融数数据基于K8S的微服务治理和构建平台

个人简介

- 现任融数数据北京研发中心CTO，负责公司大数据平台、微服务框架以及DevOps平台的研发工作；
- 毕业于天津大学，毕业后一直从事软件相关研发和架构设计工作，曾经在普元软件任资深架构师、IBM GBS任咨询经理、亚马逊任架构师等，后加入创业公司，从事研发和管理工作；
- 热爱编程，喜欢钻研新技术，对于微服务、企业架构、大数据以及DevOps有浓厚的兴趣

- 融数数据基于gRPC的微服务框架介绍
- 融数数据微服务治理和监控
- 融数数据基于K8S的微服务构建、开发和部署
- 打造适合微服务的技术团队

- **融数数据基于gRPC的微服务框架介绍**
- 融数数据微服务治理和监控
- 融数数据基于K8S的微服务构建、开发和部署
- 打造适合微服务的技术团队

微服务框架选型思考的几点原则

社区热度

- 文档多
- 坑少
- 比较容易找到人

架构成熟度

- 方便开发
- 方便迁移
- 多协议支持
- 多语言支持

学习曲线

- 基于主流技术
- 现有知识传承

可维护性

- 监控能力
- 运维能力

选型过程中，我们对比了比较流行的开源框架

功能点/服务框架	备选方案				
	Netflix/Spring cloud	Motan	gRPC	Thrift	Dubbo/DubboX
功能定位	微服务框架	RPC框架,但整合了ZK或Consul,实现集群环境的基本的服务注册/发现	RPC框架	RPC框架	服务框架
支持Rest	是	否	否	否	是
支持RPC	否	是(Hession2)	是	是	是
支持多语言	是(Rest形式)	否	是	是	否
服务注册/发现	Eureka服务注册表，Karyon服务端框架支持服务自注册和健康检查	是(zookeeper/consul)	否	否	是
负载均衡	是(服务端Zuul+客户端Ribbon)	是(客户端)	否	否	是(客户端)
配置服务	Netflix Archaius Spring Cloud Config Server集中配置	是(zookeeper提供)	否	否	是
服务调用链监控	否 Zuul提供边缘服务,API网关	否	否	否	否
高可用/容错	是(服务端Hystrix+客户端Ribbon)	是(客户端)	否	否	是(客户端)
典型应用案例	Netflix	Sina	eBay/CoreOS	Facebook	用户多
社区活跃程度	高	一般	高	一般	已经不维护了
学习难度	中等	低	高	高	低
文档丰富度	高	一般	一般	一般	高
其他	Spring Cloud Bus	支持降级	Netflix准备集成gRPC	IDL定义	实践的公司比较多，许多企业已放弃，如京东

... 那么，实现微服务框架，我们希望得到什么?

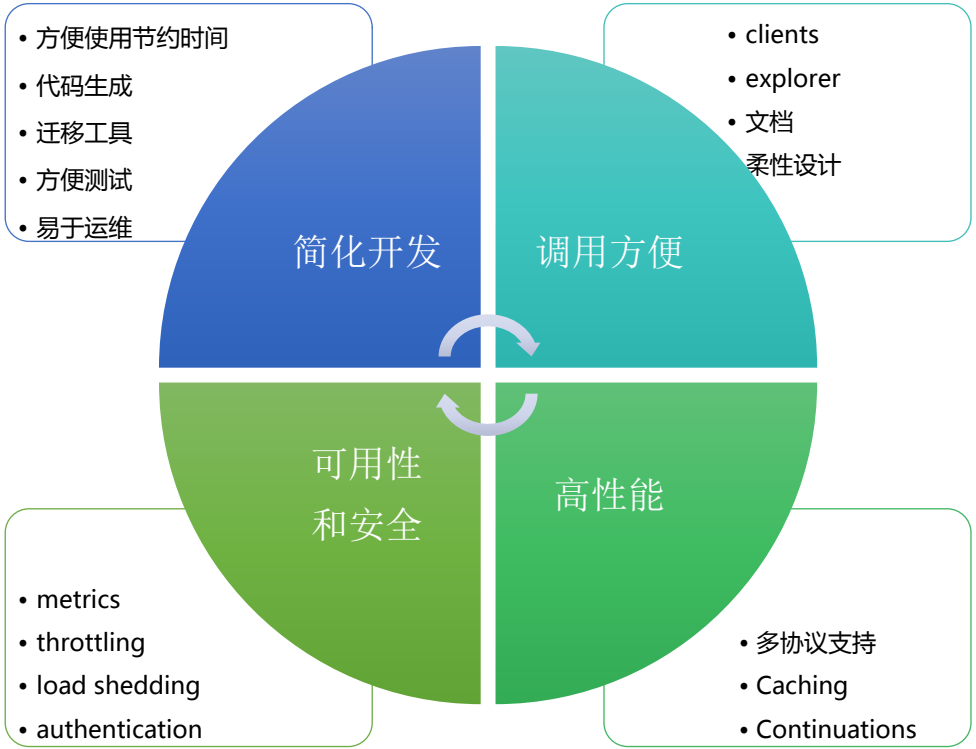

为此，我们的选型经历了如下过程

- 初步的服务化
- 缺少治理手段
- 缺少统一规范

- Spring + Netflix解决方案缺少服务实现方案, 仍然基于RestEasy
- 代码优先的开发不如契约优先好管理
- Zuul同步调用的性能损失，不支持RPC
- Eureka依然是中心化治理

- 封装GRPC，简化开发
- 基于Proxy的服务端治理、流量控制
- 基于Proxy的RPC与REST协议互转
- 基于K8S的灰度发布
- 借鉴Netflix思想
- 结合DevOps平台的语义化版本管理
- 基于APM(Pinpoint)服务监控和调用拓扑绘制

微服务框架总览

Graeae['gri:i]为希腊神话中可知过去、现在、未来的三盲人女妖,却用同一只眼睛看世界.

取此名亦想体现**微服务**共存共依,又相互独立的特点.

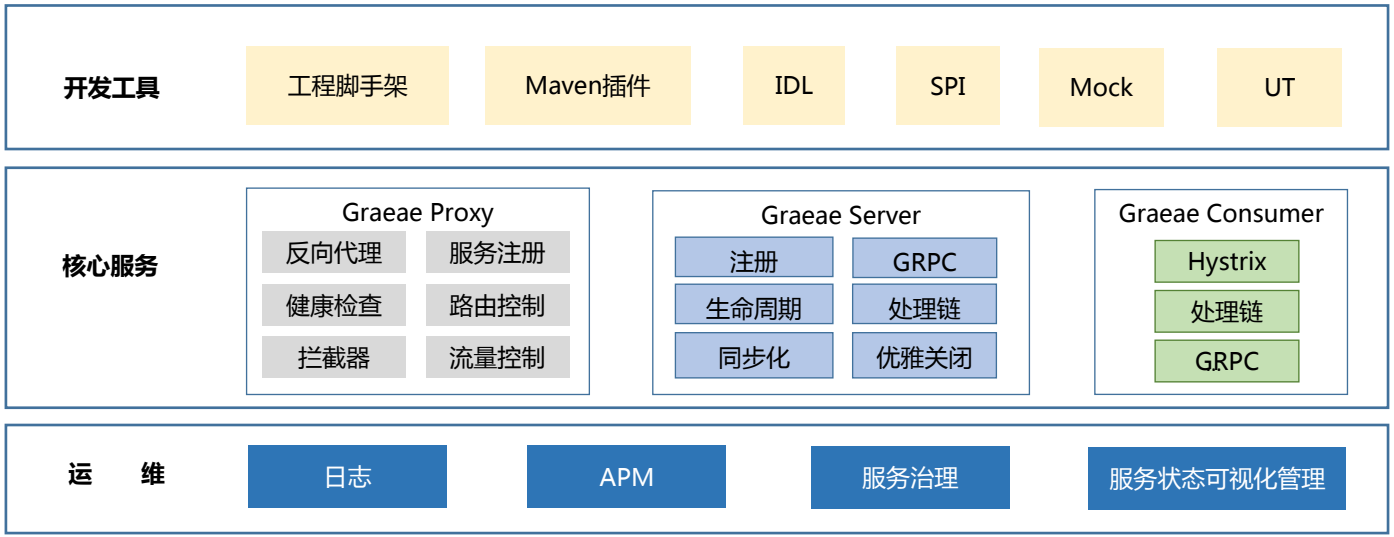

微服务框架之端点 – Graeae Endpoint

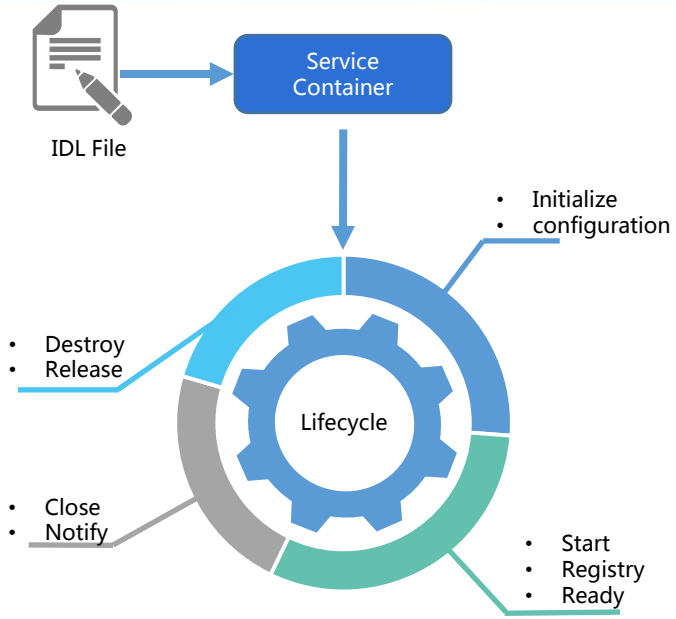

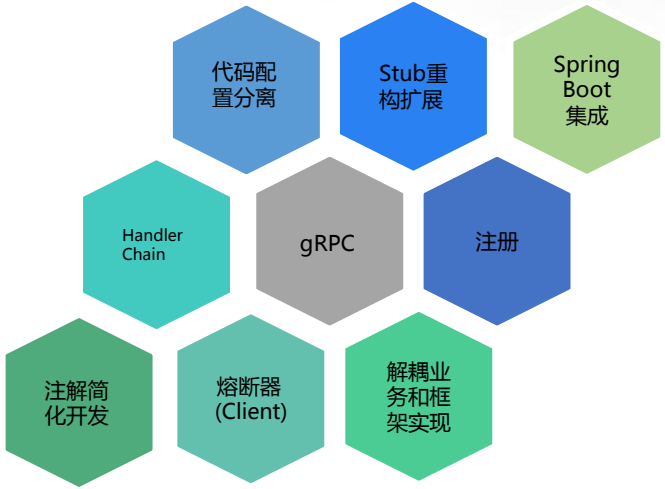

- 抽象基于生命周期的服务容器概念，将服务运行时划分为生命周期的各个阶段
- 在生命周期的各个阶段完成对服务上下文的构建与管理
- 提供对服务端治理的注册、寻址支持
- 提供对部署层的代码、配置分离
- 底层基于gRPC，在gRPC基础上对易用性及功能性进行加强
- 基于annotation标注及stub重新构建，打断业务实现与gRPC的紧耦合
- 重构stub，简化方法调用，屏蔽gRPC stub易用性间隙
- 客户端集成Netflix的Hystrix熔断器，提供fast-fail能力

Graeae对gRPC原生代码的改造和增强

- **重构gRPC原生代码的生成结构，去掉了内部类和基类继承**
  - GrpcClientBuidler
  - GrpcServerBuidler
- **使用annotation简化client，server和service的开发**
  - @GraeaeClient
  - @GraeaeServer
  - @GraeaeService
- **SpringBoot Starter集成**
  - @EnableGraeae
- **Client端Hystrix集成**
  - HystrixFaultTolerance
- **简化原生gRPC的基于观察者模式的回调实现方式，提供同步和异步两种调用方法**
  - getStub().<methodName>InBlock(Parameters）
  - getStub().<methodName>Async(Parameters）
- **基于调用链(FilterChain)的SPI扩展点**

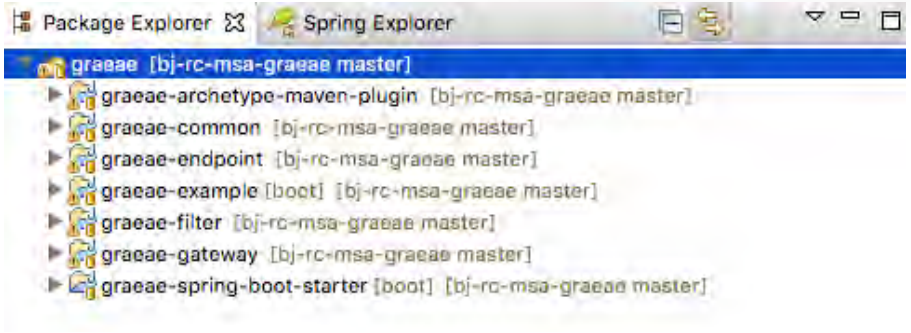

微服务框架代理服务-Proxy

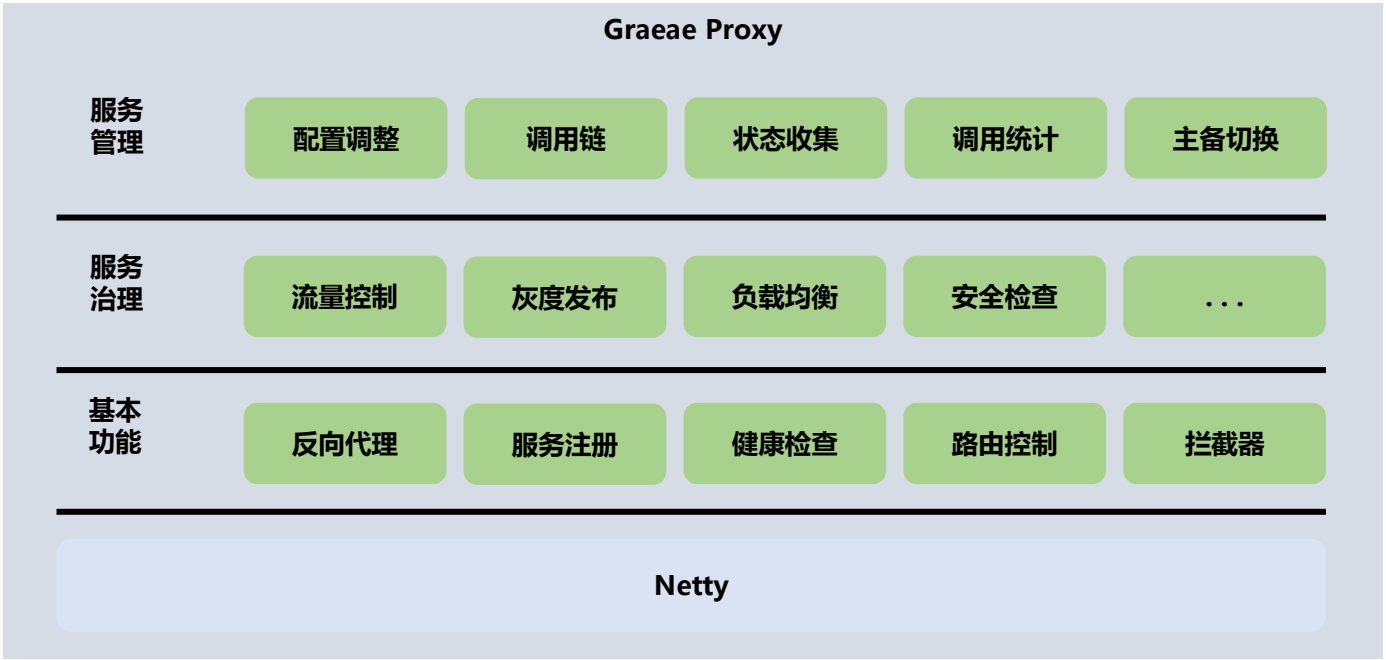

Agenda

- 融数数据基于gRPC的微服务框架介绍
- **融数数据微服务治理和监控**
- 基于K8S的微服务构建、开发和部署
- 打造适合微服务的技术团队

没有银弹 - 微服务之困

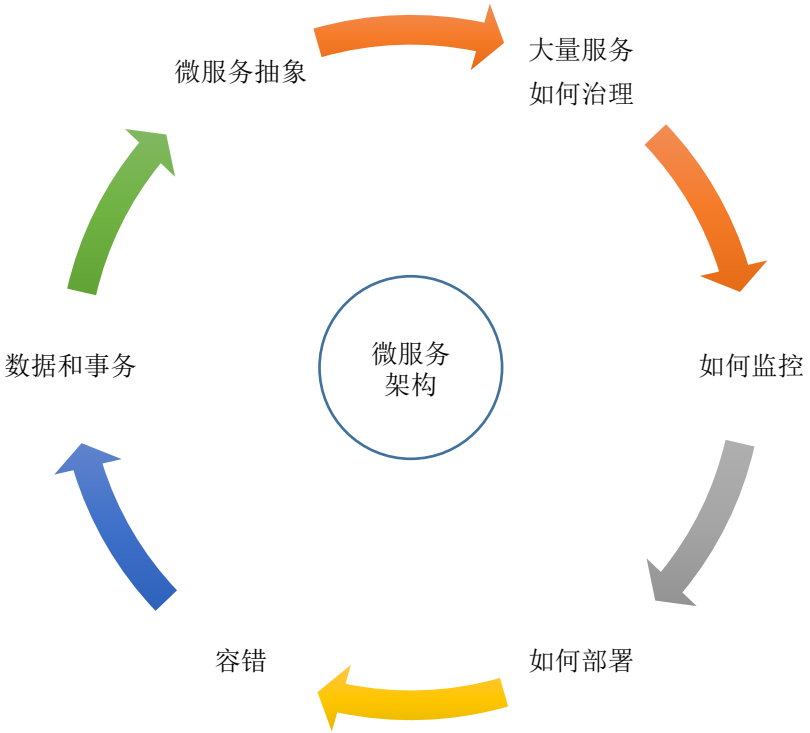

微服务如何治理？

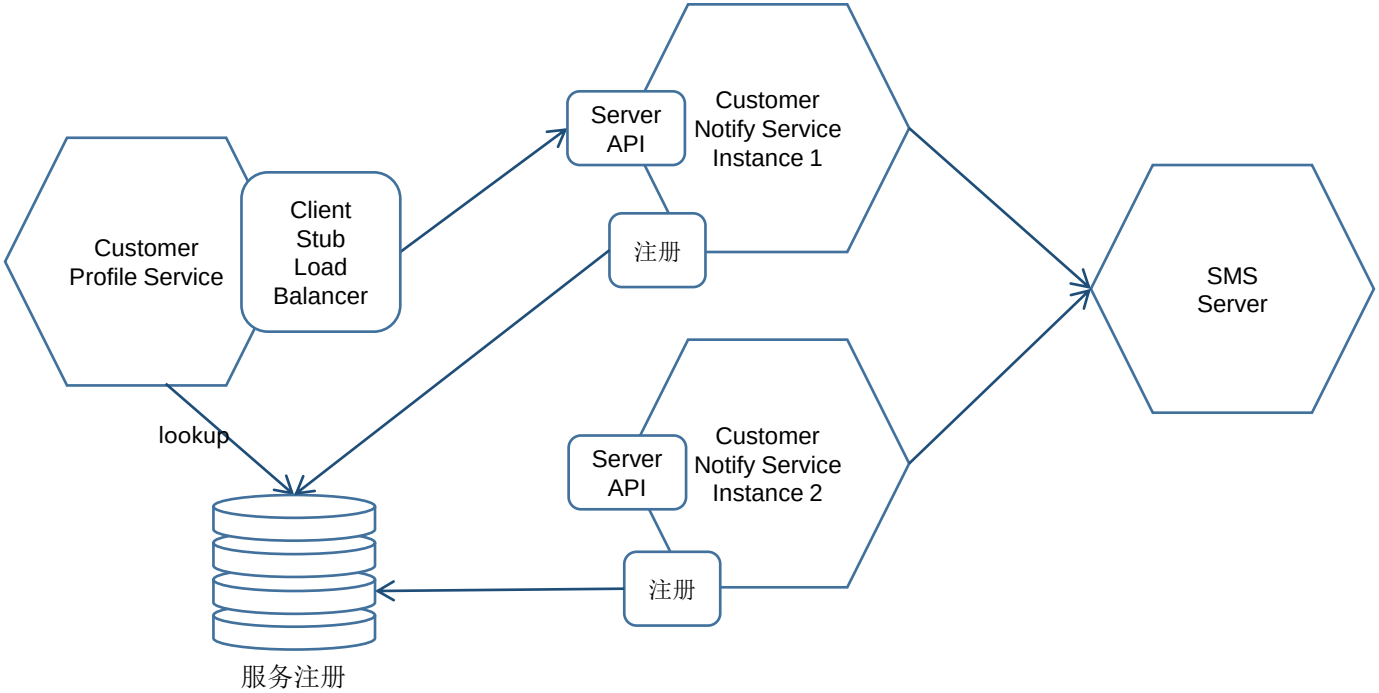
Customer
Profile Service
Client
Stub
Load
Balancer
lookup
Server
API
Customer
Notify Service
Instance 1
注册
Server
API
Customer
Notify Service
Instance 2
注册
SMS
Server
服务注册

服务端治理

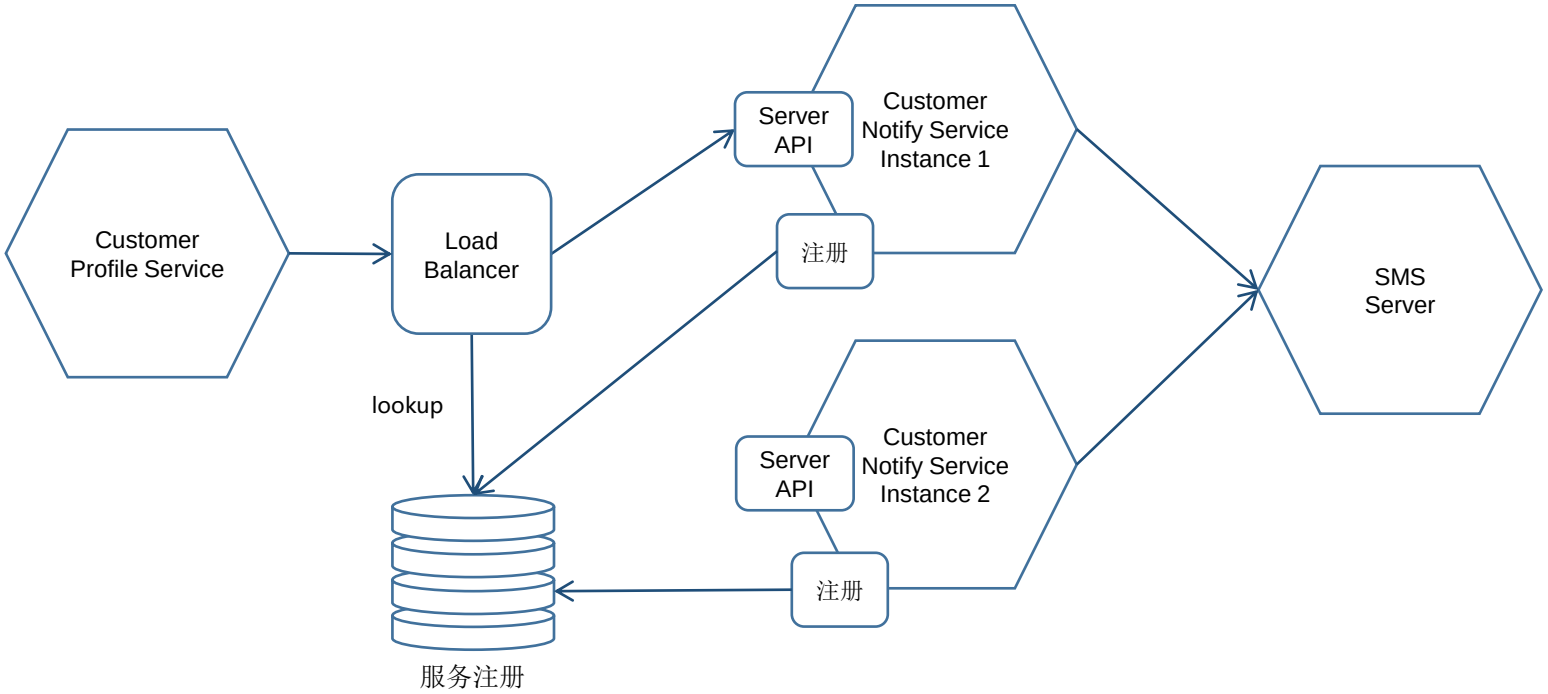
Customer
Profile Service
Load
Balancer
lookup
Server
API
Customer
Notify Service
Instance 1
注册
Server
API
Customer
Notify Service
Instance 2
注册
SMS
Server
服务注册

我们如何做？

融数微服务框架基于Proxy的去中心化治理

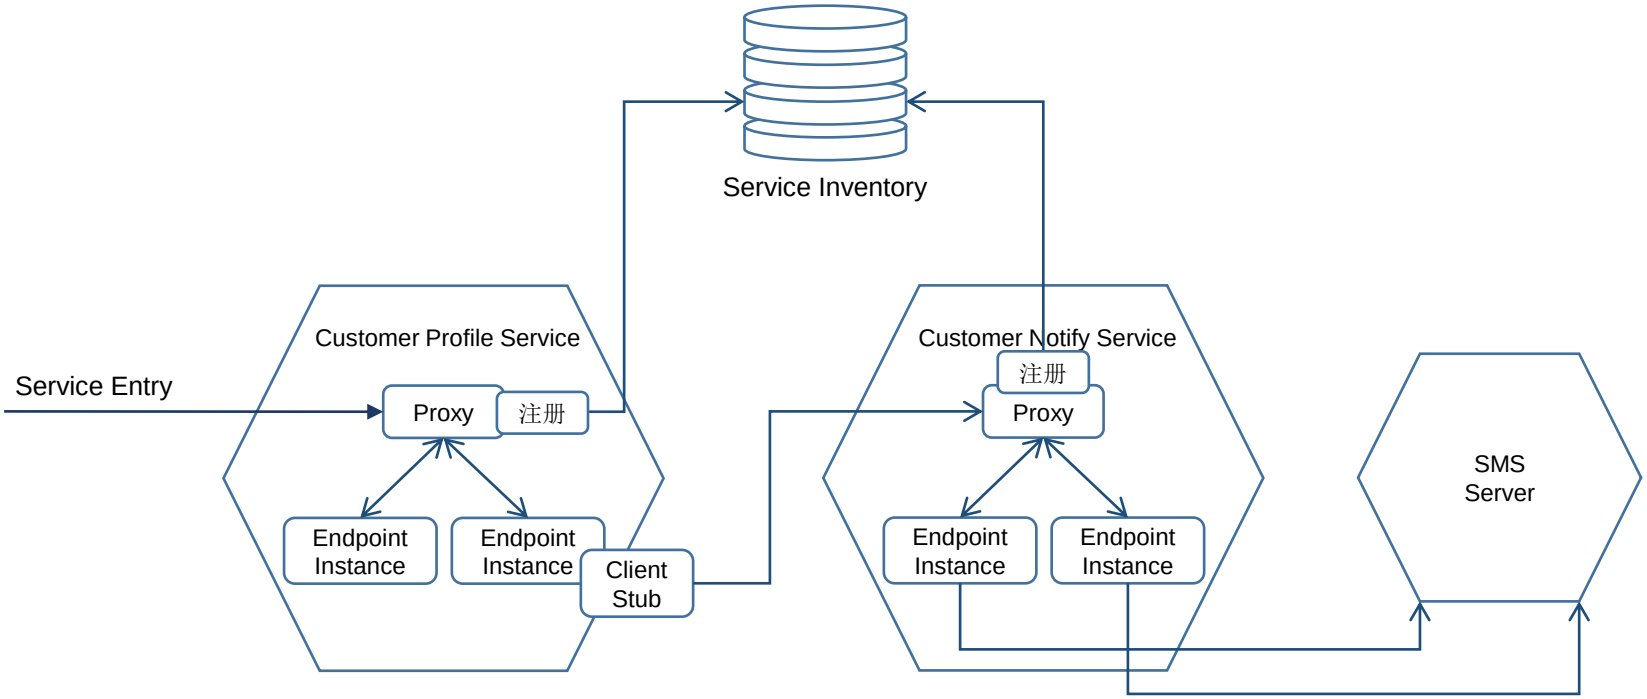

如何监控？

微服务的监控要解决什么问题

融数微服务框架监控第一代 zipkin + brave

```java
@Slf4j
public class BraveUtils {

    private static Reporter<Span> reporter() {
        return new GraeaeLoggingReporter();
    }

    public static Brave brave(int port) {
        Map<String, String> configMap = ConfigLoader.load();
        String serviceName = configMap.get(GraeaeConfigConstant.ZIPKIN_SERVICE_NAME_KEY);
        String sampleRateStr = configMap.get(GraeaeConfigConstant.ZIPKIN_SAMPLER_RATE_KEY);
        String zipkinTestEnableStr = configMap.get(GraeaeConfigConstant.ZIPKIN_TEST_ENABLE_KEY)
        boolean zipkinTestEnable = false;
        float sampleRate = GraeaeConfigConstant.ZIPKIN_SAMPLER_RATE;
        if (null == serviceName) {
            serviceName = GraeaeConfigConstant.ZIPKIN_SERVICE_NAME;
        }
        if (null != sampleRateStr) {
            sampleRate = Float.parseFloat(sampleRateStr);
        }
        if (null != zipkinTestEnableStr) {
            zipkinTestEnable = Boolean.parseBoolean(zipkinTestEnableStr);
        }
        try {
            int ip = InetAddressUtilities.toInt(InetAddressUtilities.getLocalHostLANAddress());
            final Brave.Builder builder = new Brave.Builder(ip, port, serviceName);
            builder.traceSampler(Sampler.create(sampleRate));
            Reporter<Span> reporter = false == zipkinTestEnable ? reporter() : testReporter();
            builder.reporter(reporter);
            return builder.build();
        } catch (Exception e) {
            log.error(e.getMessage(), e);
        }
        return null;
    }
```

```java
@Slf4j
public class GraeaeLoggingReporter implements Reporter<zipkin.Span> {

    @Override
    public void report(zipkin.Span span) {
        checkNotNull(span, "Null span");
        log.info(span.toString());
    }

}
```

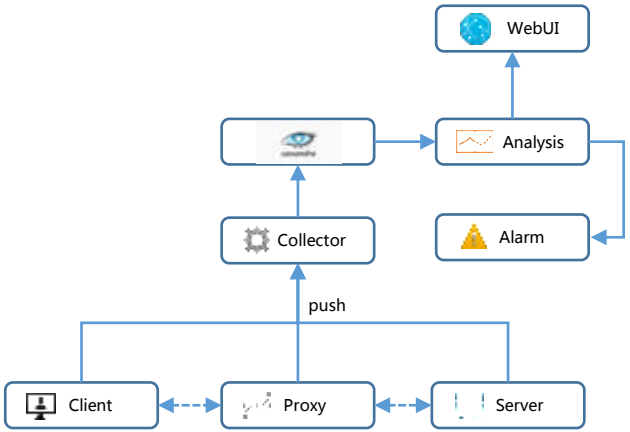
WebUI
Analysis
Collector
Alarm
push
Client
Proxy
Server


Zipkin
Investigate system behavior
Find a trace
Dependencies
Start time
End time
Analyze Dependencies
data_quality_report service
backgroud servie
wechat_join service
data_ingestion service
system_tag service
maindata service
Duration:
Services:
Depth:
Total Spans:
JSON
Expand All
Collapse All
backgroud servie x2
contract service x2
customize_tag service x1
data_ingestion service x3
data_quality_report service x2
maindata service x3
system_tag service x1
wechat_join service x1

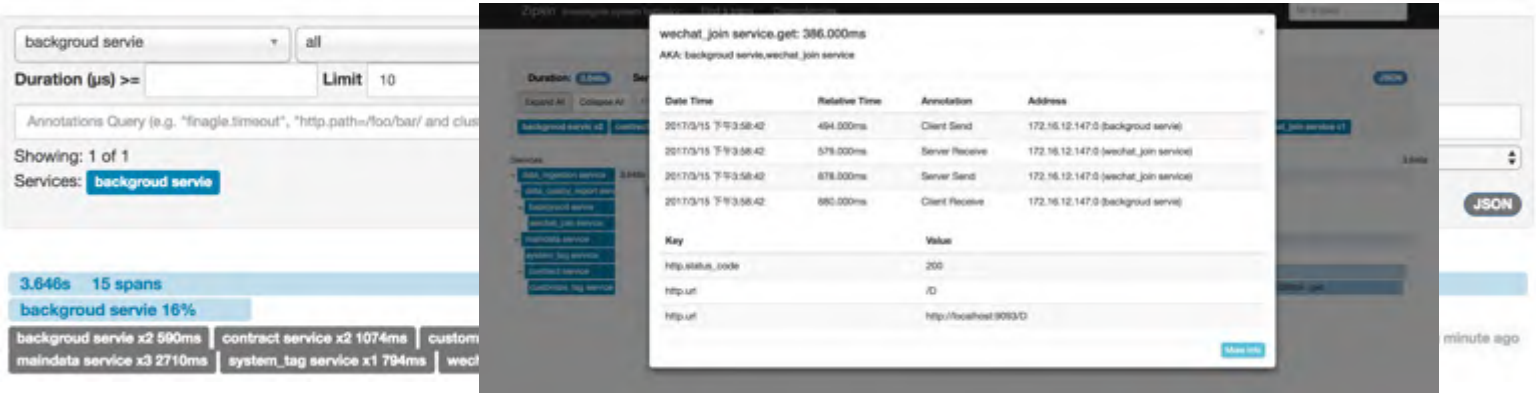
backgroud servie
all
Duration (μs) >=
Limit
10
Annotations Query (e.g. "finagle.timeout", "http.path=/foo/bar/ and clus
Showing: 1 of 1
Services:
backgroud servie
3.646s 15 spans
backgroud servie 16%
backgroud servie x2 590ms
contract service x2 1074ms
maindata service x3 2710ms
system_tag service x1 794ms
wechat_join service.get: 386.000ms
AKA: backgroud servie,wechat_join service
Date Time
Relative Time
Annotation
Address
Client Send
Server Receive
Server Send
Client Receive
Key
Value
http.status_code
200
http.url
/D
JSON
minute ago

有什么问题？

- 基于Spark Job离线绘制拓扑图，实时性不好
- Zipkin + Brave功能比较单一，只有调用链信息
- Zipkin需要依赖被监控框架或者中间件的interceptor机制，代码入侵性较强，需要对现有系统进行配置的改造

融数微服务框架监控第二代 - Pinpoint

PinPoint 特点

- 与Zipkin一样基于Google Dapper构建
- 基于Java Instrument技术，代码无入侵
- Plugins机制，方便扩展
- 支持模块多
- 虚拟机状态监控

Supported Modules

- JDK 6+
- Tomcat 6/7/8, Jetty 8/9, JBoss EAP 6, Resin 3/4
- Spring, Spring Boot
- Apache HTTP Client 3.x/4.x, JDK HttpConnector, GoogleHttpClient, OkHttpClient, NingAsyncHttpClient
- Thrift Client, Thrift Service, DUBBO PROVIDER, DUBBO CONSUMER
- MySQL, Oracle, MSSQL, CUBRID, DBCP, POSTGRESQL, MARIA
- Arcus, Memcached, Redis, CASSANDRA
- iBATIS, MyBatis
- gson, Jackson, Json Lib
- log4j, Logback

Third party agents/plugins

These include agents and plugins that are not merged into this repository.
Take a look at them if you are interested and would like to help out.

- Agents
  - NodeJS agent - https://github.com/peaksnail/pinpoint-node-agent
- Plugins
  - Websphere - https://github.com/sjmittal/pinpoint/tree/cpu_monitoring_fix/plugins/websphere
  - Hystrix - https://github.com/jiaqifeng/pinpoint/tree/dev-hystrix-plugin/plugins/hystrix
  - Kafka - https://github.com/jiaqifeng/pinpoint/tree/dev-plugin-kafka/plugins/kafka
  - RabbitMQ - https://github.com/jiaqifeng/pinpoint/tree/dev_plugin_rabbitmq/plugins/rabbitmq
  - RocketMQ - https://github.com/ruizlake/pinpoint/tree/master/plugins/rocketmq

PinPoint 架构介绍

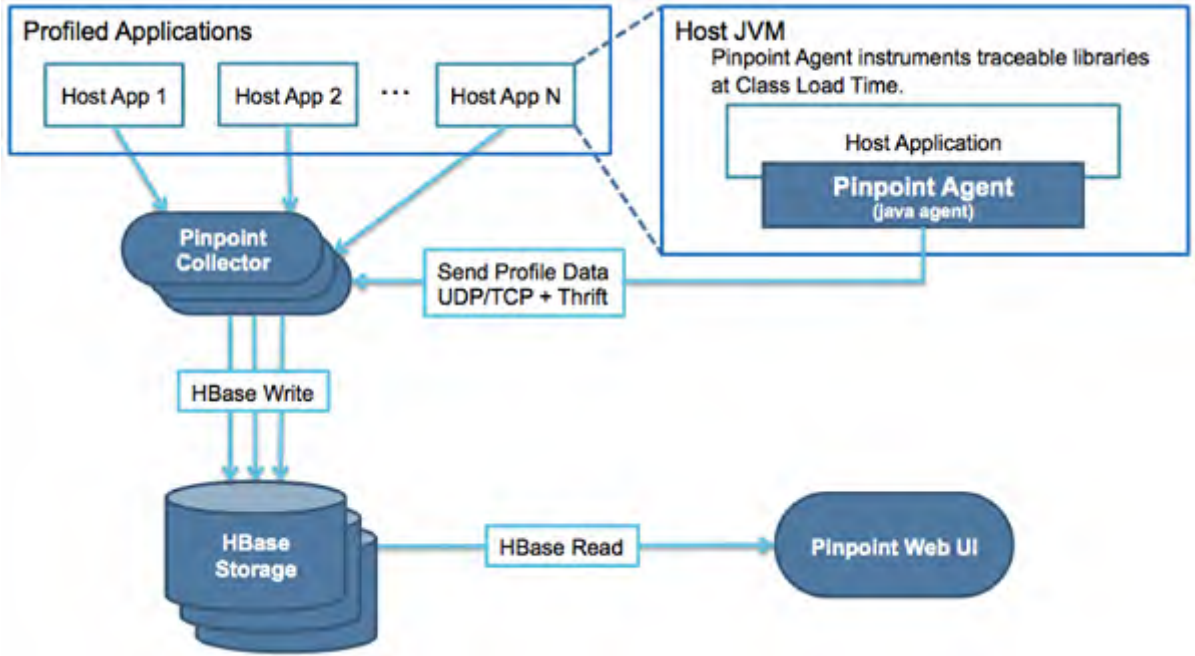

我们对Pinpoint的扩展和改造

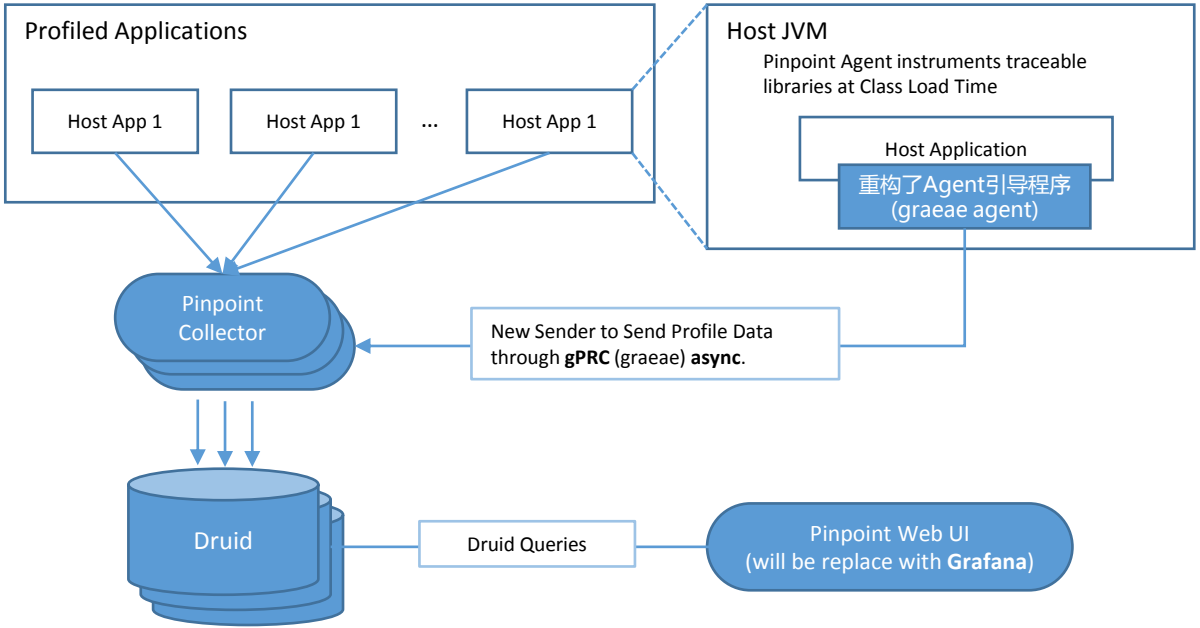

- 通信机制异步化调整
- 探针引导程序premain改造
- gRPC探针

基于Pinpoint的Graeae监控效果

实施微服务的建议

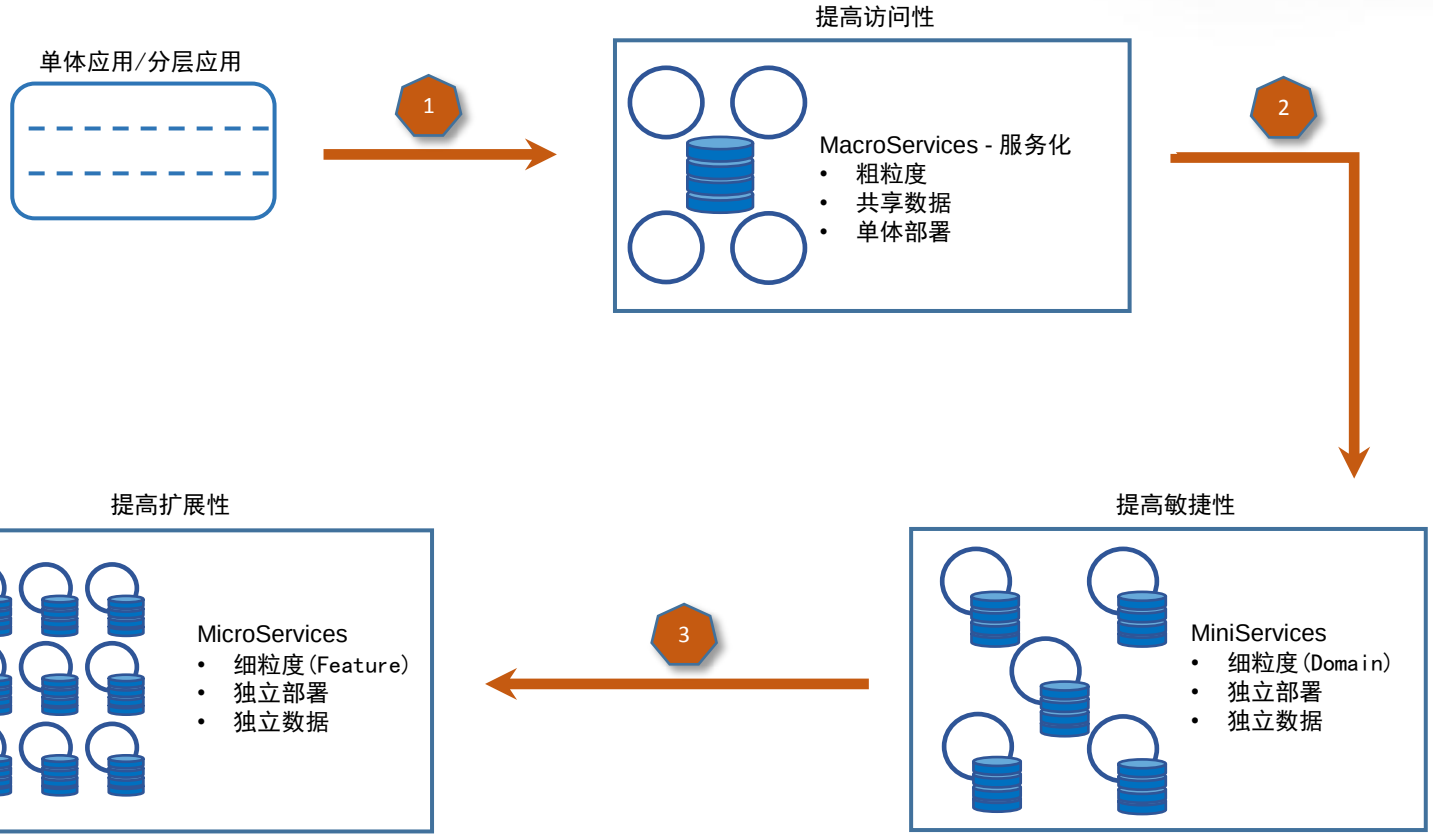
单体应用/分层应用
1
提高访问性
MacroServices - 服务化
• 粗粒度
• 共享数据
• 单体部署
2
提高敏捷性
MiniServices
• 细粒度(Domain)
• 独立部署
• 独立数据
3
提高扩展性
MicroServices
• 细粒度(Feature)
• 独立部署
• 独立数据

实施微服务的建议……

CQRS and Event Sourcing

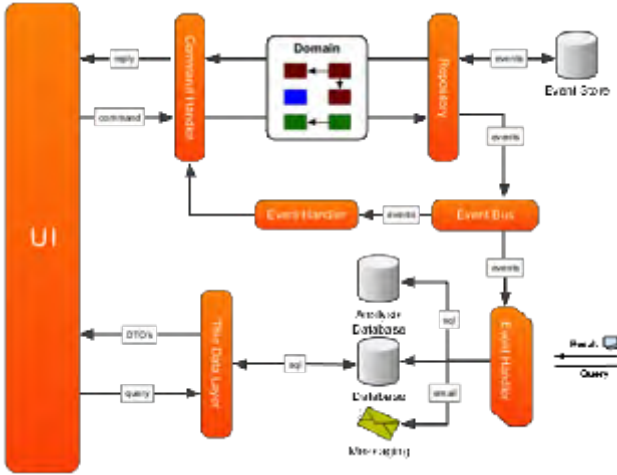

Axon Framework

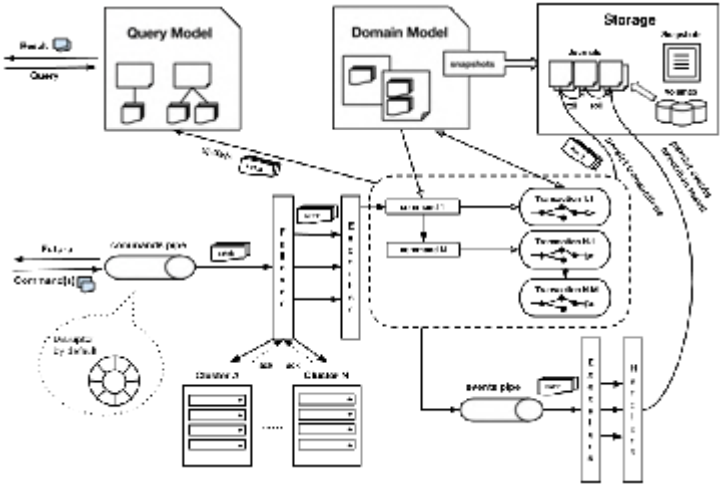

Reveno

Agenda

- 融数数据基于gRPC的微服务框架介绍
- 融数数据微服务治理和监控
- **基于K8S的微服务构建、开发和部署**
- 打造适合微服务的技术团队

融数数据微服务部署平台概览

融数部署平台构建在kuberntes上，而kuberntes搭建在openstack私有云环境上

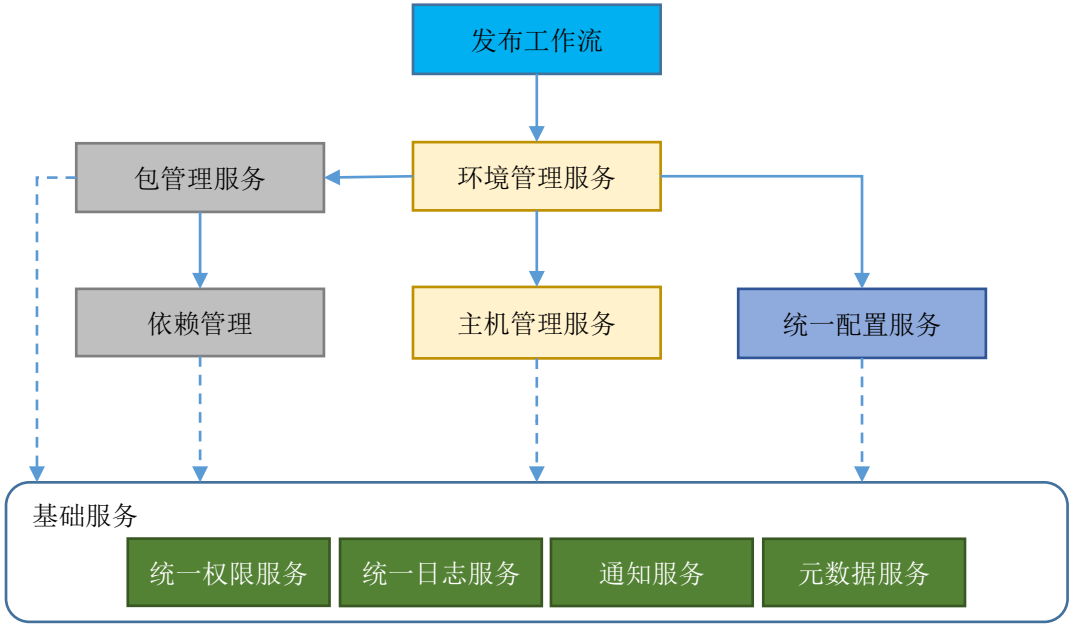

基于元数据构建持续部署平台...

- 抽象**包**的概念
  - **构建包** – 描述代码、依赖和配置
  - **部署包** – 不同构建包的组合，描述每次部署所需要的不同包的版本的集合
- **版本化一切** – 编译、构建、测试、部署同源，方便回滚
  - 代码版本
  - 构建版本
  - 发布版本
  - 配置版本
- **逻辑环境和物理环境** – 一次构建，多次部署
  - 逻辑环境描述部署需要的包、配置以及所需资源的MANIFEST
  - 物理环境适配不同的主机环境（容器或者虚拟机），从而承载逻辑构建

... 部署元数据概念模型: 包

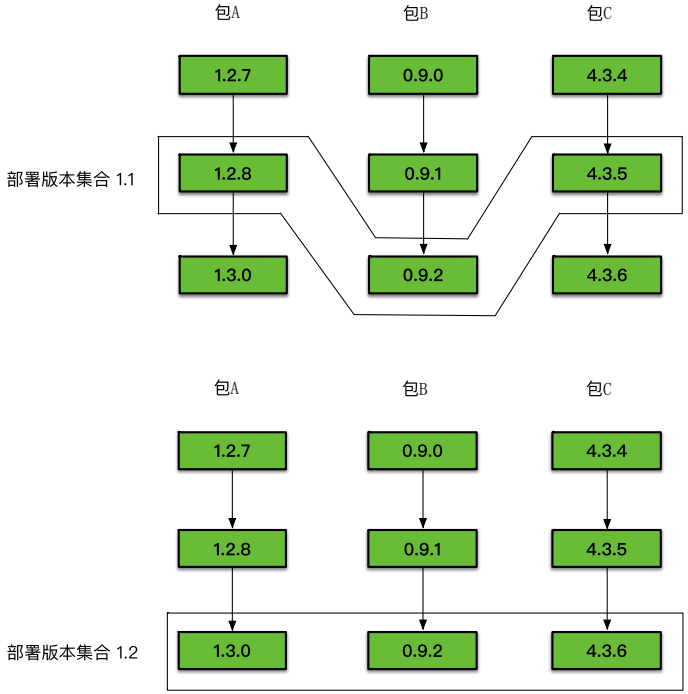
包A
包B
包C
1.2.7
0.9.0
4.3.4
部署版本集合 1.1
1.2.8
0.9.1
4.3.5
1.3.0
0.9.2
4.3.6
包A
包B
包C
1.2.7
0.9.0
4.3.4
1.2.8
0.9.1
4.3.5
部署版本集合 1.2
1.3.0
0.9.2
4.3.6

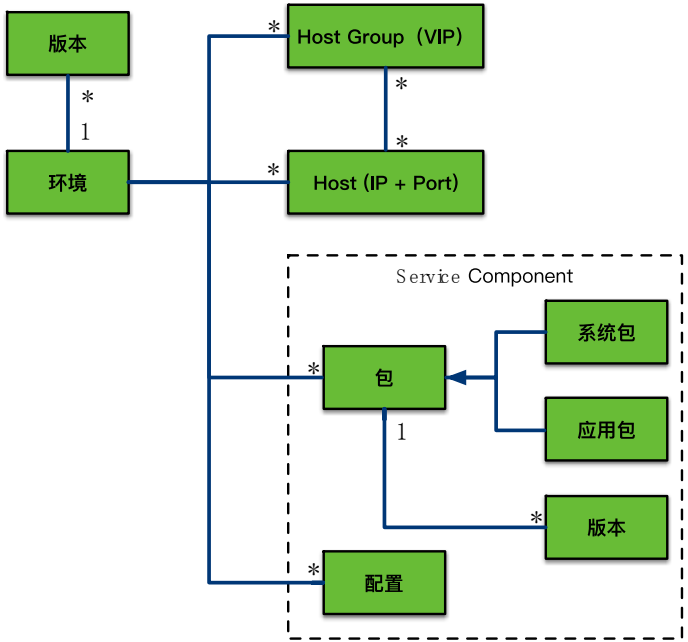
版本
*
1
环境
*
Host Group（VIP）
*
*
Host (IP + Port)
Service Component
系统包
包
*
应用包
1
*
版本
*
配置

... 部署元数据概念模型: 环境

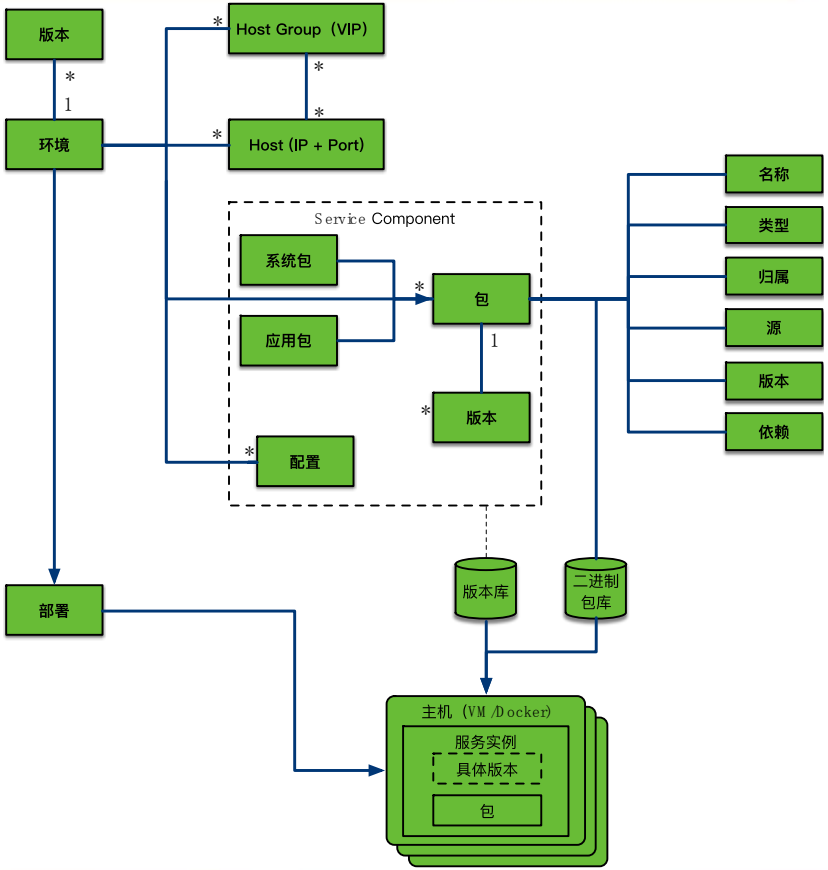

使用k8s部署微服务概述

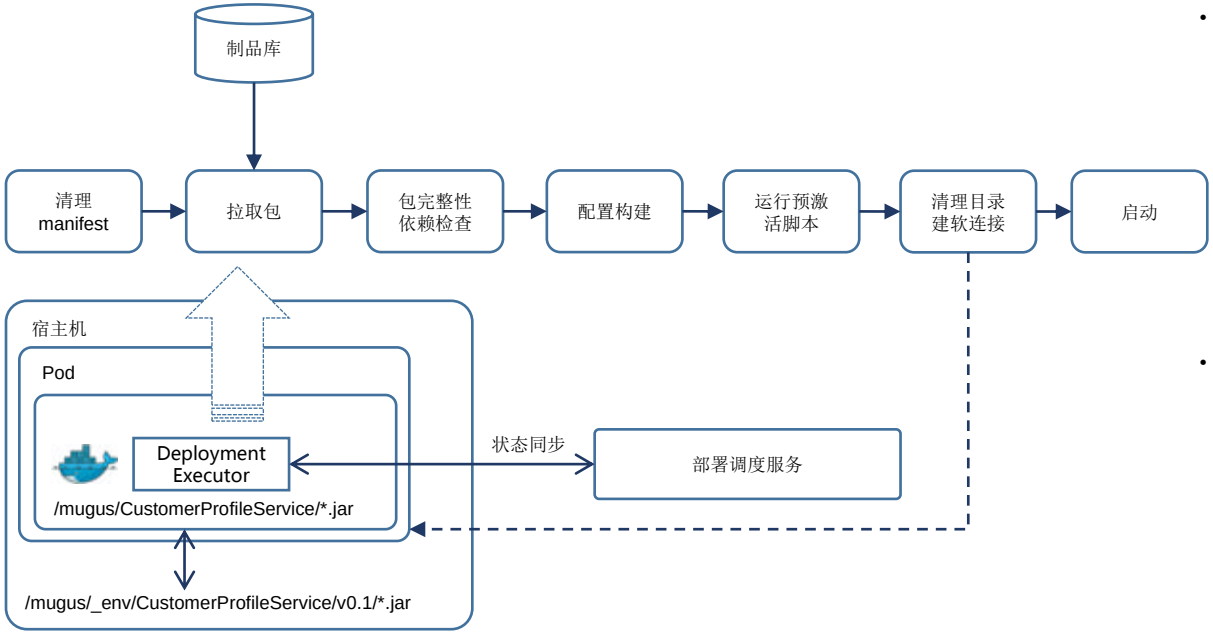

- 服务部署结构
  - Pod包含proxy和service endpoint instances
  - 通过service的cluster ip作为vip对外提供统一出口
  - 同一个服务可以部署在不同的pod上，共享数据库
  - 本地包缓存
    - 包的checksum
    - 在docker中的包通过宿主机共享目录存储
    - 不构建和部署的docker镜像，而只是通过k8s拉起基础docker镜像
- 使用Process Manager控制部署过程并报告部署状态
  - 构建于基础镜像之内
  - 过程分为
    - manifest清理，确保每个包都是最新的
    - pull包
    - 包完整性和依赖检查
    - 根据配置元数据构建配置
    - 运行预激活脚本
    - 删除并重建环境对应的目录结构，确保部署使用新的包集合
    - 启动程序

融数微服务在k8s上的部署逻辑架构

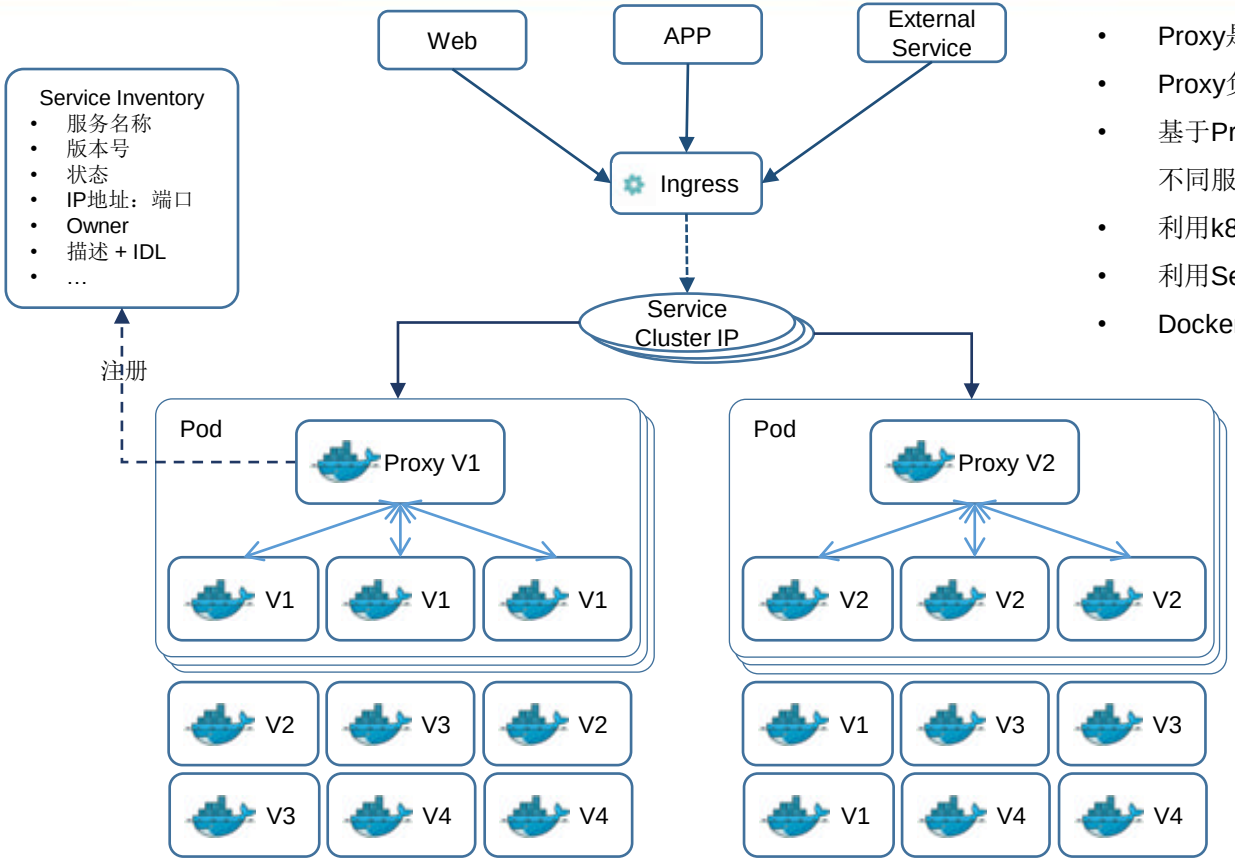

- Proxy是基于Netty的反向代理，是Client的访问入口点
- Proxy负责服务实例的信息收集并向Service Inventory注册
- 基于Proxy的路由功能结合语义化版本(**X.Y.Z**)的概念进行不同服务的版本管理
- 利用k8s简化部署
- 利用Service绑定(Virtual IP)来简化客户端寻址
- Docker通过挂载宿主机目录，增量拉取部署包

融数基于k8s的部署详细交互

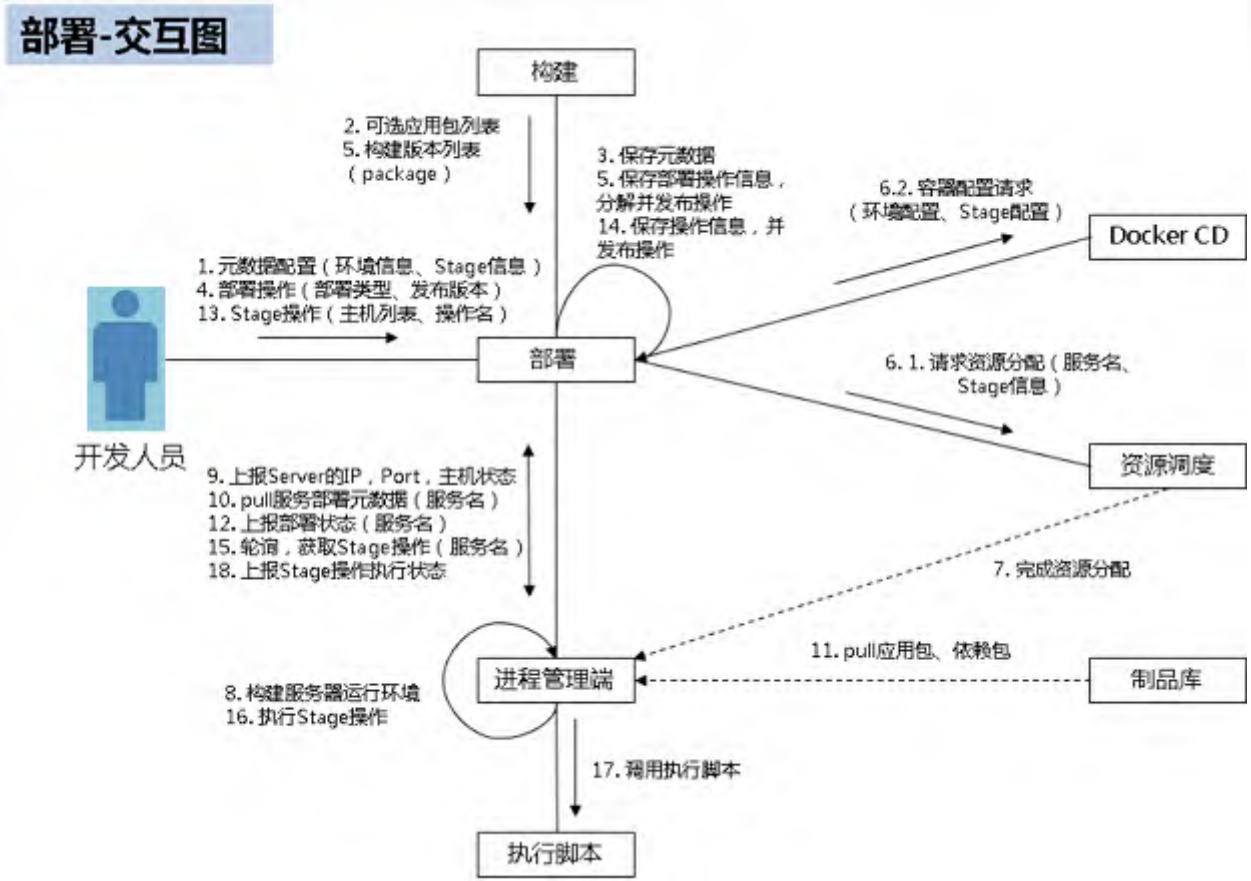

融数微服务在k8s上的部署示例

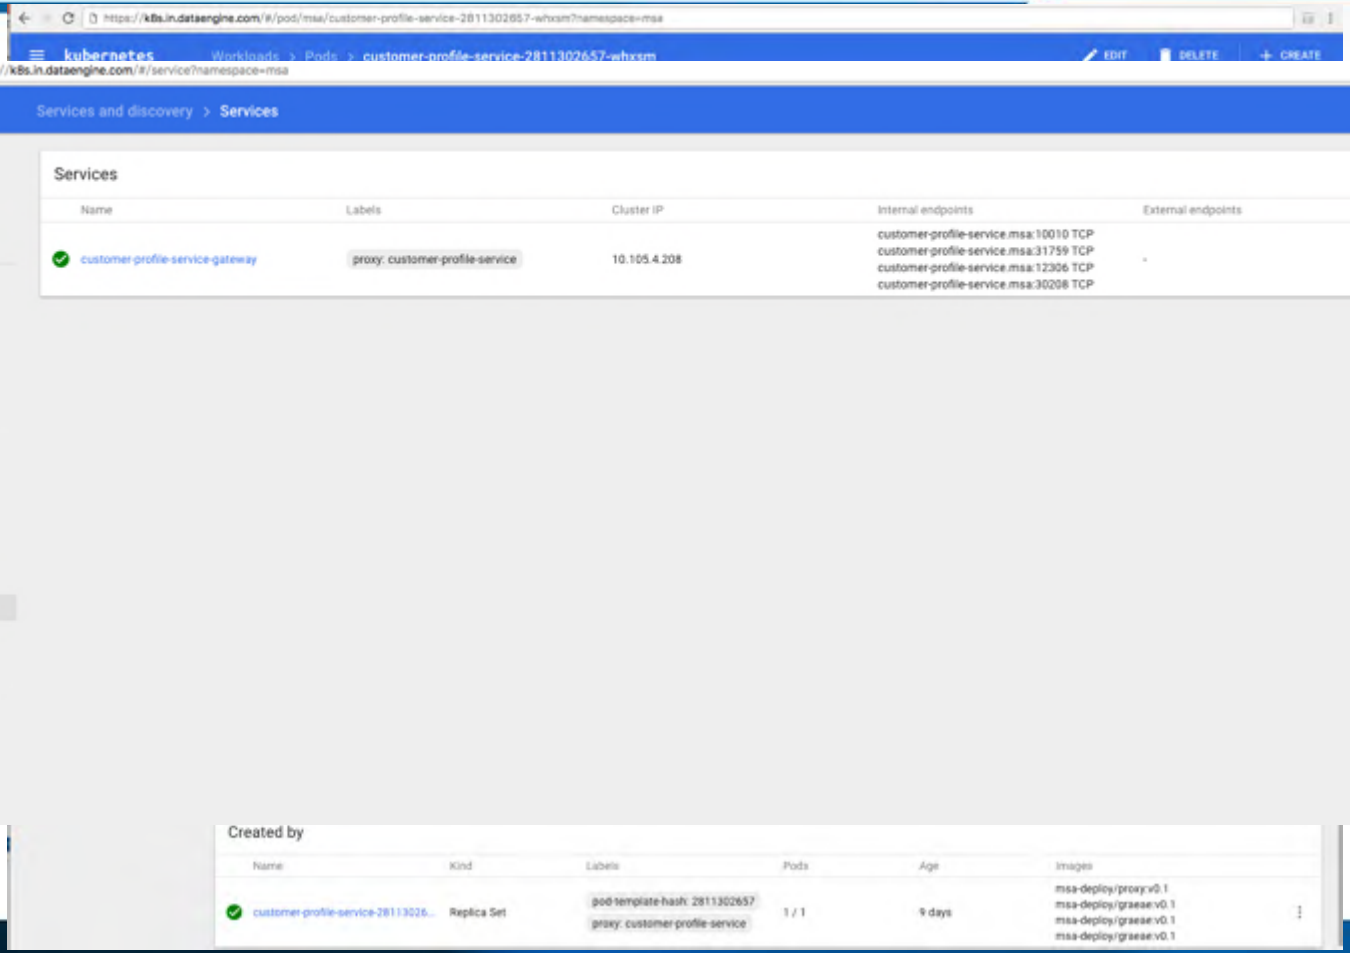

Agenda

- 融数数据基于gRPC的微服务框架介绍
- 融数数据微服务治理和监控
- 基于K8S的微服务构建、开发和部署
- **打造适合微服务的技术团队**

拥有了一套服务开发框架，我们就拥有了微服务？

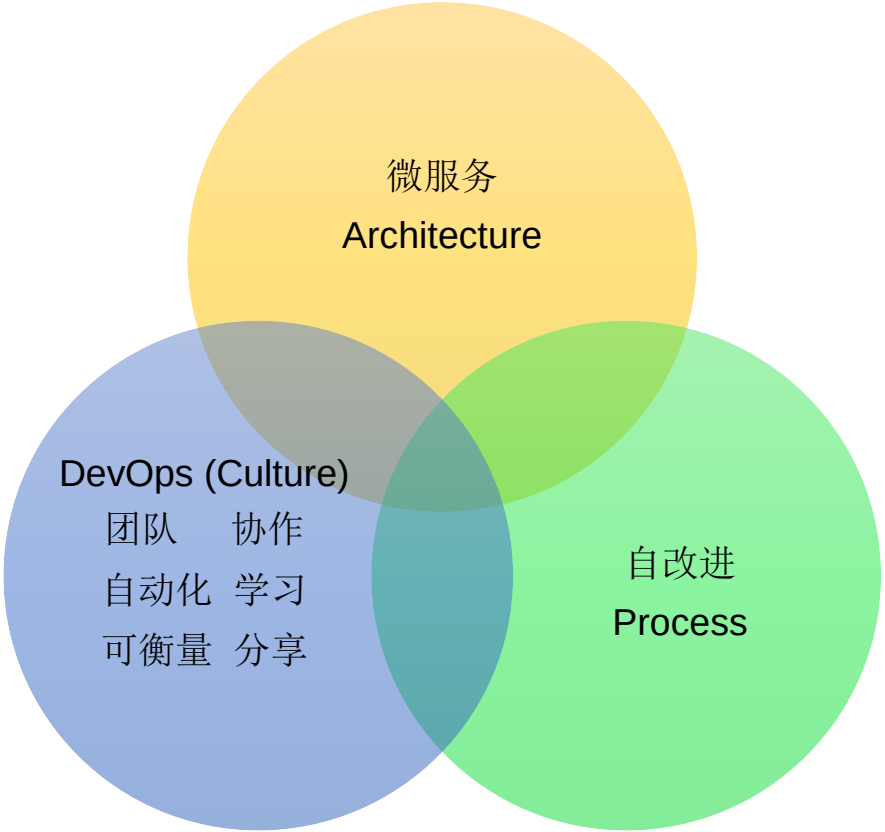

微服务不仅仅是技术架构，更是一种文化和自改进的交付模式，DevOps是微服务的基础

微服务为什么需要DevOps

- 微服务的主要目的是为了敏捷
- 微服务表达了原子核心业务（Feature），但是也带了了新的挑战-将单体应用的复杂性从程序内部转移到了服务组件之间
- 因此，根据Martin Fowler提出的观点，微服务需要具备以下三个重要能力：
  - 硬件资源是否能够快速到位 – 环境管理的能力
  - 是否具备了微服务监控能力 – 分布式监控能力
  - 是否具有快速的开发部署流程 – 敏捷成熟度和自动化程度
- 服务粒度的细化，导致团队间的合作和沟通变得困难，当发生问题时，我们希望问题快速的暴露并得到迅速的解决，而DevOps是开发和运维团队的粘合剂，能够促进合作，提升解决问题的效率。

DevOps is CAMS

Culture
Automation
Measurement
Sharing

Culture Over Tools

DevOps works for startups, but enterprises need it more

以业务为核心，打造全栈小团队

- 业务驱动的团队划分
- 业务团队和技术团队水平沟通
- 向上汇报
- 业务协调，解决依赖

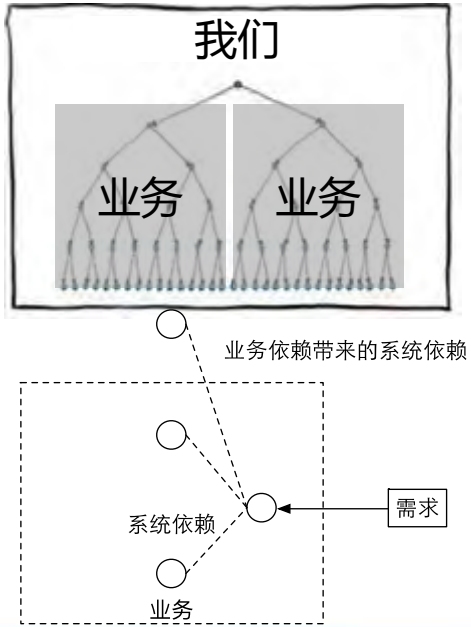

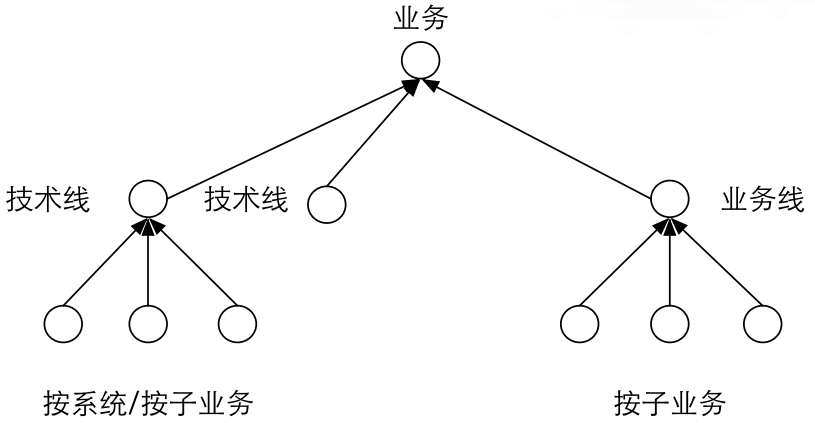

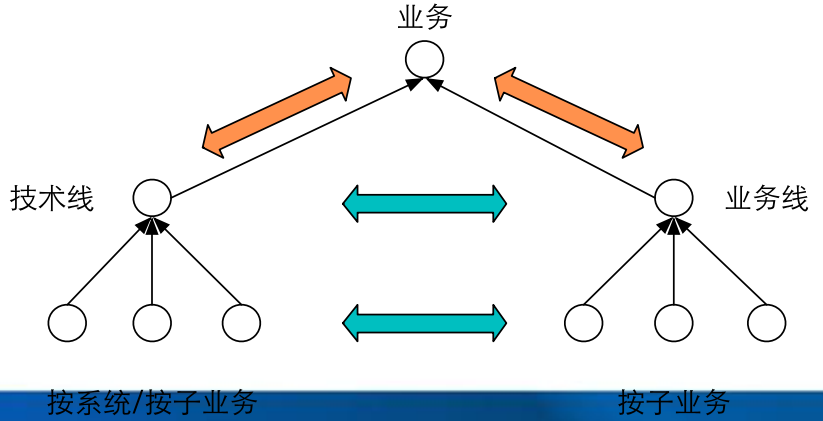

我们提倡什么样的文化

- 主人翁意识（Ownership）
- 行动力（Bias for Action）
- 吃自己的狗粮（Eat your dog food）
  - 工程师负责从需求调研、设计、开发、测试、部署、维护、监控、功能升级等一系列的工作，也就是说软件**工程师负责服务的全生命周期的所有工作**
  - **运维是团队成员的第一要务**，在强大的自动化运维工具的支撑下，软件工程师必须负责服务或者应用的 SLA
- 让开发人员参与架构设计，而不是架构师参与开发
  - 研发人员是Owner，对业务和团队负责
  - 强调抽象和简化，将复杂的问题分解成简单的问题，并有效解决，防止过度设计
  - 鼓励用新技术解决问题，但强调掌控力

建立高效的开发+运维的生产和反馈闭环

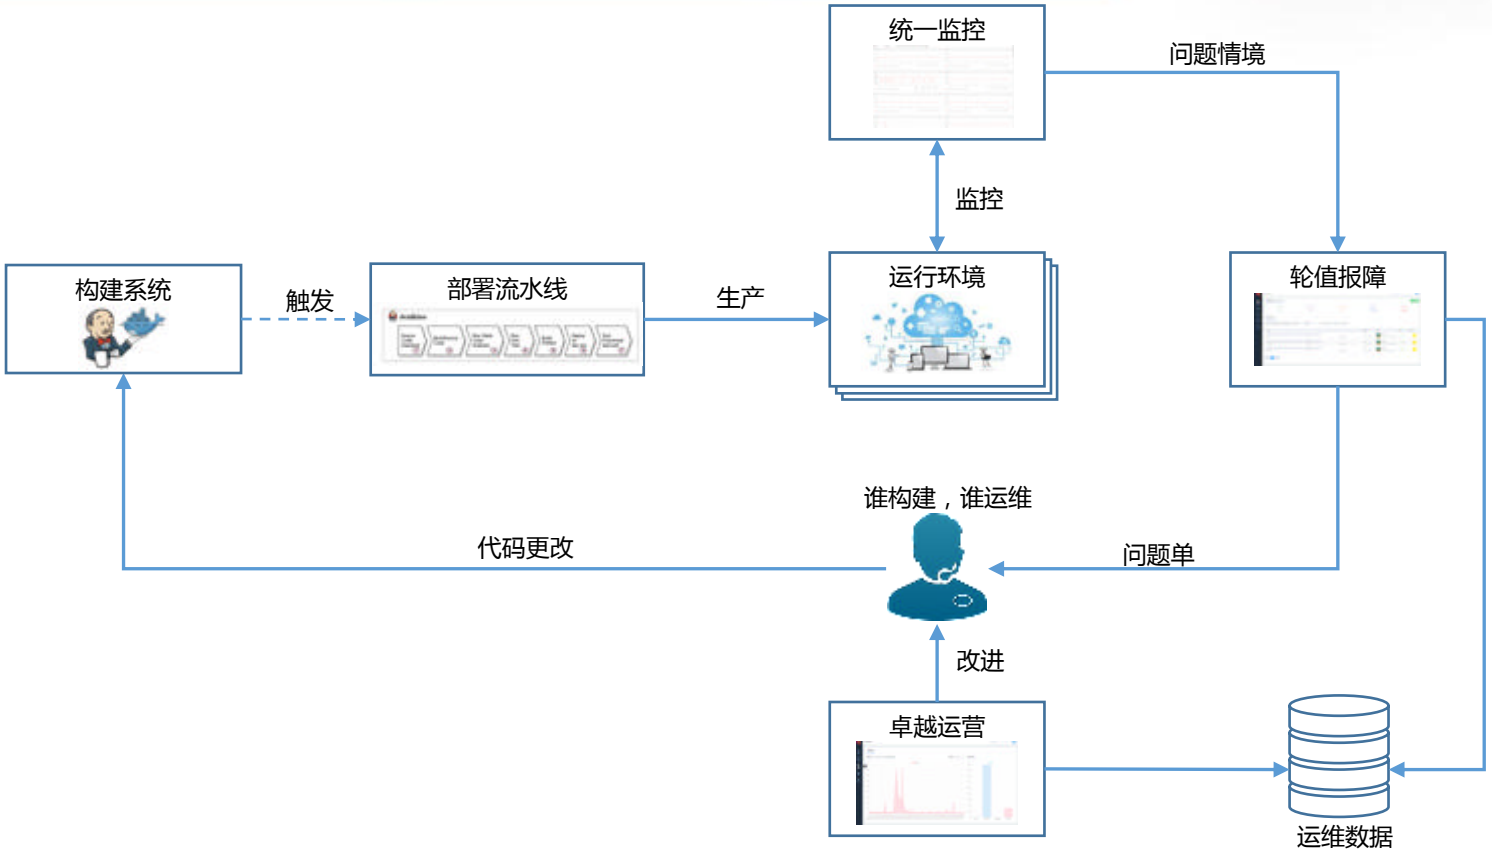

围绕智能报障的自改进生态

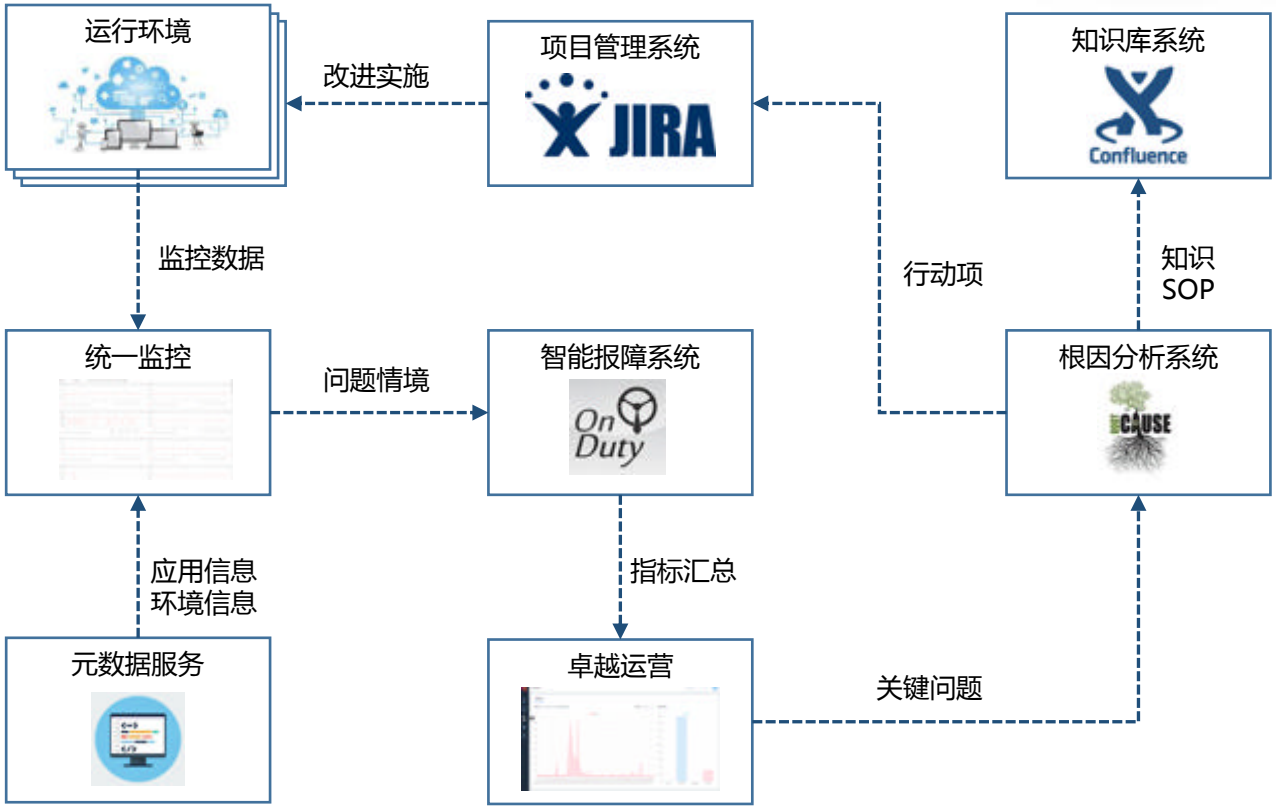

逐步构建卓越运营体系

遇到问题，迅速跟进、快速解决

- 定制 SLA
- 7X24轮值
- 时效监控
- 多渠道通知
- 上报机制

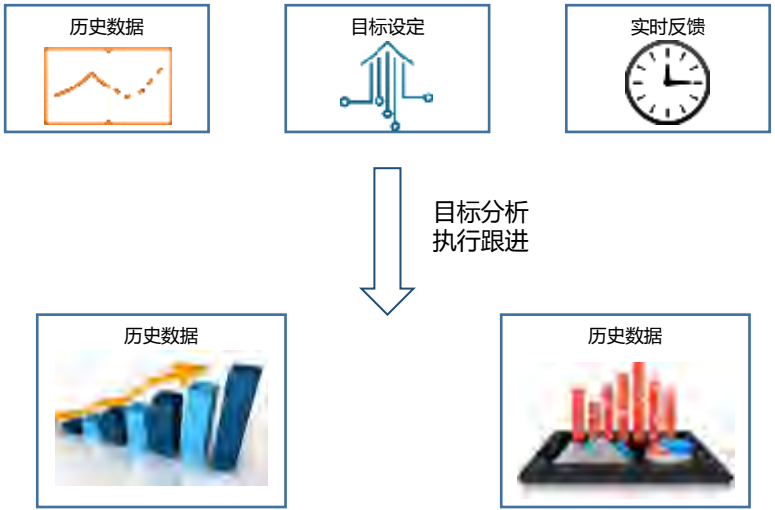

在业务增加（系统功能增加）的前提下，每年的ticket数减少10%
相同系统维护的人员减少10%

演讲完毕，谢谢大家