



2013大数据全球技术峰会
Big Data Global Summit 2013

Cloud Foundry的弹性设计

喻 勇 (Frank Yu)
yuf@vmware.com

@cloudfoundry
<http://www.cloudfoundry.cn>

VMware上海研发中心

内容提要

- Cloud Foundry产品概述
- Cloud Foundry架构剖析
- Cloud Foundry的NATS模块
- Warden Container
- 数据及服务的整合
- Q&A



Cloud Foundry产品概述

云计算的三个层次

SaaS
Software as a Service



PaaS
Platform as a Service



IaaS
Infrastructure as a Service




IaaS: 硬件的自动化管理，人与机器的解耦合

获得效率/牺牲性能

PaaS: 应用的自动化管理，应用与OS的解耦合

获得弹性/牺牲控制

Cloud Foundry的元素



演 示



vmc 工具

Create app, update app, control app

```
vmc push [appname] [--path] [--url] [--instances N] [--mem] [--no-start]
vmc update <appname> [--path PATH]
vmc stop <appname>
vmc start <appname>
vmc target [url]
```

Update app settings, get app information

```
vmc mem <appname> [memsize]
vmc map <appname> <url>
vmc instances <appname> <num | delta>
vmc {crashes, crashlogs, logs} <appname>
vmc files <appname> [path]
```

Deal with services, users, and information

```
vmc create-service <service> [--name servicename] [--bind appname]
vmc bind-service <servicename> <appname>
vmc unbind-service <servicename> <appname>
vmc delete-service <servicename>
```

```
vmc user, vmc passwd, vmc login, vmc logout, vmc add-user
vmc services, vmc apps, vmc info
```

应用平台支持: 不断增多

■ Java平台

- [Grails](#) 模仿Rails的Java平台实现
- Java_web 普通Java web程序
- [Lift](#) 基于Scale的web框架
- [Spring](#) 流行的Java框架
- Play

■ Ruby平台

- [Rack](#) 最小化的Ruby Web框架
- [Rails3](#) 一站式的Ruby Web框架
- [Sinatra](#) 极简主义的Ruby Web框架

■ Python平台

- [Django](#) 最流行的PythonWeb框架
- Wsgi Python的CGI

■ 其他平台

- [node.js](#) 异步Web框架
- [Erlang](#)
- [Php](#)
- [Microsoft .net](#)
- Standalone 独立的程序

服务平台支持：不断增多

■ 主流服务

- MongoDB
最流行的Nosql数据库
- MySQL
传统开源关系数据库
- Postgresql
MySQL的有力竞争者
- Redis
极快的内存KV数据库
- Neo4j
图数据库

More on github

■ 存储

- Blob
 - Amazon S3
 - Atmos
 - NFS
 - Local Disk
- FileSystem 远程NFS支持

■ 消息

- RabbitMQ 出色的Erlang队列系统

■ 大数据


- Hadoop集成
- Project Serengeti

<http://serengeti.cloudfoundry.com>


Cloud Foundry架构剖析



Cloud Foundry架构的逻辑视图 - 1



Cloud Foundry架构的逻辑视图 - 2



Cloud Foundry的设计理念

■ 前提

- 假设失败
- 为MTTR优化，而不是MTBF
- 快速失效，自我修复
- 横向扩展的组件
- 分布式状态，没有单点故障
- 极度简单

■ 模式

- 事件(消息)驱动
- 异步
- 非堵塞
- 独立
- 消息传递
- 最终一致性

■ 设计


- 组件的松耦合
 - 更少的类，更多的实例
- 消息是基础
 - 寻址和组件发现
 - 命令和控制
- JSON
- 数据通过HTTP或File/Blob传递

■ 内核组件的特点

- 动态发现
- 无依赖性和启动顺序
- 通过HTTP/JSON监控
- 位置独立性


消息总线

- 寻址和发现
 - 不需要静态IP和DNS查询
 - Layer 4协议
- 命令和控制
- 中央通讯系统
- Dial tone, fire and forget
- Protects *itself* at all costs
- Idempotent Semantics



路由引擎

- 处理所有HTTP流量
- 从DEAs获得信息并实时更新路由表
- 维护分布式路由状态
- 将对URL的访问路由至具体的应用
- 在应用实例之间分发流量（均衡负载）



大管家：Cloud Controller

- 处理所有的状态（state）变化

- 控制用户、应用和服务


- 对应用进行打包和预处理*

- 将服务绑定到应用

- 对外提供REST API接口

- 可在Github中查看

- https://github.com/cloudfoundry/cloud_controller/blob/master/cloud_controller/config/routes.rb




```
# The priority is based upon order of creation:
# first created -> highest priority.
# Routes with asterisks should go at the end of the file if they are ambiguous.
CloudController::Application.routes.draw do
  get 'info' => 'default#info', :as => :cloud_info
  get 'info/services' => 'default#service_info', :as => :cloud_service_info
  get 'info/runtimes' => 'default#runtime_info', :as => :cloud_runtime_info
  get 'users' => 'users#list', :as => :list_users
  post 'users' => 'users#create', :as => :create_user
  get 'users/*email' => 'users#info', :as => :user_info
  delete 'users/*email' => 'users#delete', :as => :delete_user
  put 'users/*email' => 'users#update', :as => :update_user
  post 'users/*email/tokens' => 'user_tokens#create', :as => :create_token
  post 'apps' => 'apps#create', :as => :app_create
  get 'apps' => 'apps#list', :as => :list_apps
  get 'apps/:name' => 'apps#get', :as => :app_get
  put 'apps/:name' => 'apps#update', :as => :app_update
  delete 'apps/:name' => 'apps#delete', :as => :app_delete

  put 'apps/:name/application' => 'apps#upload', :as => :app_upload
  get 'apps/:name/crashes' => 'apps#crashes', :as => :app_crashes
  post 'resources' => 'resource_pool#match', :as => :resource_match
  get 'apps/:name/application' => 'apps#download', :as => :app_download
  get 'staged_droplets/:id/:hash' => 'apps#download_staged', :as => :app_download_staged
  get 'apps/:name/instances' => 'apps#instances', :as => :app_instances
  get 'apps/:name/stats' => 'apps#stats', :as => :app_stats
  get 'apps/:name/update' => 'apps#check_update'
  put 'apps/:name/update' => 'apps#start_update'
```


小护士：HealthManager

- 负责监控应用和服务的状态
- 如果出现状态异常，通知CloudController
- 没有改变应用或服务状态的权力（只读）
- Initial value with real-time delta updates to intended vs. real
- Determines drift




DEA

- **Droplet 和 Droplet Execution Agent**
- **负责运行所有的应用**
- **监控应用的具体运行参数**
 - CPU , 内存 , IO , 线程 , 磁盘 , 等等
- **对于DEA来说 , 所有应用都是一样的**
- **“concept” of ability and desire to run an application**
 - runtimes, options, cluster avoidance, memory/cpu
- **Alerts on any change in state of applications**
- **Provides secure/constrained OS runtime**
 - Hypervisor, Unix File and User, Linux Containers
 - Single or Multi-Tenant




服务

- 一个可扩展/扩充的层
- Service Gateway和服务 Node
- 绑定到应用
- 可以被共享
- 服务API用来发现、列表和provision
- Provision之后，应用对服务的访问是直接的
- 很容易将各类应用和各类服务自动绑定



内核重构的路线图



Cloud Foundry的NATS模块




什么是NATS

- 一个基于事件驱动的轻量级支持消息发布、订阅的系统
- 使用Ruby实现
- 依赖以下模块构建
 - eventmachine
 - json_pure
 - daemons
 - Thin
- <https://github.com/dereckcollison/nats/>

消息的发布和订阅

- 基于Topic
- 发布者以Topic发送消息
- 订阅者订阅特定Topic并收到



Cloud Foundry下的NATS用例

▪ DEA启动和处理应用运行

- **DEA:** `NATS.publish('dea.start', @hello_message_json)`
 - @hello_message_json for UUID, IP, Port, Version of the DEA

• Cloud Controller需要启动一个Droplet的实例

- **DEA:** `NATS.subscribe('dea.#{UUID}.start') {|msg|process_dea_start(msg)}`
 - Send message with the topic of "dea.#{uuid}.start" to start this DEA
 - 对自己UUID的消息主题进行订阅
- **Cloud Controller:** `NATS.publish('dea.#{dea_id}.start',json)`
 - DEA get the msg, call process_dea_start(msg)
 - msg = droplet_id, instance_index, service, runtime

NATS的源代码

■ lib

- nats/client.rb #NATS client
- nats/server.rb #NATS server wrapper
- nats/server/server.rb #NATS server
- nats/server/connection.rb #Connection processing
- nats/server/sublist.rb #Subscriber manager
- nats/server/options.rb
- nats/ext

■ bin #commands to start client and server

■ spec #test cases

■ examples

■ benchmark

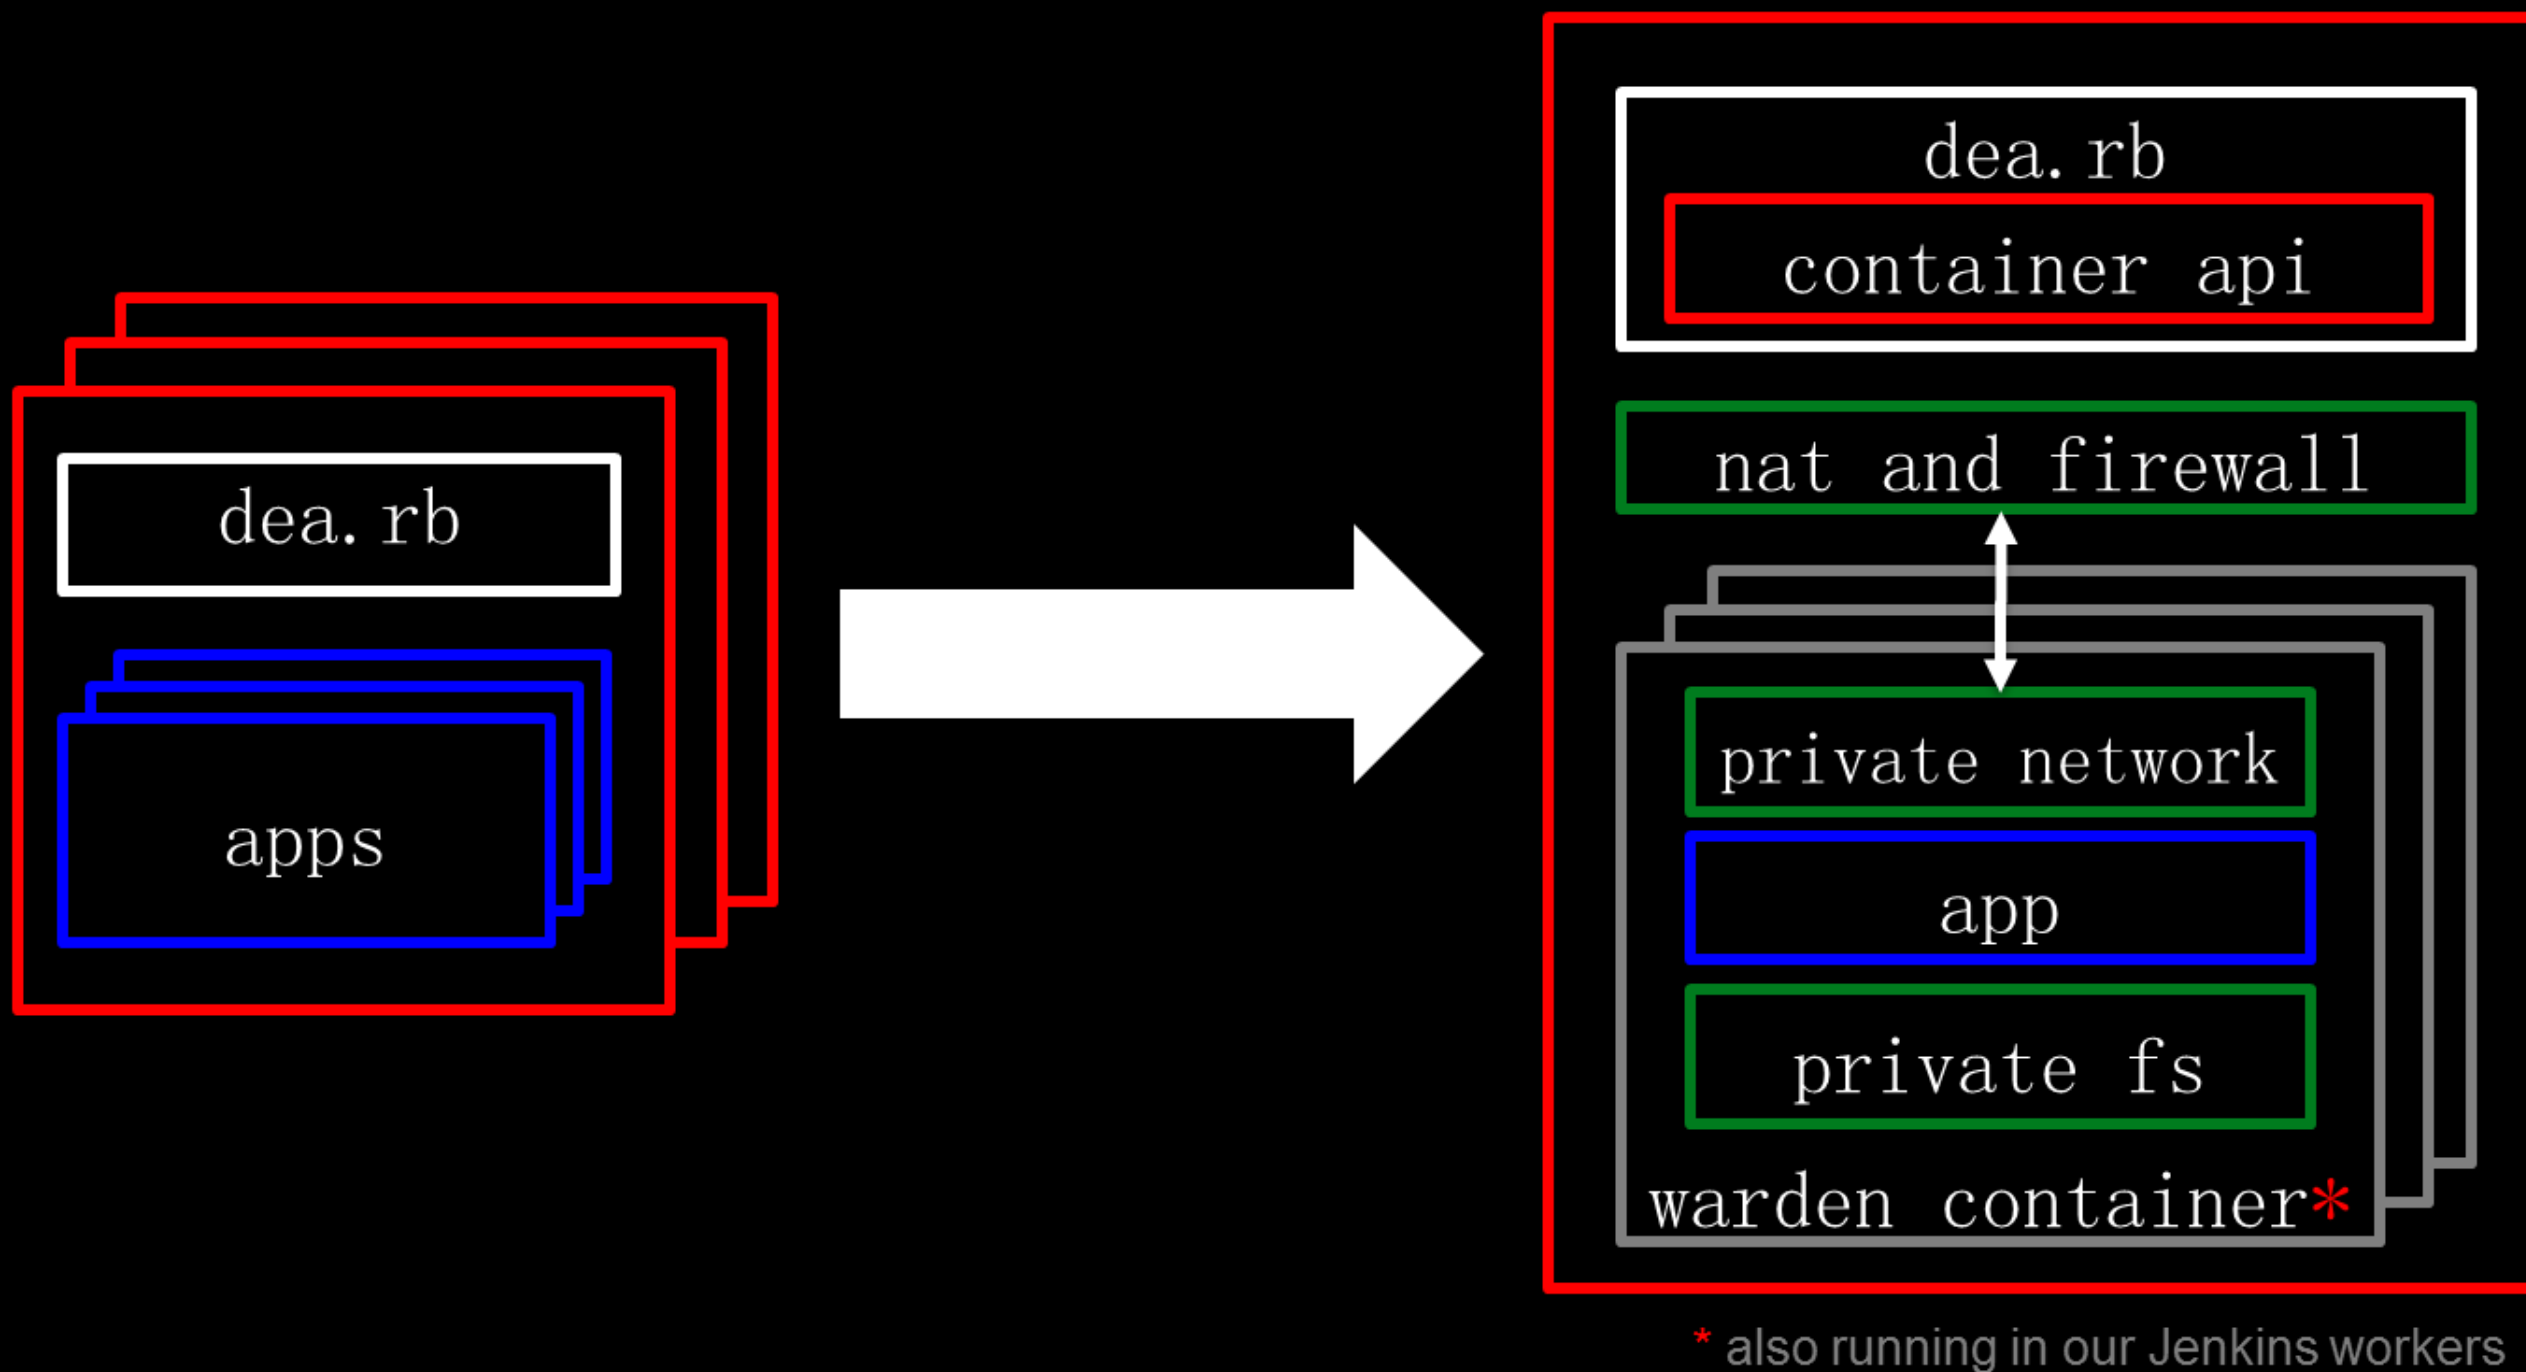
幕后英雄：EventMachine

- 高速可伸缩的事件驱动I/O框架
- Reactor Pattern（反应堆模式）的Ruby实现
 - 将网络逻辑层从应用逻辑层中抽离。无需操心底层的网络连接和 Socket 逻辑处理
- 性能优先
 - 引入了一种避免使用线程的编程模型
 - 轻量级的并且支持系统底层网络基础操作
 - 关注高性能的部分都是由 C/C++ 实现
 - 操作系统的最优特性（比如Linux 下的 epoll）
- <http://rubyeventmachine.com/>
- <http://www.infoq.com/cn/news/2008/08/eventmachine>
- Research on EventMachine
 - <http://blog.csdn.net/resouer/article/details/7975550>
 - <http://www.igvita.com/2008/05/27/ruby-eventmachine-the-speed-demon/>

Warden Container



DEA的重构和增强




Warden Container


- 源自于Cgroup
- 非硬件类Hypervisor的一种隔离技术
- 起源于Google
 - KVM虚拟机是Linux的一个进程，因此Google采用了Cgroups机制来进行资源管理
 - 用户态的虚拟化技术
 - Cgroup控制KVM虚拟机可以使用的物理资源，包括CPU占用率，CPU核心，内存等
- **Warden是一个孤立的环境，Droplet只可以获得受限的CPU,内存，磁盘访问权限，网络权限**
- 目前在GCE，OpenShift等IaaS/PaaS平台中广泛使用
- 满足应用隔离要求的同时，获得高性能和伸缩性
- 不直接使用Cgroup，以确保Cloud Foundry DEA对操作系统无依赖性

数据及服务的整合



Service Gateway & Service Node





Service Broker



Cloud Foundry + Virtualized Database



Cloud Foundry + Virtualized Hadoop



Open source project that leverage virtualization to simplify Hadoop deployment and operations

<http://serengeti.cloudfoundry.com>

小结

- 选择高效的编程语言
- 用消息订阅代替模块之间的接口
- 来自架构的弹性
- 细节之处优化
- 利用现有的技术
- 与IaaS层的紧密结合，获得平台级的弹性



Q&A

更多内容，请关注官方微博：

@CloudFoundry