

BDTC 2017 中国大数据技术大会
Big Data Technology Conference 2017

腾讯docker云平台GaiaStack

罗韩梅

目录

CONTENT

项目背景



架构及特性



底层能力





关于GaiaStack Docker私有云

GaiaStack是腾讯基于Kubernetes打造的Docker私有云解决方案，腾讯内部所有BG都有产品在GaiaStack上运行，包括IEG、TEG、OMG、WXG、SNG、CDG的信鸽、MTA、游戏云、EasyCount、广点通、深度学习平台等众多产品和服务。

一个通用的资源管理和调度平台，作为集群操作系统服务于上层各类应用。
(as a **Cluster Operating System**)

- ✓ 将一个数据中心的硬件资源逻辑上整合成一台服务器
- ✓ 为云应用软件提供统一、标准的接口
- ✓ 管理海量的任务以及资源调配

GaiaStack

提供了从构建至交付到运行的一整套的解决方案



容器服务



持续集成



镜像仓库



资源编排



私有集群



部署与管理

对内



开放



自研

开源




微服务



大数据

AI

ALL







Linux




keystone

cinder

套件


监控





Online + offline


正在使用CPU核 (个)



- 在线业务通常有以天为周期的资源特征
- 但是每个小时/每半小时资源都不同，甚至波动较大


网络入带宽 (Mbit/s)

当前时间段均值 144.27 当前时间段峰值 341.61



网络出带宽 (Mbit/s)

当前时间段均值 183.14 当前时间段峰值 375.92



kernel


docker

ceph

Registry

kubernetes

kernel




增加资源维度

- 更多的资源管理纬度
- 弹性的CPU控制
- 弹性的内存控制
- 弹性的磁盘容量控制
- 弹性的网络出带宽控制
- 弹性的网络入带宽控制
- 弹性的Disk IO控制
- Buffer IO控制

Kernel: network IO



下图是两个进程都拼命争抢网络带宽时的效果。两个进程的带宽和时延都得不到任何程度的保证。



设计目标

- 在某个cgroup网络繁忙时，能保证其设定配额不会被其他cgroup挤占
- 在某个cgroup没有用满其配额时，其他cgroup可以自动使用其空闲的部分带宽
- 在多个cgroup分享其他cgroup的空闲带宽时，优先级高的优先；优先级相同时，配额大的占用多，配额小的占用少
- 尽量减少为了流控而主动丢包

Kernel: network IO





- 队列：不增加队列，对每个报文直接在正常代码路径上进行决策
- Cgroup区分(标记)：在正常处理流程中，报文查找到目标socket结构之后，根据socket的owner process来确定cgroup
- 报文决策：令牌桶 + 共享令牌池 + 显式借令牌
- 限速方式：ECN标记 + TCP滑窗 + 丢包

Kernel: Disk IO

对buffer io失控。cgroup通过识别pid，控制磁盘io。但在buffer io中，失去了原有的pid信息，导致不可控。

Normal Write




throttle=50k		throttle=200k		期望比例	0.2500
最小	90.0	最小	17.0	实际比例	0.9849
最大	8185.0	最大	8155.0		
平均	1154.1	平均	1171.8		
方差	2368974.4	方差	2282716.1		

weight=10%		weight=60%		期望比例	0.1667
最小	125.0	最小	37.0	实际比例	1.0162
最大	8206.0	最大	8206.0		
平均	1264.1	平均	1244.0		
方差	2718006.0	方差	2483813.4		


Kernel: Disk IO

- 在io weight方面（cfq机制），是通过时间片进行分割的，而不是通过iops或者bps进行衡量。用户观察到的传输数据波动比较大。
- cgroup对io的控制目前是hard模式(throttle)，即给某个进程限速后，该进程永远不会超过该速率

Direct Write




throttle=50k		throttle=200k		期望比例	0.2500
最小	29.0	最小	115.0	实际比例	0.2482
最大	51.0	最大	204.0		
平均	48.6	平均	195.9		
方差	12.7	方差	234.8		




weight=10%		weight=60%		期望比例	0.1667
最小	67.0	最小	353.0	实际比例	0.1808
最大	358.0	最大	1154.0		
平均	138.5	平均	766.2		
方差	1536.4	方差	24653.2		

Kernel: Disk IO




Buffer write测试



Direct write测试

 Docker

- Bug fix
- Docker热升级
- 网络插件
- 弹性内存控制
- RBD插件



- ▶ Docker daemon停止时主动杀掉所有container, 主要受限子
 - ▶ 用户进程是daemon的子进程
 - ▶ IO流经过daemon缓存
- ▶ 原来的两层进程父子关系变为三层, monitor由goroutine改为进程, 由它等待container运行结束
- ▶ Docker重启时, monitor孤儿进程托管给init进程, container不受任何影响
- ▶ Docker重启后恢复所有Container状态



离线数据存储

cephFS

- 多MDS
- Cephfs大目录处理优化
 - 优化mds对大量文件的目录处理速度，速度提高6~10倍
 - 提高了mds主备切换的速度
- cephfs内核模块的bug fix
 - 稳定性改进
 - 支持quota
 - 支持Jewel, 支持keyring挂载权限

云硬盘



cephRBD

- 普通云硬盘
- 内置云硬盘
 - 临时云硬盘
 - 可迁移云硬盘



kubernetes


- Quota管理
 - 在线
 - 离线
- APP
 - 引入Tapp
- 网络模式
 - Overlay
 - Floating IP
 - NAT
 - Host
- 磁盘管理
 - Log、data
 - 云盘
- GPU应用



registry

GaiaStack有大规模部署应用的场景（如机器学习作业），需要对registry做相应优化

- 镜像仓库优化（迁移至registry2.0，使用ceph作为后端存储）
- registry服务高可用与负载均衡
- 多集群镜像的同步
- 基于P2P的大规模镜像分发



主要设计思想：

- 在镜像下载过程中，引入BT协议
- 在Blob上传时，对Blob生成种子
- 在下载镜像的Blob时，先下载种子，再通过种子文件下载数据

主要有三个组件：

- **P2P Registry**：镜像仓库, 种子生成
- **Agent**：P2P下载任务的主要功能组件
- **Tracker**：P2P下载资源查询定位组件

registry





图5 P2Pull与docker原生pull在不同并发量下的distribution时间对比，在腾讯云的200台物理机上进行了实验

镜像选择：

registry (30M) ,centos (200M) , hadoop (500M) , tensorflow (1G)

Distribution time = Average(pull(image))

从图5、6可以看出，引入P2P后，pull镜像的速度显著提升，而且使得registry的流量大幅度减少（蓝色是如果不用P2P registry应该承担的流量）。




图6 在整个实验中，使用P2P下载时，registry(绿色)与agent(蓝色)出流量占比

开放的GaiaStack

主机服务 主机视图 服务视图

主机服务展示当前部署的主机和服，可以快速定位问题、重启主机或服务。

增量部署

集群管理

主机管理

服务管理

业务管理

用户管理

监控

告警

日志

配置

主机服务 > 增量部署

部署规模

部署规模:



* 所属IDC: szps

集群的物理及逻辑分区，同一IDC的集群共用IDC基础服务，不需要多次部署

* 所属集群: 请选择所属集群

填写主机

新增主机

批量上传

模板下载

主机IP

账号

密码

主机IP

账号

密码

主机IP

账号

密码

注册主机

请保持网络环境畅通，我们将尝试连接主机

服务配置

Thanks

BDTC 2017 中国大数据技术大会
Big Data Technology Conference 2017