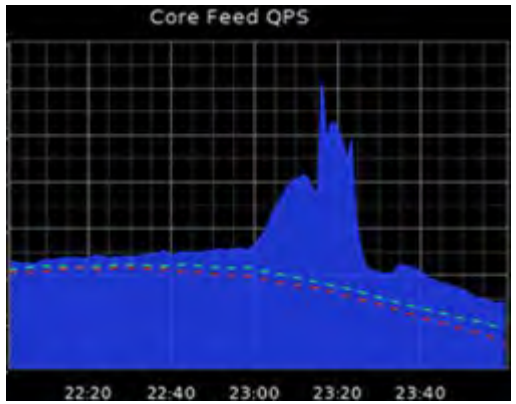

混合云弹性调度可伸缩业务成本节省数倍

场景	私有云方案	公有云方案	预估总成本对比（私/公）
短期峰值应对	部分调度，部分采购	按小时付费	数十倍
日常常规部署	按月租赁	包月付费	1.0~1.2
离线计算	按月租赁	按小时付费	数十倍

配置	按量（元/小时）	包月（元/月）
4核4G，20G磁盘	1.13	302
4核8G，20G磁盘	1.77	402
4核16G，20G磁盘	3.05	602
8核8G，20G磁盘	2.25	598
8核32G，20G磁盘	6.09	1198
16核16G，磁盘20G	4.52	1207
16核64G，磁盘20G	12.17	2390
备注	小时计费按月方包月3~4折（64G必须选择16核）	

运维标准化

产品更新迭代快，系统变更代码指数增长

混合云趋势

混合云趋势：安全、可扩展性、成本...

- 阿里云、AWS等公有云平台趋于成熟
  - 国外Zynga、Airbnb、Yelp等使用AWS进行部署
  - 国内阿里云12306、高德、快的已部署，陌陌等部署中
  - 12306借助阿里云解决饱受诟病的春节余票查询峰值问题
- Docker、Mesos等容器新技术使大规模动态调度成为可能
  - 京东618大促借助Docker为基础的弹性云解决峰值流量问题


12306混合云案例

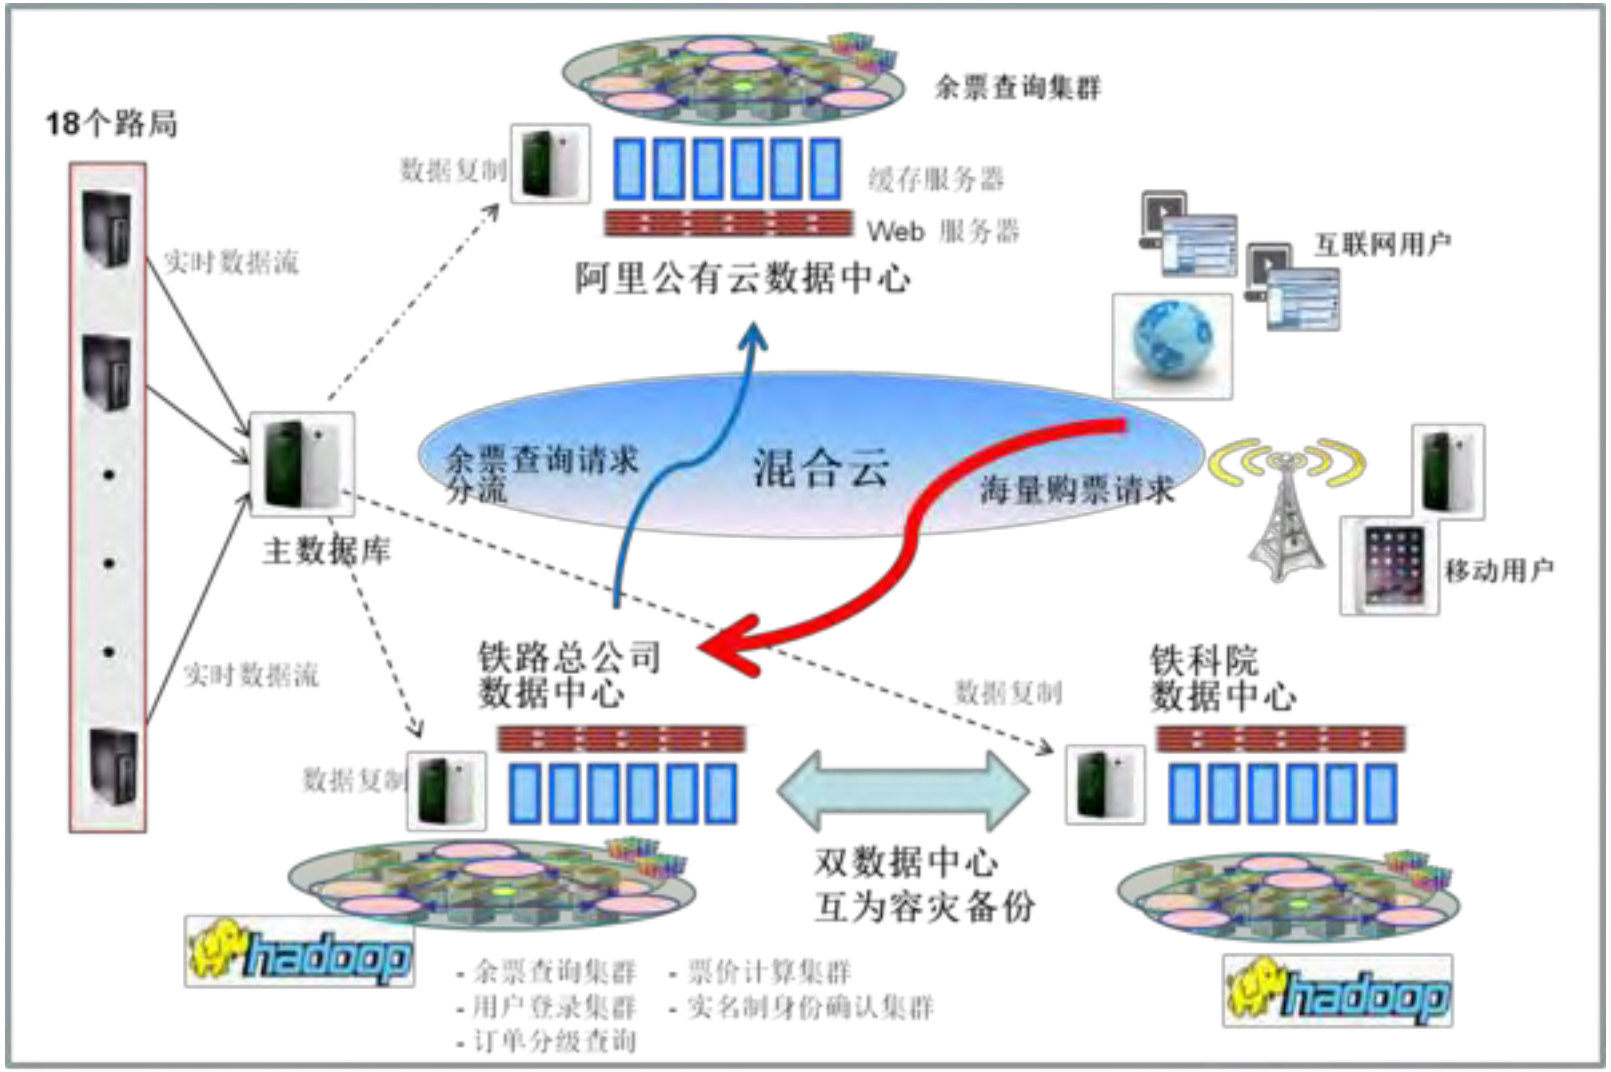

12306 两地三中心 混合云架构

混合云核心点

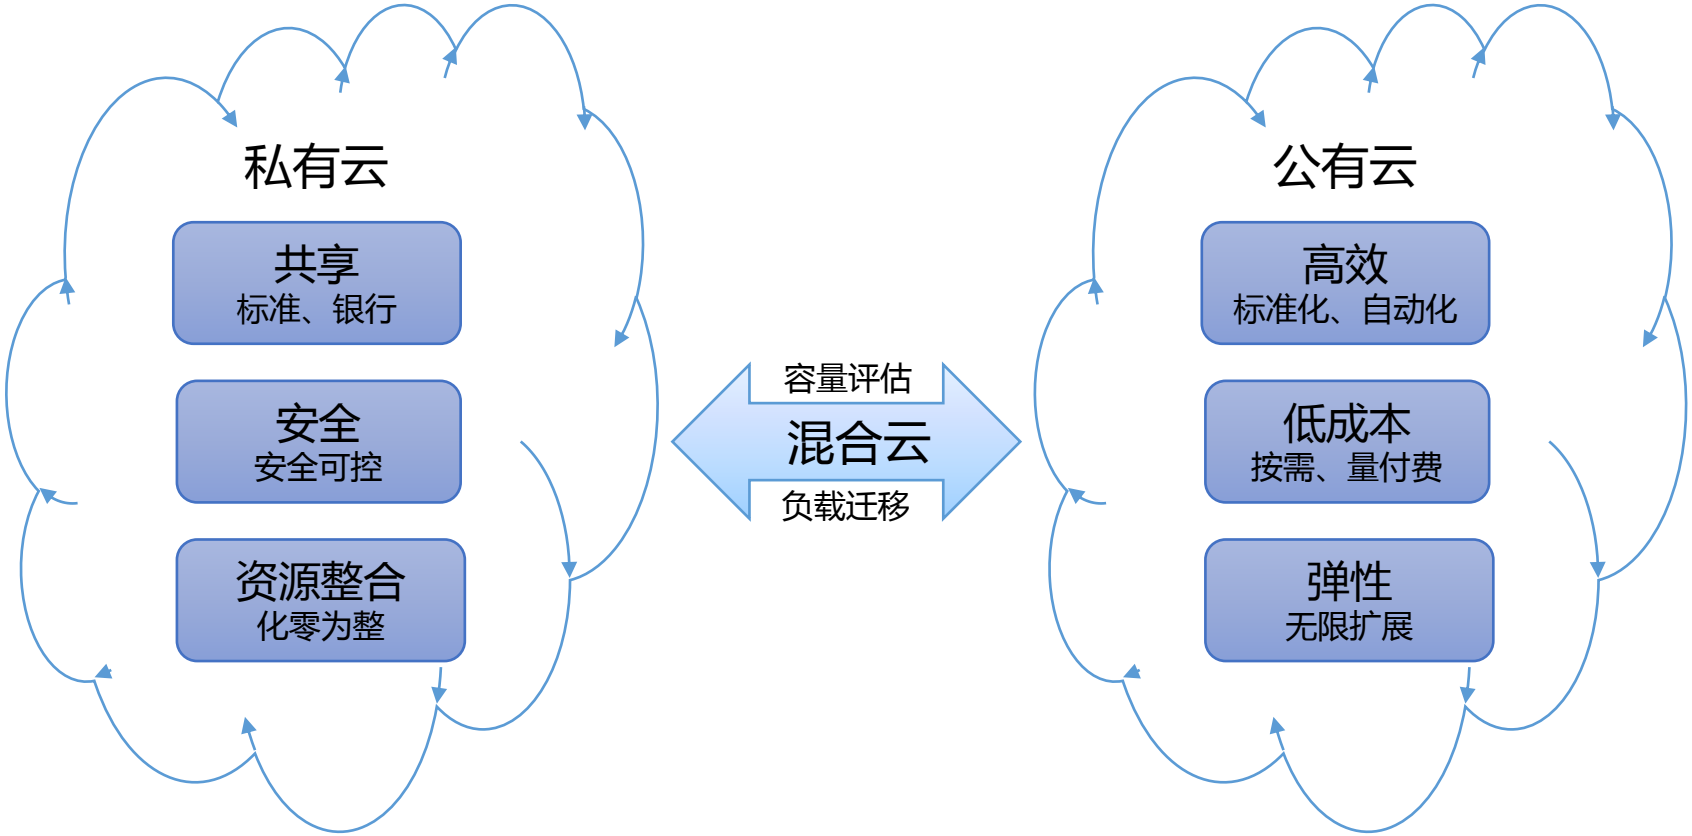

私有网络

VPC网络

基于Docker弹性调度

基础设施跨云

二、Weibo DCP设计与实现

微博DCP技术架构演进

容器化

单机容器化

在线Docker集群

私有云

弹性调度

服务发现

私有云建设

混合云

在线离线业务整合

混合云机器学习支持

OpenDCP

混合云DCP技术架构

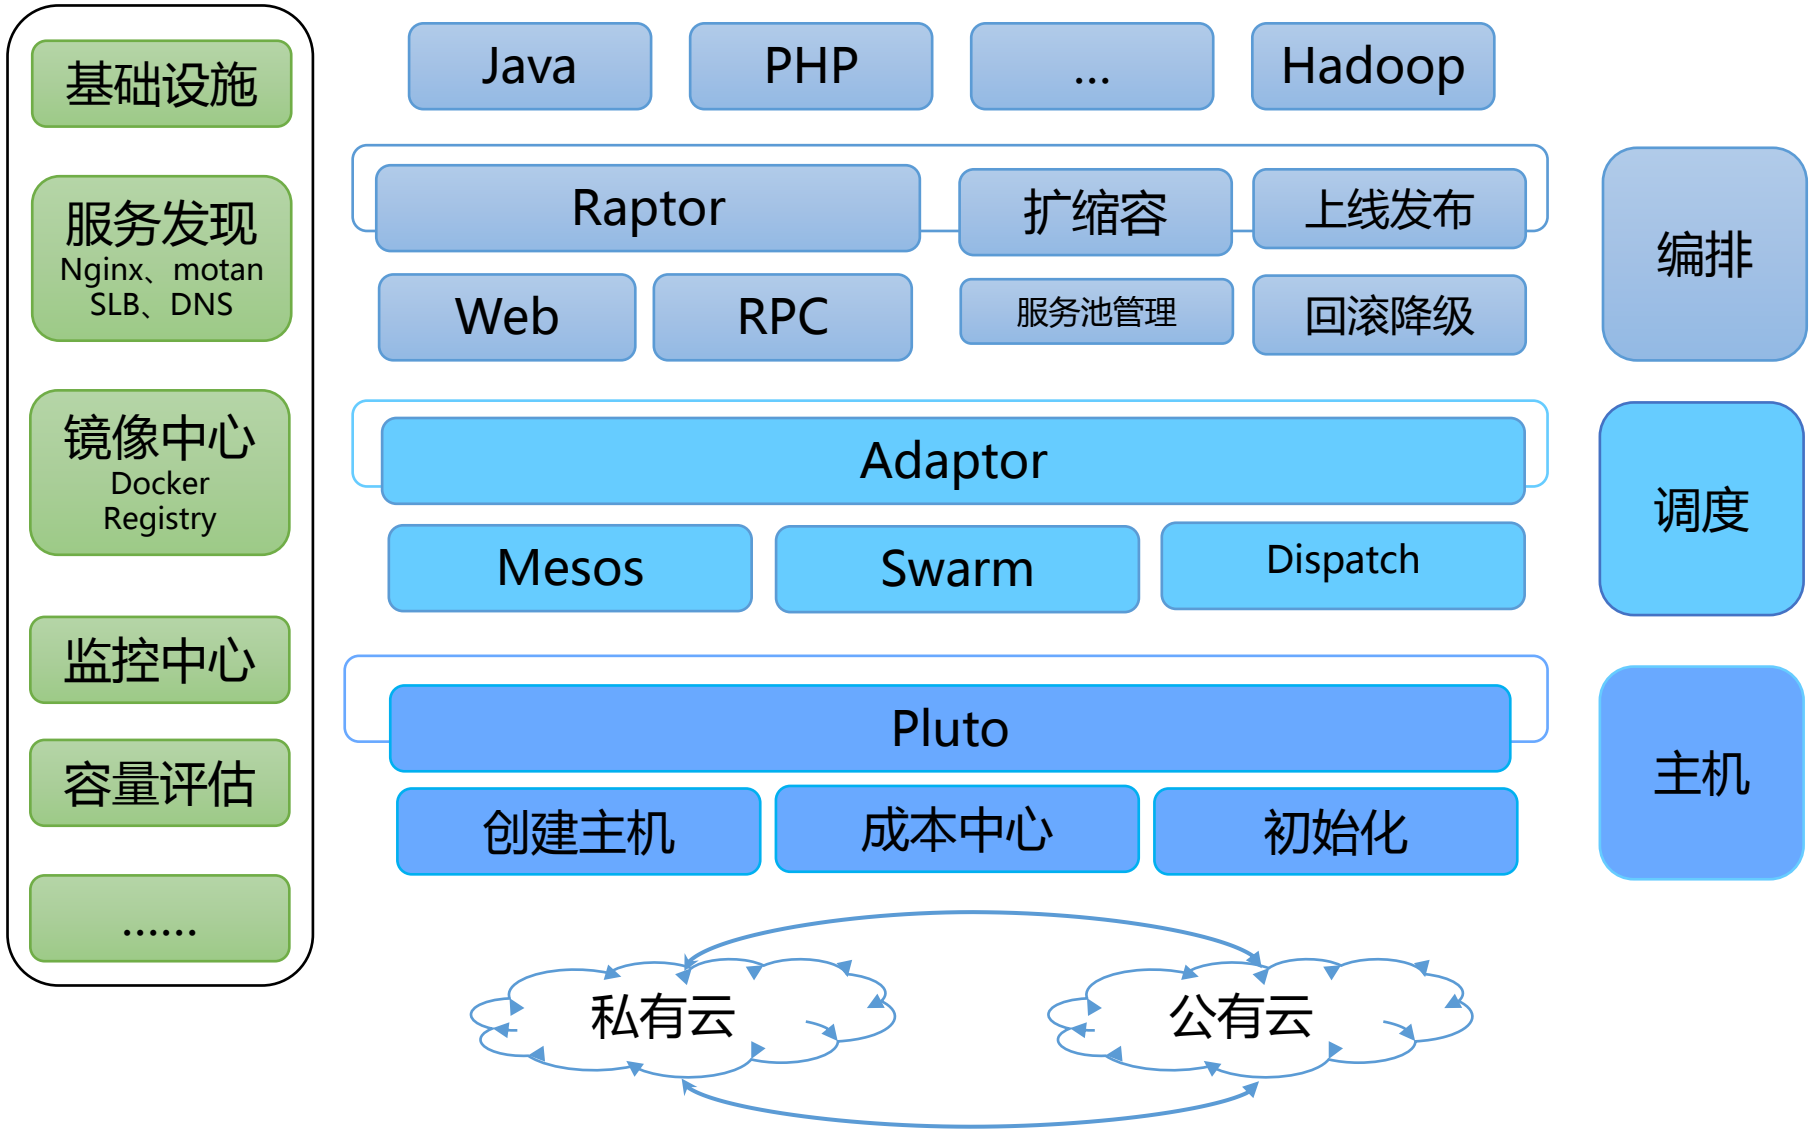
基础设施
服务发现
Nginx、motan
SLB、DNS
镜像中心
Docker
Registry
监控中心
容量评估
……
Java
PHP
...
Hadoop
Raptor
扩缩容
上线发布
Web
RPC
服务池管理
回滚降级
编排
Adaptor
Mesos
Swarm
Dispatch
调度
Pluto
创建主机
成本中心
初始化
主机
私有云
公有云

混合云DCP技术栈

主机 or VM	裸主机/Openstack	公有云VM(ECS)		
OS	CentOS 6.5	CentOS 7.0		
Docker	1.6.2	Host	iptables=false	DeviceMapper
Docker Registry	V1	V2		
Swarm	1.0.0			
Mesos	0.25			
Marathon	0.13.0			
Consul	0.6.0			
Ansible	1.9.4			

混合云DCP功能模块


业务方
红包飞
MAPI
广告
有信
Feed
用户
通讯
平台架构
PAAS
Swarm
Docker 调度策略
Mesos 调度管理
容量评估
容器监控
调度监控
IAAS
共享池管理
成本核算
ECS管理
SLB 管理
四七层解决方案
专线保障
公有云流量管理
审批流程
基础框架
软件安装
工程框架
安全保障
账户体系
监控体系
DNS管理
配置管理
阿里云 Yum/日志
Docker Register
Docker 镜像市场
Consul 工具管理
OS升级自动化
Docker 工具体系

DCP-核心设计思想

- 核心问题：设备从哪来？
- 设备方案：内网共享池 + 公有云=BufferPool
- 服务：IP + Port

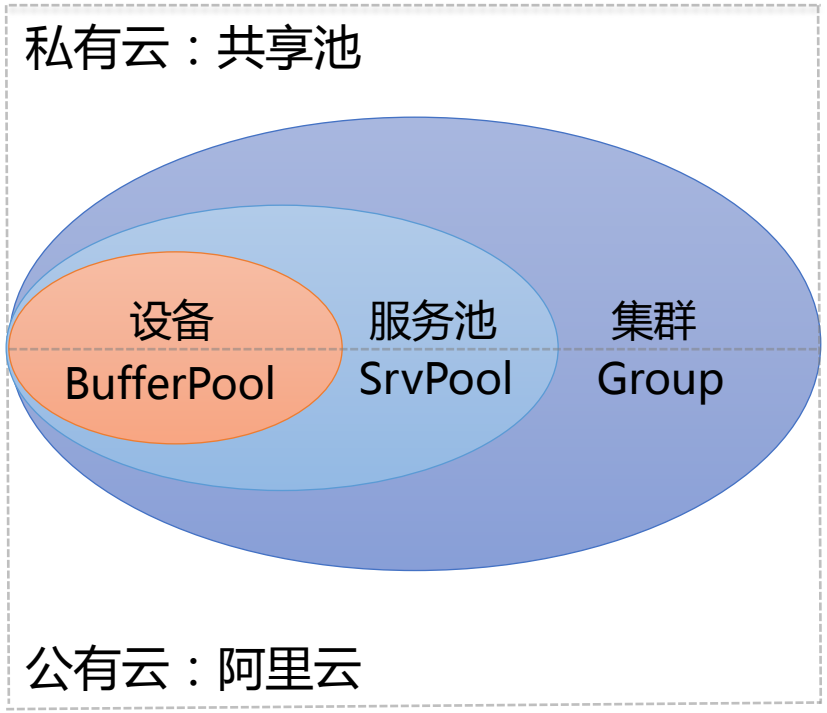

层级关系

- DCP：分为多个集群
- 集群：为独立平台，对应业务线
  - 集群内：自由调度（跨池）
  - 集群外：配额调度
- 服务池：同一业务线的同构服务
- 设备：buffer池 = 共享池 + ECS

DCP-资源共享

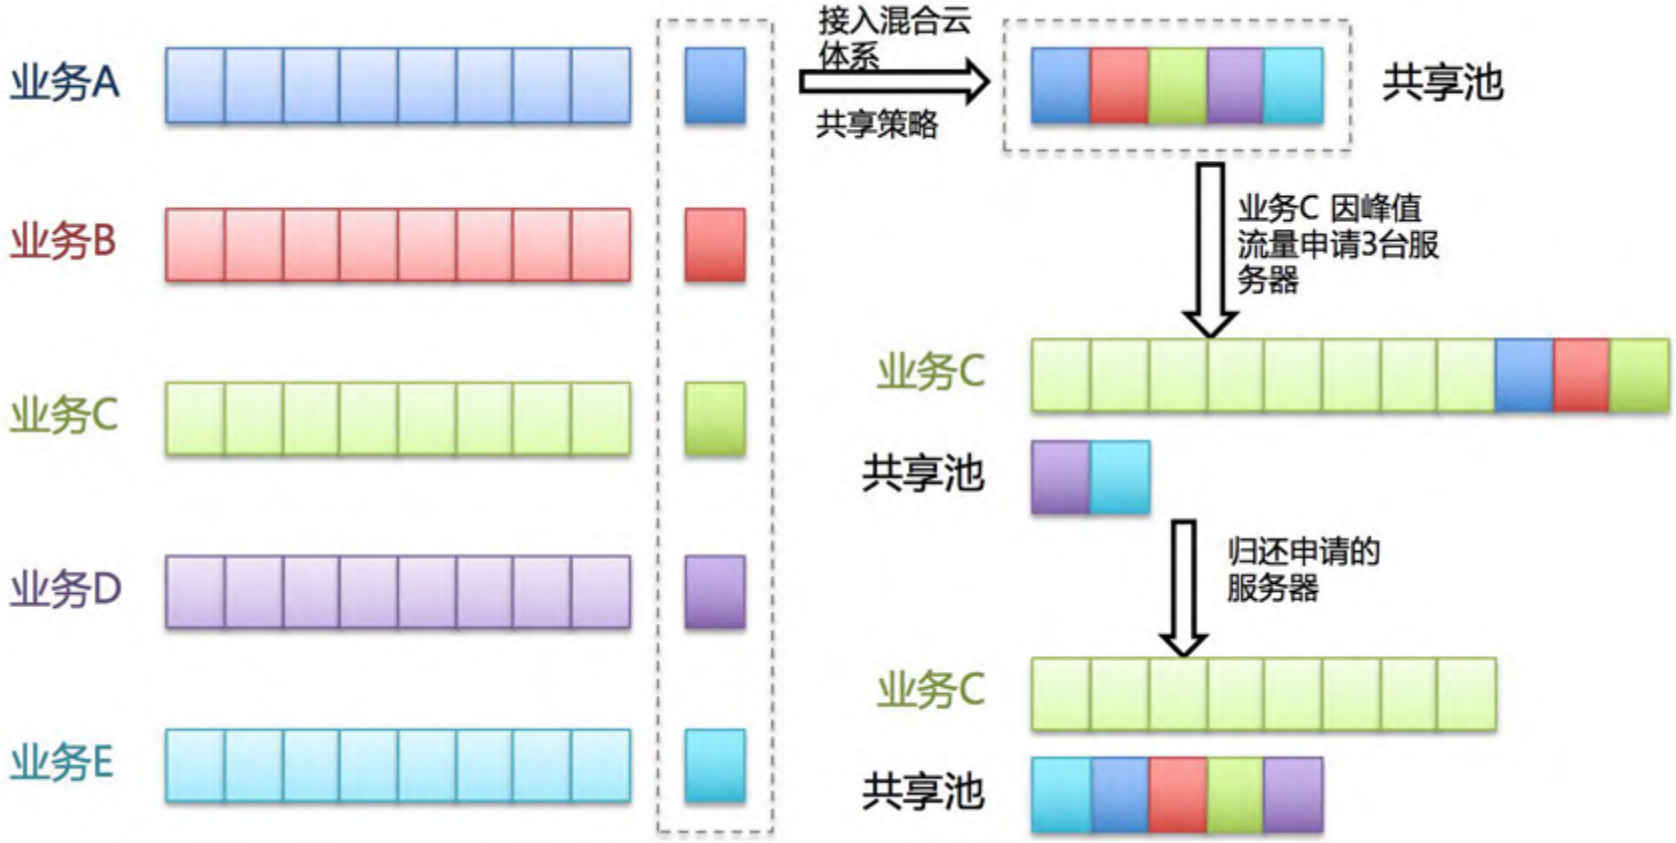
业务A
业务B
业务C
业务D
业务E
接入混合云体系
共享策略
共享池
业务C 因峰值流量申请3台服务器
业务C
共享池
归还申请的服务器
业务C
共享池

DCP-大规模集群扩容方式

私有内弹性扩容

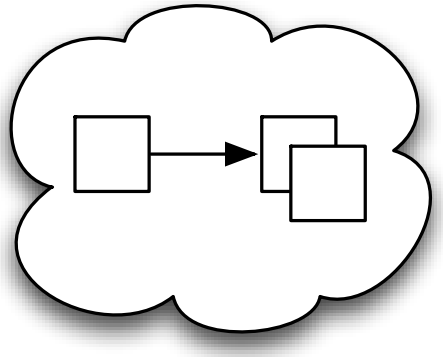

扩容到公有云弹性

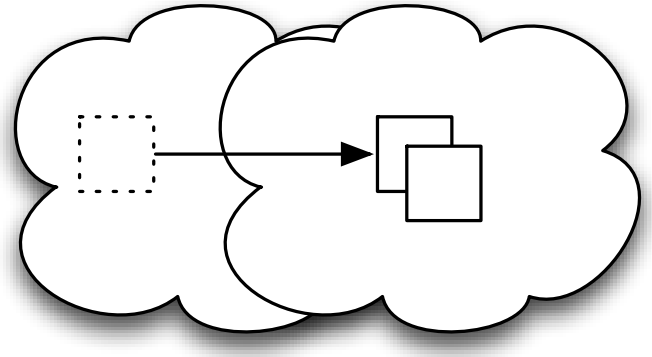

私有云、公有云同时弹性扩容

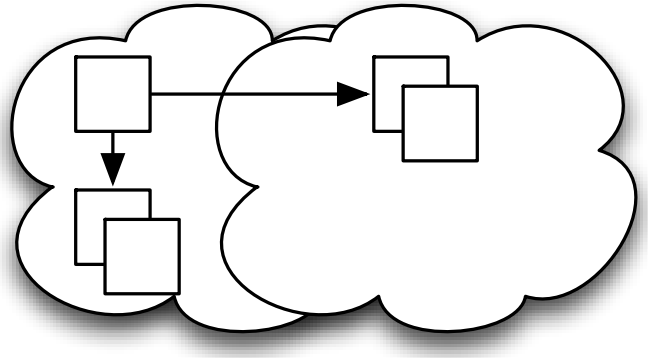

混合云DCP流程

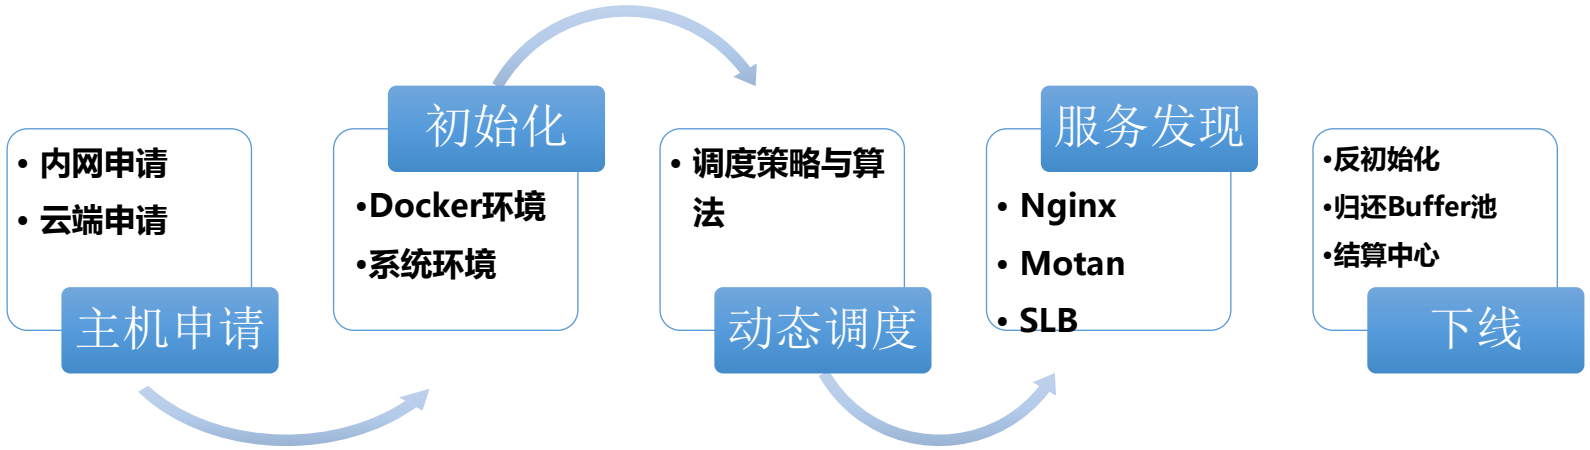
• 内网申请
• 云端申请
主机申请
初始化
•Docker环境
•系统环境
• 调度策略与算法
动态调度
服务发现
• Nginx
• Motan
• SLB
•反初始化
•归还Buffer池
•结算中心
下线

二、基础设施

统一资源管理

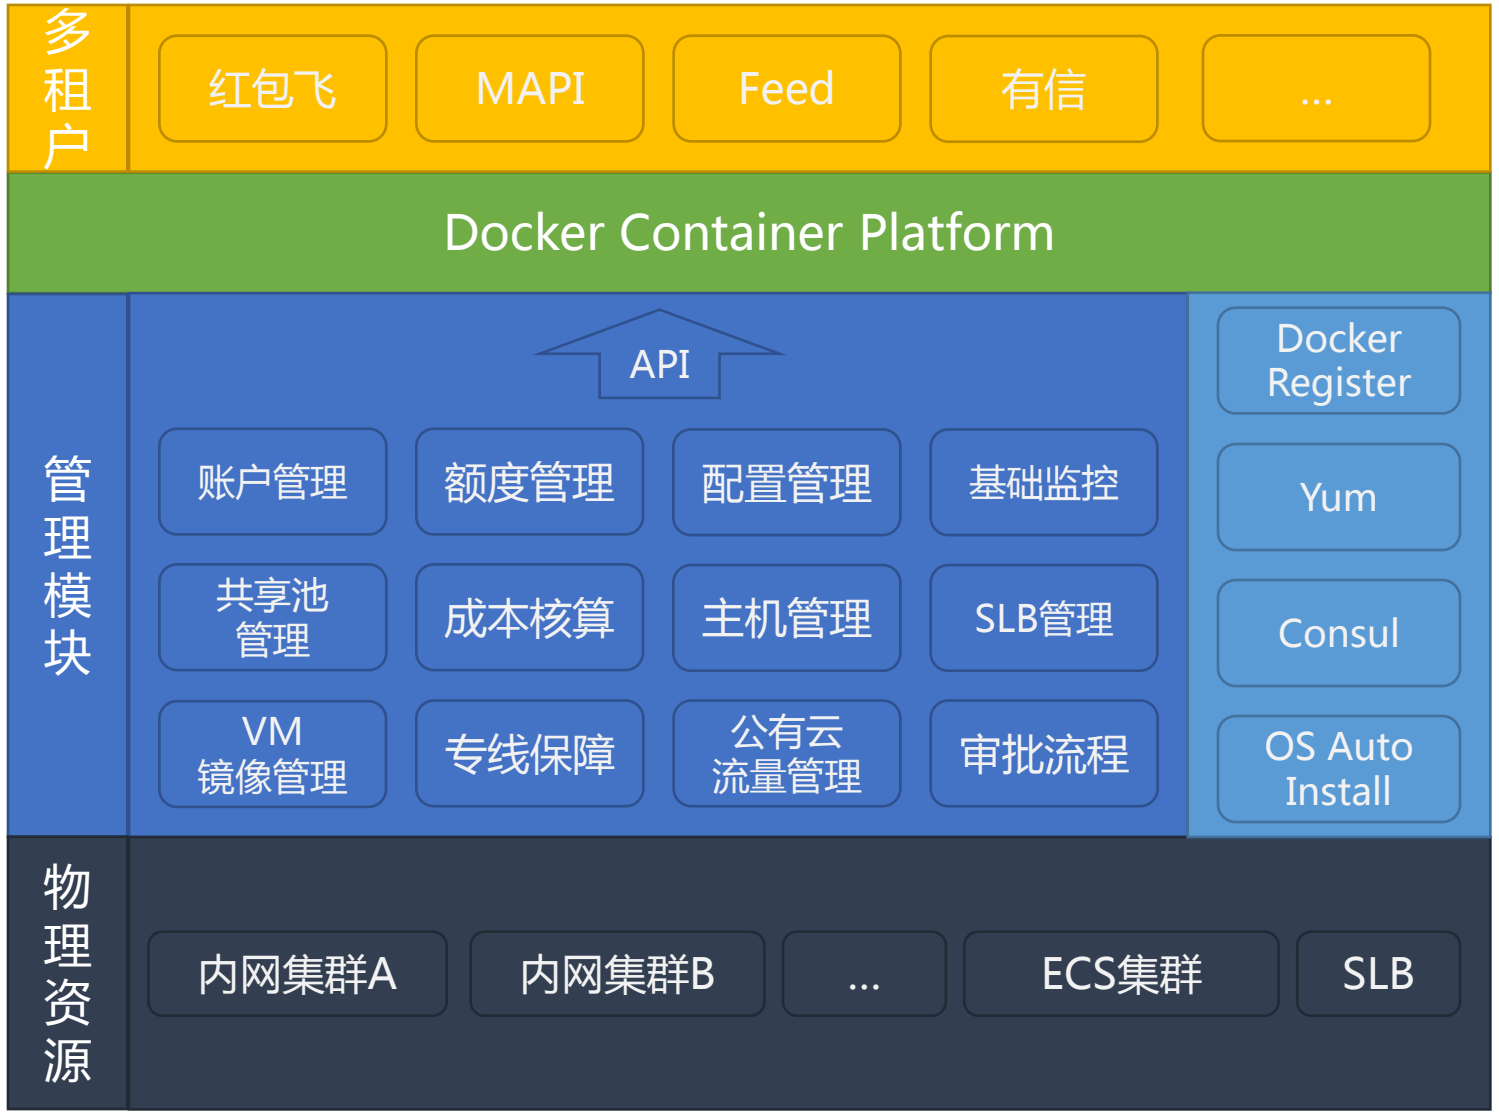
多租户
红包飞
MAPI
Feed
有信
...
Docker Container Platform
管理模块
API
账户管理
额度管理
配置管理
基础监控
共享池管理
成本核算
主机管理
SLB管理
VM镜像管理
专线保障
公有云流量管理
审批流程
Docker Register
Yum
Consul
OS Auto Install
物理资源
内网集群A
内网集群B
...
ECS集群
SLB

单机部署方案

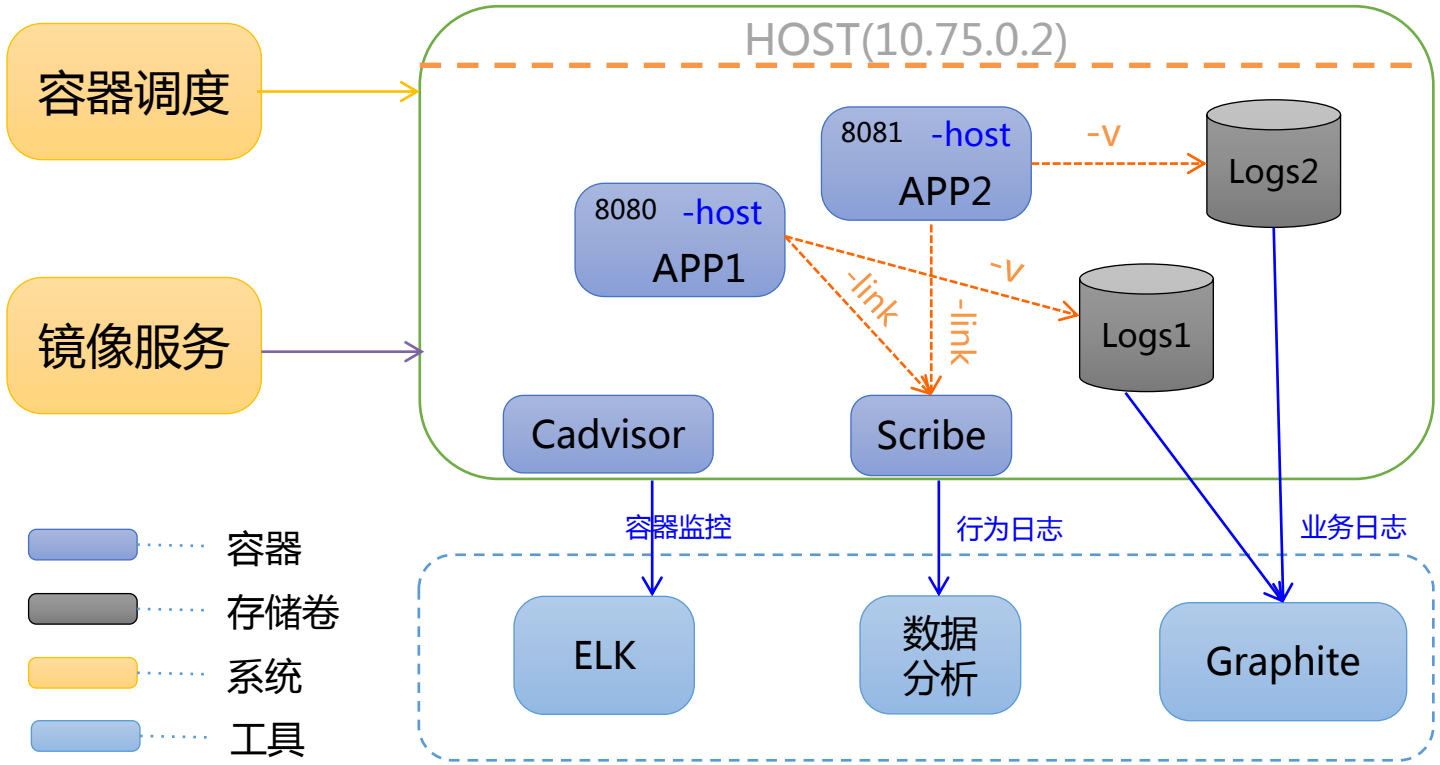
容器调度
镜像服务
HOST(10.75.0.2)
8081 -host
APP2
-v
Logs2
8080 -host
APP1
-v
-link
-link
Logs1
Cadvisor
Scribe
容器监控
行为日志
业务日志
ELK
数据
分析
Graphite
容器
存储卷
系统
工具

基础环境软件版本

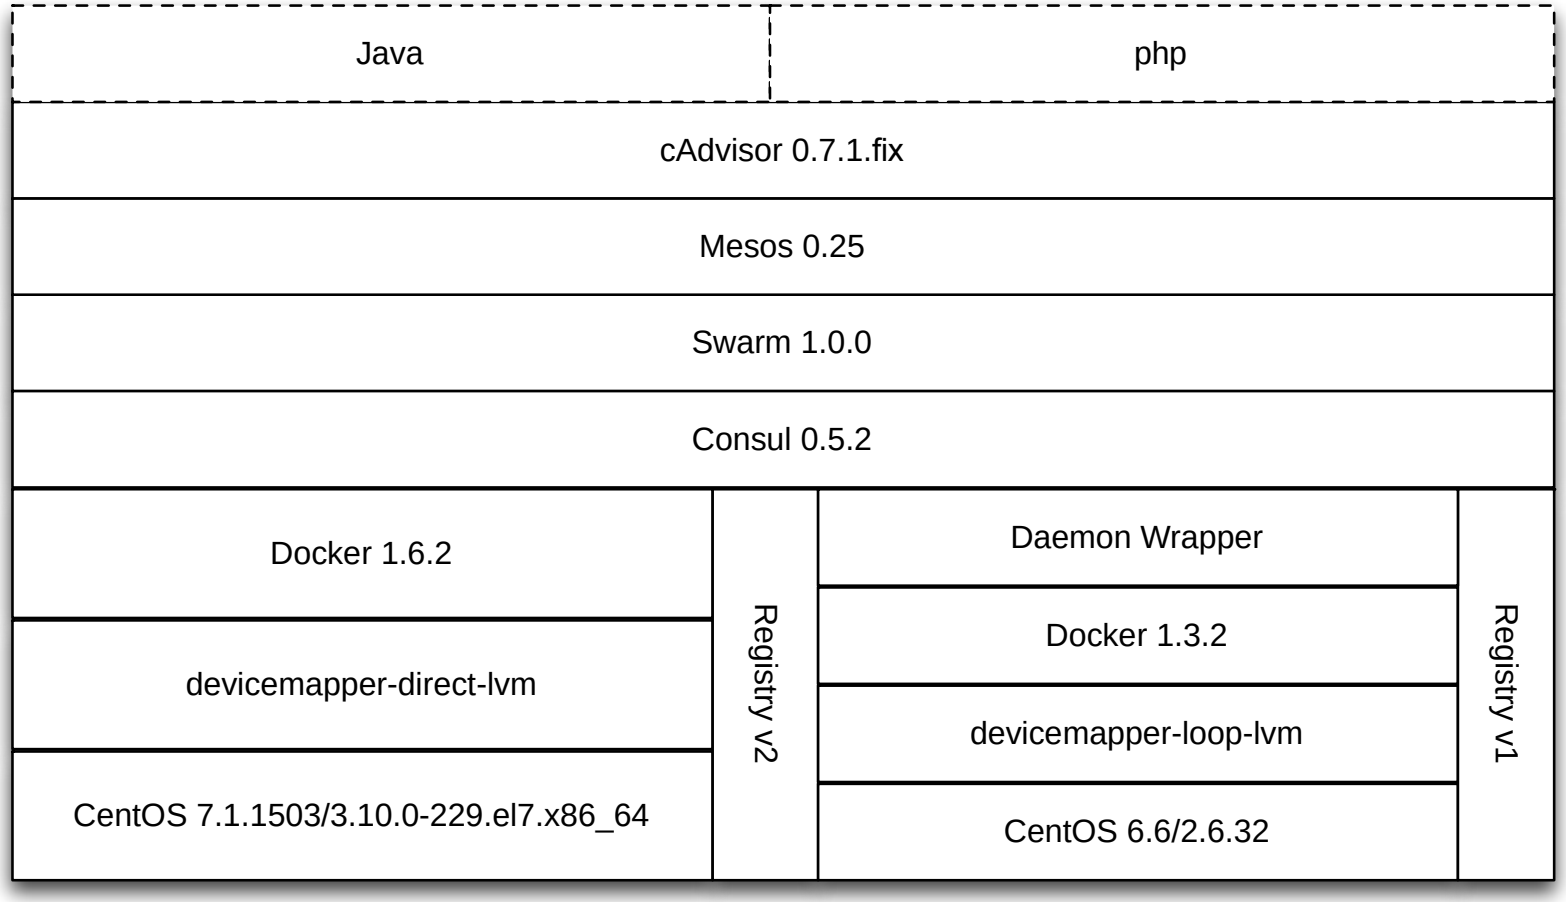
Java
php
cAdvisor 0.7.1.fix
Mesos 0.25
Swarm 1.0.0
Consul 0.5.2
Docker 1.6.2
devicemapper-direct-lvm
CentOS 7.1.1503/3.10.0-229.el7.x86_64
Registry v2
Daemon Wrapper
Docker 1.3.2
devicemapper-loop-lvm
CentOS 6.6/2.6.32
Registry v1

镜像分层服务

- 镜像服务
  - 分层设计，逐层复用
  - 基础环境/运行时/容器/业务
  - 优化大小，dockerignore
  - 禁止使用latest

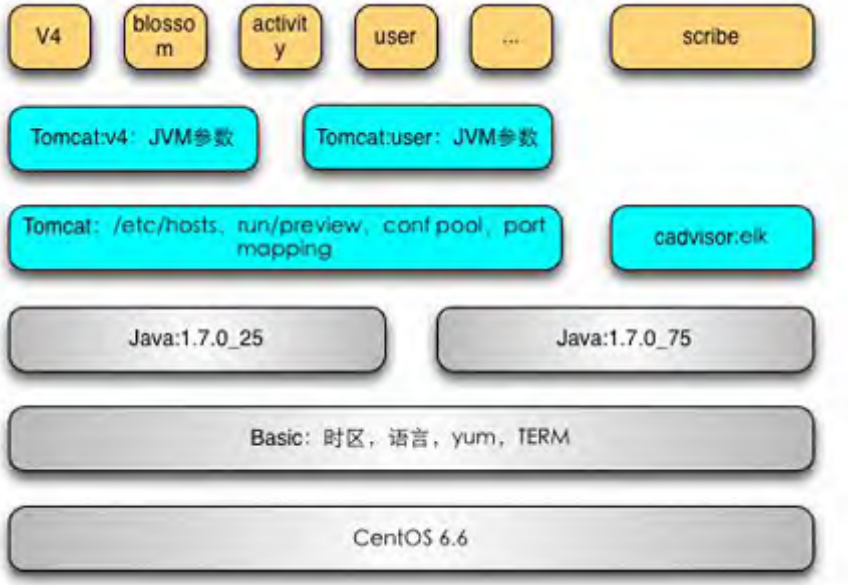

Docker Registry – 部署架构

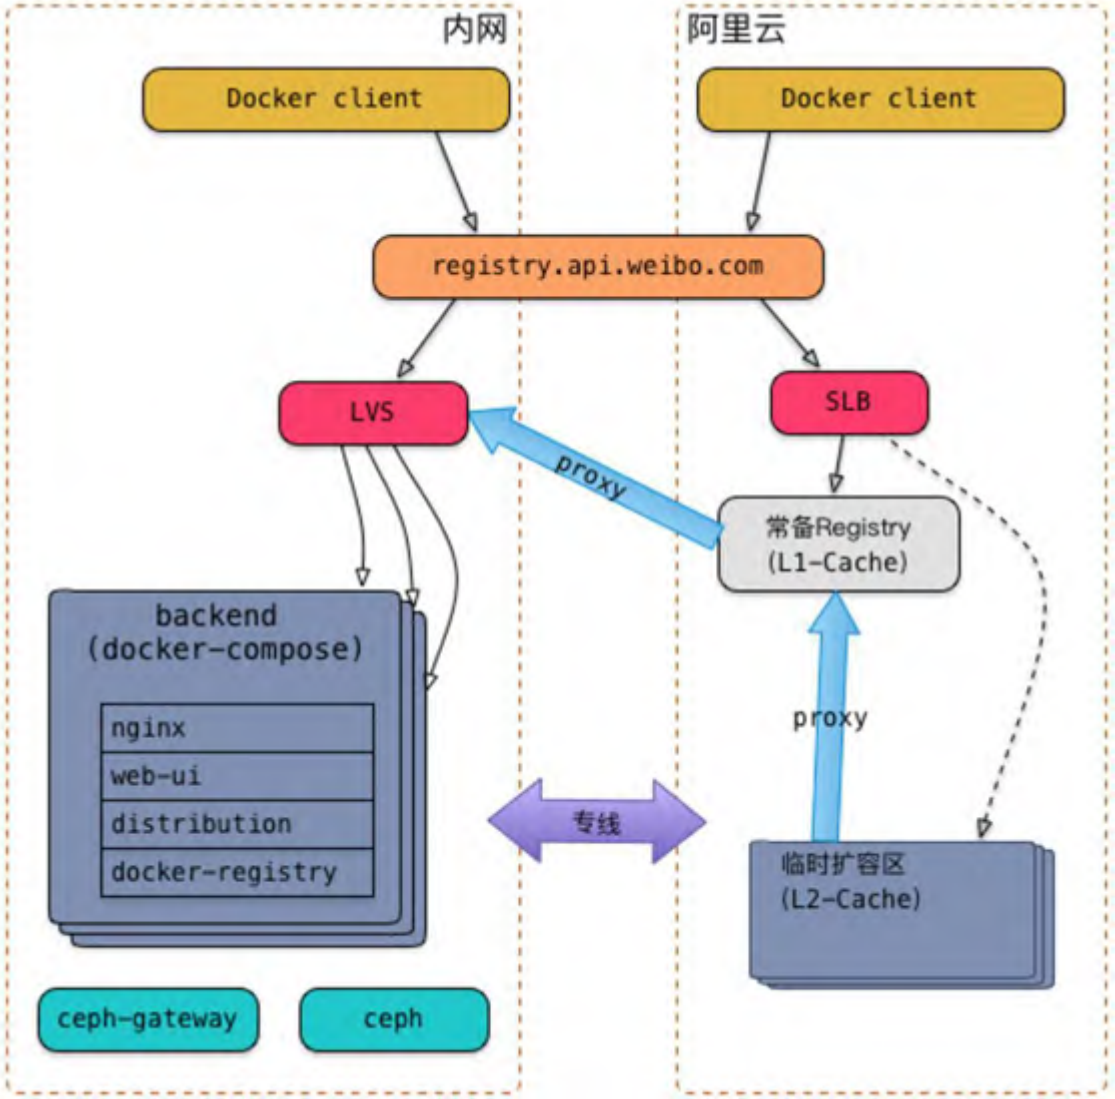

DCP中SLB的应用

- DNS高可用

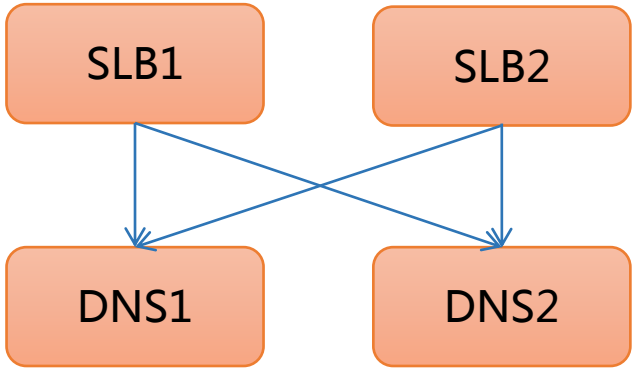

- Registry负载均衡

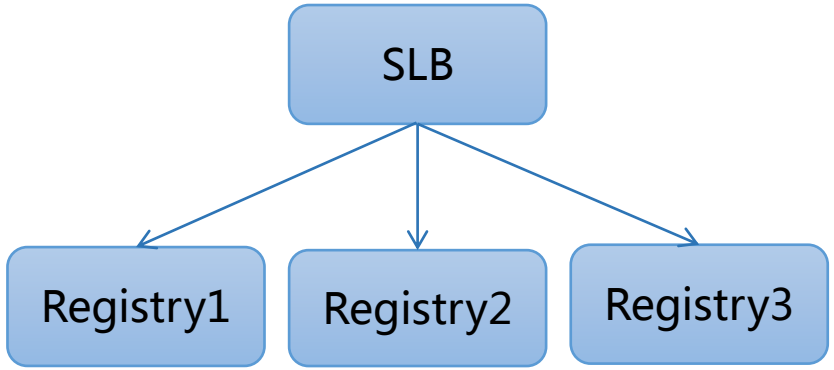

- 快速水平扩容

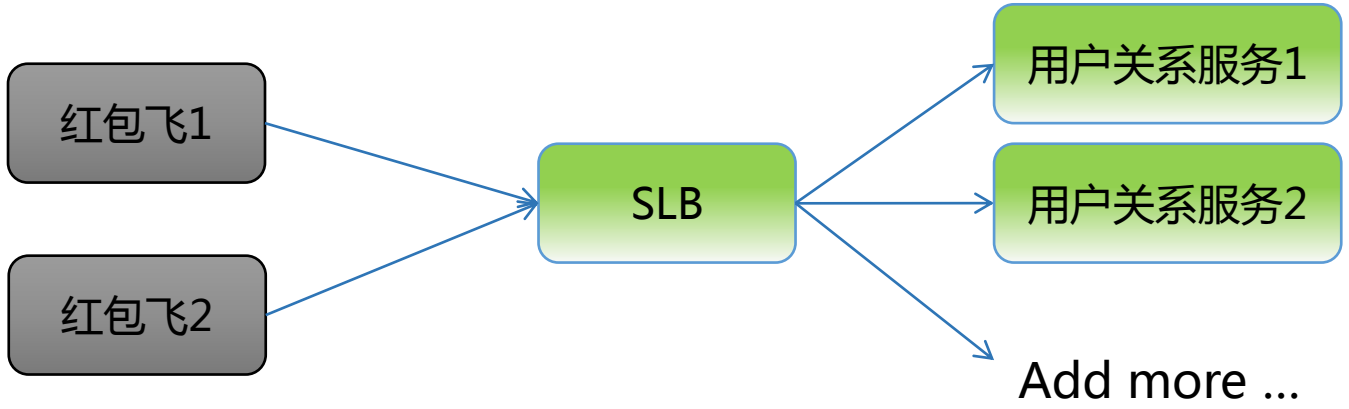

DNS智能解析

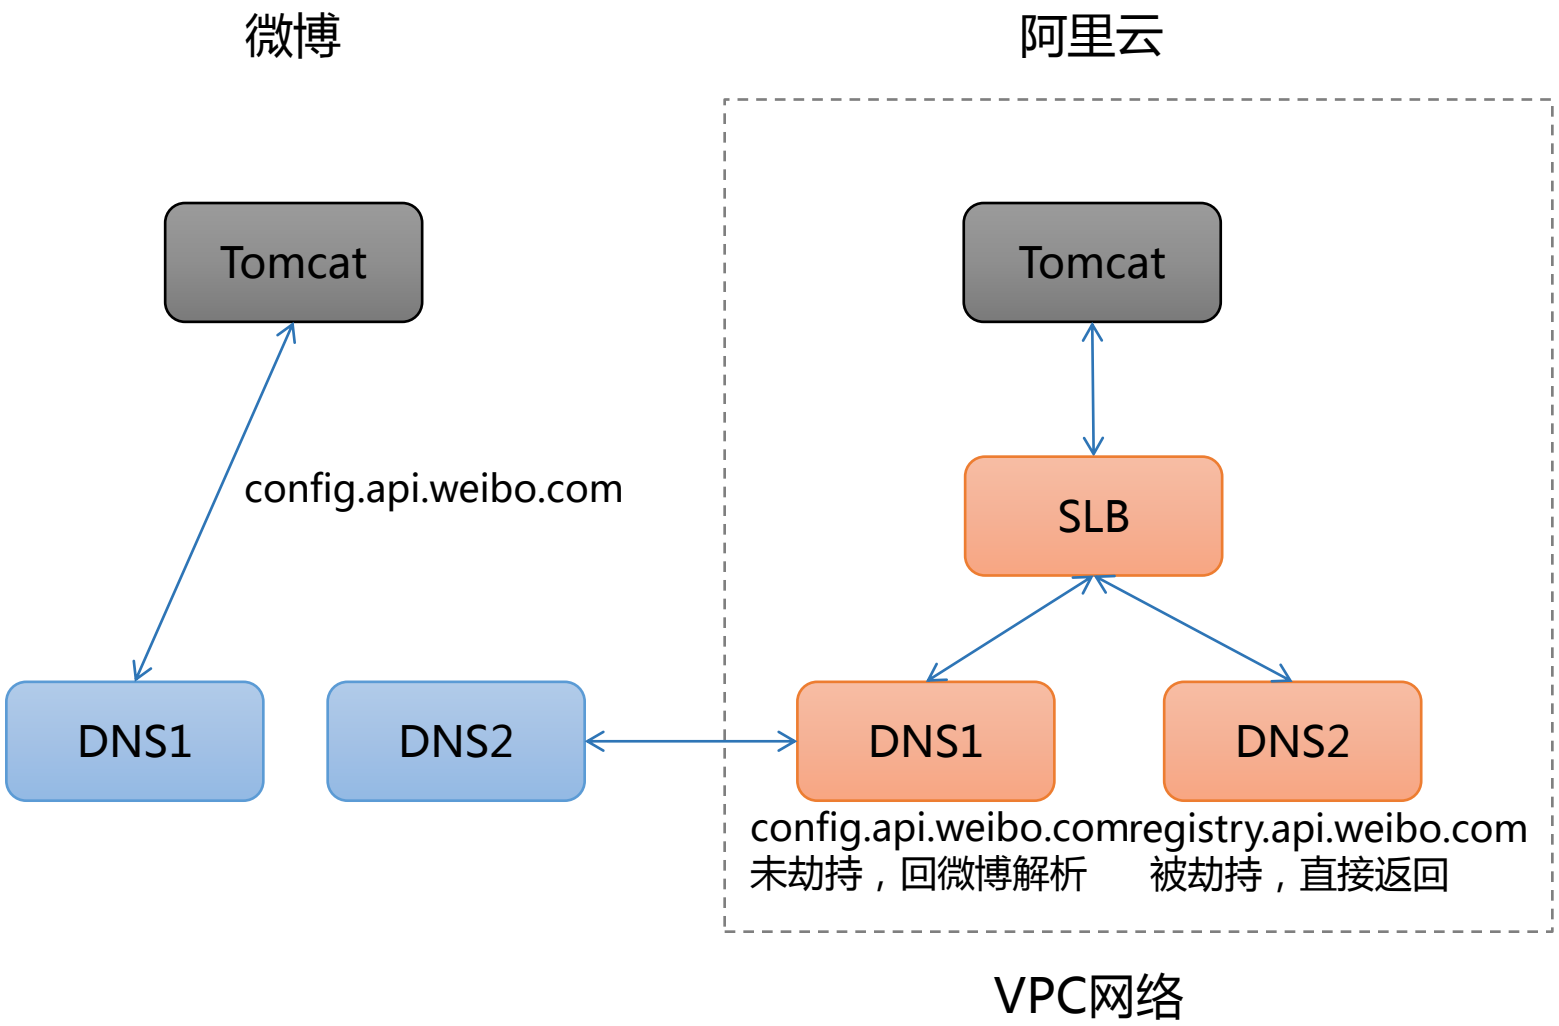
微博
阿里云
Tomcat
Tomcat
config.api.weibo.com
SLB
DNS1
DNS2
DNS1
DNS2
config.api.weibo.com
未劫持，回微博解析
registry.api.weibo.com
被劫持，直接返回
VPC网络

专线网络架构

- 通过路由配置分散两条专线压力，可随时切换
- VPN做备用
- 不同业务划分网段，便于监控专线带宽使用情况

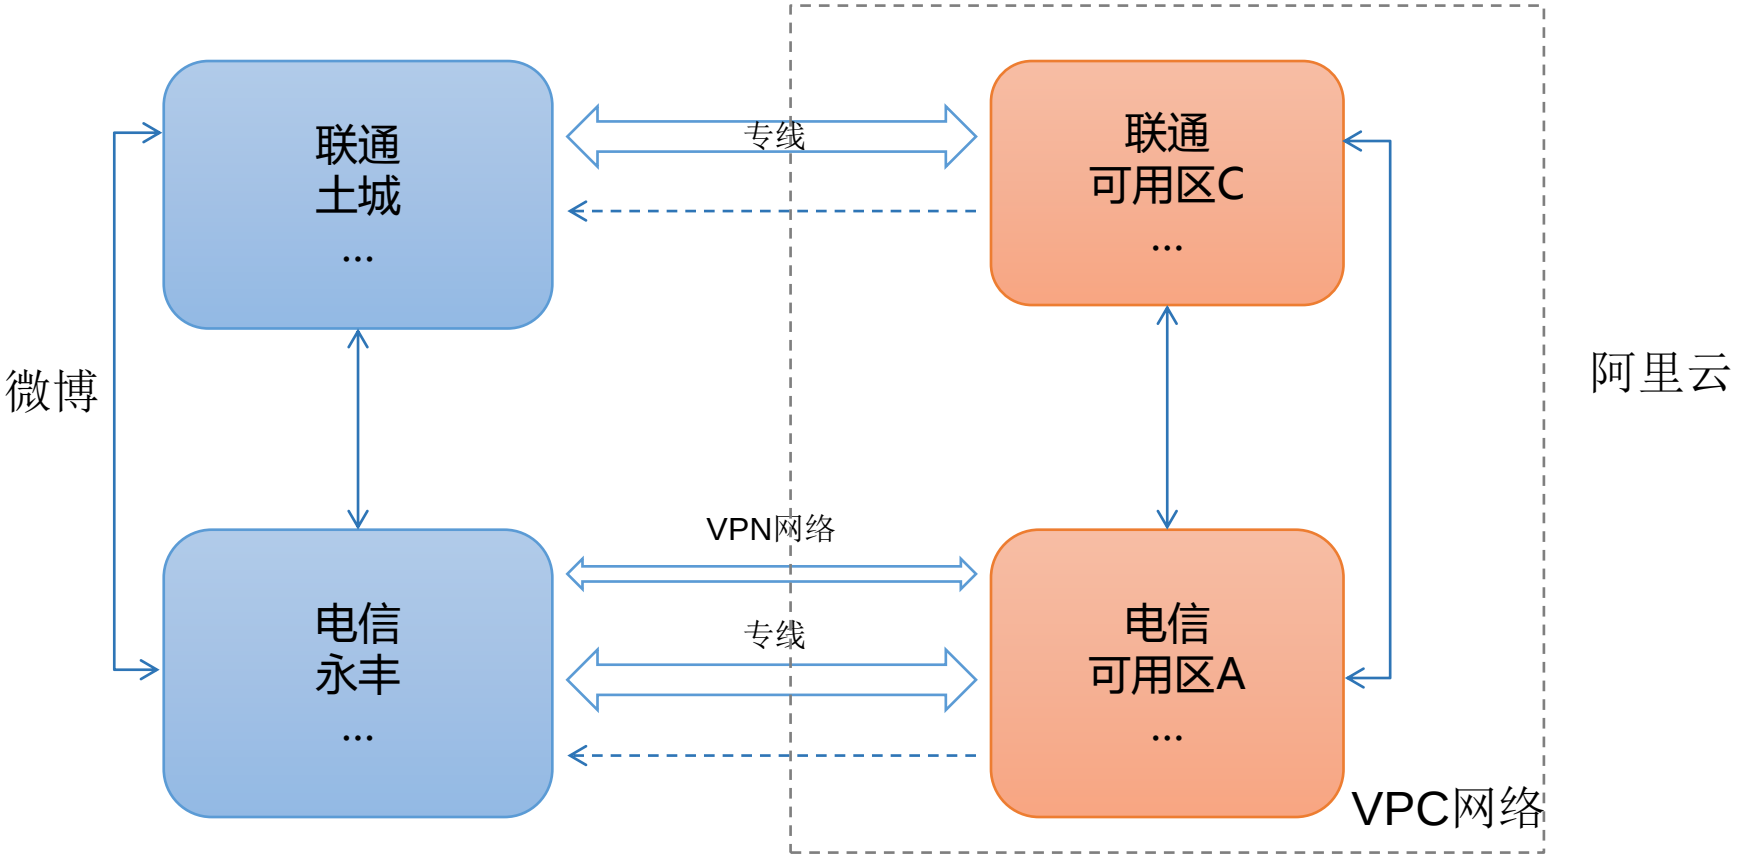

DCP-弹性扩容第一步：主机申请

- 私有云：共享池（离线集群，低负载集群，错峰）
- 公有云：阿里云（动态创建）

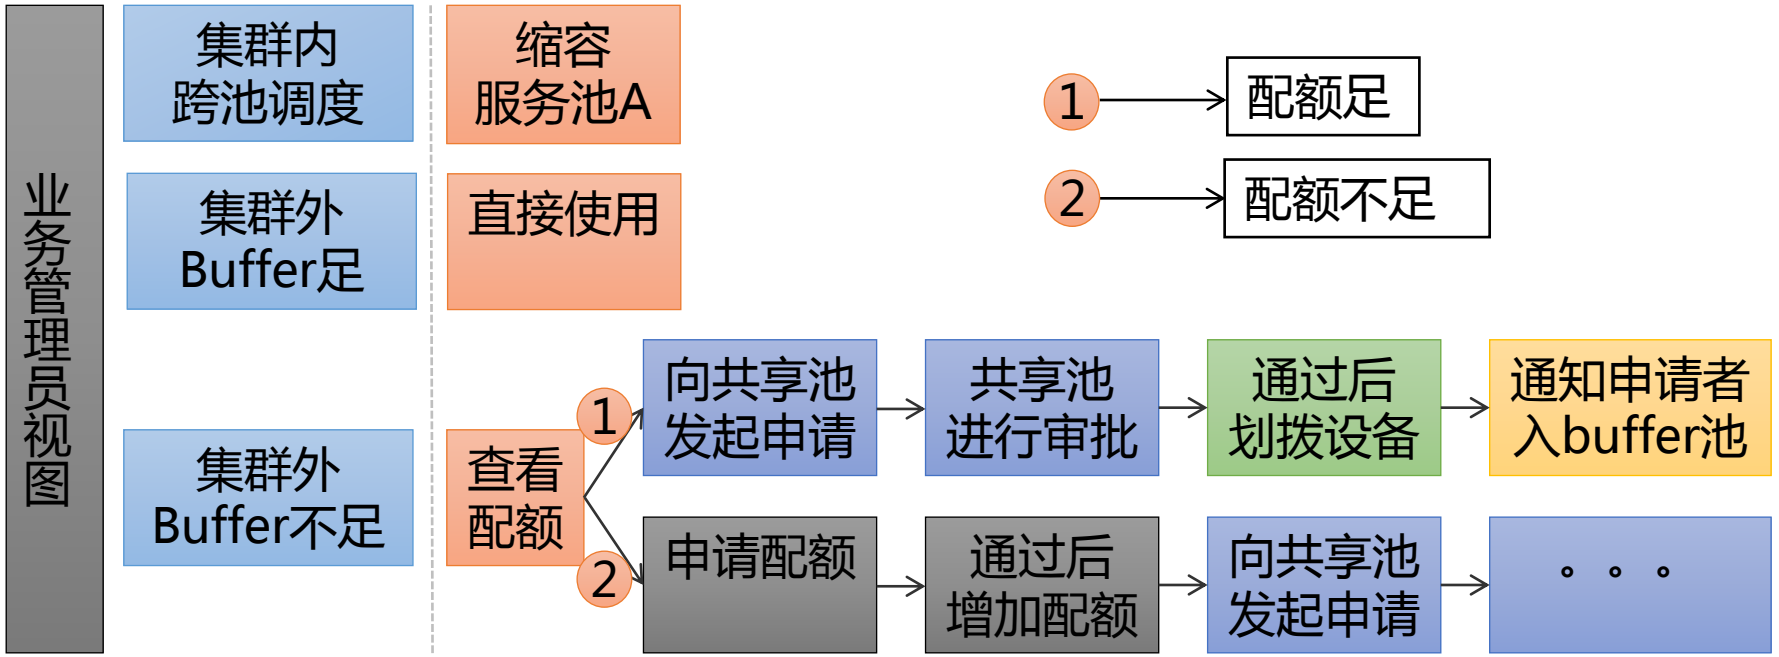

ECS批量创建

- 封装阿里云接口
  - 阿里云golang sdk
  - goroutines并发
  - chan异步调用
  - websocket和前端同步状态

- 遇到的问题
  - ECS前后端（瑶池和后羿）状态不同步，sleep解决
  - 并发数限制，单vpc下有锁，50秒拿不到锁即超时

VM镜像

- 各业务方管理自己的VM镜像，加快构建环境的速度

1. 创建一台ECS
2. 配置所需环境和软件
3. 构建快照和镜像
4. 设置自定义启动脚本

DCP - 设备申请案例：阿里云主机

DCP-弹性扩容第二步：初始化

DCP初始化流程

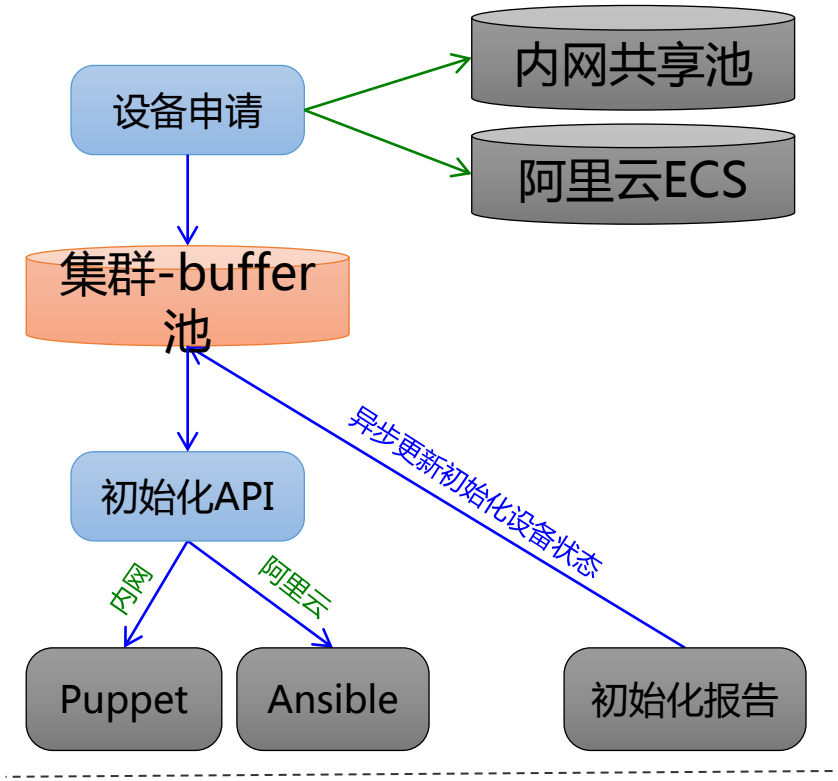

1. 运维环境安装
2. Docker环境安装

配置管理

- 微博内网
  - 已有模块稳定
  - 无法SSH

- 阿里云
  - 依赖少
  - 集成SSH登录权限

➢ 性能问题

  - 异步队列
  - 高并发下水平扩容
  - 分布式改造

配置初始化

- ECS创建完成后，自动执行初始化

1. 选择已有VM镜像创建ECS
2. 根据VM镜像和roles的对应关系，执行playbook
3. 执行自定义脚本
4. 主机可用于部署服务，耗时3分钟

二、弹性调度

弹性调度 - 选型

-	Swarm	Mesos	k8s
架构特点	针对Docker体系	借鉴Borg理念	源自Borg，原生Docker
与Mesos结合	社区完善中	成熟	社区积极推荐
隔离机制	Docker	Mesos/Docker/其它	Docker
资源类型	内存 CPU 端口	内存 CPU 端口 Ulimit	内存 CPU 端口 Ulimit
调度非Docker	No	Yes	No
主机分组	Docker进程标签	Slave配置	Slave配置
打分策略	资源使用情况	资源使用情况	资源使用情况+应用节点均衡
端口编排	No	Yes	Yes
网络模式	Docker原生	支持自建	支持自建
主高可用	双主切换	zk	etcd
扩缩容	Roam二次开发	API修改实例数	API修改实例数
应用节点健康检测	No	Yes	Yes
应用节点自动故障转移	No	Yes	Yes
服务发现	Consul	zk	etcd
负载均衡	No	Haproxy	Kube-proxy
DNS	No	No	skydns
使用复杂度	低	中	中
集群规模	小	中	中，在提升
生产使用	尚无大规模使用	业界大规模使用	业界大规模使用

弹性调度 – 选型

需求：
快速迭代
实现内网
计算资源
统一管理
调配，公
有云上获
得计算资
源，快速
自动化资
源调度与
应用部署

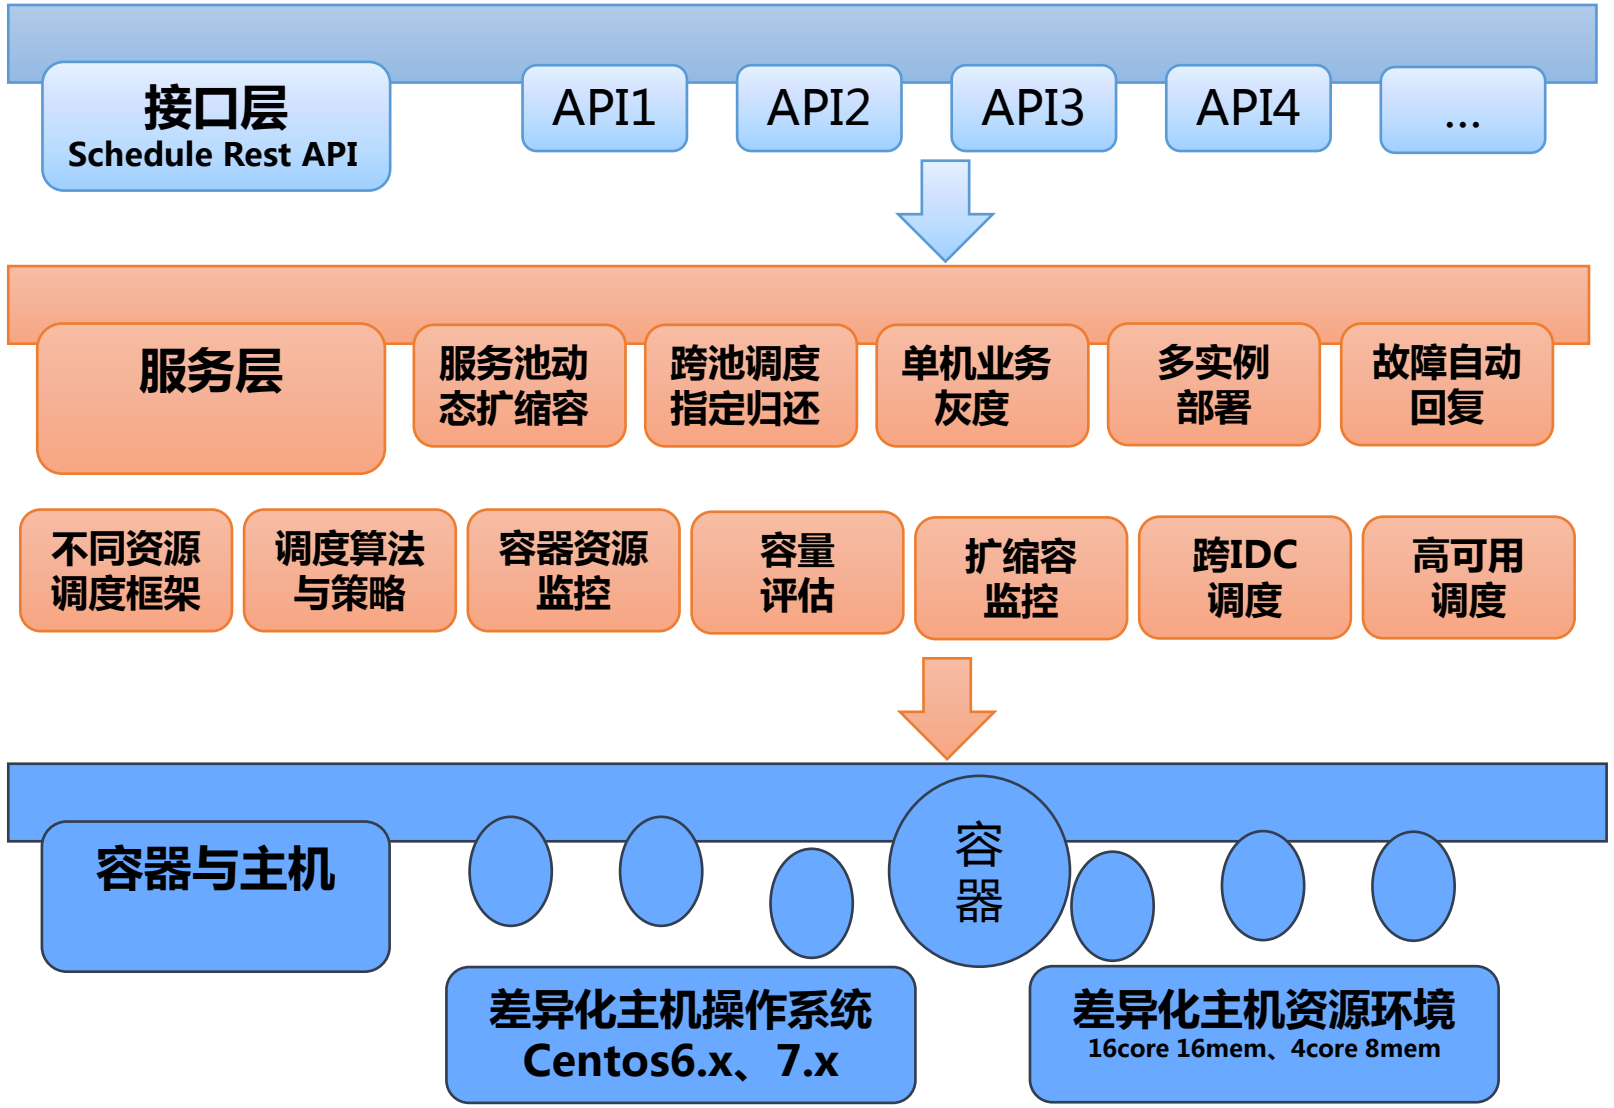

弹性调度系统

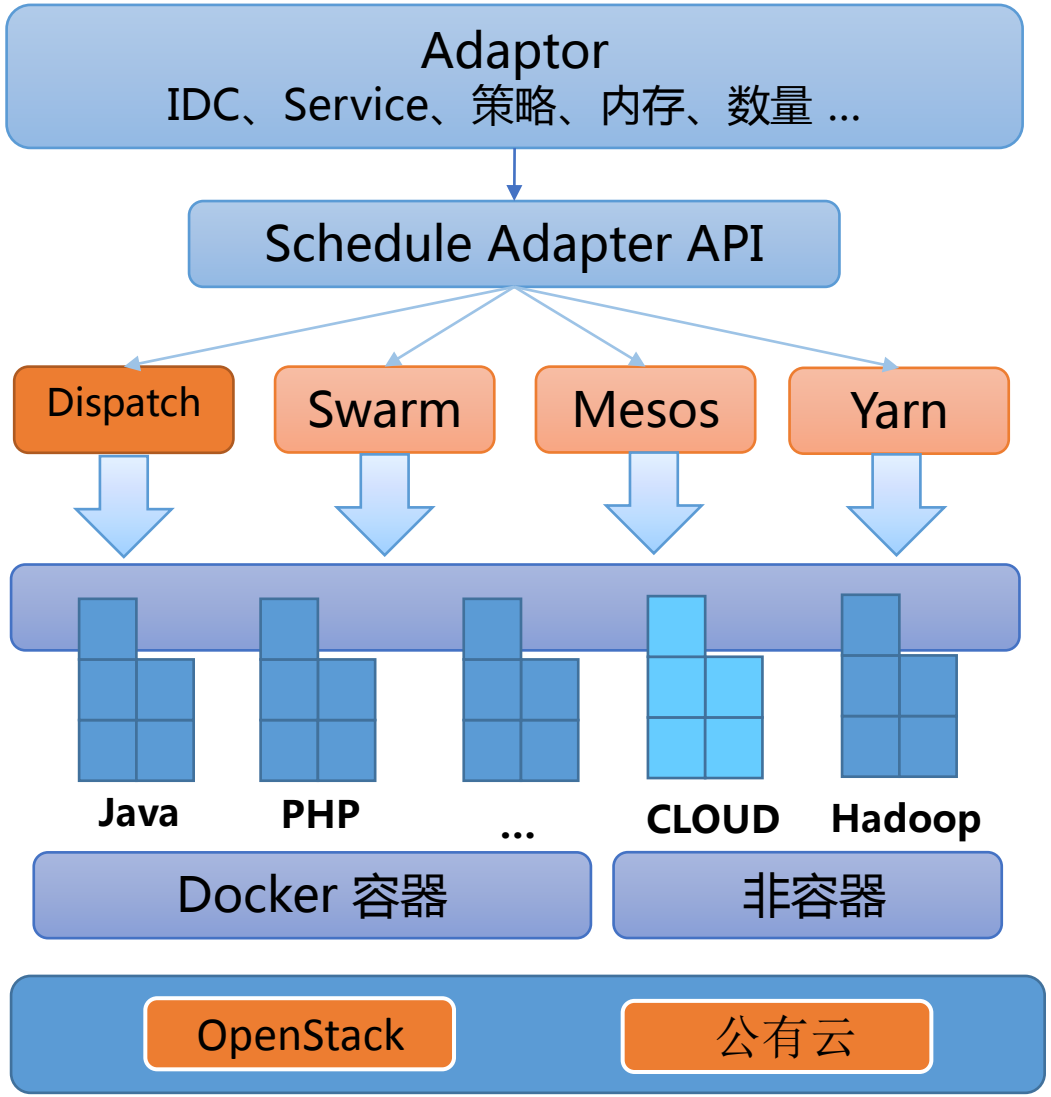

- 服务发现
- 调度框架
- 自定义调度
- 资源管理
- 容量评估
- 监控报警

问题-容器调度–Swarm

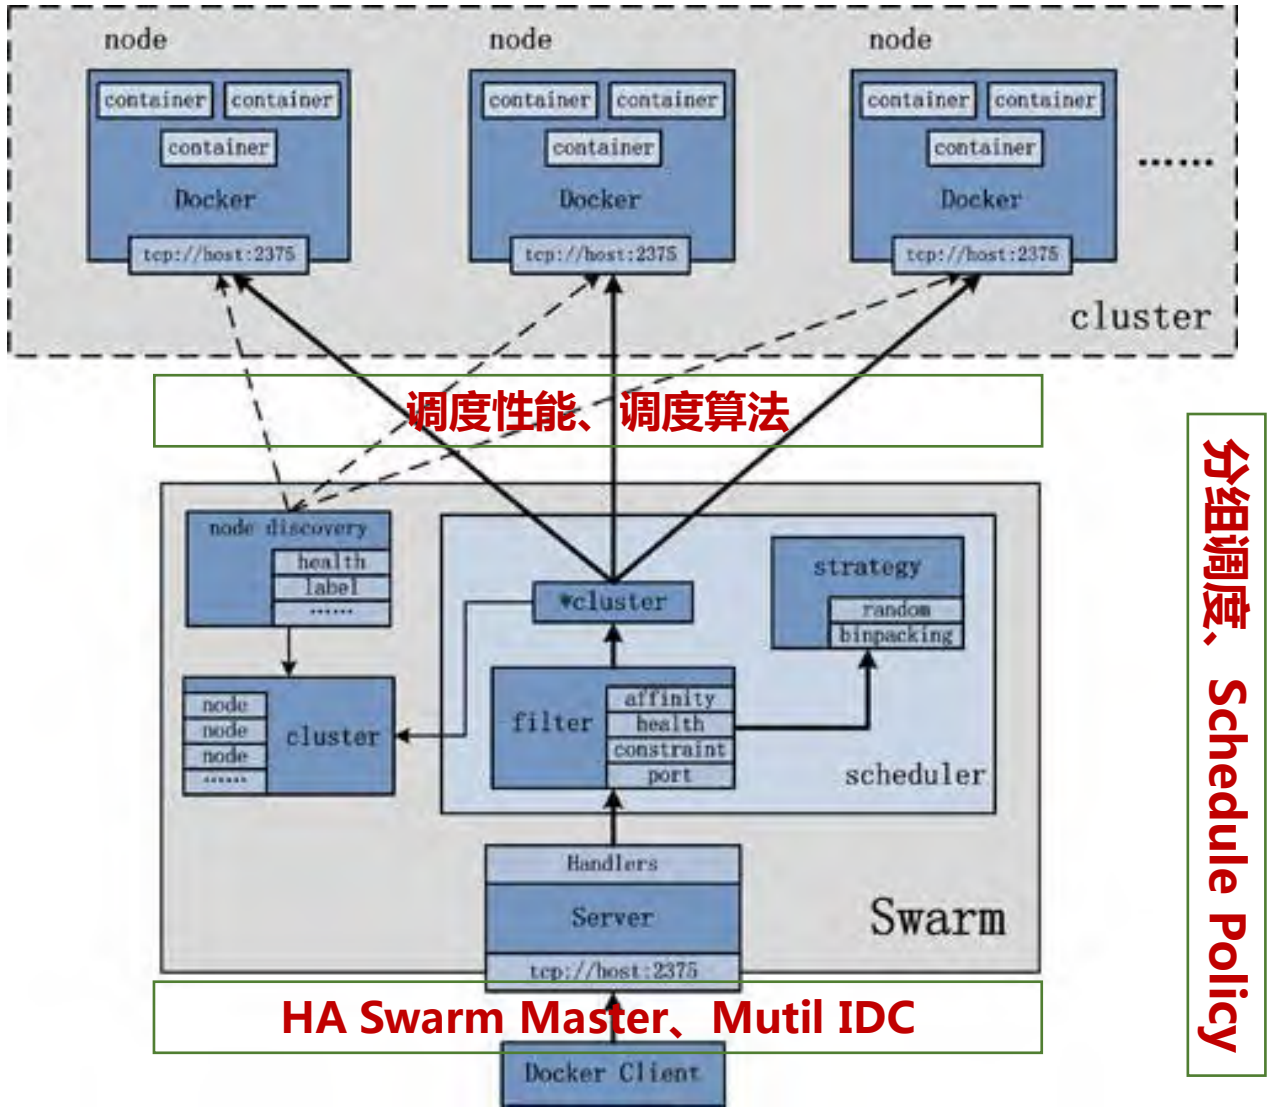

问题 –多IDC、高可用、可扩展

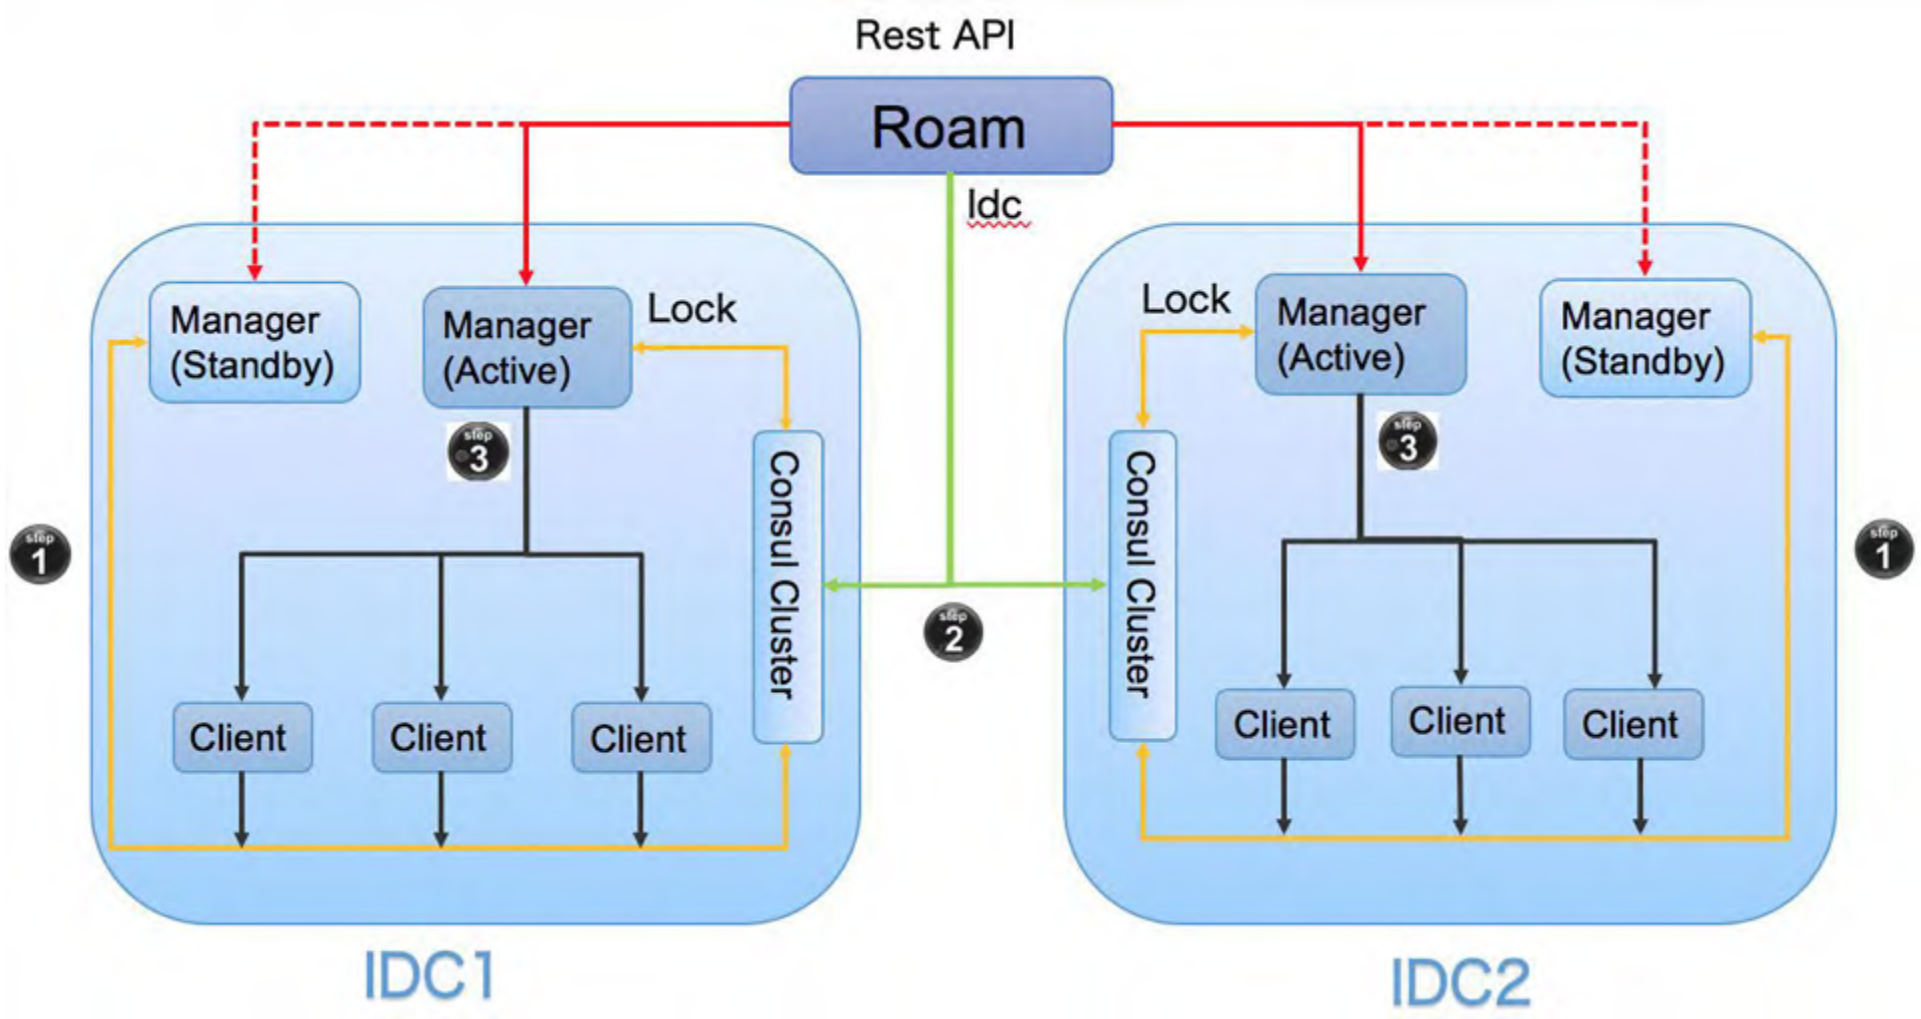

Swarm – 调度策略 – 不适用

- **调度=主机 or 容器过滤 +策略选择**
- **过滤器filter**
  - **Node Filters：health（会根据节点状态进行过滤，会去除故障节点）、constraint（约束过滤器、Label分组调度）**
  - **Container Configuration Filters：affinity（亲和性过滤器）、denpendency（依赖过滤器）、Port（会根据端口的使用情况过滤）**
- **调度策略**
  - **根据各个节点的可用的CPU, Mem及正在运行的容器的数量来计算应该运行容器的节点进行打分，剔除掉资源不足的主机，然后策略选择：spread、binpack、random**
  - **Binpack：在同等条件下，选择资源使用最多的节点**
  - **Spread：在同等条件下，选择资源使用最少的节点**
  - **Random：随机选择一个**
- **调度颗粒度**
  - **Memory：docker run –m 1g …**
  - **CPU：docker run –c 1 …**

Swarm–调度算法-打分机制

```
if config.CpuShares > 0 {
        cpuScore = (node.UsedCpus + config.CpuShares) * 100 / nodeCpus
        //cpuScore=（物理机已用CPU+本次需用CPU）*100/物理机CPU
}
if config.Memory > 0 {
        memoryScore = (node.UsedMemory + config.Memory) * 100 / nodeMemory
        //memScore=（物理机已用内存+本次需用内存）*100/物理机内存
}
```

```
if cpuScore <= 100 && memoryScore <= 100 {同时满足可用内存、CPU
    weightedNodes = append(weightedNodes, &weightedNode{Node: node, Weight: cpuScore + memoryScore})
}
```

资源只与容器Create时配置有关，与运行时实际使用资源情况无关。无论容器是否由Swarm创建，无论容器处在何种状态，只要配置了资源限额，调度时均会计算在内！

任务调度框架 - Dispatch

新浪自研：C++编写

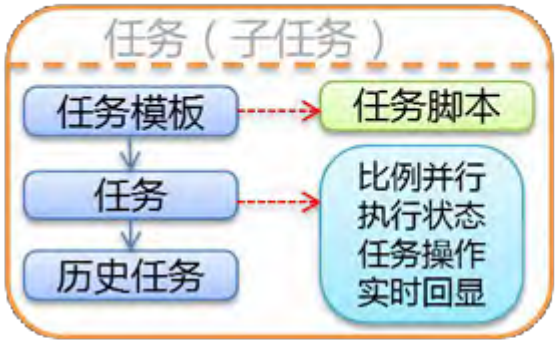

主线程

agent上报

Shell调度

任务调度

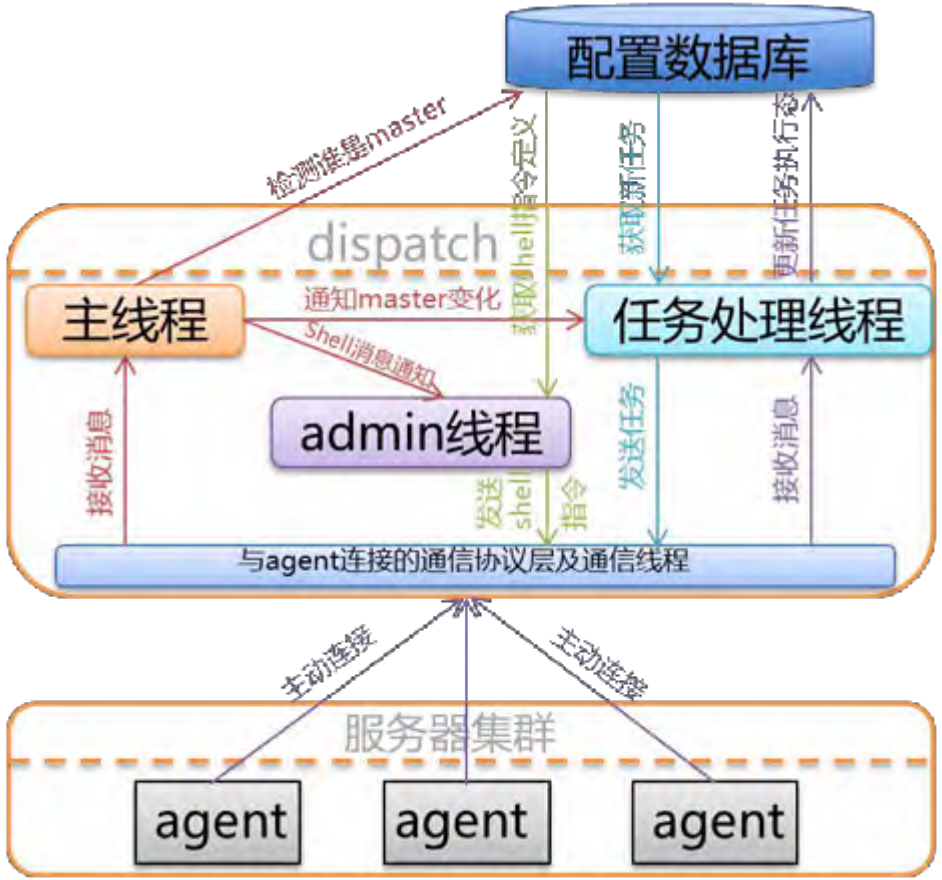

DCP-弹性扩容第二步：服务扩容

- 扩容
  - 输入：服务池名称、服务类型，容器类型、数量、镜像地址等
  - 输出：扩容报告
- 记账中心
  - 资源拥有者、使用方、型号、使用时间、日期、信用等
- 容器服务类型：按照dPxx(dockerPxx)命名

dP01	dP02	dP03	dP04
8核12G	12核12G	12核16G	16核16G

DCP-扩容操作任务化

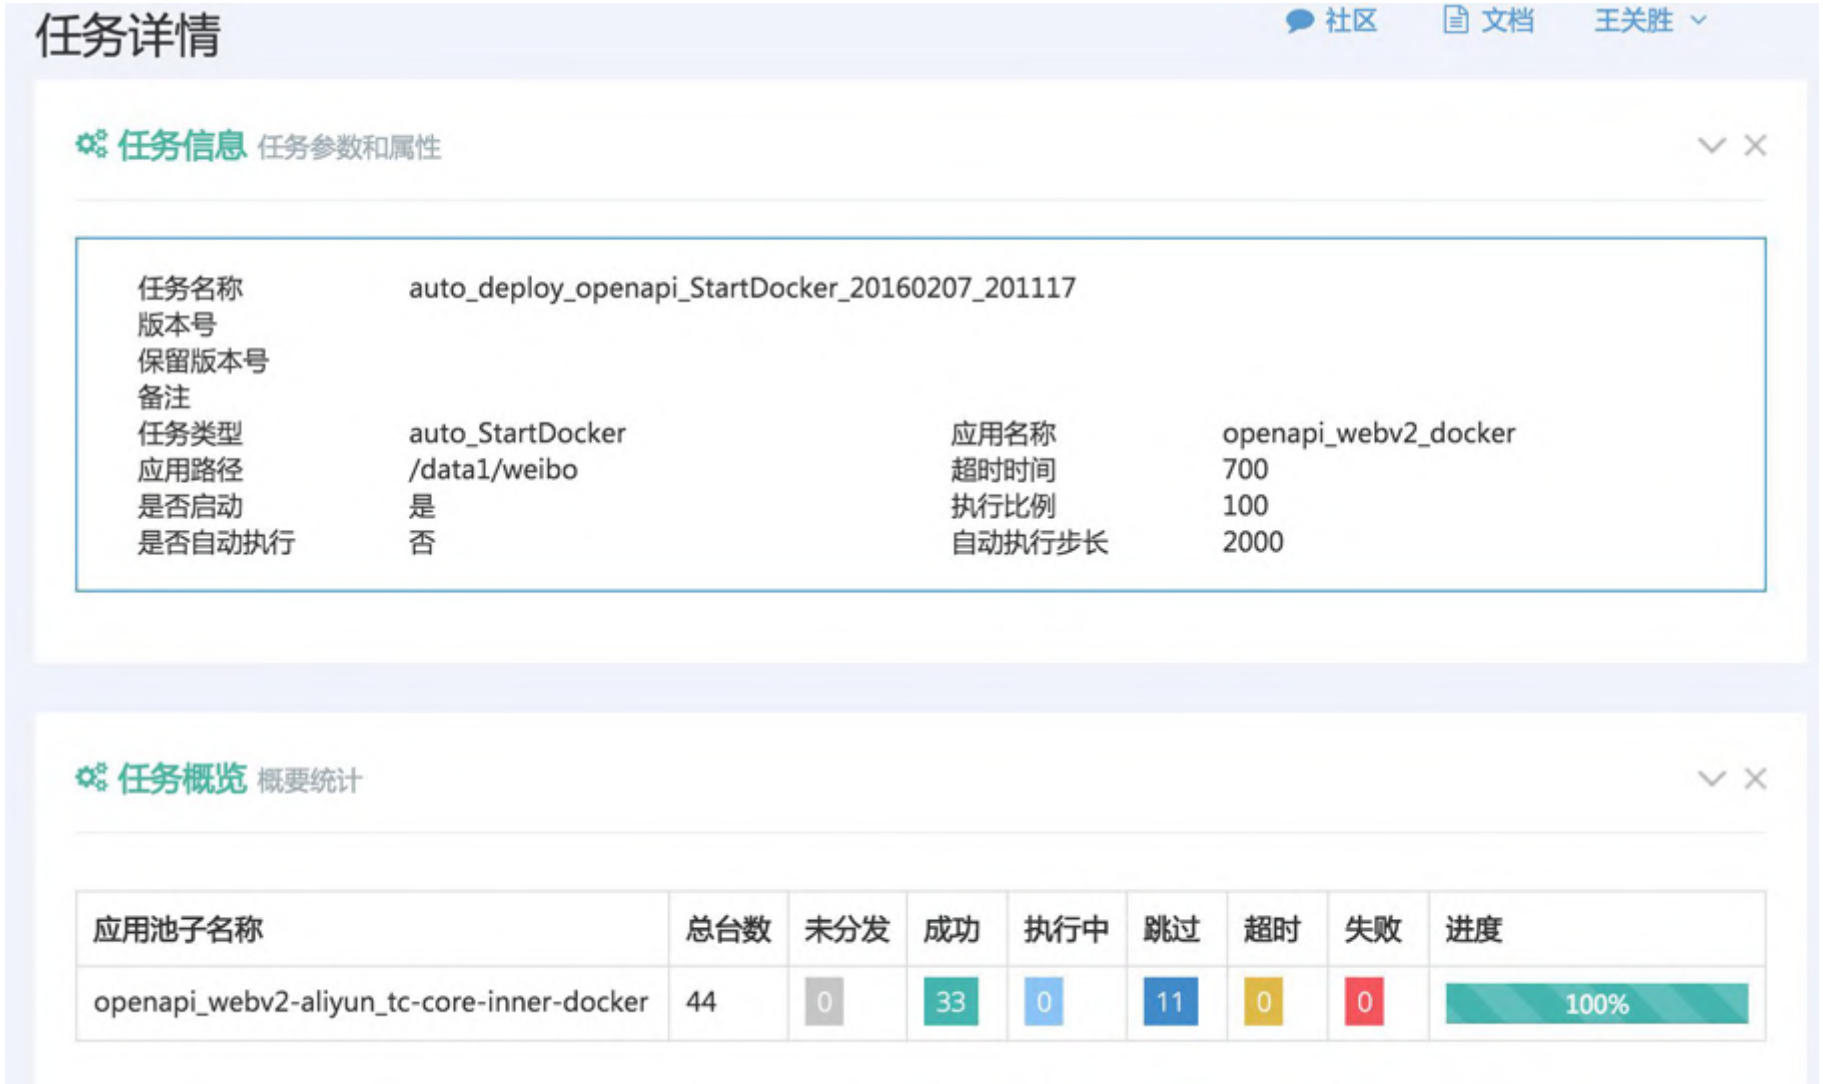
任务详情
社区
文档
王关胜
任务信息 任务参数和属性
任务名称 auto_deploy_openapi_StartDocker_20160207_201117
版本号
保留版本号
备注
任务类型 auto_StartDocker
应用路径 /data1/weibo
是否启动 是
是否自动执行 否
应用名称 openapi_webv2_docker
超时时间 700
执行比例 100
自动执行步长 2000
任务概览 概要统计
应用池子名称 总台数 未分发 成功 执行中 跳过 超时 失败 进度
openapi_webv2-aliyun_tc-core-inner-docker 44 0 33 0 11 0 0 100%

DCP-弹性扩容：流程

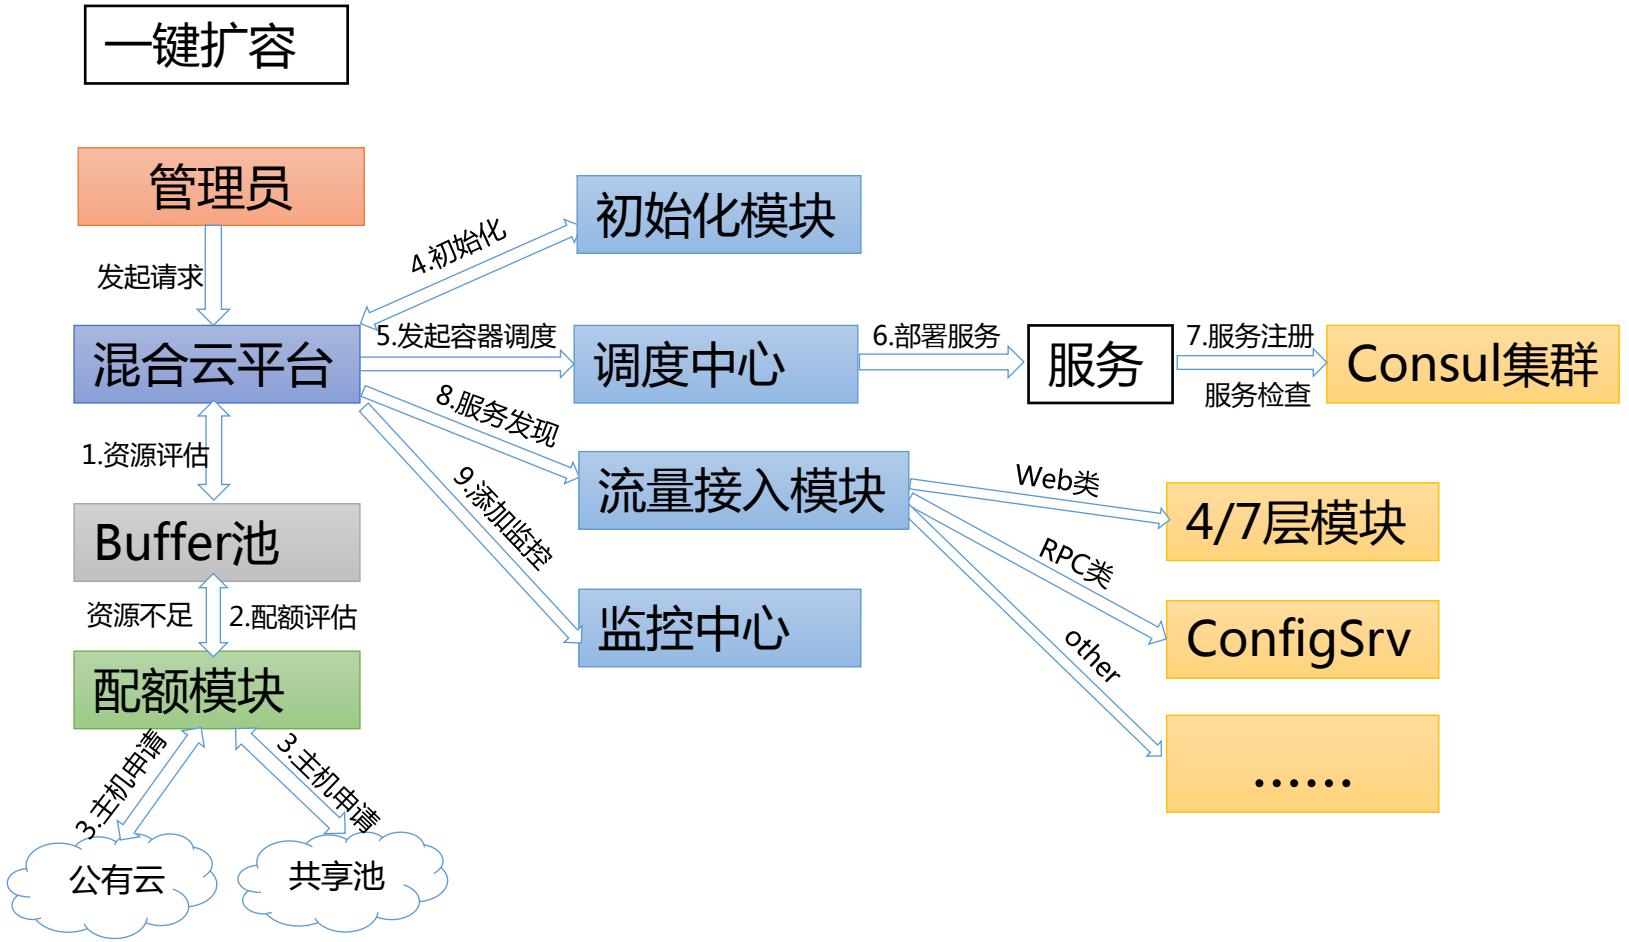
一键扩容
管理员
发起请求
混合云平台
1.资源评估
Buffer池
资源不足
2.配额评估
配额模块
3.主机申请
3.主机申请
公有云
共享池
4.初始化
初始化模块
5.发起容器调度
调度中心
6.部署服务
服务
7.服务注册
服务检查
Consul集群
8.服务发现
9.添加监控
流量接入模块
监控中心
Web类
RPC类
other
4/7层模块
ConfigSrv
……

主机设备生命周期

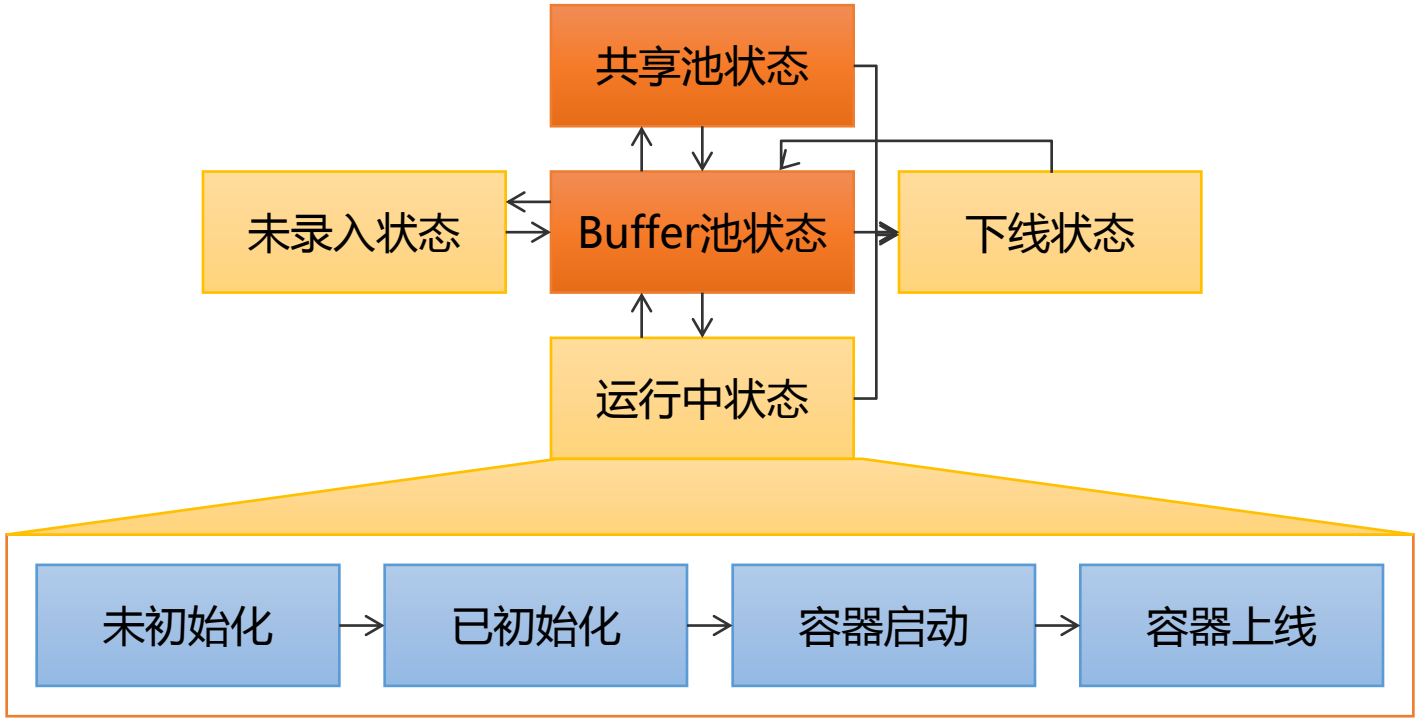

正常主机状态变迁

关键点：服务发现

流量要快速、安全的切到弹性节点

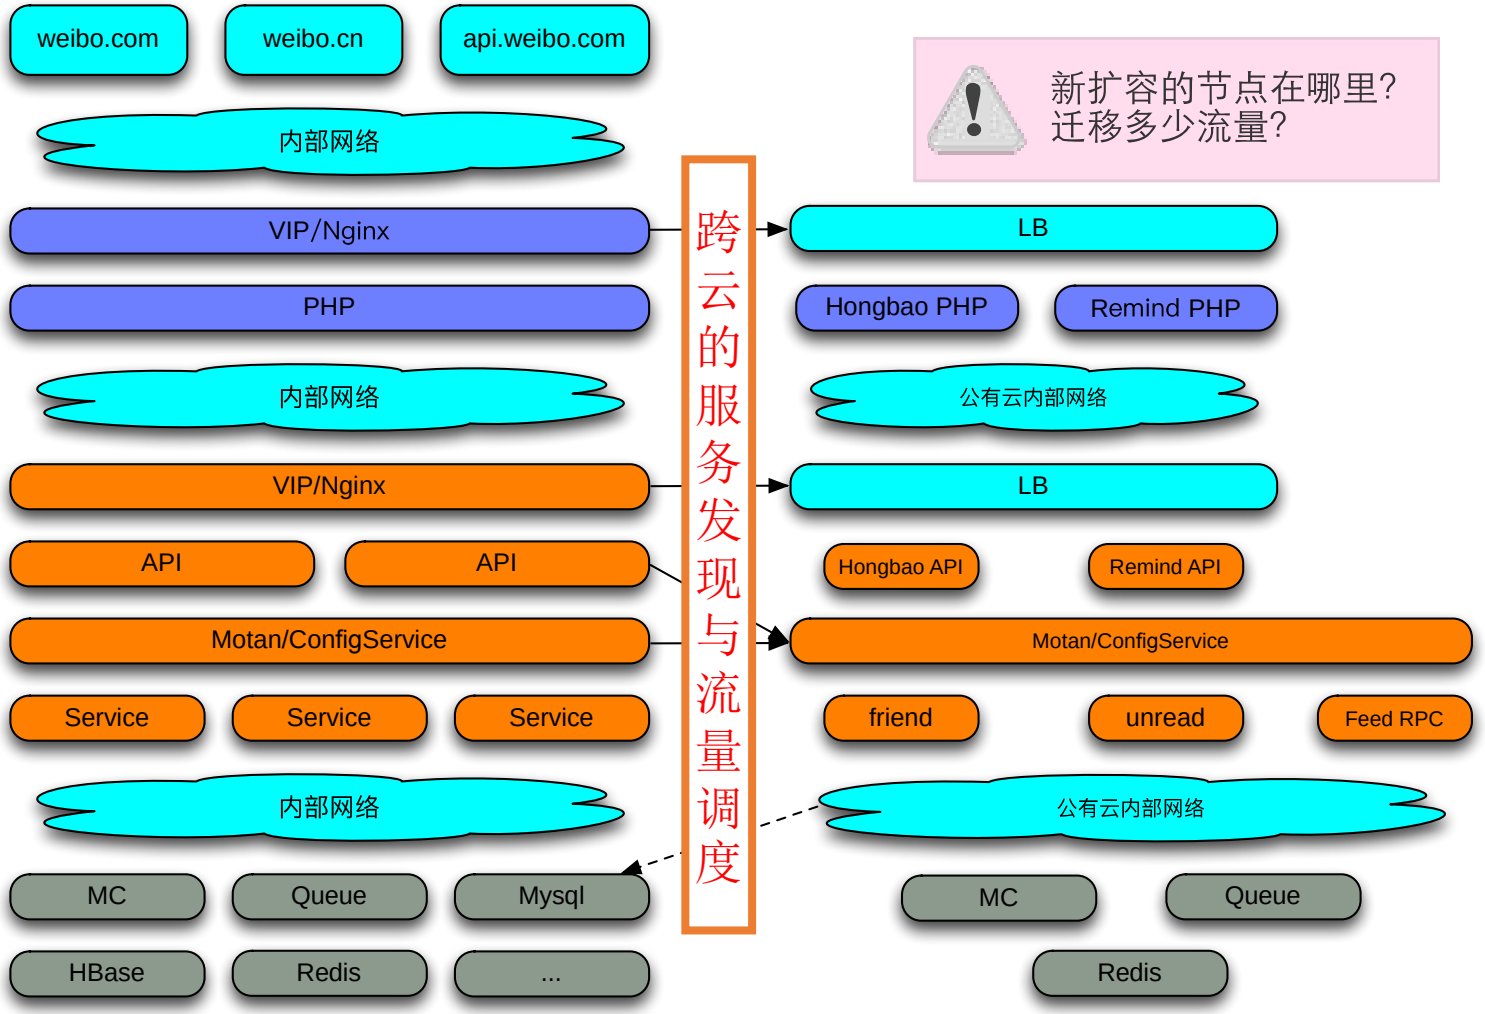

服务发现-业界常用方案

问题：Reload损耗

- 开源解决方案大多利用Nginx的Reload机制
- 性能损耗情况:
  - 请求量：普通reload会导致吞吐量下降10%
  - 平均耗时： 差异不大

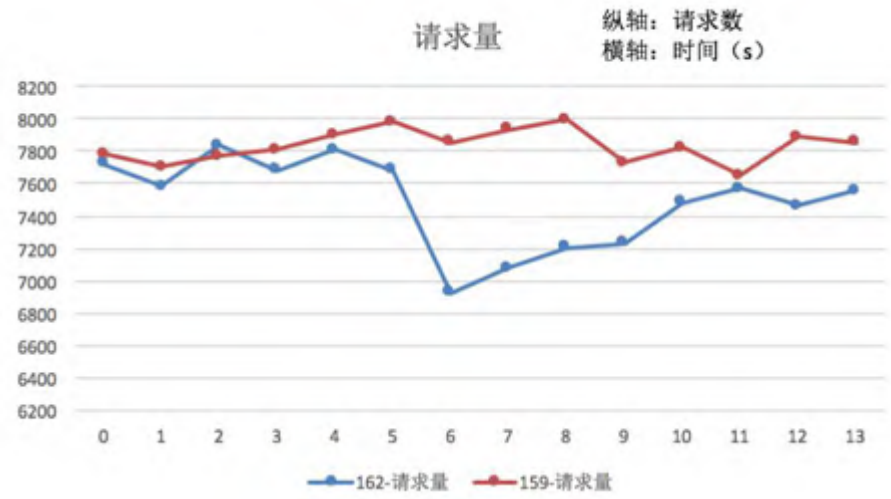

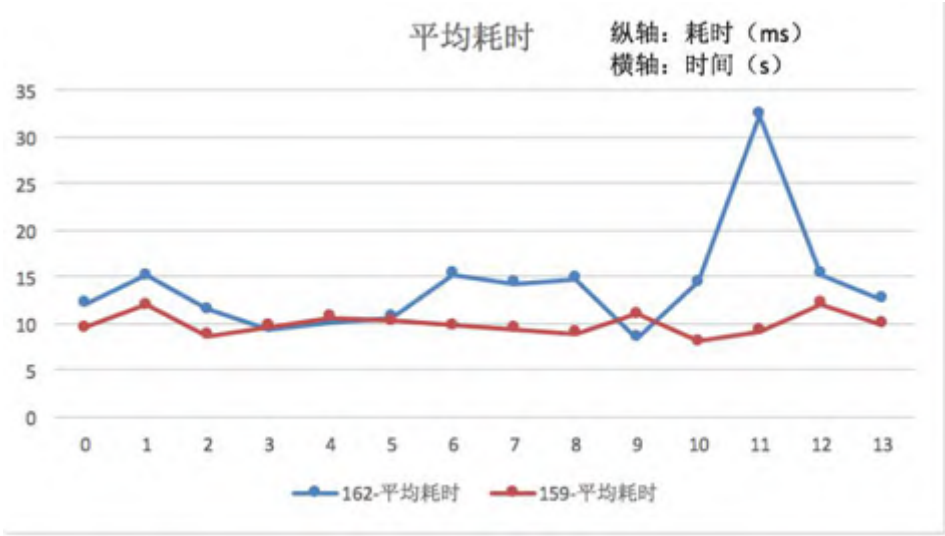

服务发现：微博方案

微博方案 - nginx-upsync-module

- Nginx Plus的开源版
- 支持基于Consul自动服务发现
- 开源：https://github.com/weibocom/nginx-upsync-module

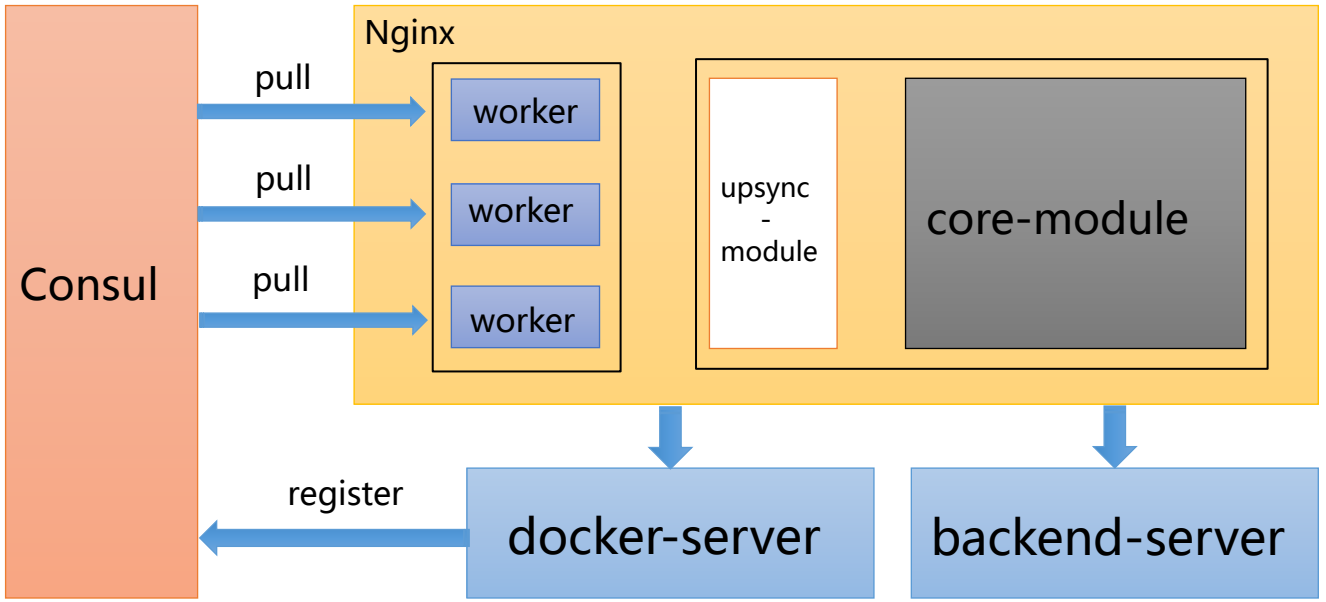

Nginx Upsync-自适配后端处理能力

- **弹性节点的处理能力不对等**
  - server 10.xx.xx.xx:xxxx max_fails=0 fail_timeout=30s

    weight=20; #同样的权重导致单点性能恶化
- 节点注册计算能力
  - 所有节点默认权重是20；
  - 公有云有20%性能损耗，权重=16；

RPC-Motan RPC服务发现

- 开源：微服务RPC框架Motan
  - https://github.com/weibocom/motan
- Motan流量路由模型优先匹配单IDC
  - IDC间切换一般仅在故障处理时采用
- 新版Motan已支持按流量权重配置定向路由

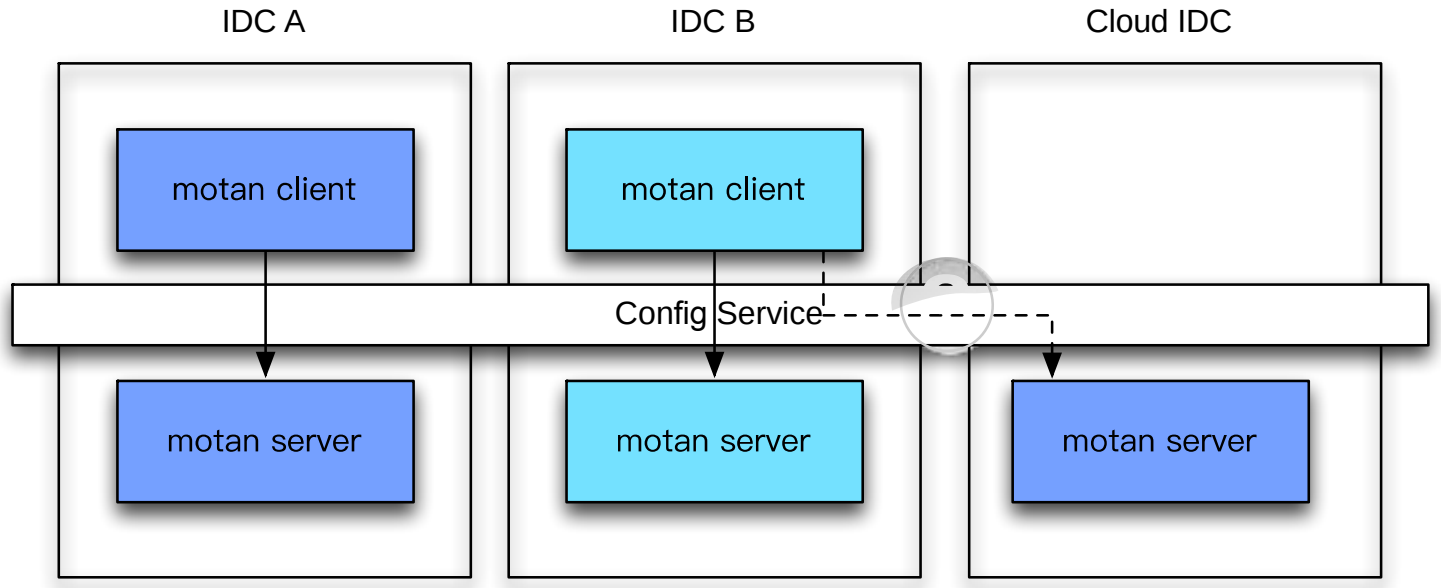

五、春晚实战与总结

DCP-三节保障：监控体系

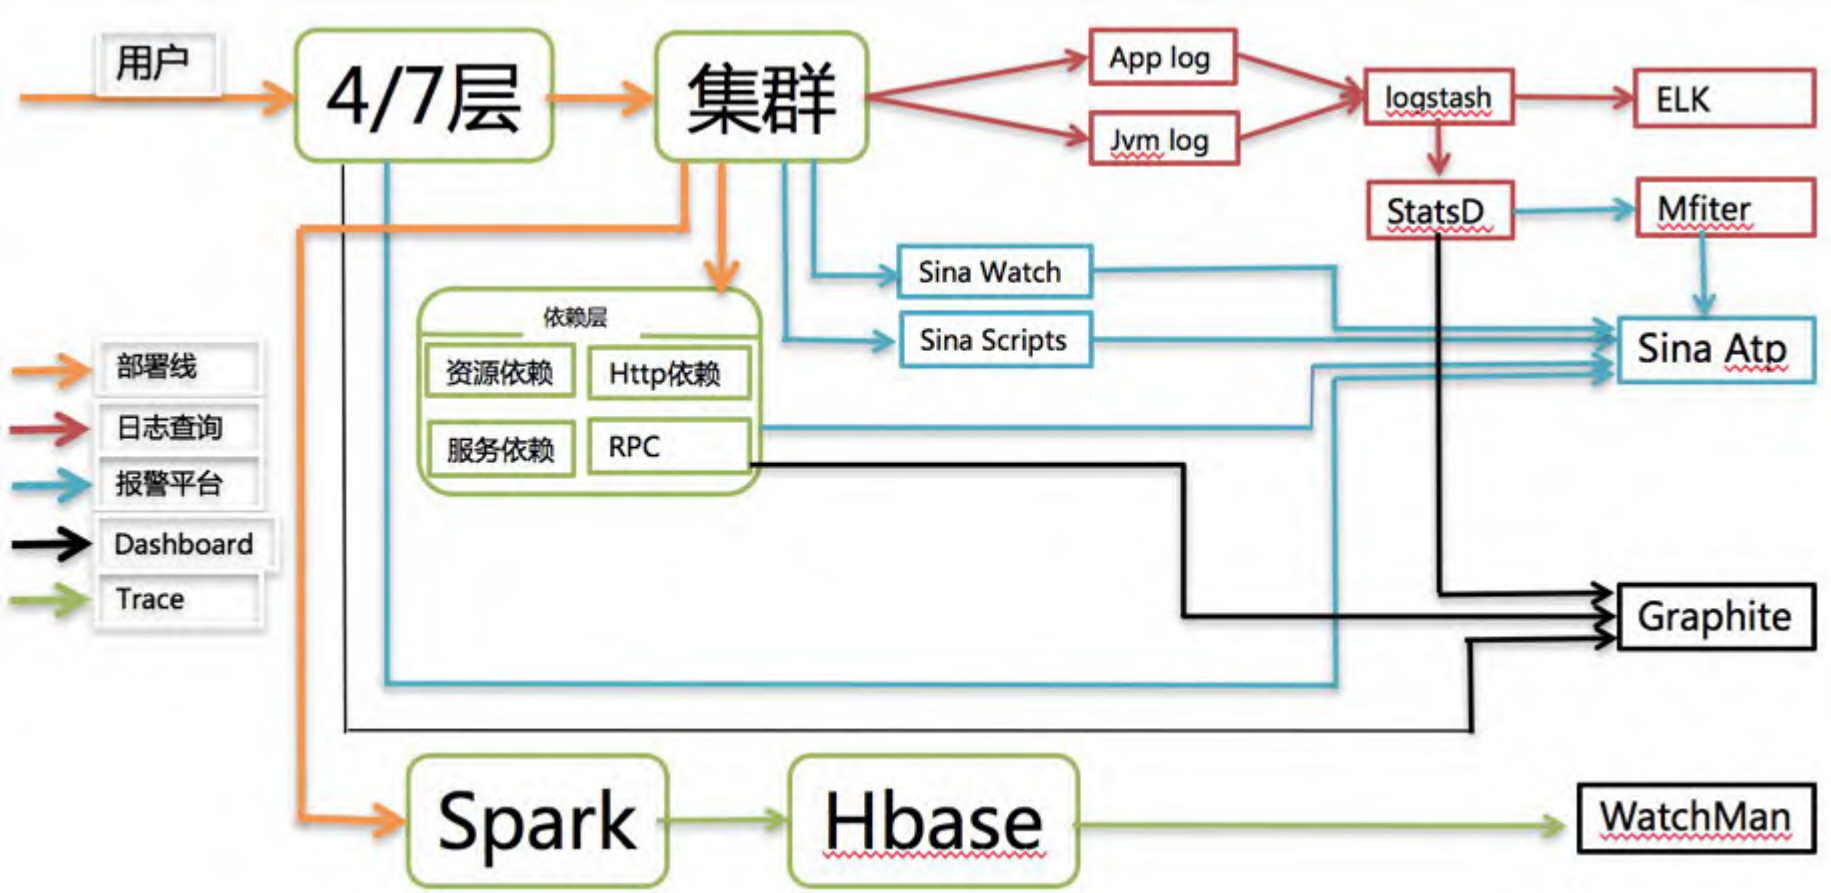

三节保障与阿里云部署

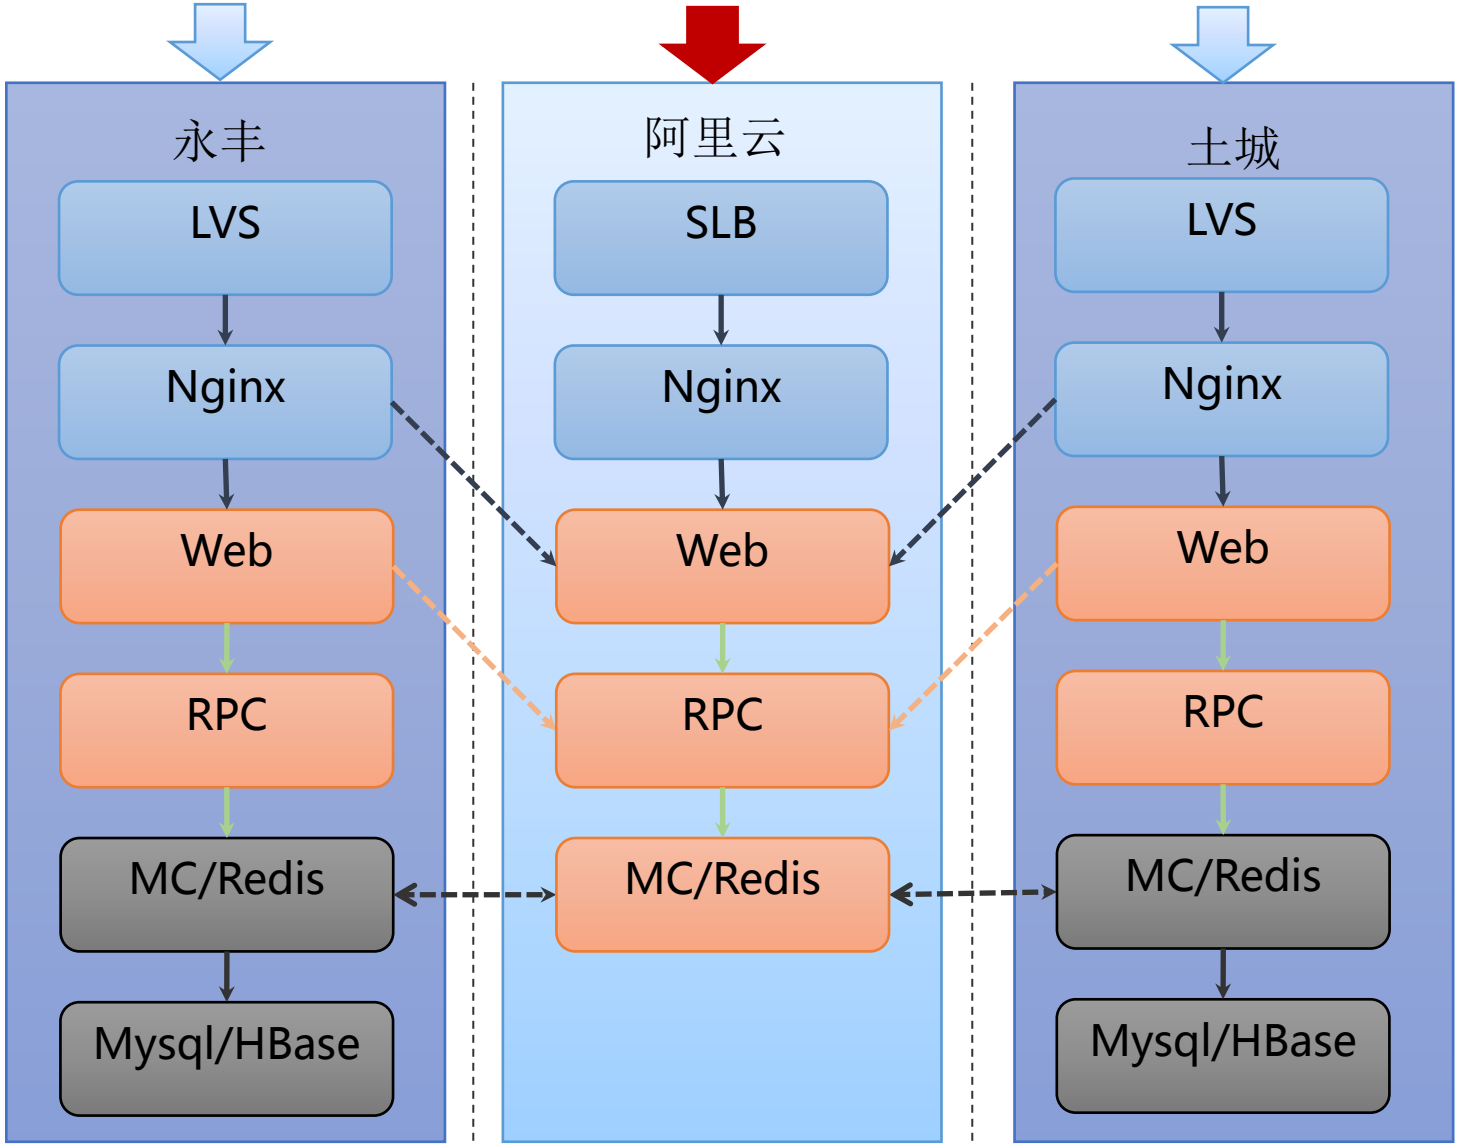
永丰
LVS
Nginx
Web
RPC
MC/Redis
Mysql/HBase
阿里云
SLB
Nginx
Web
RPC
MC/Redis
土城
LVS
Nginx
Web
RPC
MC/Redis
Mysql/HBase

微博混合云DCP成果

- 混合云进展：
  - 容器数：5000+
  - 晚高峰自动扩容500+

- 春晚备战：
  - 10分钟混合云扩容1000节点技术能力
  - 2017春晚峰值历史新高，完成4700台阿里云ECS扩容，实现无降级平滑过渡，公有云高峰支持微博50%主体流量。完成eed流、红包飞、手机微博公司各主要业务线均完成上云支持

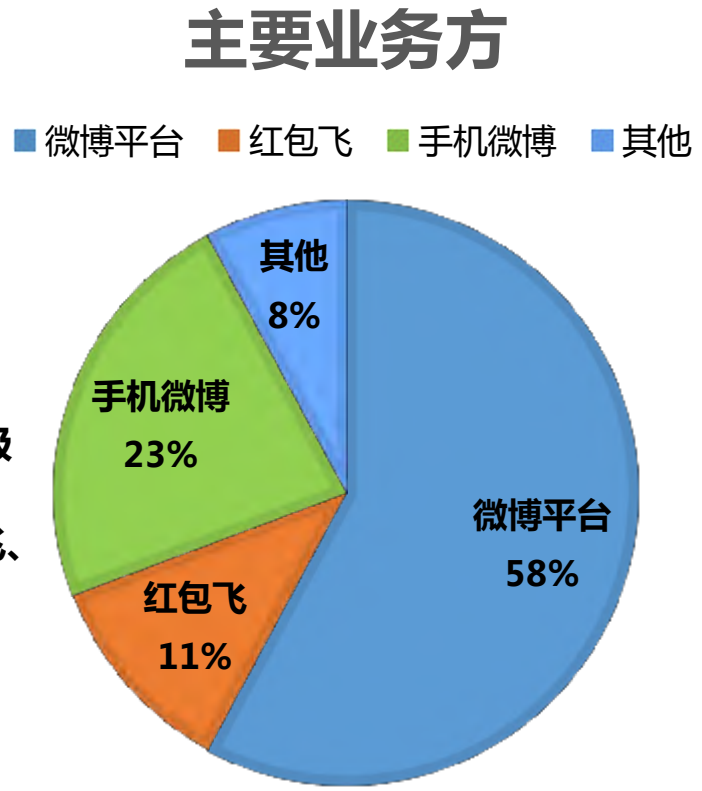

总结 – 春晚问题与总结

问题	解决
阿里云部署缓存ECS PPS打满	扩容缓存MC L1一倍
Feed性能恶化，部分ECS性能差	单机监控发现性能恶化ECS，执行503
资源DNS解析失败	不使用SLB负载均衡，直接配置
环网带宽优化	网络链路优化 业务架构优化


open
source
software
free
community
access
Source
term
culture
Internet
production
Commons
Wikipedia
process
copyright
edit
new
public
work
concept
system
example
open-source
digital
users
development
technology
code
sharing
Free
Software
Creative
communities
online
blogs
Initiative
media
scientific
used
including
movement
products
idea
movie
companies
available
cultural
content
information
research
use
made
also
political
hardware
created
computer
network
cost
business
web
works
resources
one
Wikipedia
beer
projects
format
called
term
platform
product
article
intellectual
similar
Commons
process
file
publishing
model
general
ethics
goods
design
manufacturers
Public
company
century
20th
Media
making
costs
property
anyone
original
expression
various
release
began
Creative
Commons
Free
Software
Initiative
communities
Wikipedia
Internet
culture
Source
open
source
software
free
community
access
term
concept
copyright
media
scientific
edit
new
public
work
system
production
example
open-source
digital
users
development
technology
code
sharing
used
including
movement
products
idea
movie
companies
available
cultural
content
information
research
use
made
also
political
hardware
created
computer
network
cost
business
web
works
resources
one
Wikipedia
beer
projects
format
called
term
platform
product
article
intellectual
similar
Commons
process
file
publishing
model
general
ethics
goods
design
manufacturers
Public
company
century
20th
Media
making
costs
property
anyone
original
expression
various
release
began

OpenDCP：基于Docker技术的混合云管理平台

OpenDCP：https://github.com/weibocom/opendcp

- 综合性的运维管理平台。涵盖运维配置、发布、上线变更等运维管理主要功能，而不局限于容器集群管理，可适配Kubernetes、Mesos、Swarm等
- 功能覆盖镜像市场、多云对接、服务编排、服务发现等云资源管理主要环节
- 支持阿里云、AWS、私有云等主流云厂商
- 支持Nginx、SLB等服务发现方式
- 支持Java、PHP、C/C++、Go等主流语言

欢迎大家到OpenDCP开源社区沟通交流：

itfuwen@163.com @it_fuwen


WOTA
51CTO
Thank you !