WOTA

51CTO

World Of Tech 2017

全球架构与运维技术峰会

2017年4月14日-15日　北京富力万丽酒店

ARCHITECTURE

WOTA

51CTO

出品人及主持人：

张立刚

1号店技术部
电商云平台技术总监

云服务架构

WOTA

51CTO

YY 游戏私有云建设历程

虎牙信息
刘亚丹

WOTA

51CTO

刘亚丹

虎牙直播

基础运维负责人

分享主题：

YY游戏私有云建设历程

个人简介

- 虎牙信息-基础运维负责人
- 9 年互联网运维经历
- 5 年私有云 IaaS 和 PaaS 实践
- 参与编写《自主实现SDN虚拟网络和企业私有云》

大纲

1. 需求背景
2. YY私有云1.0现状
3. 2.0平台方案选型
4. 网络，存储，计算集成实践方案

需求背景

页游和 Web 类应用适合虚拟化

↓

YY游戏运营平台：联运和独代游戏，具备一定的规模经济性

↓

页游特点：开服多，周期短，云化提高资源利用率和回收效率

↓

Web类应用特点：无状态，弹性伸缩，故障隔离

建设历程-YY 私有云1.0平台现状

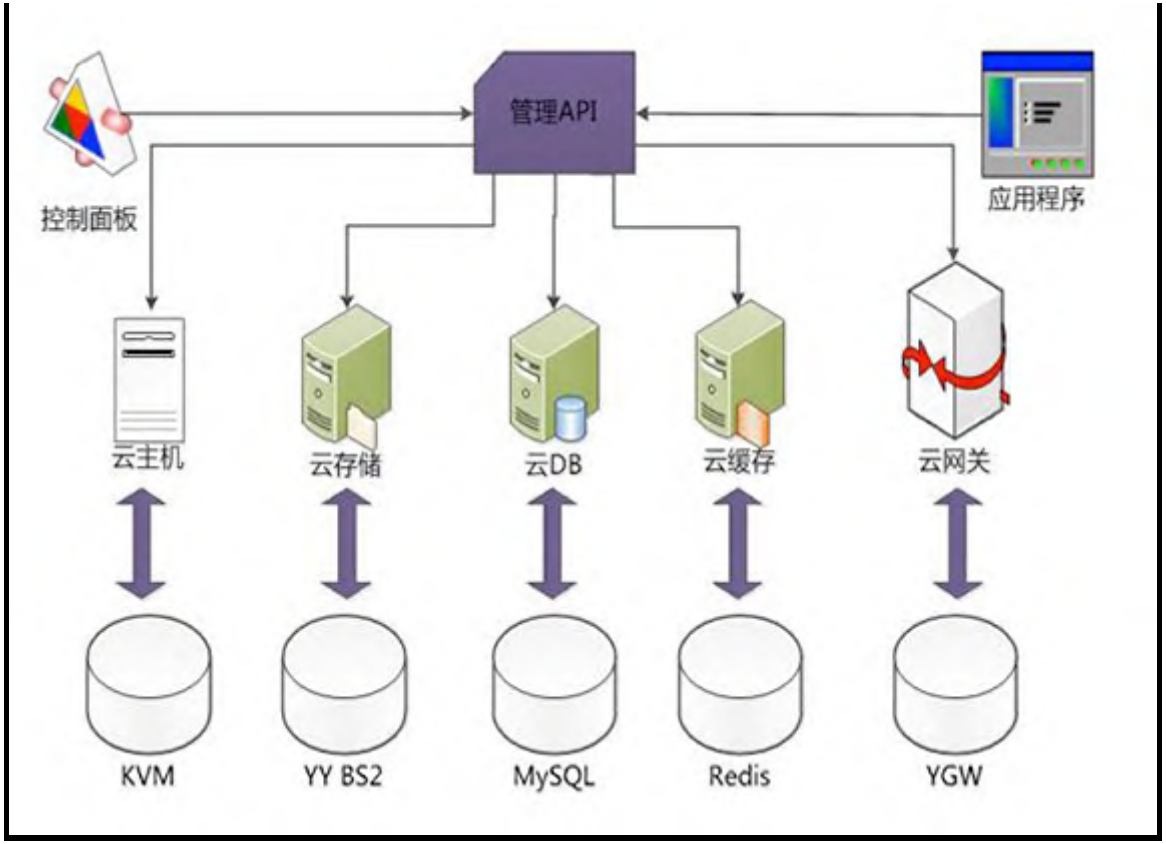

- 1.0 核心功能
  - **云主机**-本地存储
  - 云网关（LVS+NAT）
  - 云 DB， 云缓存
  - 云存储（对象存储）
  - 云监控
- Cloud1.0的不足
  - **租户**网络未隔离
  - 可控性差

建设历程-基于OpenStack 的1.0平台网络架构

Privoder Network

- flat+vlan 模式

典型网络配置支持

- 公网模式：VM 双网卡，eth0绑定电信、联通(Flat)；eth1绑定内网 IP（flat+vlan）
- 云网关模式：eth0绑定内网 IP（flat+vlan）

建设历程-OpenStack 上踩过的坑

稳定性

- 架构组件复杂
- 代码质量不高

可维护性

- 安装部署复杂对运维要求极高
- 无法平滑升级

扩展性

- L3-Agent性能瓶颈
- Dnsmasq & Keystone MQ 等性能瓶颈

建设历程-OpenStack上踩过的坑

- 从全局来看，OpenStack存在的问题包括：
  - 项目庞大复杂，过多的模块、扩展、功能让这个产品很难部署使用，出错时也难以调试。
  - 发布质量一般。目前是按时间周期发布，每个版本的维护时间过短，且旧版本不支持无缝升级到新版本。整个项目不太注重生产环境的可用性。
  - 项目的代码量仍然在持续增长，但是不注重代码质量和功能完整性。很多部分实现的功能成为遗留代码。
  - 可控性差，对运维的素质要求非常高。
  - 如下是我们在生产环境中面临的具体问题：
    - 由于Neutron租户网络存在l3-agent瓶颈，无法实现生产环境可用的租户隔离网络。
    - Metadata服务存在明显的性能问题。Metadata 服务网络结构复杂，容易导致VM创建或者重启失败。
    - 直到IceHouse版本，仍然不能在线无缝升级。升级不方便加上旧版本的维护时间短，不适合生产环境大规模使用。
    - 授权体系一直是软肋。默认的policy.json不安全，也不支持全局动态配置权限。
- 自身的Bug影响稳定性，上游社区不重视。已知的Bug包括：
  - Keystone性能Bug。
  - Neutron定时任务执行稍有异常就清空OVS配置。
  - Neutron DHCP 服务器（Dnsmasq）性能问题。
  - 在某些情况下，动态迁移（Live Migration）不支持按Region迁移。
  - 动态迁移的实现没有考虑超时和网络不通时如何进行恢复。

建设历程-YY 私有云2.0-选型思路

- 关键需求：
  - 提供高性能，可扩展的 VPC 网络
  - 云管理平台自主可控

- 基本策略：以开源软件为基础，自主研发为核心，专业厂商为关键补充
  - 虚拟计算：**KVM**
  - 虚拟存储：**Ceph**
  - 虚拟网络：借助专业厂商的专门网络硬件和控制器，实现 **VXLAN** 网络

建设历程-YY 私有云2.0-方案选型

- 虚拟网络的灵魂：SDN 控制器
  - 工作机制复杂，开发工作量巨大
- **基于硬件的 VXLAN 和集中式组合网关**
  - 实现 VPC，NAT，floatingIP,子网，路由等功能
- 云管理平台
  - 实现对计算，存储，网络，以及云数据库等模块的调用，调度，监控和反馈

建设历程-YY 私有云2.0-方案选型

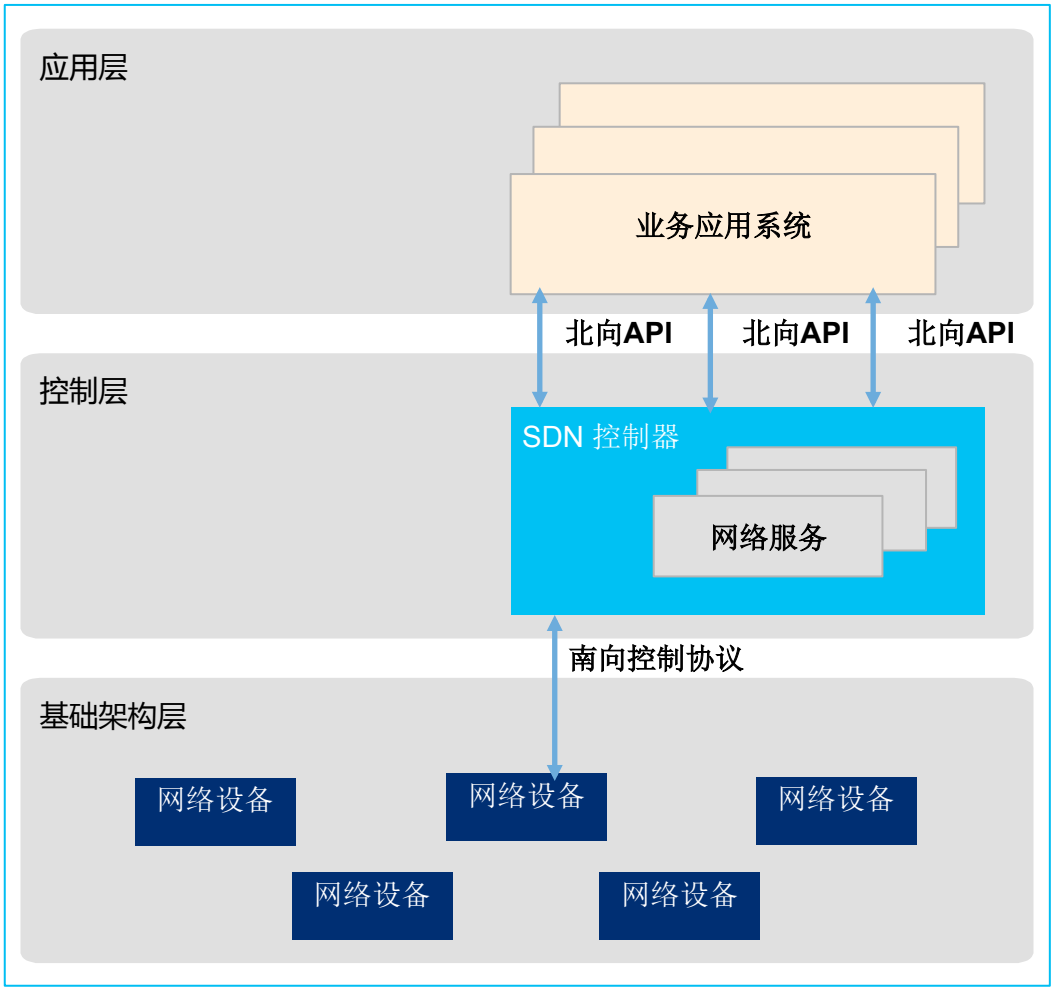

- 虚拟网络的灵魂：SDN 控制器
  - 基本结构
  - 工作机制
  - 选型方案：
    - 简单标准的北向接口
    - 复杂的南向接口由厂商实现

建设历程-2.0 Overlay 网络模型

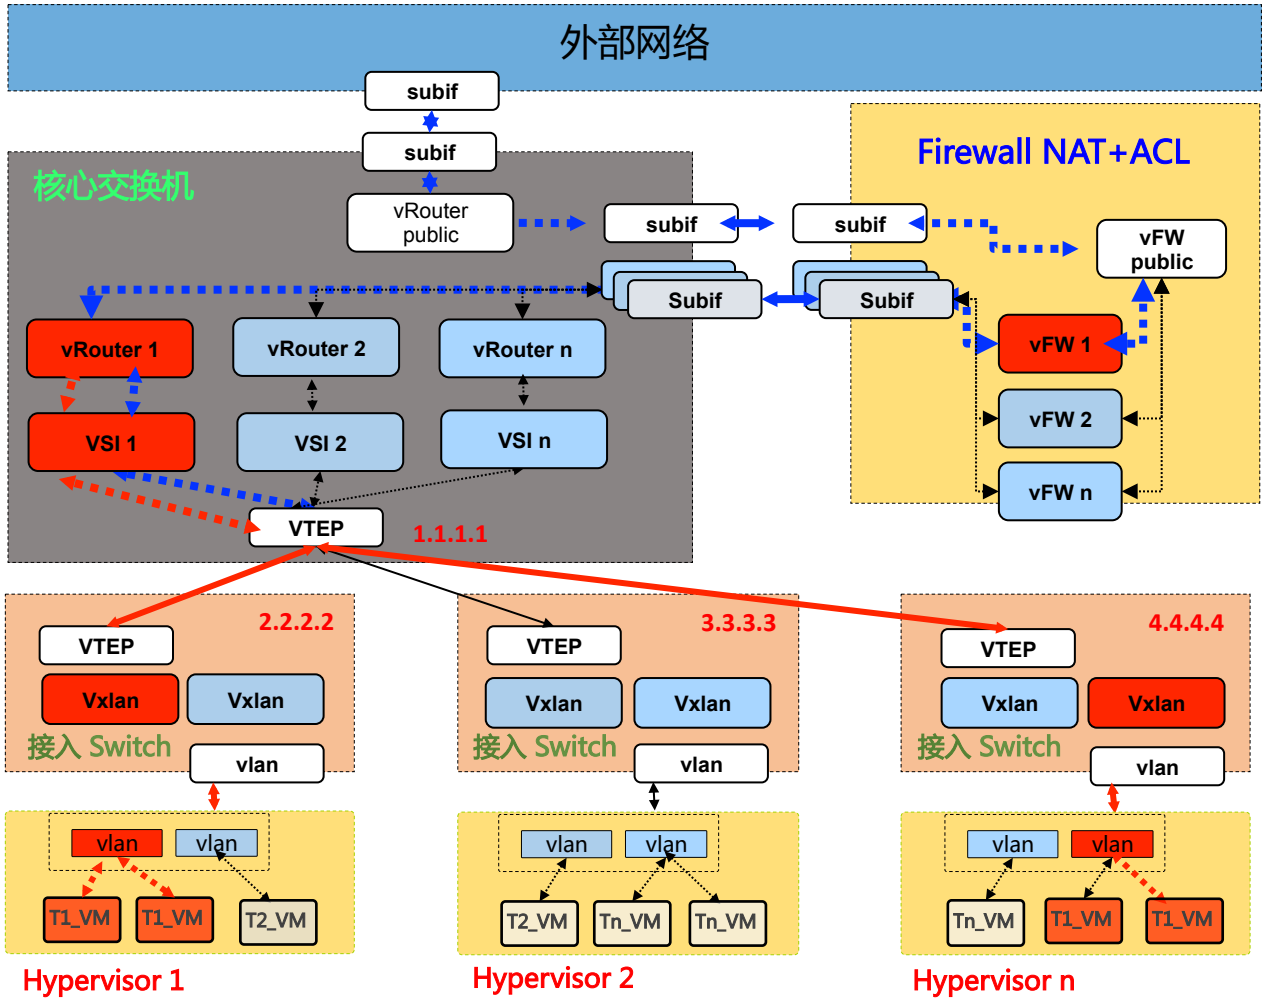

- 基于硬件的 VXLAN 和集中式组合网关
- 东西向流量转发
- 南北向流量转发

建设历程-云平台各层交互流程

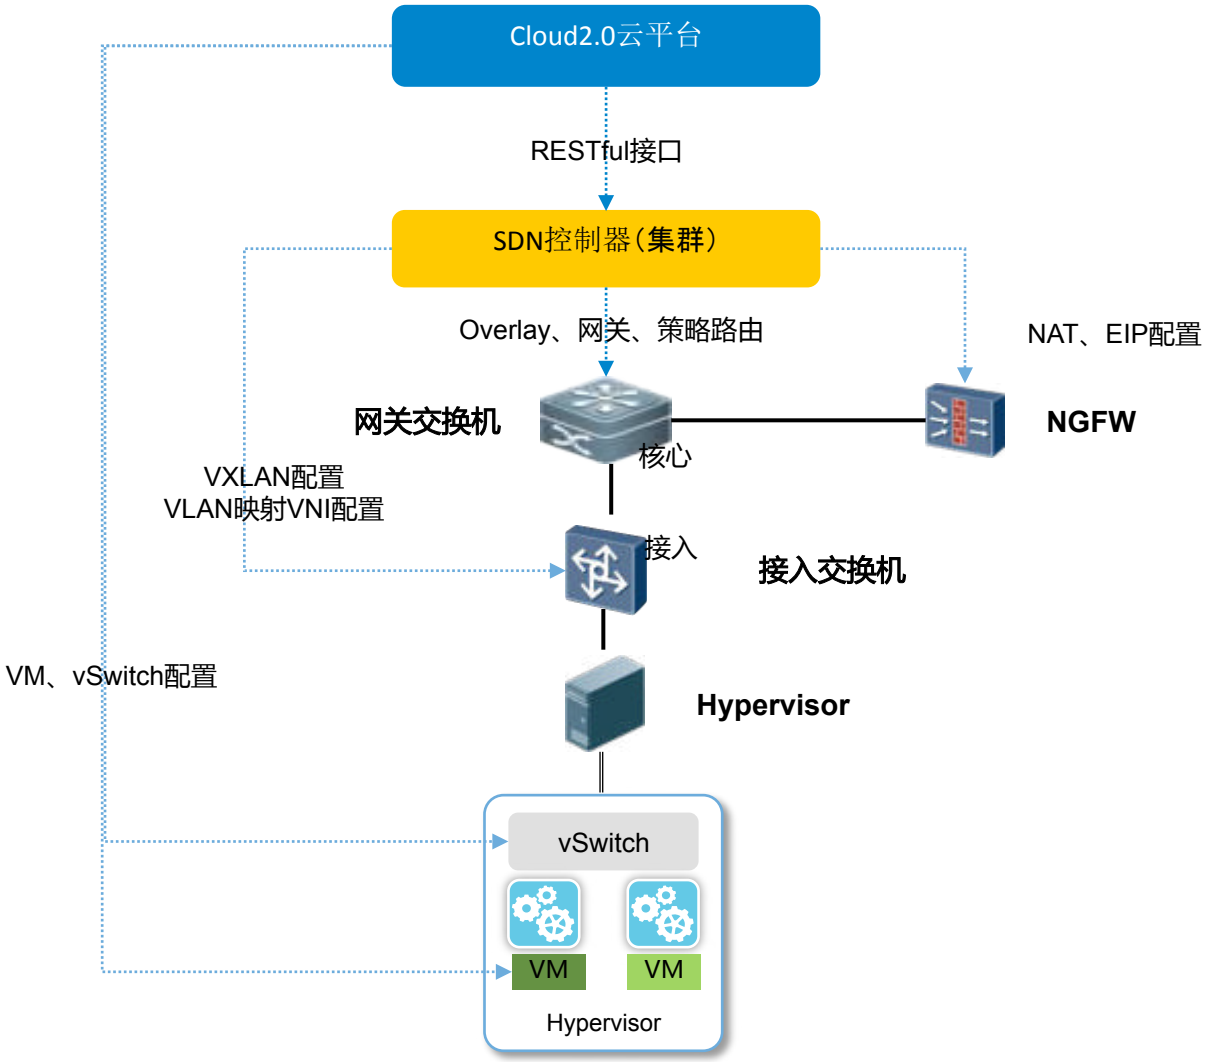

- 交互流程
  - 云平台与控制器交互
  - 云平台与宿主机交互
  - 云平台与监控交互

建设历程-虚拟网络模型-整体模型

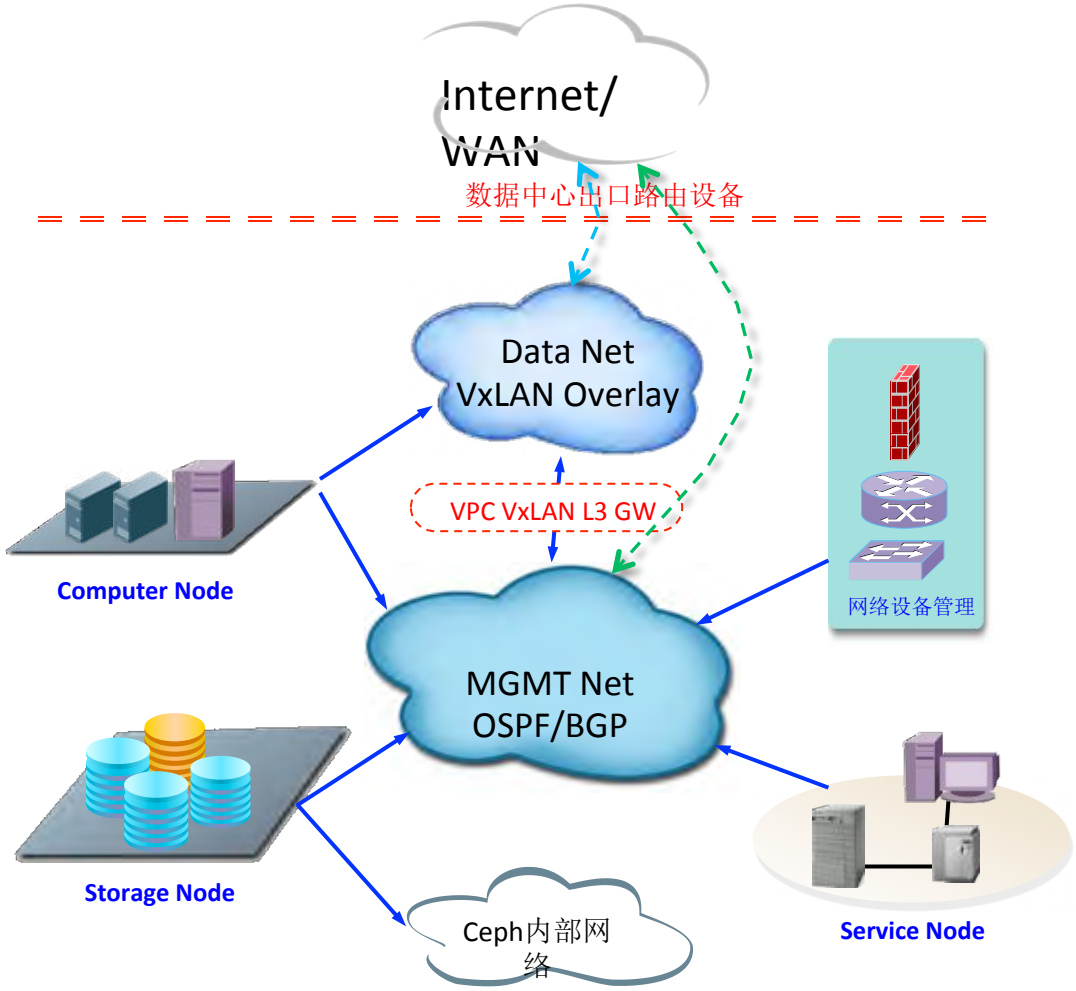

模型描述：

- 三个网络
  - Data net：Tenant VPC，利用VxLAN虚拟化技术构建叠加网络
  - MGMT net：组件内部通信、存储访问
  - Ceph内部网络

建设历程-网络架构-Data Net

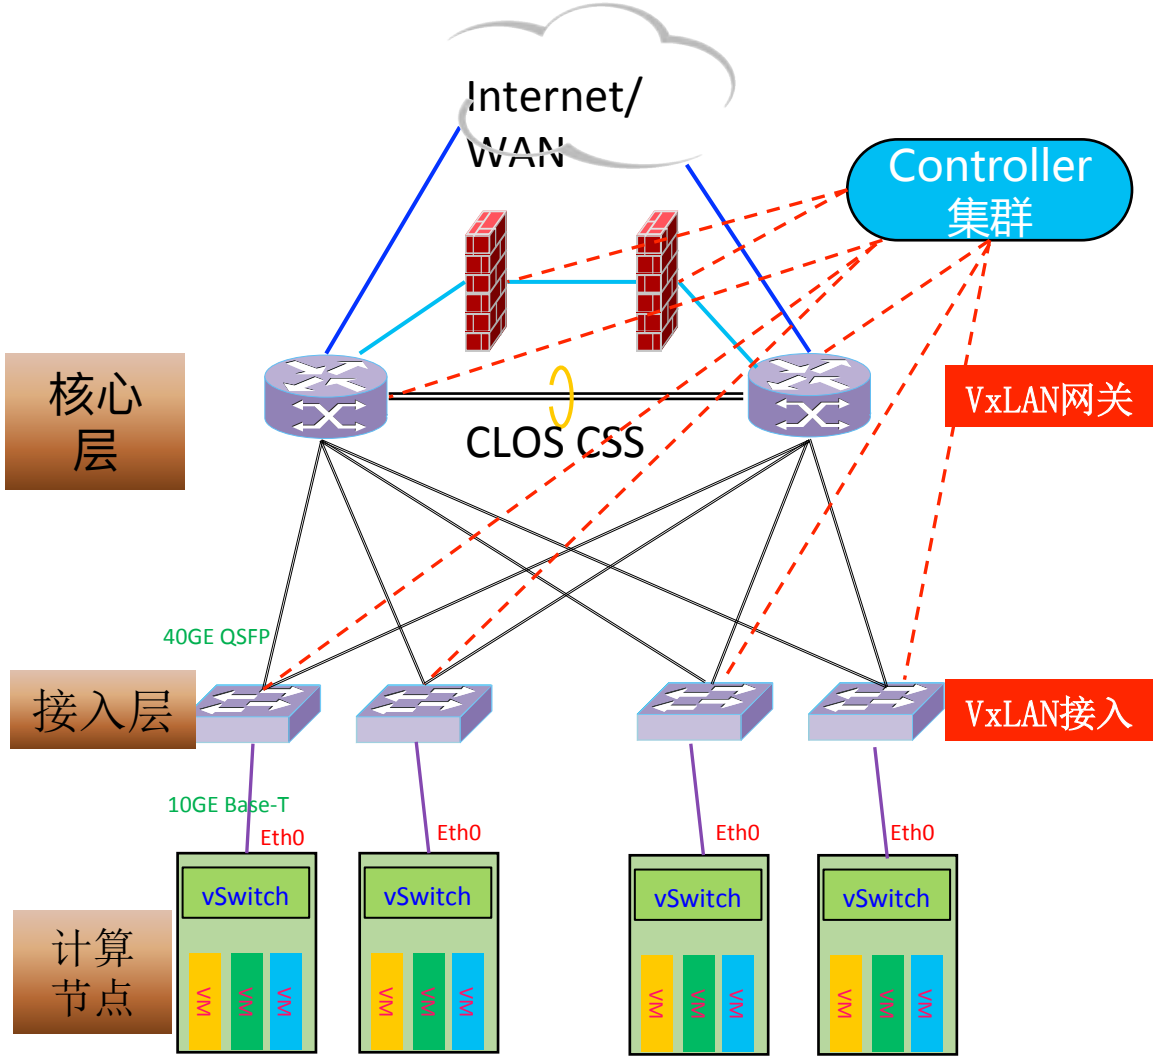

数据网络-架构描述

- SDN Hybrid Switch构
- Controller集群集中控制
- 采用核心层-接入层结构
  - 核心 Switch：采用CLOS架构核心交换机，多级多平面无阻塞交换架构，双机高可用热部署
  - 接入层：40GE 双归接入
  - 防火墙：旁挂核心Switch，采用主-**被部署**

建设历程-网络架构-MGMT Net

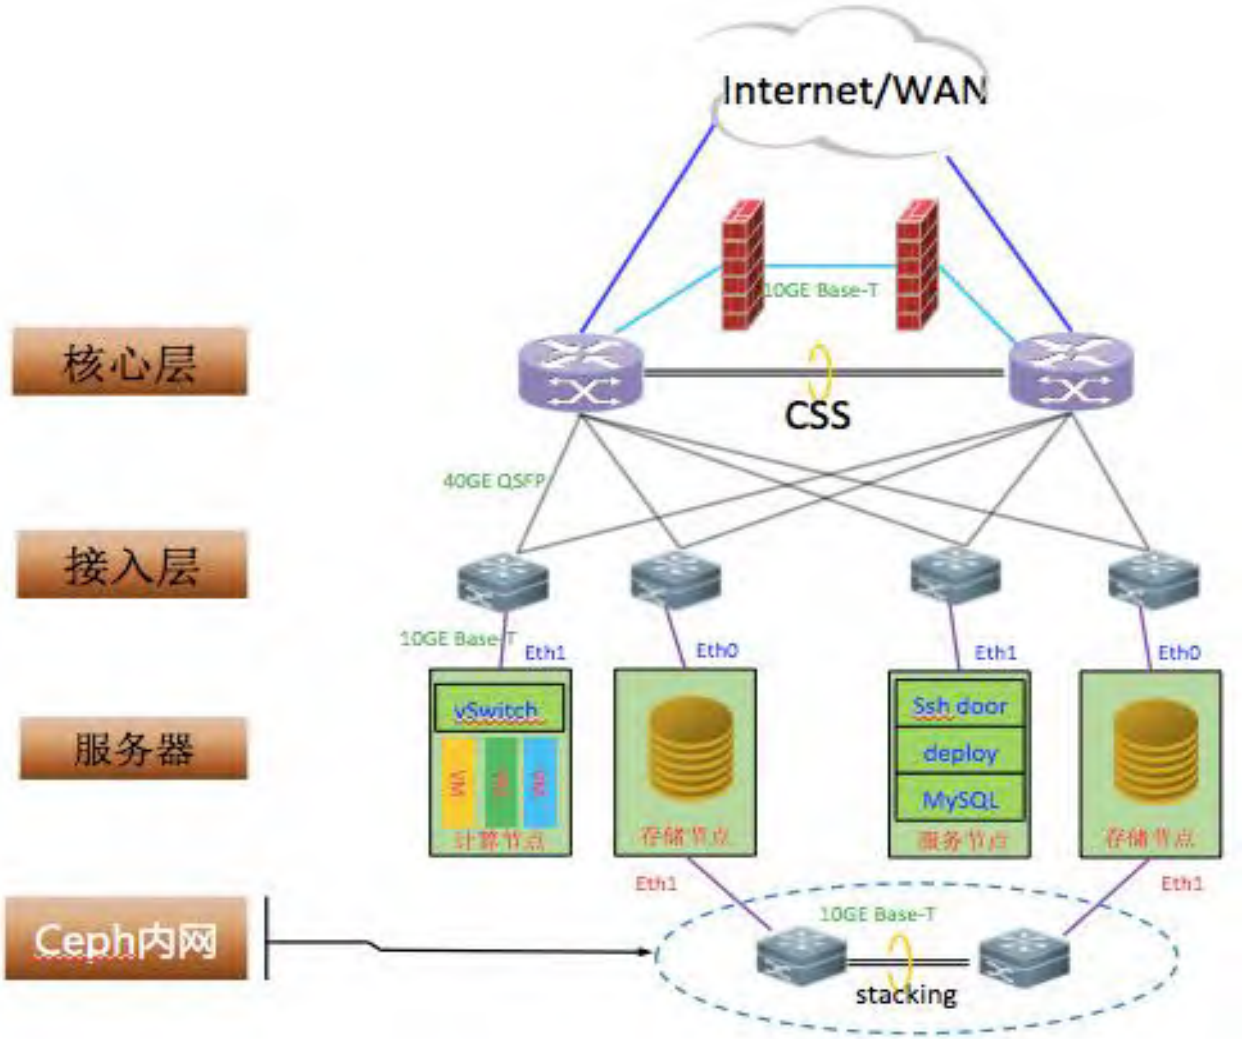

管理网络-架构描述：

- 通用L3 Switch构建
- 采用核心层-接入层结构
  - 10GE接入
  - 40GE汇聚
- 与Data net共用核心交换机，核心交换机用作数据中心出口设备
- 接入层 Switch使用40GE双归接入核心 Switch

建设历程-网络设备选型

- SDN Hybrid Switch：
  - 国内厂家：Huawei，H3C，锐捷，中兴，盛科
  - 国外厂家：Cisco、Arista
- SDN Controller：
  - H3C：VCF Controller
  - Huawei：Agile Controller
  - 云杉：NSP Controller
- NGFW：
  - H3C：M9000
  - Huawei：USG9500
  - Hillstone：X7180
- 设备组合：
  - H3C：VCFC+M9006+S12508AX-F+S6800
  - Huawei：AC+USG9520+CE12808+CE6850
  - 云杉+Huawei：NSP+USG9520+CE12808+CE6850

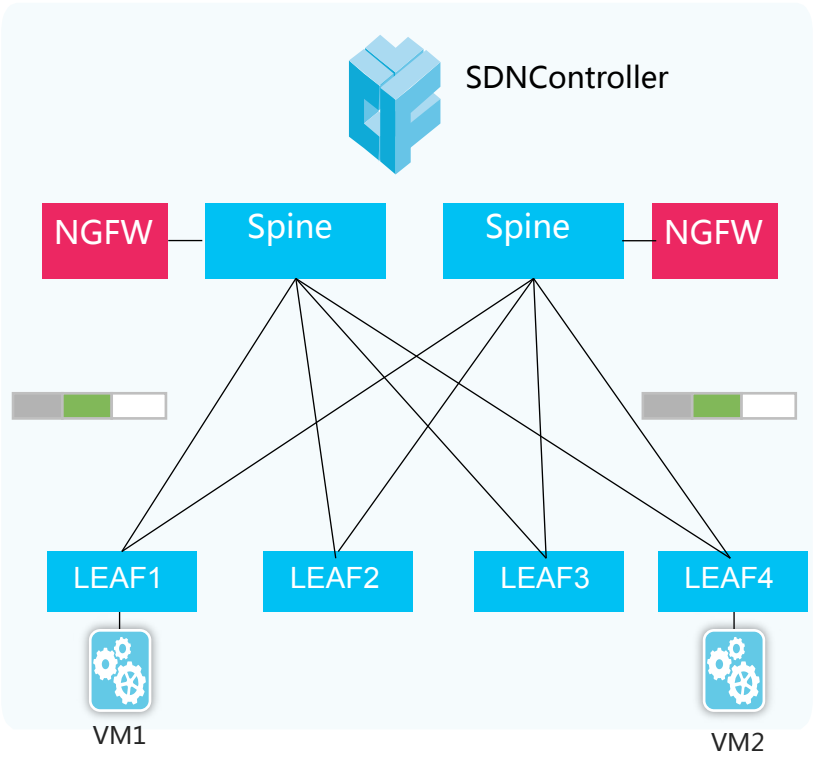

演进路线:

Cloud 1.0

Cloud 2.0

Cloud 2.0 Ext

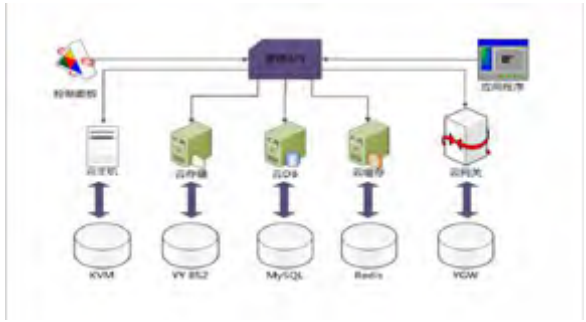

RiseCloud 1.0

- 基于Opensack Provider Network混合网络
- 千兆以太基础网络，VLAN隔离方式

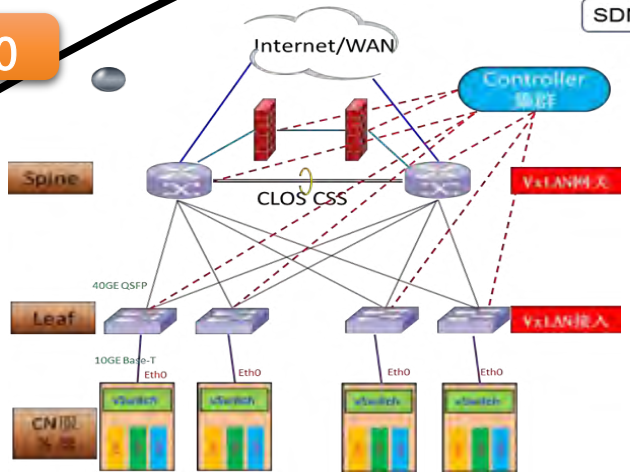

RiseCloud 2.0

- 基于纯硬件VxLAN Fabric的Overlay网络方案
- 集中式硬件L3 VxLAN网关方式
- 万兆以太基础网络，无阻塞Spine-Leaf结构

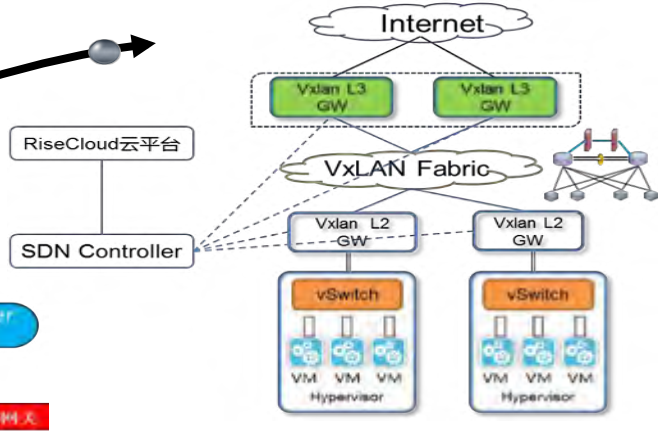

RiseCloud 2.0 Ext.

- 基于混合VxLAN Fabric的Overlay网络方案
- 采用VGW服务器集群作为L3 VxLAN网关
- 真正具有弹性伸缩能力

集成方案-计算节点网络结构变化

1.0

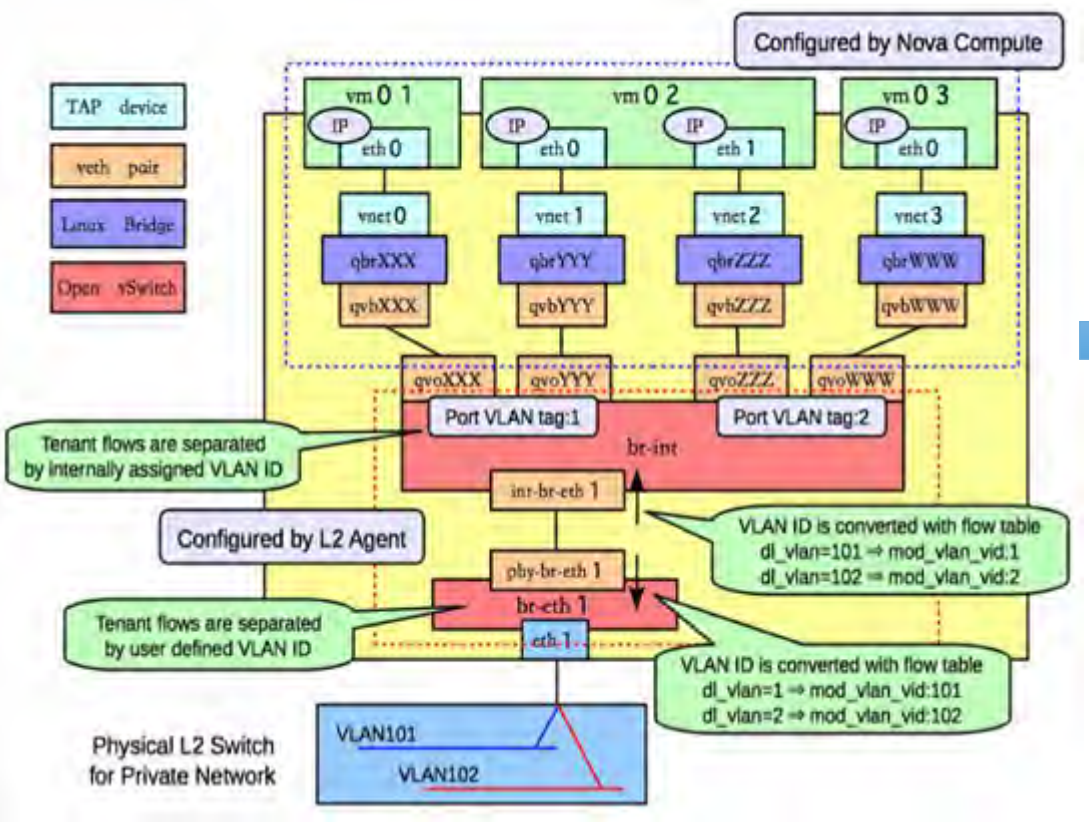

2.0

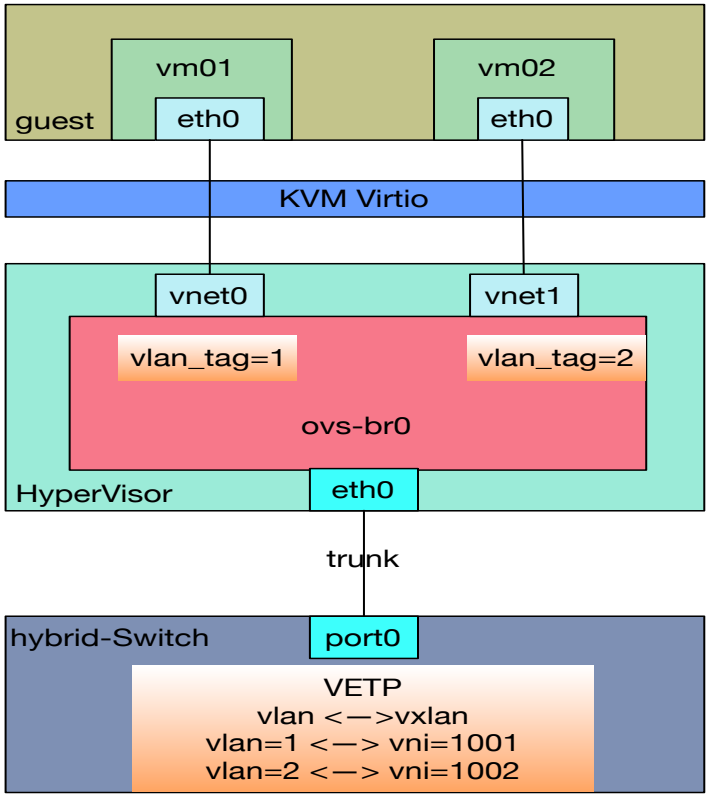

集成方案-虚拟存储方案

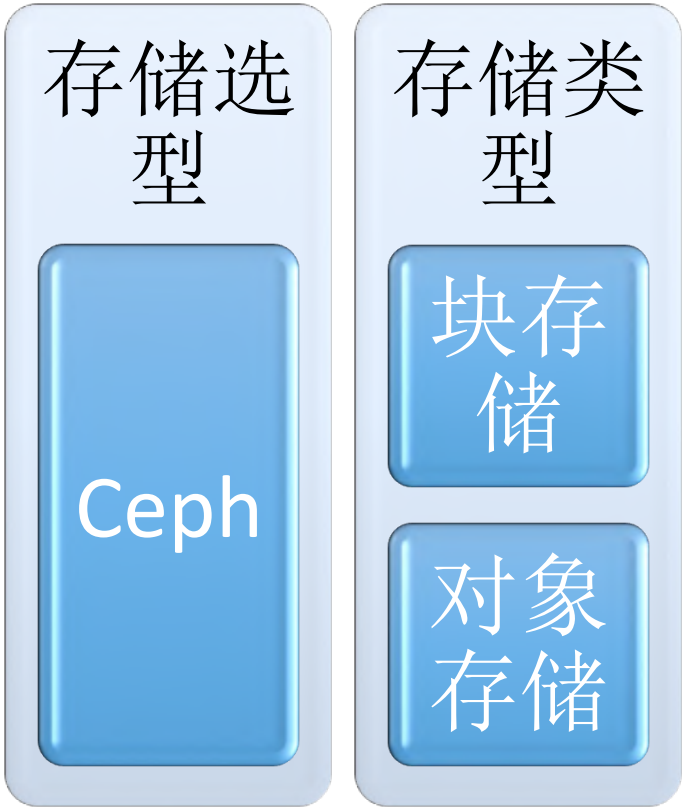

系统、数据盘均使用Ceph 网络盘

MySQL 数据使用本地 SSD 硬盘、数据备份使用 ceph 网络盘

Metadata数据通过挂载Ceph 网络盘进行VM初始化配置

集成方案-VM 创建流程

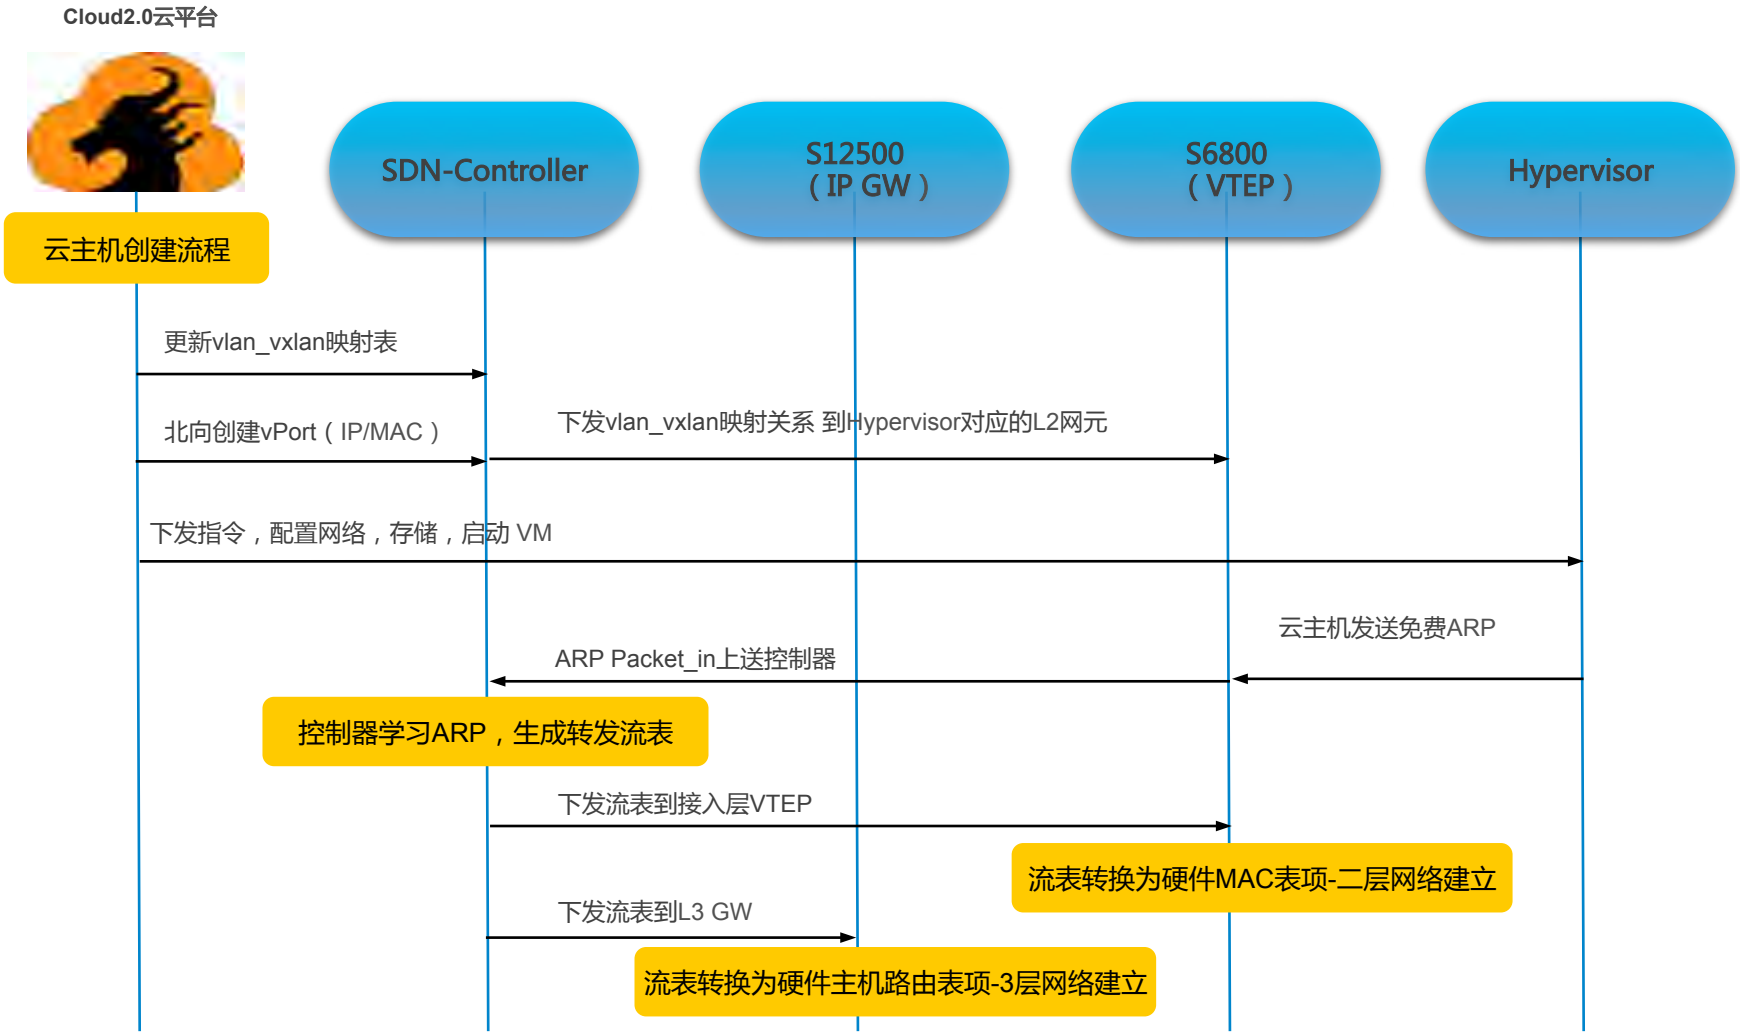
Cloud2.0云平台
SDN-Controller
S12500
（IP GW）
S6800
（VTEP）
Hypervisor
云主机创建流程
更新vlan_vxlan映射表
北向创建vPort（IP/MAC）
下发vlan_vxlan映射关系 到Hypervisor对应的L2网元
下发指令，配置网络，存储，启动 VM
云主机发送免费ARP
ARP Packet_in上送控制器
控制器学习ARP，生成转发流表
下发流表到接入层VTEP
流表转换为硬件MAC表项-二层网络建立
下发流表到L3 GW
流表转换为硬件主机路由表项-3层网络建立

运营保障

- 上线和迭代
  - 部分业务测试
  - 功能，稳定性磨合
- 关键组件质量保障
  - 集中式网关的性能，稳定性
  - 集群性能, 稳定性, 容量保障


WOTA
51CTO
Thank you !