Kubernetes On Alibaba Cloud

谢瑶瑶 @ 阿里云

2017-10-09

主办：CLOUD NATIVE COMPUTING FOUNDATION　caicloud 才云　K8S 中国社区

阿里云容器服务介绍

Kubernetes集群

阿里云CloudProvider

主办： CLOUD NATIVE COMPUTING FOUNDATION caicloud 才云 K8S 中国社区

阿里云容器服务发展

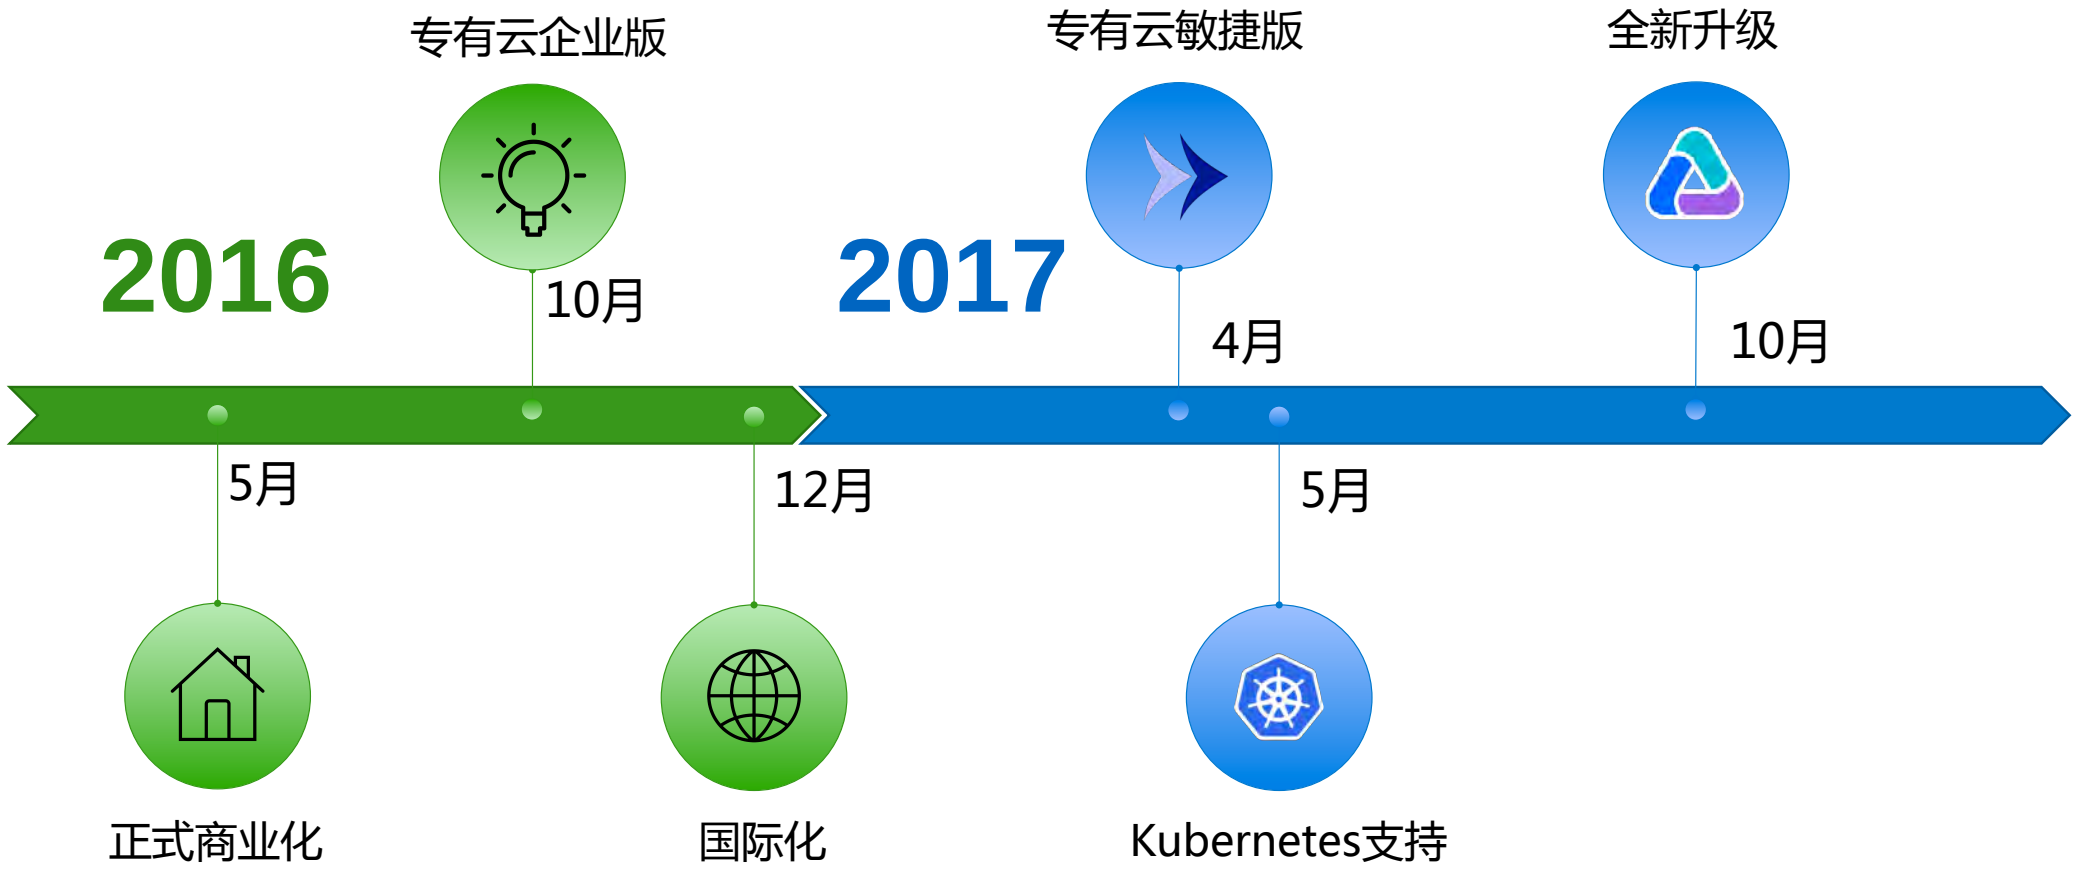

阿里云容器服务

生命周期管理

集群与应用：创建、删除，自动扩缩容，故障恢复，健康监控

服务发现

提供四层、七层服务路由，支持阿里云SLB提供负载均衡

持久化存储

支持多种存储选择，阿里云盘，NAS网络文件存储

日志管理

支持对接阿里云日志系统

编排与调度

支持docker与kubernetes双核心编排引擎

网络管理

多种网络选择，VPC，vxlan

监控管理

集群监控，应用监控

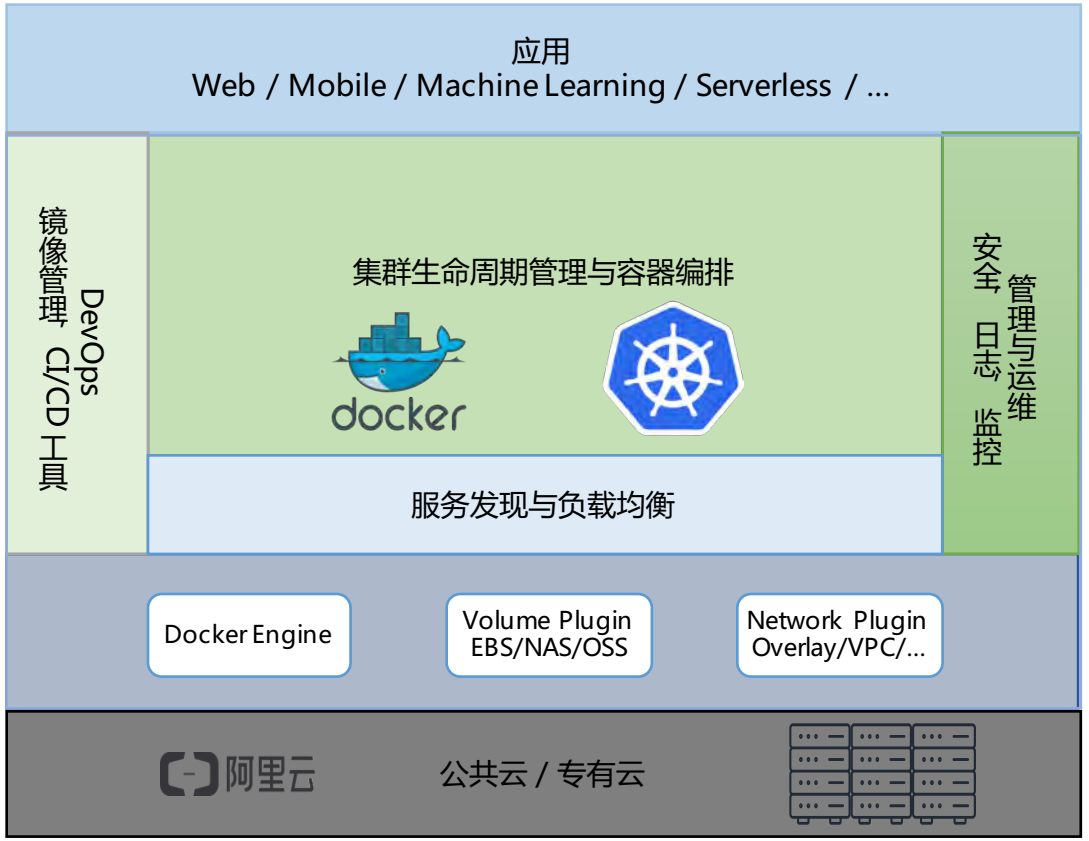

主办：CLOUD NATIVE COMPUTING FOUNDATION caicloud 才云 K8S 中国社区

容器服务Kubernetes与开源社区

Kubernetes
Out-of-tree CloudProvider

VPC网络
Flannel vpc driver

阿里云盘
Flexvolume driver

OSS存储
Registry 后端存储

日志
Fluentd-pilot日志

主办： CLOUD NATIVE COMPUTING FOUNDATION caicloud 才云 K8S 中国社区

阿里云容器服务介绍

Kubernetes集群

阿里云CloudProvider

主办： CLOUD NATIVE COMPUTING FOUNDATION caicloud 才云 K8S 中国社区

高可用的kubernetes用户集群

高可用

阿里云SLB为多副本组件提供统一负载均衡。
master的本地组件访问apiserver直接走本机IP，不经过内网SLB。

安全

ETCD节点之间通过证书认证，客户端通过证书访问etcd集群。
Kubernetes各个组件通过证书认证。
VPC网络提供安全隔离，自定义最小安全组策略控制节点访问。

云资源

提供阿里云CloudProvider集成，轻松访问阿里云资源。

扩缩容

应用和集群动态扩缩容。

镜像加速

默认提供dockerhub官方镜像加速，解决官方镜像下载缓慢的问题。

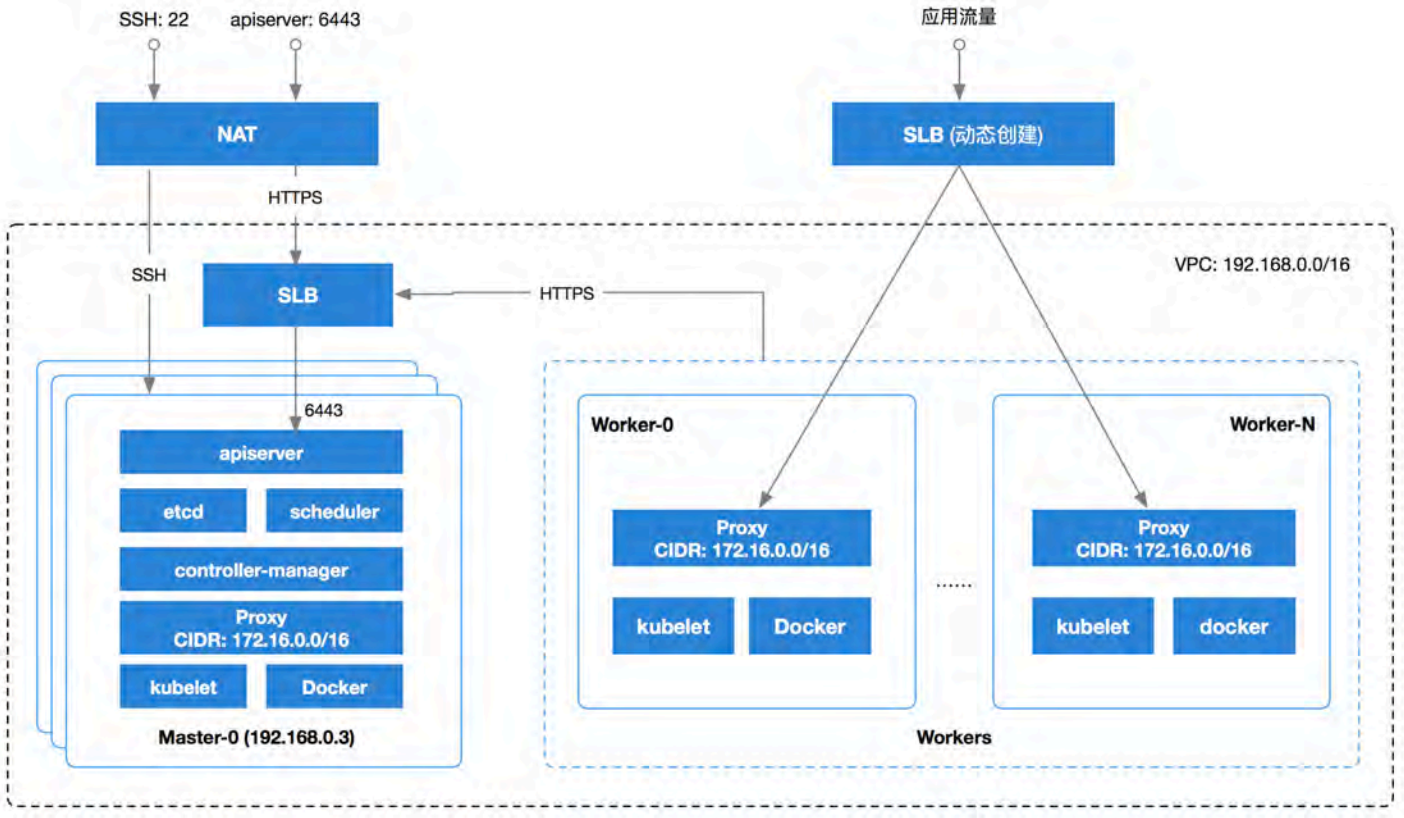

一些建议

Kubeadm 支持部署单机开发测试集群

Cloud-Config路径问题

新版的Kubeadm为了安全原因，不在整体挂载/etc/kubernetes目录到组件容器中，同时也漏掉了cloud-config文件，造成升级故障。

镜来源问题

修改kubeadm可以使用非gcr.io来源的镜像。

处理证书方面

Cluaster CA。
EXTRA CN 允许通过LoadBalancer访问。

处理kubeproxy问题

kubeadm生成的ds默认适合单集群，kubeproxy在访问apiserver时需要修改成LoadBalancer的地址。
kubeproxy在处理externalTraffic的时候，依赖hostname来判断Pod是否属于本地节点。

apiserver_count

kubernetes service 的endpoint会在多个master IP里面随机跳来跳去。

Dashboard权限

阿里云容器服务介绍

Kubernetes集群

阿里云CloudProvider

主办：

Kubernetes out-of-tree alibaba cloudprovider

CloudProvider

定义了一组接口，不同的云厂商通过实现这组接口来将本厂提供的各种服务集成到kubernetes集群中。

能力集成

网络路由配置、负载均衡动态配置、可用区管理、虚拟机管理

进化

In-tree-cloudprovider
cloud-out-of-tree cloud controller

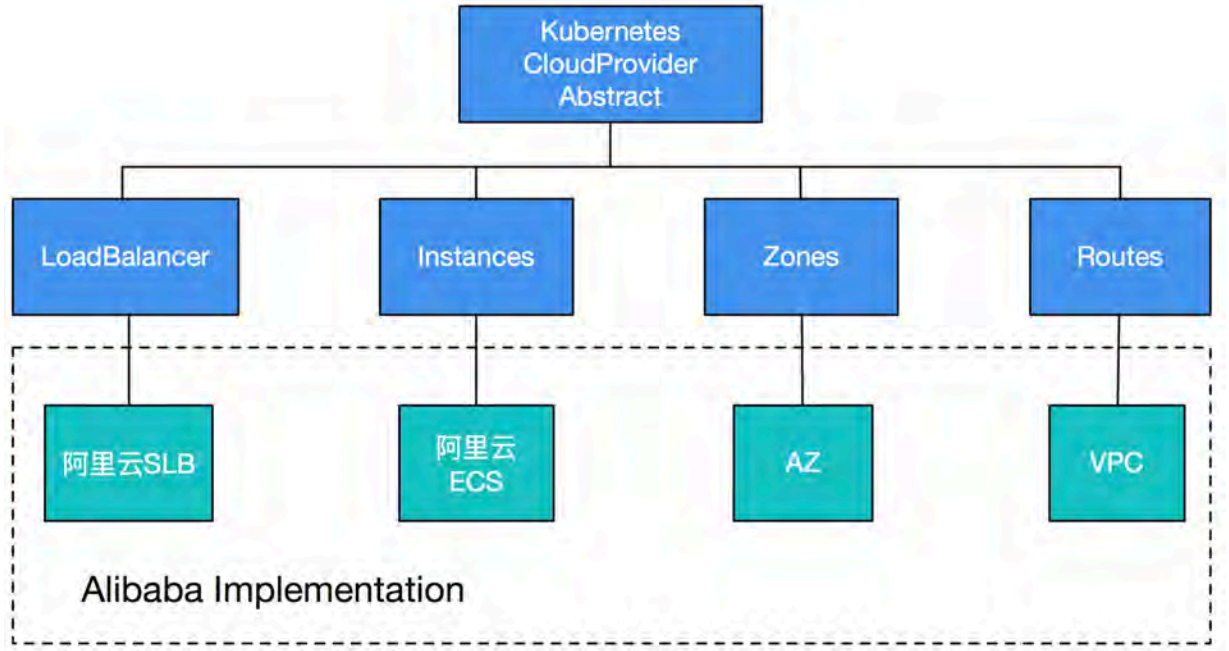

进化In-Tree vs Out tree

传统 In-tree 问题

所有的云厂商的provider代码放在core kubernetes仓库可维护性低。
Cloud provider实现发布周期与kuberentes core耦合，无法快速迭代

解决方案

out-of-tree cloud providers
使用kubernetes的controller的概念来设计重构cloud provider, 即cloud-controller-manager。
将与云厂商实现相关代码移动到一个单独仓库，作为单独的二进制文件发布

路线图

Alpha: 1.7 => Beta: 1.8 => Stable: 1.10

开源

https://github.com/AliyunContainerService/alicloud-controller-manager

Kubernetes集群网络支持高效互联和混合云

CNI规范

定义了如何处理容器内网络设置。创建网卡分配IP，设置路由，DNS。Meta/Main

集群容器间网络

VPC：路由转发，去往172.16.0.0/24网段的数据包的下一跳是ECS1，性能最优的方案。
VXLAN： 数据封包，overlay

Flannel alivpc driver

开源，连接容器网络

混合云支持

#571 Add alibaba cloud VPC network support

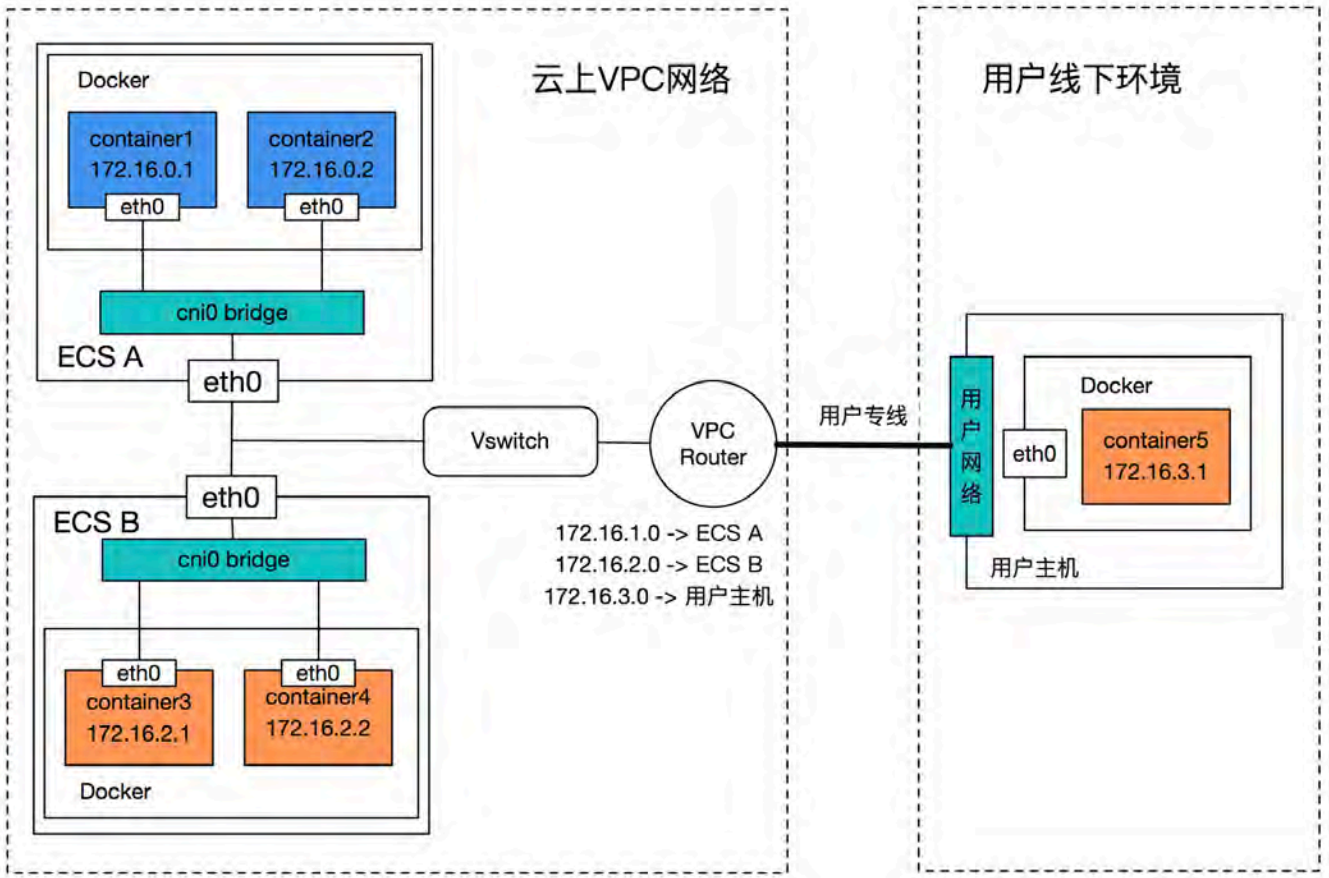

主办：

案例分析：一个神奇的内核网络配置问题

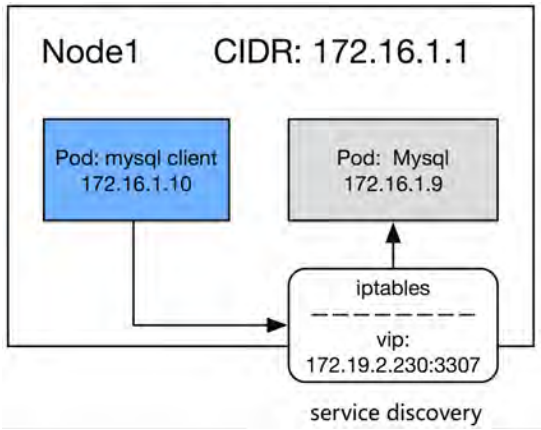

排查流程

kubectl get po 检查pod是否正常启动
kubectl get svc 检查服务是否创建
kubectl logs mysql 查看服务日志是否正常
ketstat –anp|grep 3307查看端口
iptable -t nat –vnL 查看数据流规则

….

然而。。。一切看似正常

=> tcpdump

Client Pod: 172.16.1.10

```
root@172.16.1.10# tcpdump -i any -nnnn tcp and host 172.16.1.9 or host 172.16.1.10
06:35:55.731187 IP 172.16.1.10.49908 > 172.19.2.230.3307: Flags [S], seq 1112696560, win 292
06:35:55.731313 IP 172.16.1.9.80 > 172.16.1.10.49908: Flags [S.], seq 951763388, ack 111269
06:35:55.731331 IP 172.16.1.10.49908 > 172.16.1.9.80: Flags [R], seq 1112696561, win 0, leng
06:35:56.732987 IP 172.16.1.10.49908 > 172.19.2.230.3307: Flags [S], seq 1112696560, win 292
06:35:56.733078 IP 172.16.1.9.80 > 172.16.1.10.49908: Flags [S.], seq 967416508, ack 111269
06:35:56.733088 IP 172.16.1.10.49908 > 172.16.1.9.80: Flags [R], seq 1112696561, win 0, leng
```

On Mysql Server Pod 172.16.1.9

```
root@172.16.1.19# tcpdump -i any -nnnn tcp and host 172.16.1.9 or host 172.16.1.10
06:35:55.731249 IP 172.16.1.10.49908 > 172.16.1.9.80: Flags [S], seq 1112696560, win 29200,
06:35:55.731309 IP 172.16.1.9.80 > 172.16.1.10.49908: Flags [S.], seq 951763388, ack 111269
06:35:55.731335 IP 172.16.1.10.49908 > 172.16.1.9.80: Flags [R], seq 1112696561, win 0, leng
06:35:56.733042 IP 172.16.1.10.49908 > 172.16.1.9.80: Flags [S], seq 1112696560, win 29200,
06:35:56.733072 IP 172.16.1.9.80 > 172.16.1.10.49908: Flags [S.], seq 967416508, ack 111269
06:35:56.733092 IP 172.16.1.10.49908 > 172.16.1.9.80: Flags [R], seq 1112696561, win 0, leng
```

On Host 172.16.1.1

```
root@172.16.1.1# tcpdump -i any -nnnn tcp and host 172.16.1.9 or host 172.16.1.10
14:35:55.731205 IP 172.16.1.10.49908 > 172.19.2.230.3307: Flags [S], seq 1112696560, win 292
14:35:55.731205 IP 172.16.1.10.49908 > 172.19.2.230.3307: Flags [S], seq 1112696560, win 292
14:35:55.731244 IP 172.16.1.10.49908 > 172.16.1.9.80: Flags [S], seq 1112696560, win 29200,
14:35:55.731248 IP 172.16.1.10.49908 > 172.16.1.9.80: Flags [S], seq 1112696560, win 29200,
14:35:55.731277 ARP, Request who-has 172.16.1.10 tell 172.16.1.9, length 28
14:35:55.731281 ARP, Request who-has 172.16.1.10 tell 172.16.1.9, length 28
14:35:55.731283 ARP, Request who-has 172.16.1.10 tell 172.16.1.9, length 28
14:35:55.731285 ARP, Request who-has 172.16.1.10 tell 172.16.1.9, length 28
14:35:55.731288 ARP, Request who-has 172.16.1.10 tell 172.16.1.9, length 28
14:35:55.731277 ARP, Request who-has 172.16.1.10 tell 172.16.1.9, length 28
14:35:55.731300 ARP, Reply 172.16.1.10 is-at 0a:58:ac:10:01:0a, length 28
14:35:55.731307 ARP, Reply 172.16.1.10 is-at 0a:58:ac:10:01:0a, length 28
14:35:55.731310 IP 172.16.1.9.80 > 172.16.1.10.49908: Flags [S.], seq 951763388, ack 111269
14:35:55.731312 IP 172.16.1.9.80 > 172.16.1.10.49908: Flags [S.], seq 951763388, ack 111269
14:35:55.731332 IP 172.16.1.10.49908 > 172.16.1.9.80: Flags [R], seq 1112696561, win 0, leng
14:35:55.731334 IP 172.16.1.10.49908 > 172.16.1.9.80: Flags [R], seq 1112696561, win 0, leng
```

案例分析：一个神奇的内核网络配置问题

你会发现：

目的Pod返回给请求方的数据包里直接使用了自己的IP作为源IP。
DNAT规则没被iptables正确处理？

iptables

```
[root@iZ2ze8z5wwcy8sspdlld3rZ ~]# iptables -t nat -vnL
Chain PREROUTING (policy ACCEPT 0 packets, 0 bytes)
 pkts bytes target     prot opt in     out     source               destination
29237 1718K KUBE-SERVICES  all  --  *      *       0.0.0.0/0            0.0.0.0/0
 4793  291K DOCKER     all  --  *      *       0.0.0.0/0            0.0.0.0/0            ADD

Chain KUBE-SERVICES (2 references)
 pkts bytes target     prot opt in     out     source               destination
    0     0 KUBE-SVC-4N57TFCL4MD7ZTDA  tcp  --  *      *       0.0.0.0/0            172.19.2
    0     0 KUBE-NODEPORTS  all  --  *      *       0.0.0.0/0            0.0.0.0/0

Chain KUBE-SVC-4N57TFCL4MD7ZTDA (1 references)
 pkts bytes target     prot opt in     out     source               destination
    0     0 KUBE-SEP-NOHDPPG5W6CM56QM  all  --  *      *       0.0.0.0/0            0.0.0.0/
    0     0 KUBE-SEP-5QE6DV4YQ5V2GPQM  all  --  *      *       0.0.0.0/0            0.0.0.0/

Chain KUBE-SEP-5QE6DV4YQ5V2GPQM (1 references)
 pkts bytes target     prot opt in     out     source               destination
    0     0 KUBE-MARK-MASQ  all  --  *      *       172.16.1.9           0.0.0.0/0
    0     0 DNAT       tcp  --  *      *       0.0.0.0/0            0.0.0.0/0            /*
```

=====> Linux 网桥的一项内核参数控制流经网桥的数据包是否会被iptables规则进一步处理。
net.bridge.bridge-nf-call-iptables

案例分析：Docker 的默认网络转发策略

Forward Table

```
[root@iZbp138x ~]# iptables -vnL
Chain INPUT (policy ACCEPT 1988 packets, 742K bytes)
 pkts bytes target     prot opt in     out     source               destination
  92M   32G KUBE-SERVICES  all  --  *      *       0.0.0.0/0            0.0.0.0/0
  92M   32G KUBE-FIREWALL  all  --  *      *       0.0.0.0/0            0.0.0.0/0

Chain FORWARD (policy DROP 0 packets, 0 bytes)
 pkts bytes target     prot opt in     out     source               destination
    0     0 DOCKER-ISOLATION  all  --  *      *       0.0.0.0/0            0.0.0.0/0
    0     0 DOCKER     all  --  *      docker0  0.0.0.0/0            0.0.0.0/0
    0     0 ACCEPT     all  --  *      docker0  0.0.0.0/0            0.0.0.0/0           ct
    0     0 ACCEPT     all  --  docker0 !docker0  0.0.0.0/0            0.0.0.0/0
    0     0 ACCEPT     all  --  docker0 docker0  0.0.0.0/0            0.0.0.0/0
```

iptables –P FORWARD ACCEPT

阿里云负载均衡SLB集成

LoadBalancer能力

地址类型： internet/intranet
协议类型： tcp/udp/http/https
Region选择： 默认与自定义
收费类型： 按量付费/按带宽收费，自定义带宽
健康检查： 自定义健康检查

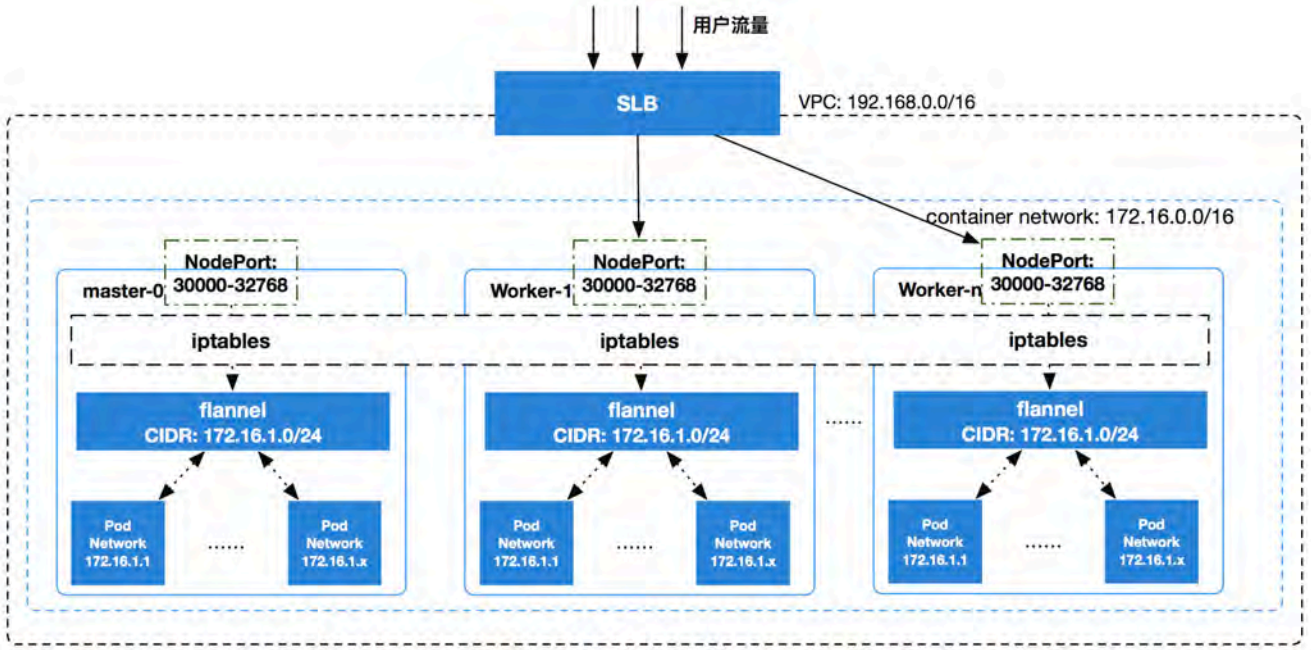

案例分析：阿里云SLB 源IP保留

原则: 负载均衡是否能够保留客户请求的源IP取决于连接是否被SNAT过。

Type: ClusterIP

永远不会被SNAT，因此始终可以获得源IP

Type: NodePort

访问不在本节点上的Pod后端时会被SNAT。
因此不一定能保留源IP

Type: LoadBalancer

依赖于NodePort

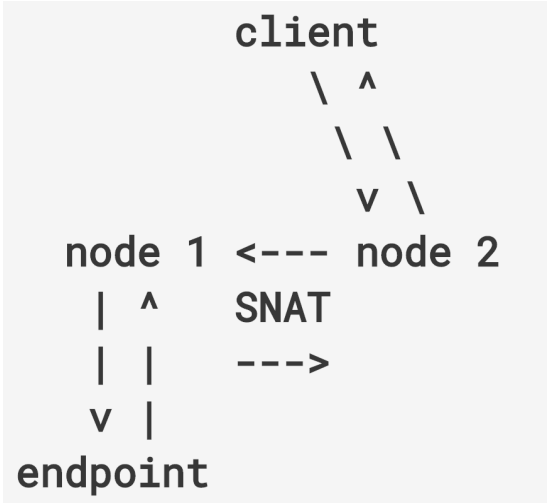

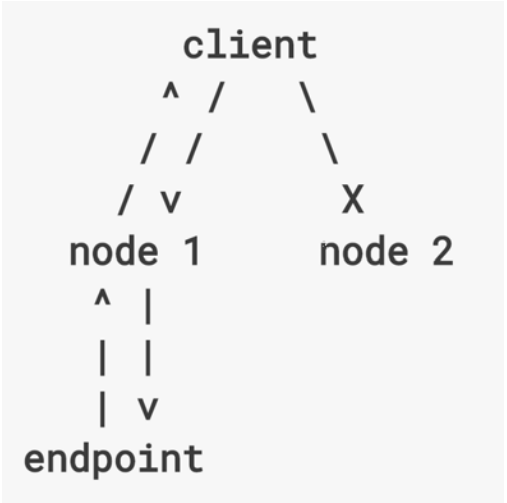

spec.externalTraffic: Local

小结

阿里云容器服务

阿里云Kubernetes集群

阿里云CloudProvider

Q&A

Thank you for your time

主办：