从Borg到Kubernetes

PaaS产品设计探讨

钟成.难易@

https://github.com/HardySimpson

目录 CONTENTS

PATR
1

Borg

解决了什么问题？

What is Borg ?

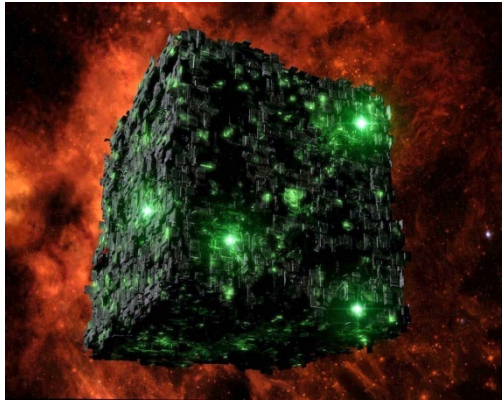

——We are the Borg. Lower your shields and surrender your ships. We will add your biological and technological distinctiveness to our own. Your culture will adapt to service us. **Resistance is futile.**

What is Borg ?

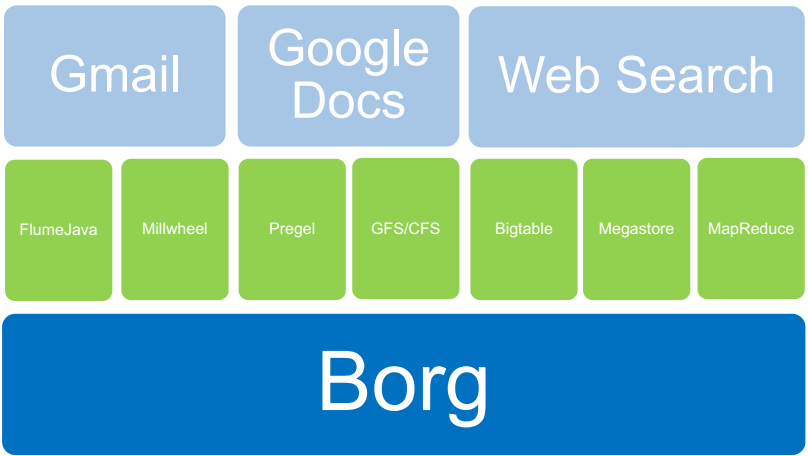

十年

The **cluster management** system we internally call Borg

admits, schedules, starts, restarts, and monitors

the full range of applications that Google runs.

Work Flow

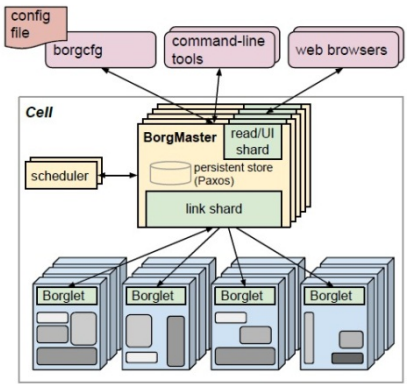

Figure 1: The high-level architecture of Borg. *Only a tiny fraction of the thousands of worker nodes are shown.*

- 用户使用Borgcfg或者Web UI提交需要跑的应用（Task）：例如一个跑100个副本的web服务，或一个批处理任务
- Borgmaster接受这个请求，放入队列内
- Scheduler扫描队列，查看这个应用的资源需求，在集群中寻找匹配的机器
- Borgmaster通知Borglet，在相应机器上启动应用

提交应用 → 应用启动 25秒

Schedule Policy

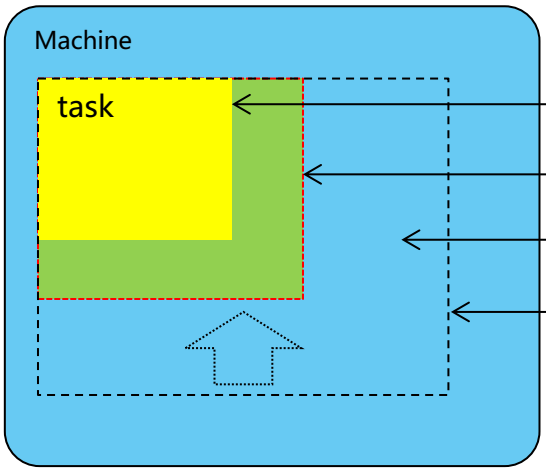

实际使用资源(actual)

保留资源(reservation)

回收资源(reclamation)

限制资源(limit)

在task启动300s后，进行资源回收工作，逐渐把保留资源设置为实际使用资源+安全红线资源，并每过几秒再重新计计算一次。所以图中的红线是随着时间而波动的。

Schedule Policy

- prod task
  - 永不停止，面向用户（Gmail，Google Search，Google Docs）
  - 几微秒到几百毫秒
  - 短期性能波动敏感
- non-prod task
  - 批处理任务，不面向用户（Map Reduce）
  - 几秒到几天
  - 短期性能波动不敏感

Schedule Policy

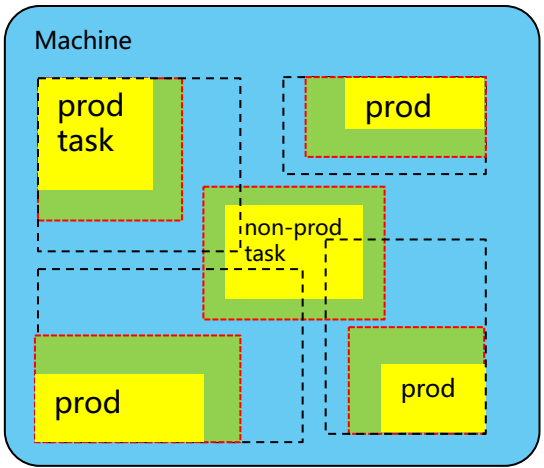

- 使用限制资源计算prod task的可用性
- prod task可以抢占non-prod task的资源，从而导致non-prod task被杀死而重调度
- prod task不能互相抢占资源而驱逐对方

20%的工作负载跑在回收资源上

Effect

- 即使Borgmaster或Borglet挂了，task继续运行
- 99.99%可用性
- 10k 机器/Cell
- 10k task/分钟
- 99% UI < 1s
- 95% borglet poll < 10s

Utilization == Money

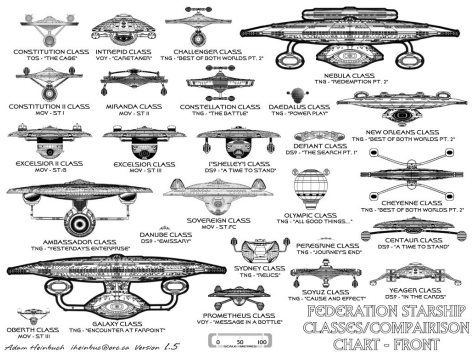

- 如何去定义一个异构集群的效率？
- 把多个用户、prod和non-prod的task混合会提升还是降低效率？
- 资源回收和调度策略怎么样才是最佳的？
- 如何划分资源粒度？
- Cell是越大越好吗？

Utilization

- 压缩率，给定一个负载，部署到可以运行这个负载的最小Cell里面去
- prod和non-prod task混合运行，会降低3%-20%的CPU速度，但会节省20%-50%的机器
- task请求的资源粒度小(0.001核,byte计数内存)能提升压缩率
- 详见论文《Google使用Borg进行大规模集群的管理》

Benefits

- 隐藏资源管理和故障处理细节，使用户可以专注于应用开发
- 本身提供高可靠性和高可用性的操作，并支持应用程序做到高可靠高可用
- 在数以万计的机器上高资源利用率运行

PATR
2

Kubernetes的不同之处和方向

Architecture

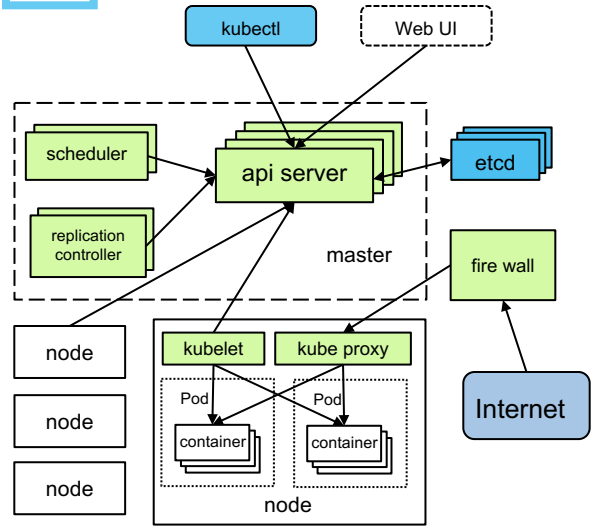

- 用户通过kubectl提交需要运行的docker container(pod)
- api server把请求存储在etcd里面
- scheduler扫描，分配机器
- kubelet找到自己需要跑的container，在本机上运行

- 用户提交RC描述，replication controller监视集群中的容器并保持数量
- 用户提交service描述文件，由kube proxy负责具体的工作流量转发

Difference

- 在Google的数以百万计的集群上运行超过十年
- 使用lxc容器
- C++编写
- 对集群调度性能要求非常苛刻
- 单集群能调度超过上万台机器

Borg

- 2014.7开始有提交记录，发展较快
- 使用Docker容器
- Go语言编写
- 目前还没有做很多性能优化
- 目前单集群只支持几百台机器

Kubernetes

Workload

- 静态编译，包括可执行程序和数据文件
- 接受SIGTERM信号，用于清理保存状态
- 被kill之后能够在其他机器上重启，无状态
- 一般内置http服务，用于获取健康信息
- 数据和日志一般都存储在分布式存储上

应用在设计期就是分布式的

Borg

- Docker容器，自带干粮
- 支持挂载外部的各种持久层 (GCEPersistentDisk, AWSElasticBlockStore, NFS, iSCSI.....)
- 从容器中读取监控信息，从多个层面检查应用性能
- 支持在Pod中包含日志处理容器

假定容器能在其他机器上重启，但实际上还需应用做一定改造

Kubernetes

Workload

- 静态编译，包括可执行程序和数据文件
- 接受SIGTERM信号，用于清理保存状态
- 被kill之后能够在其他机器上重启，无状态
- 一般内置http服务，用于获取健康信息
- 数据和日志一般都存储在分布式存储上

应用在设计期就是分布式的

Borg

- Docker容器，自带干粮
- 支持挂载外部的各种持久层 (GCEPersistentDisk, AWSElasticBlockStore, NFS, iSCSI.....)
- 从容器中读取监控信息，从多个层面检查应用性能
- 支持在Pod中包含日志处理容器

假定容器能在其他机器上重启，但实际上还需应用做一定改造

Kubernetes

Design

- 机器/IP vs Pod/IP
  - 允许应用自由选择端口，不必考虑冲突
  - 保证外部的其他的服务发现/命名也不用操心端口
- Jobs分组 vs Selector/Label分组
  - 提供更灵活的组合搭配
- 对资深用户优化 vs 对初级用户友好
  - Borg有230个多参数

Kubernetes Special

- 插件化
  - rc, scheduler,persist volume…
  - 用户可以按照plugin接口自定义实现，扩展功能
- 容器化
  - api server, scheduler, controller, etcd, cadvisor, flannel…
  - kubelet不会被容器化
- 支持多种I层部署和适配
  - GCE, Vagrant, Microsoft Azure, CoreOS, vSphere, Amazon Web Service…
  - SaltStack部署支持

Summary

Borg

Kubernetes

Future

- 多租户支持(namespace)
- 容器持久化
- 提升集群规模，100->1k，模拟器
- 并行共享资源调度(Omega)，提升利用率
- 容器网络层优化，proxy->内核
- 多集群管理
- 单集群跨I层调度

Relate Work @Huawei

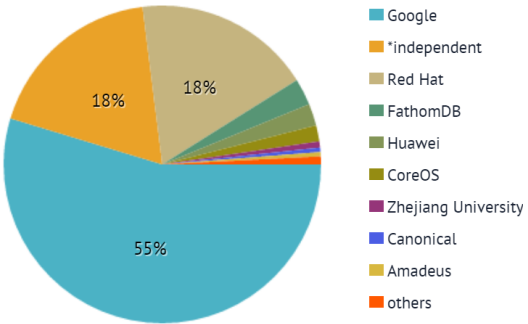

- CentOS baremetal的部署脚本
- Heapster standalone 文档和bug提交
- Ubuntu k8s升级脚本和文档
- Heapster kafka sink
- Heapster elasticsearch sink
- Bugfix, cmd.....

PATR
3

未来的云需要什么？

Technology Lifecycle

- IBM PC
- Linux/Unix
- C/Java
- JavaScript
- PHP
- Windows
- Git

- Cobol
- Dephi
- EJB
- OS/360
- Multics
- DOS
- Minix
- Perl
- Microkernel
- .....

Kubernetes/Docker

DockOne.io
Community of Docker

Fail of Tower of Babel

三十幅共一毂，当其无，有车之用。

埏埴以为器，当其无，有器之用。

凿户牖以为室，当其无，有室之用。

故有之以为利，无之以为用。

The Long March

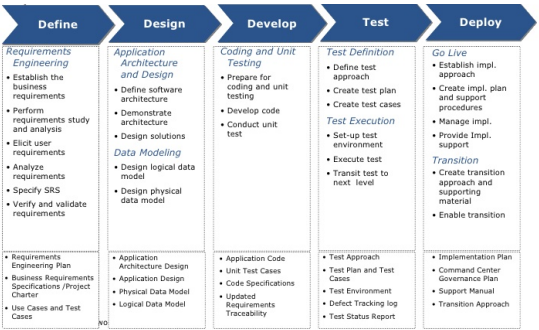

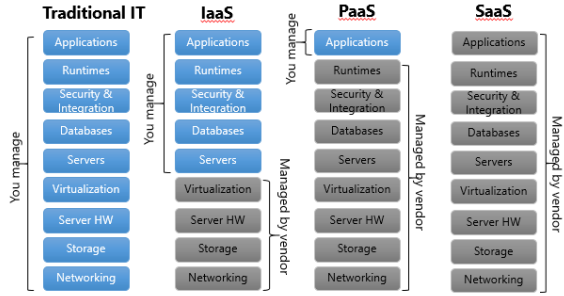

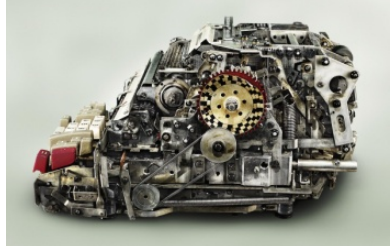

Gain or Loss ?

- 产品是否能减少语言、程序、框架不同带来的复杂性？
- 产品是否能减少设计、编码、测试、部署流程中带来的复杂性？
- 产品是否能减少大规模集群、网络、服务依赖、错误追踪带来的复杂性？

Make Life Simpler ！

下次再见