

Kubernetes and Democratizing Infrastructure

Kubernetes项目与基础设施“民主化”的探索

Lei Zhang

Kubernetes Community

36讲·从技术到管理的进阶之路

朱赞

计算机博士
Airbnb 技术经理

¥68 / 36期

新人立减 ¥30



从0开始学架构

资深技术专家的
实战架构心法

李运华

资深技术专家

拼团价

¥79

3人成团

原价: 99



Java核心技术36讲

Oracle 首席工程师

带你修炼 Java 内功

杨晓峰

Oracle 首席工程师

拼团价

¥58

3人成团

原价: 68



QCon

上海站

全球软件开发大会【2018】

2018年10月18-20日

8折优惠进行中



SPEAKER INTRODUCE


Lei Zhang Kubernetes Community

- 浙江大学, HyperHQ, Microsoft Research (MSR)
- 阿里巴巴集团 技术顾问 & 高级技术专家



Kubernetes的项目画像

- 目标用户： 分布式应用的开发者
- 目标集群规模： 5000， 舒适区： 100~1000
- 核心能力： 提供基于容器的设计模式与编程规范
- 功能/性能取舍： 功能性需求 > 性能性需求
- 用户评价：
 - “太复杂了！”



Kubernetes中最复杂的是： yaml文件

yaml文件 = 声明式API

- 什么是声明式API?
- docker service create --name nginx --replicas 2 nginx
- docker service update --image nginx:1.7.9 nginx
- 命令式命令行操作
- 有一个与yaml文件对应的API实体 (Entity)
- kubectl create -f nginx.yaml
- kubectl replace -f nginx.yaml
 - 命令式配置文件操作
- 别逗，到底什么才是声明式API?

```
1  apiVersion: apps/v1
2  kind: Deployment
3  metadata:
4    name: nginx-deployment
5  spec:
6    selector:
7      matchLabels:
8        app: nginx
9    replicas: 2
10   template:
11     metadata:
12       labels:
13         app: nginx
14     spec:
15       containers:
16       - name: nginx
17         image: nginx:1.7.9
```


声明式API

- `kubectl apply -f nginx.yaml`
- // 将image改成nginx:1.7.9
- `kubectl apply -f nginx.yaml`
- 区别?
 - `kubectl replace = replace`
 - i.e. 1 writer
 - `kubectl apply = patch`
 - i.e. 1+ writers

- **Kubernetes声明式API的本质:**

- 在Etcd中维护(CRUD)了一个API实体
- 允许有**多个API写端**，以**PATCH**的方式对API实体进行修改，而无需关心本地的原始yaml文件

Istio



自动化的proxy容器注入，是Service Mesh的“灵魂”所在

Initializer

```
1  apiVersion: v1
2  kind: ConfigMap
3  metadata:
4    name: envoy-initializer
5  data:
6    config: |
7    containers:
8      - name: envoy
9        image: lyft/envoy:845747db88f102c0fd262ab23
10       command: ["/usr/local/bin/envoy"]
11       args:
12         - "--concurrency 4"
13         - "--config-path /etc/envoy/envoy.json"
14         - "--mode serve"
15       ports: {}
16       resources: {}
17       volumeMounts:
18         - name: envoy-conf
19           mountPath: /etc/envoy
```

13 app: nginx

14 spec:

15 containers:

16 - name: nginx

17 image: nginx:1.7.9

oldData

On Pod add

Loop

```
newData.Containers = append(
  oldData.Containers,
  config.Containers,
)


patchBytes, err := strategicpatch.CreateTwoWayMergePatch(
  oldData,
  newData,
  v1beta1.Deployment{},
)

_, err = clientset.AppsV1beta1().Deployments(
  oldData.Namespace,
).Patch(
  oldData.Name,
  types.StrategicMergePatchType,
  patchBytes,
```

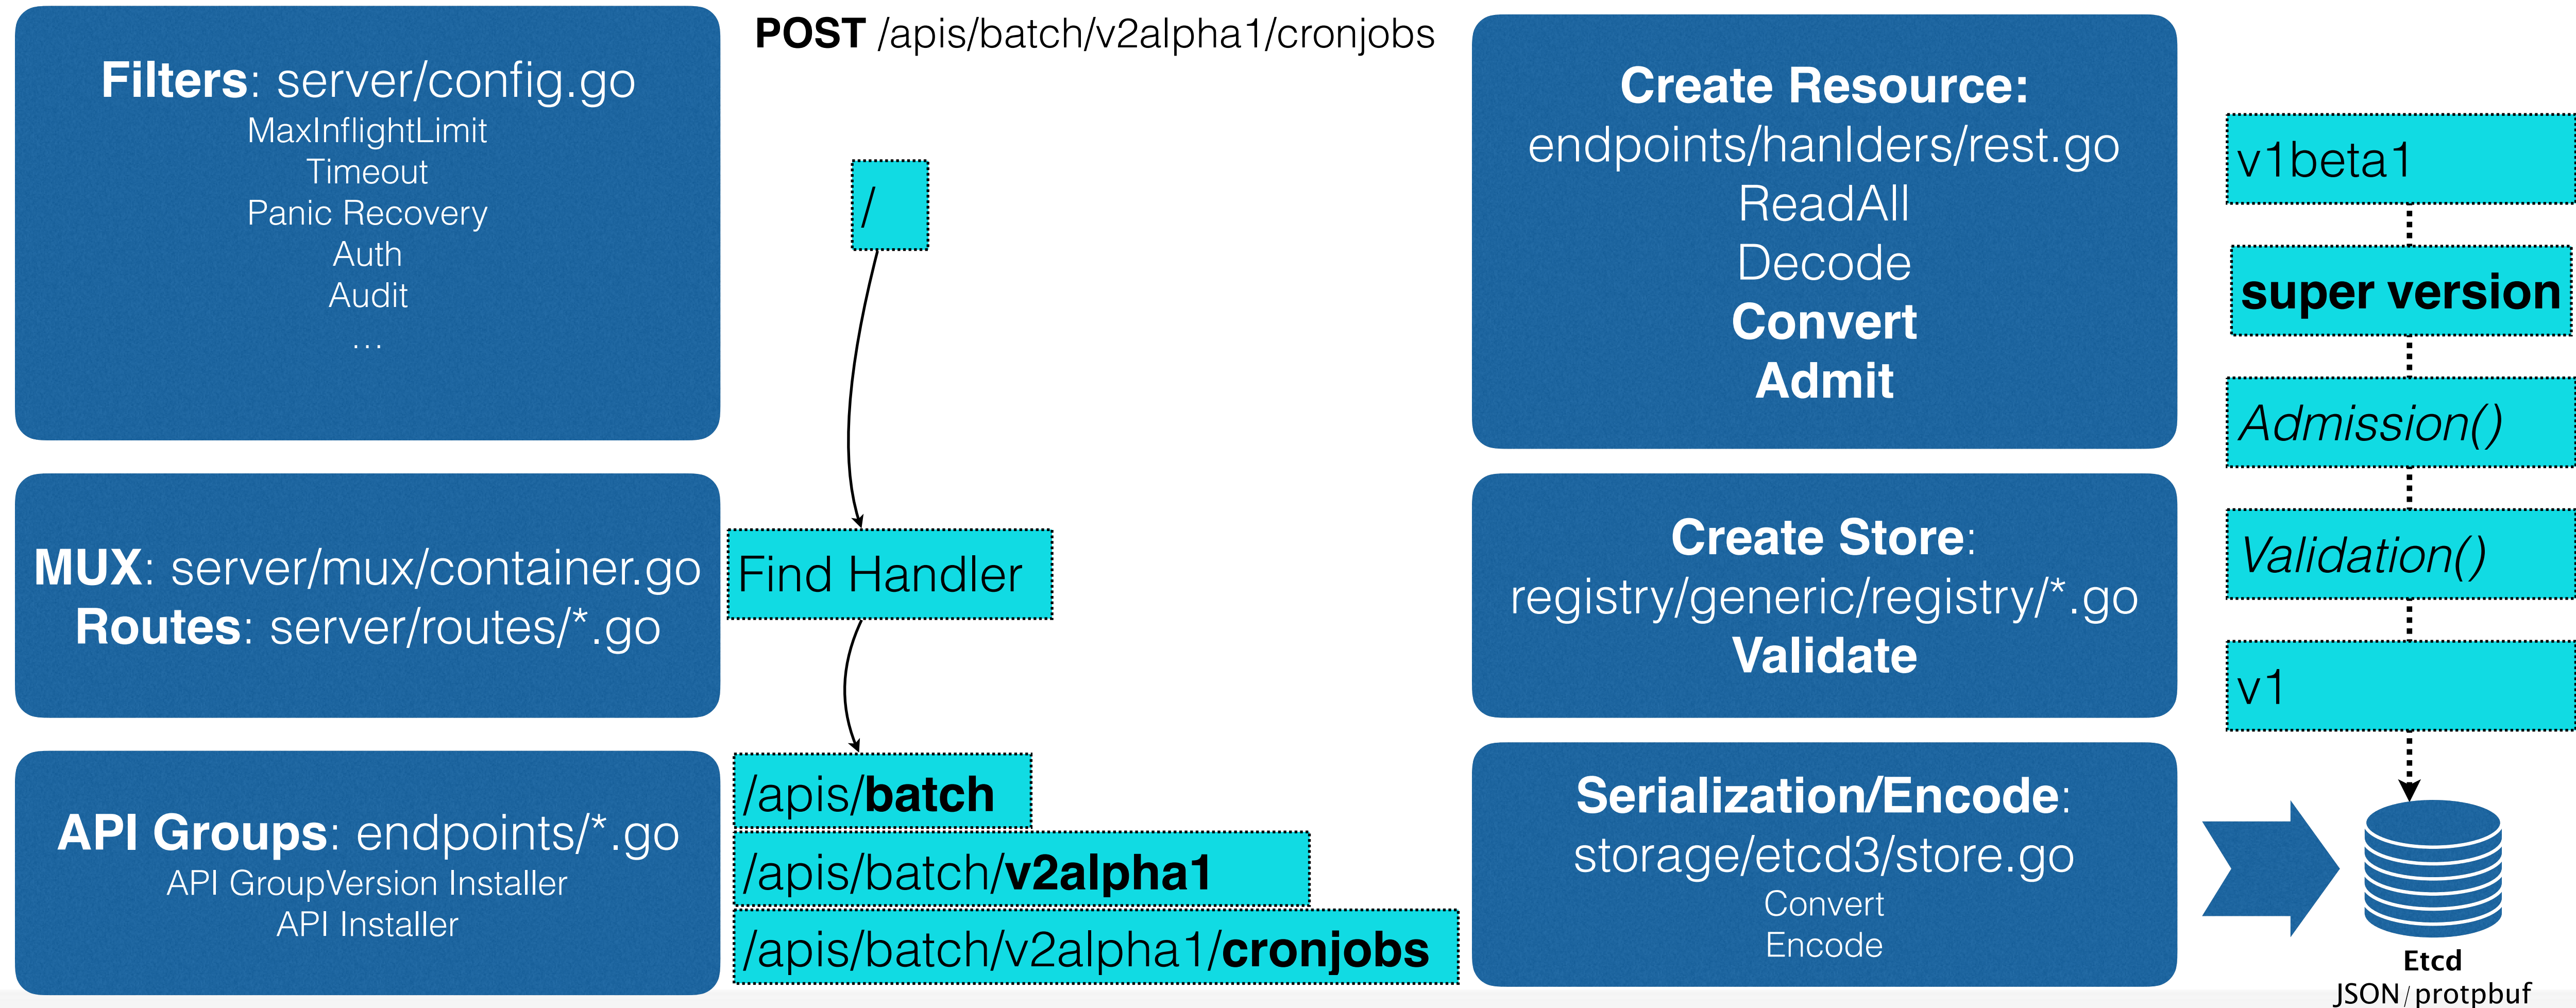
声明式API的意义

- 编程友好，而非最终用户友好
- 提供了一套面向**API**实体的编程模型
- 原因：生态！生态！生态！
- 这正是Kubernetes项目“复杂性”的根本来源！

Kubernetes的API资源模型



Kubernetes API Workflow



典型的用户诉求

- “如何在Kubernetes中添加新的API”?
- “如何在Etcd里保存一个我自己的API对象”?

Custom Resource Definition (CRD)


- 自定义API资源模型 (CRD) 举例：自定义Network
- kubectl apply -f network-crd.yaml
- kubectl apply -f my-network.yaml
- kubectl get network

```
apiVersion: apiextensions.k8s.io/v1beta1
kind: CustomResourceDefinition
metadata:
  # name must match the spec fields below,
  # and be in the form: <plural>.<group>
  name: network.crd.archsummit.com
spec:
  # group name to use for
  # REST API: /apis/<group>/<version>
  group: crd.archsummit.com
  # version name to use for
  # REST API: /apis/<group>/<version>
  version: v1
  # either Namespaced or Cluster
  scope: Namespaced
```

```
apiVersion: "crd.archsummit.com/v1"
kind: Network
metadata:
  name: my-new-network-object
```


NAME	AGE	
my-new-network-object	6s	"192.168.0.0/16" y: "192.168.1.1"

Kubernetes的API编程范式



Controller Pattern

- 即：Reconcile Loop, Kubernetes项目最基本的控制模型




声明式API实体

```
for {  
    desired := getDesiredState()  
    current := getCurrentState()  
    makeChanges(desired, current)  
}
```

主动获取
心跳/反馈
Metrics

...

Controller Deep Dive



Custom Controller

Kubernetes API Programming

- 对于给定的API Object
- Kubernetes会为用户自动生成
 - client, informer, lister
 - 并提供多个work queue的实现
- 用户需要编写的代码
 - controller, 以及controller中的sync()

```
// +genclient
// +k8s:deepcopy-gen:interfaces=k8s.io/apimachinery/pkg/


// Network is a specification for a Network resource
type Network struct {
    metav1.TypeMeta   `json:",inline"`
    metav1.ObjectMeta `json:"metadata,omitempty"`

    Spec   NetworkSpec   `json:"spec"`
    Status NetworkStatus `json:"status"`
}
```

CRD不是万能的

- 不应该被当作数据库使用
- CRD有性能瓶颈
 - API Object数量>1K，或者单个对象>1KB
 - 高频请求 (e.g. > 10 req/s)
- 暂不支持protobuf
- 不支持命令式API操作
- 需要等待API最终返回，或者检查API完成状态
- API没办法用API Object的方式建模
- 需要实现完整的Kubernetes API功能
- **API Aggregation**

API Aggregation (AA)



Kubernetes的API层的演化

- 集中式的API组件 $\implies$ SDK化的API框架
- 催生出以Kubernetes API为基础的、容器化分布式应用生态
 - e.g. Operator, CRD, Istio, Serverless, Rook.io, Vitess, Google Cloud工具集 $\sim$ 整个CNCF


kube-scheduler

- **Cache化**


- 调度全部基于缓存来决策
- 使用Informer机制来同步缓存
- 无锁
- Optimistic Bind
- Http Extender

- **Framework化**

- Status: Draft



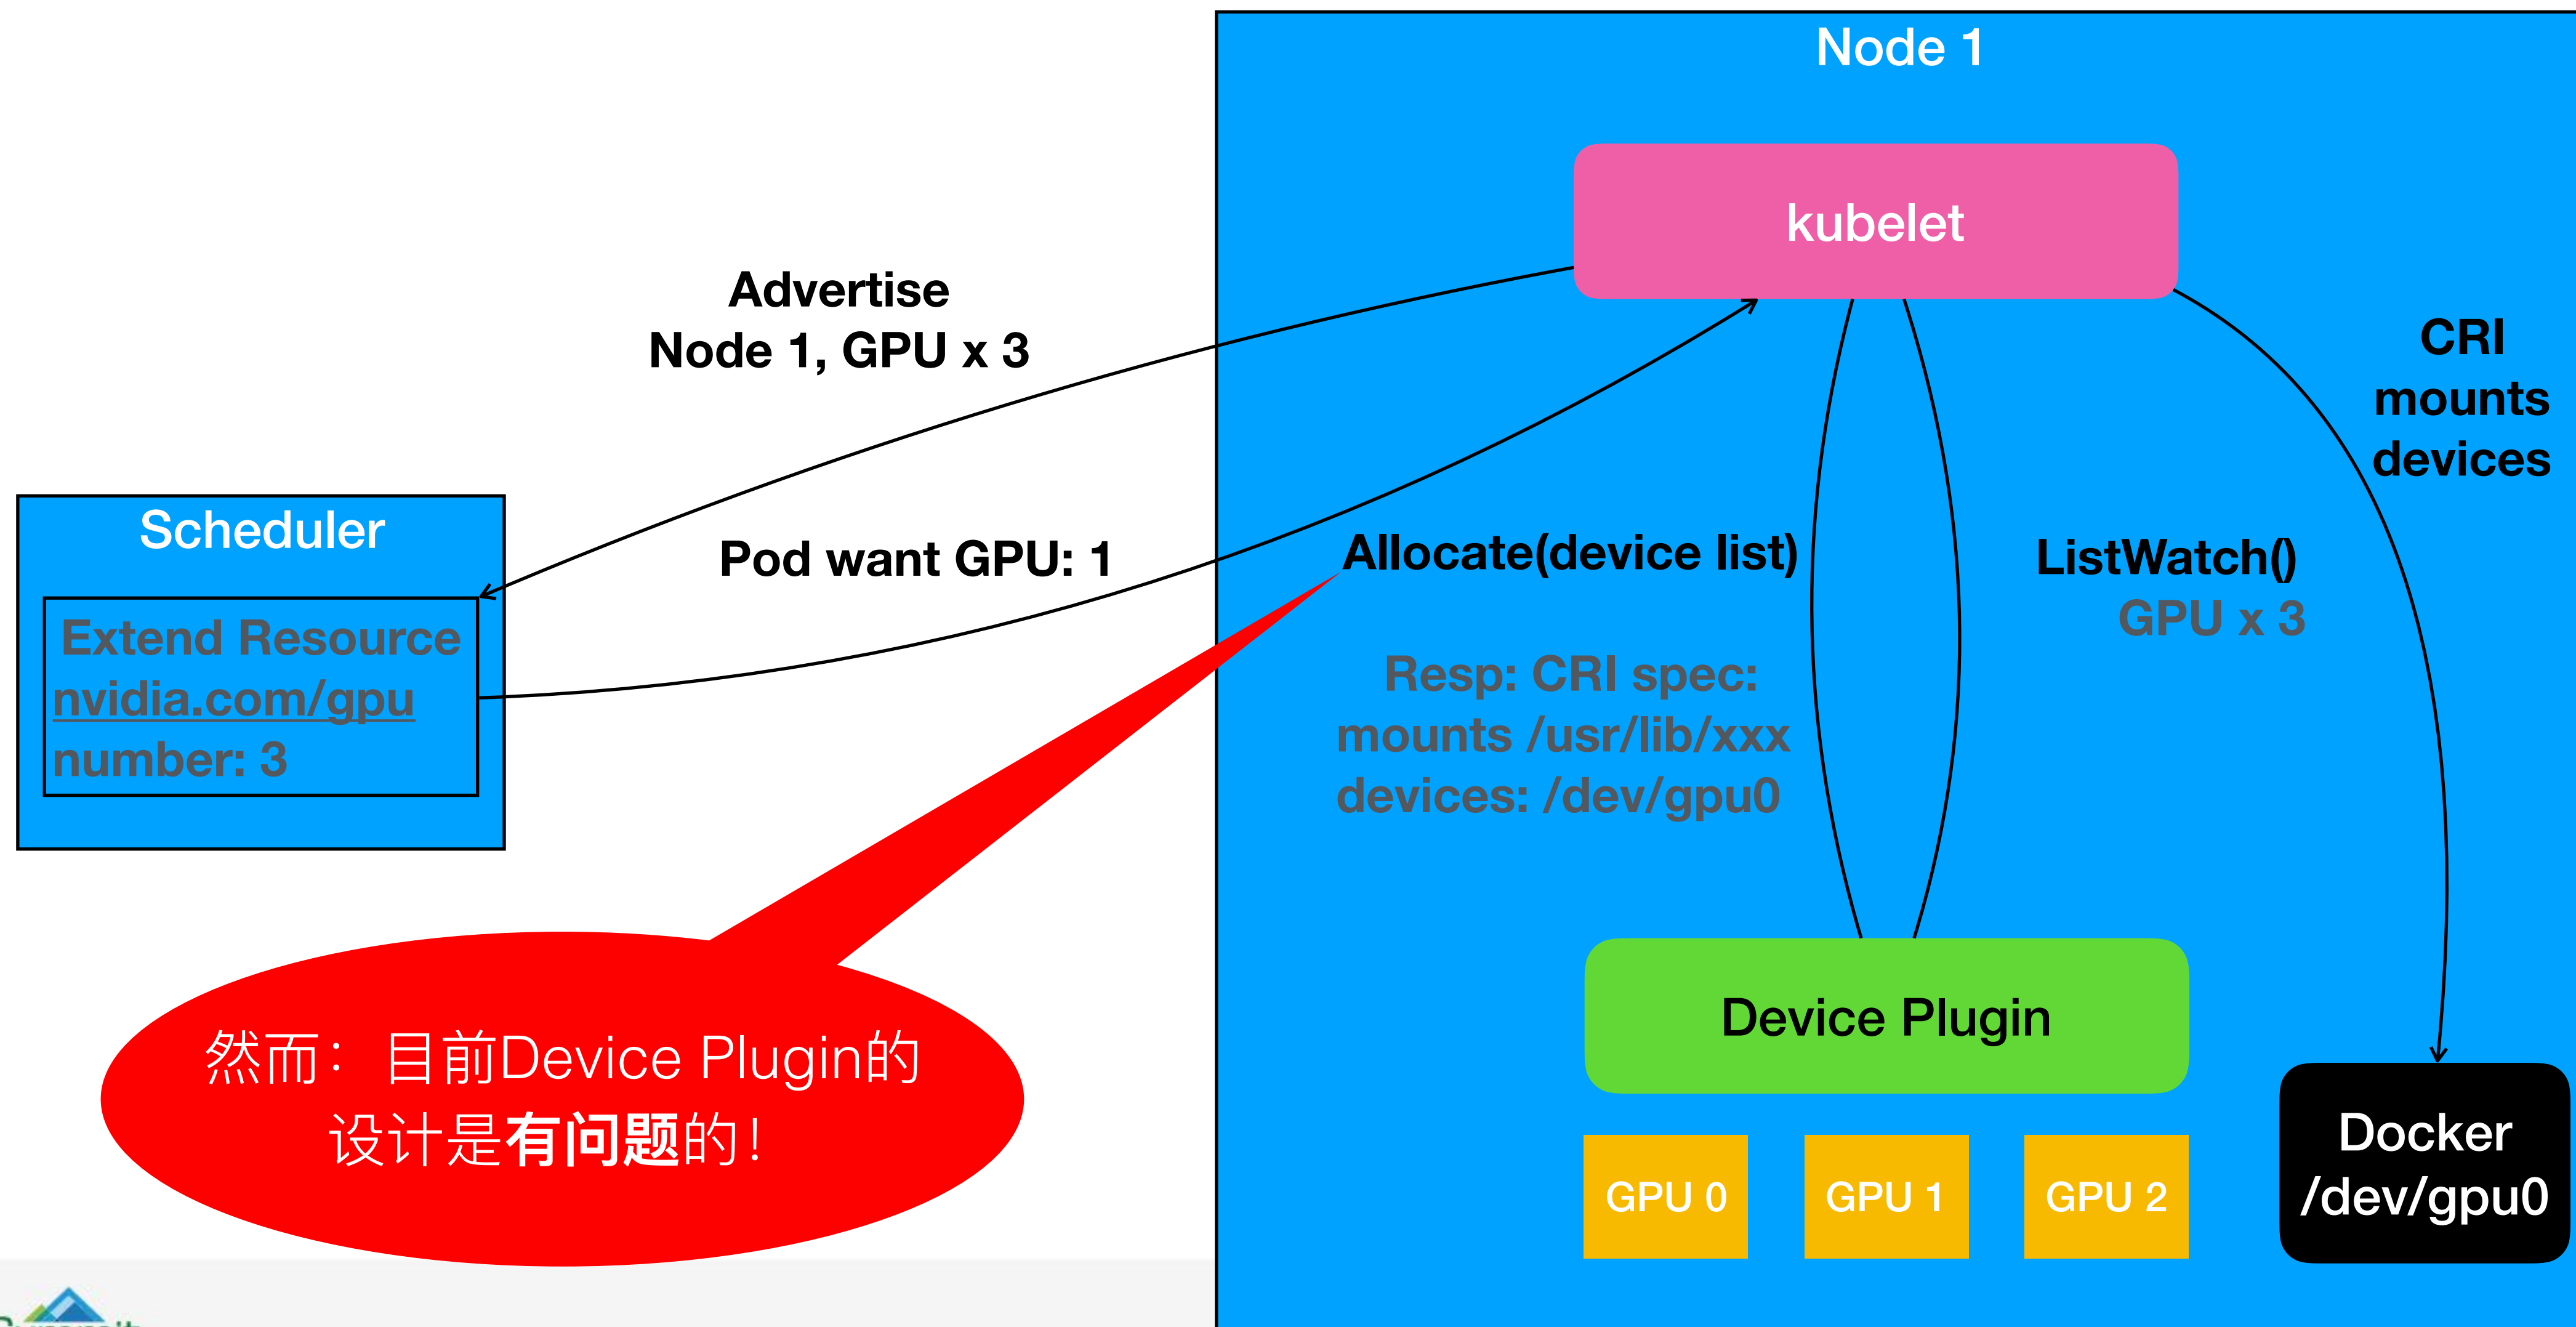
kube-scheduler的Framework化



DevicePlugin

- 以GPU支持为例
 - < v1.9: 直接跟Docker绑定
 - kubelet直接hack dockershim, 在发起Docker API之前inject注入的GPU device和mount目录
 - v1.9+: 使用CRI和grpc接口
 - Inject CRI spec

DevicePlugin的设计



DevicePlugin的问题出在哪?

- ```
struct ComputeResource {
 metav1.ObjectMeta
 Spec ComputeResourceSpec
 Status ComputeResourceStatus
}
struct ComputeResourceSpec {
 // For node-level resource, this is the name of the Node that owns this ComputeResource.
 // For cluster-level resource, this field is empty.
 NodeName string
 // Raw resource name. E.g.: nvidia.com/gpu
 ResourceName string
 // gpuType: k80
 // zone: us-west1-b
 // Note Kubelet adds a special property corresponding to the above ResourceName field.
 // This will allow a single ResourceClass (e.g., "gpu") to match multiple types of
 // resources (e.g., nvidia.com/gpu and amd.com/gpu) through general set selector.
 Properties map[string]string
}
struct ComputeResourceStatus {
 Capacity resource.Quantity
}
```

```
// +nonNamespaced=true
// +genclient=true

type ResourceClass struct {
 metav1.TypeMeta
 metav1.ObjectMeta
 Spec ResourceClassSpec
 // +optional
}

type ResourceClassSpec struct {
 // defines general resource property matching constraints.
 // e.g.: zone in { us-west1-b, us-west1-c }; type: k80
 MetadataRequirements metav1.LabelSelector
 // used to compare preference of two matching ResourceClasses
 // The purpose to introduce this field is explained more later
 Priority int
}
```

che

```
kind: ResourceClass
metadata:
 name: nvidia.high.mem
spec:
 labelSelector:
 - matchExpressions:
 - key: "Kind"
 operator: "In"
 values:
 - "nvidia-gpu"
 - key: "memory"
 operator: "GtEq"
 values:
 - "30G"
```

- 正在讨论中的解决方案:
- Resource API

# Kubernetes生态的发展方向

- 头重
  - API层的扩展与插件能力的进一步提升
  - 基于扩展型API的Serverless、CI/CD等周边项目涌现
- 脚轻
  - 核心组件进一步插件化、框架化

# 结语

Kubernetes社区的第一次繁荣已经进入尾声

以扩展型API、插件化核心组件、各类标准化接口为代表的第二次繁荣，正呼之欲出

开源基础设施项目的“民主化”趋势

Democratizing Infrastructure



# 全球区块链生态技术大会

## —— 一场纯粹的区块链技术大会 ——

核心技术

智能合约

区块链金融

区块链安全

区块链游戏

...

2018.8.18-19 北京·国际会议中心

7月29日之前报名，享受**8**折，团购更多优惠



关注 ArchSummit 公众号  
获取国内外一线架构设计  
了解上千名知名架构师的实践动向



北京站：2018年12月7-10日

# 极客邦企业培训与咨询

帮助企业与技术人员成长



## 精品课程

Excellent Course

- ✓ 《互联网大规模分布式架构设计与实践》
- ✓ 《基于大数据的企业运营与精准营销》
- ✓ 《大数据和人工智能在金融领域的应用》
- ✓ 《区块链应用与开发技术高级培训》
- ✓ 《通往卓越管理的阶梯》



扫码关注官方微信服务号  
了解更多课程详细信息

**Geekbang**  
极客邦科技

# THANKS