QCon 全球软件开发大会
INTERNATIONAL SOFTWARE DEVELOPMENT CONFERENCE

BEIJING 2017

AWS数据中心与VPC揭秘

余骏 Ivan Yu

主办方 Geekbang. 极客邦科技 InfoQ

弹性是新常态

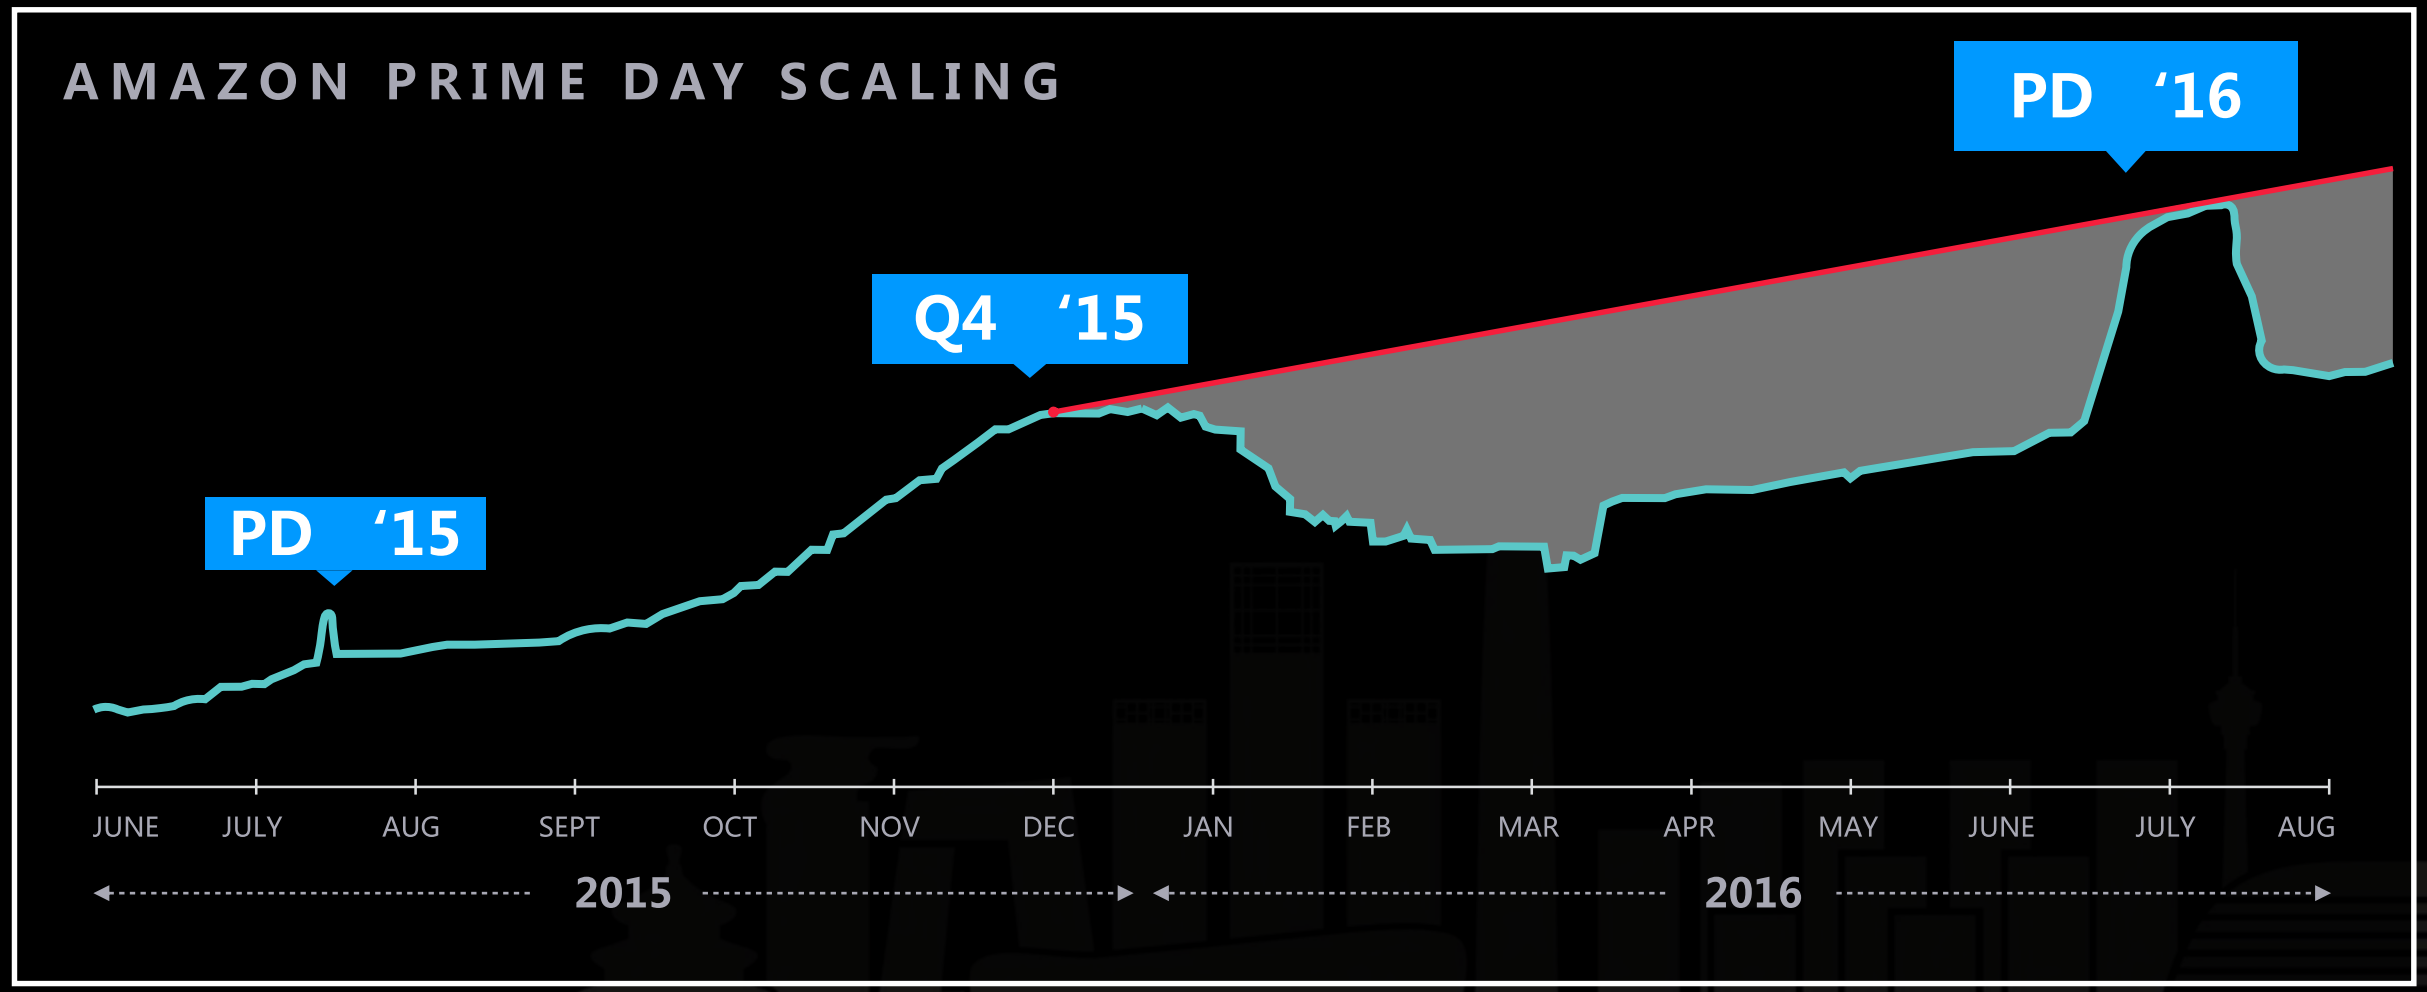
AMAZON PRIME DAY SCALING
PD '16
Q4 '15
PD '15
JUNE
JULY
AUG
SEPT
OCT
NOV
DEC
JAN
FEB
MAR
APR
MAY
JUNE
JULY
AUG
2015
2016

In 2015 AWS Deployed Almost

ENOUGH SERVER CAPACITY EVERY DAY TO SUPPORT AMAZON IN 2005

When it was an $8.49B Enterprise

AWS adds the capacity equivalent of a FORTUNE 500 Enterprise daily

Calculation was done by measuring server capacity in GHz using Amazon's net sales data from 2005.


AWS Govcloud
Oregon
N. California
Ohio
Montreal
N. Virginia
Ireland
London
Frankfurt
Paris
Ningxia
Beijing
Seoul
Tokyo
Mumbai
Singapore
São Paulo
Sydney
目前全球拥有16个区域
今年会扩展到18个区域


在全球拥有73个边缘站点

AWS全球网络基础设施

- 改善延迟、丢包率及总体网络质量
- 避免网络互联的带宽瓶颈
- 统一管理控制，快速响应

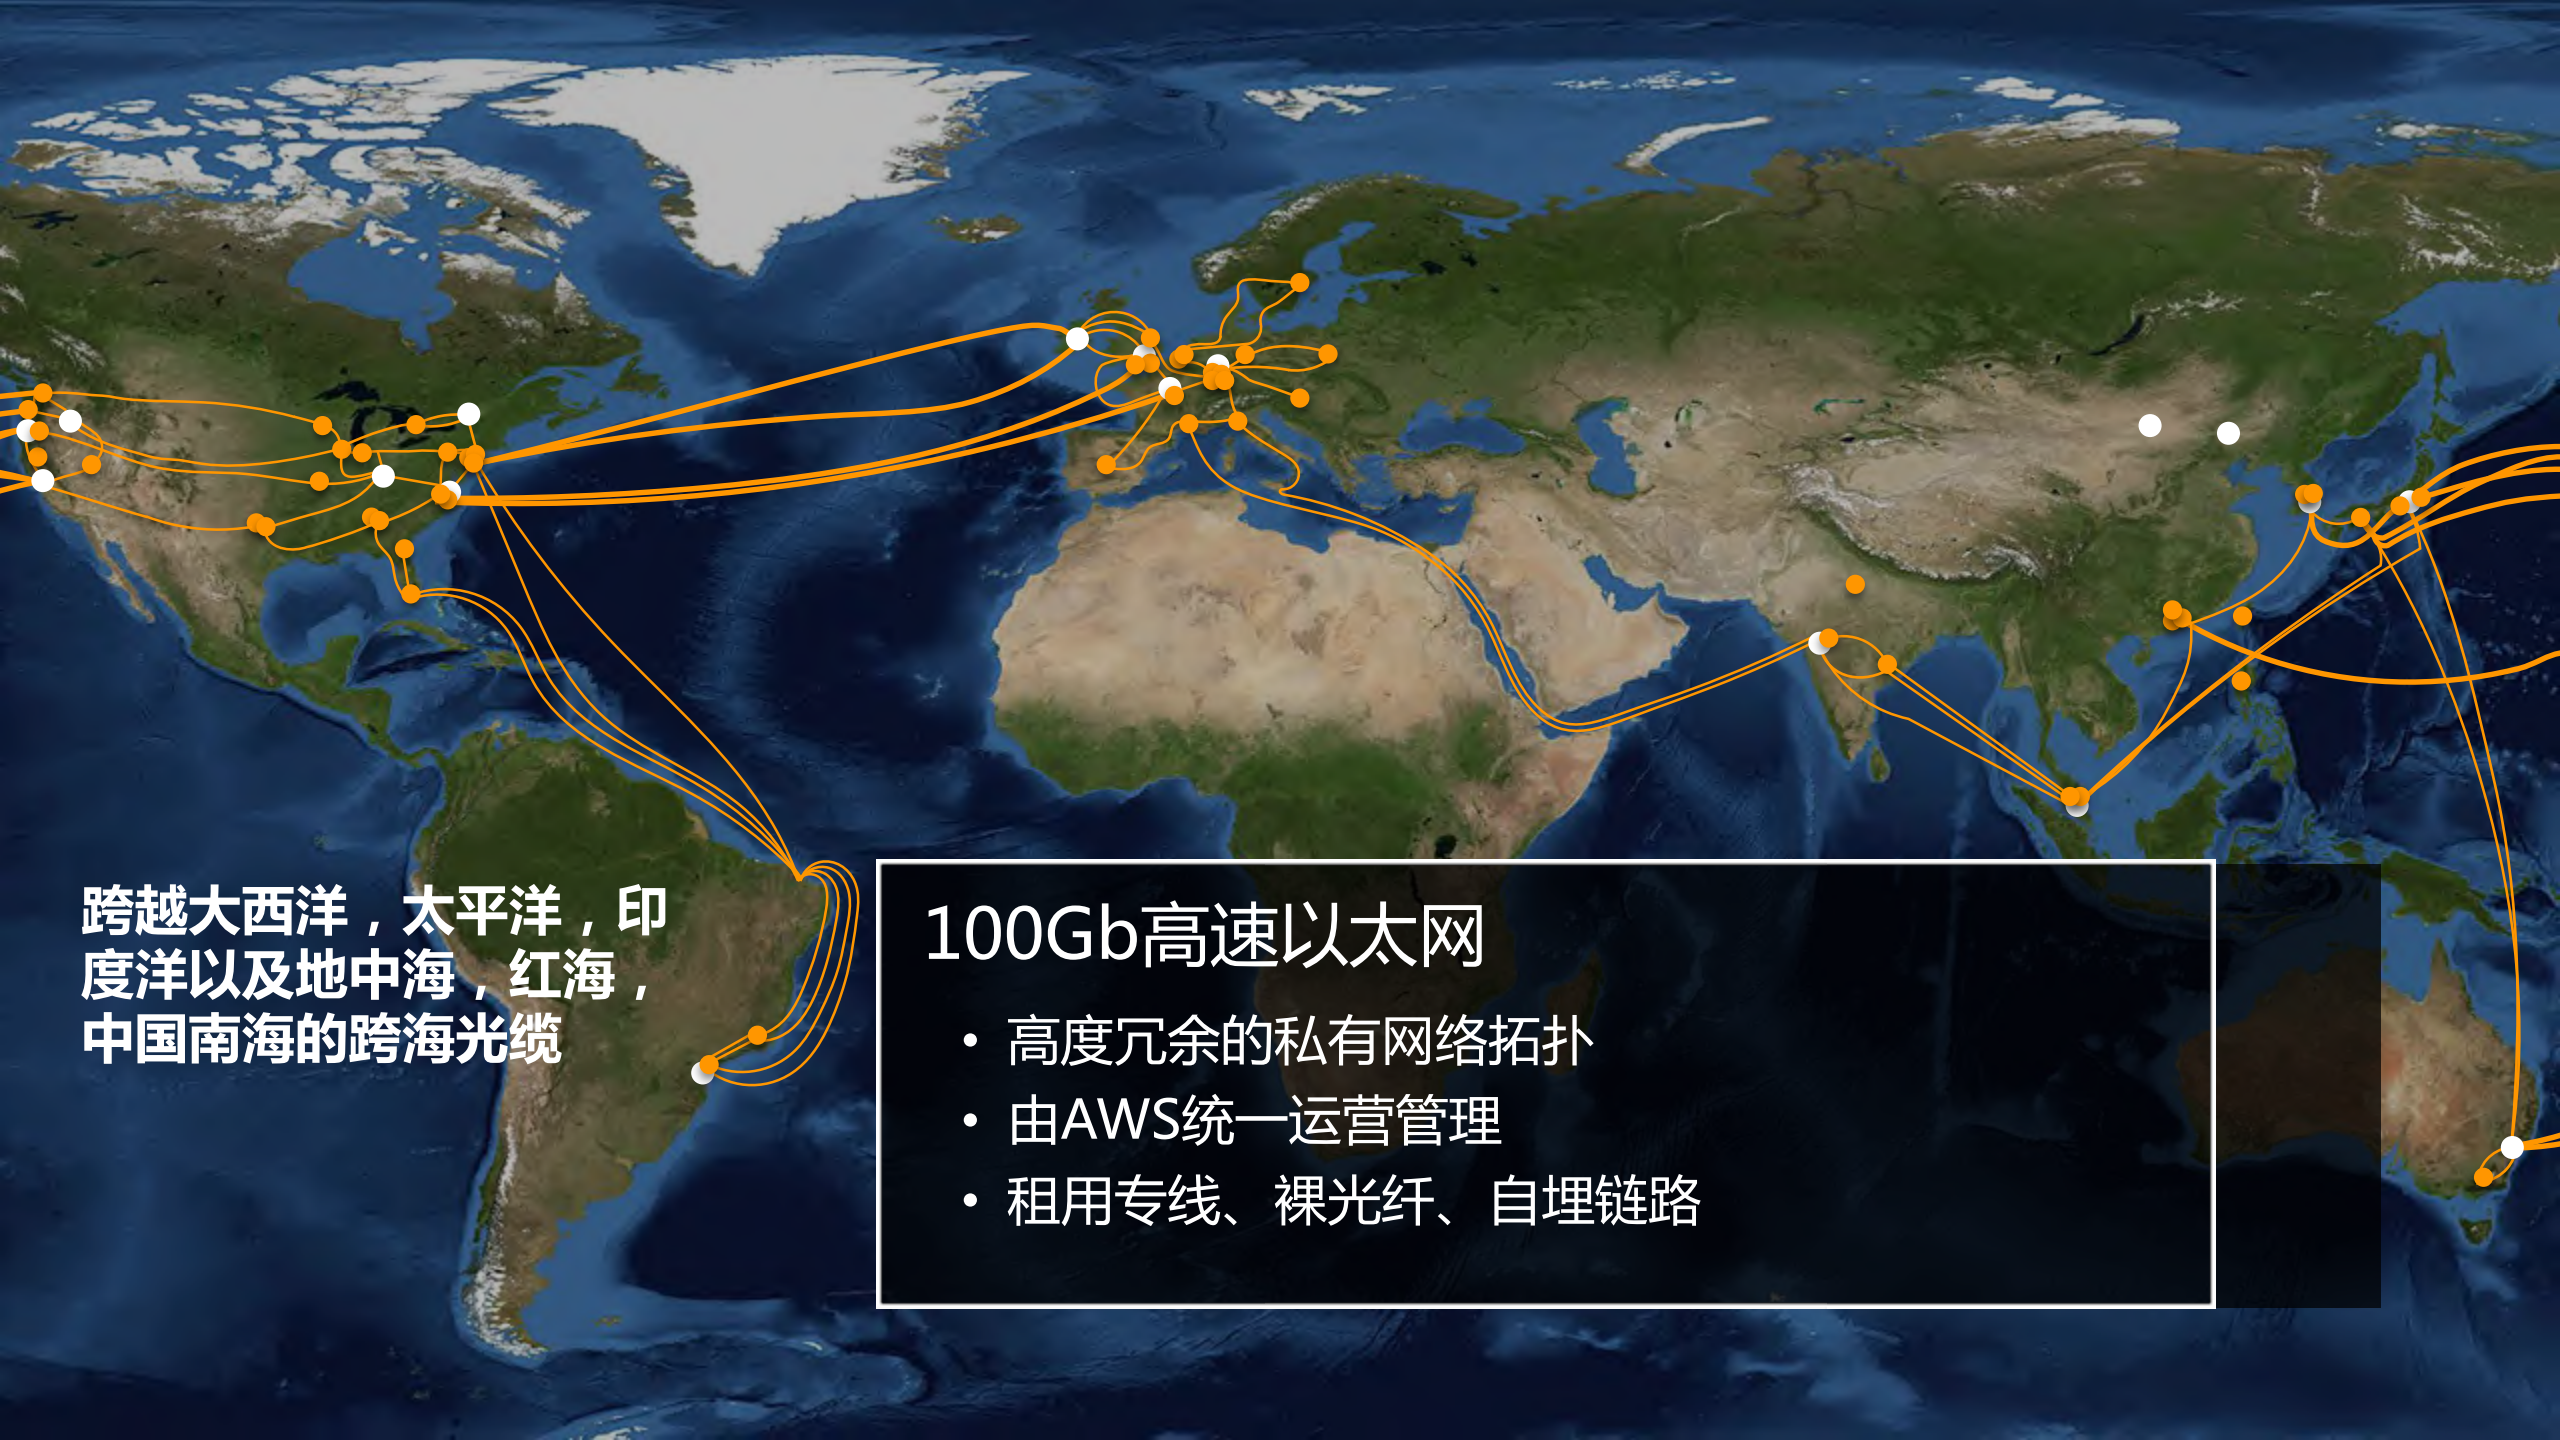

跨越大西洋，太平洋，印度洋以及地中海，红海，中国南海的跨海光缆

100Gb高速以太网

- 高度冗余的私有网络拓扑
- 由AWS统一运营管理
- 租用专线、裸光纤、自埋链路

最新项目

- 跨太平洋海底光缆
- 总长14,000km，连接澳大利亚，新西兰，夏威夷和俄勒冈
- 3对光纤
- 100 waves @ 100G
- 新西兰海岸破土工程已于去年启动

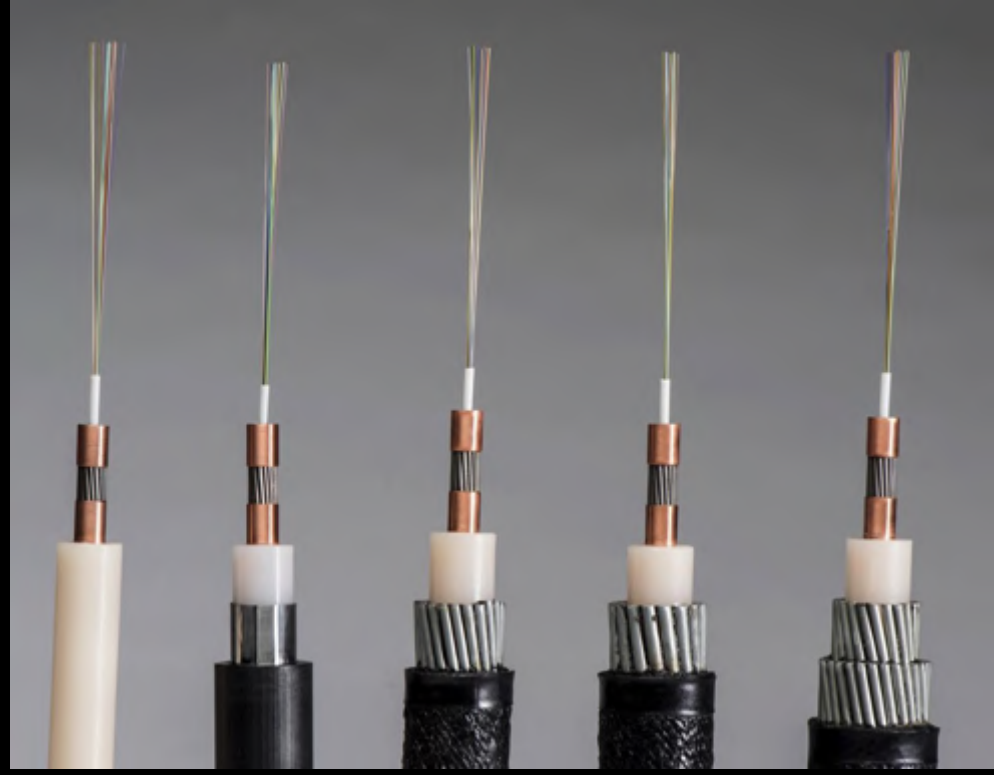

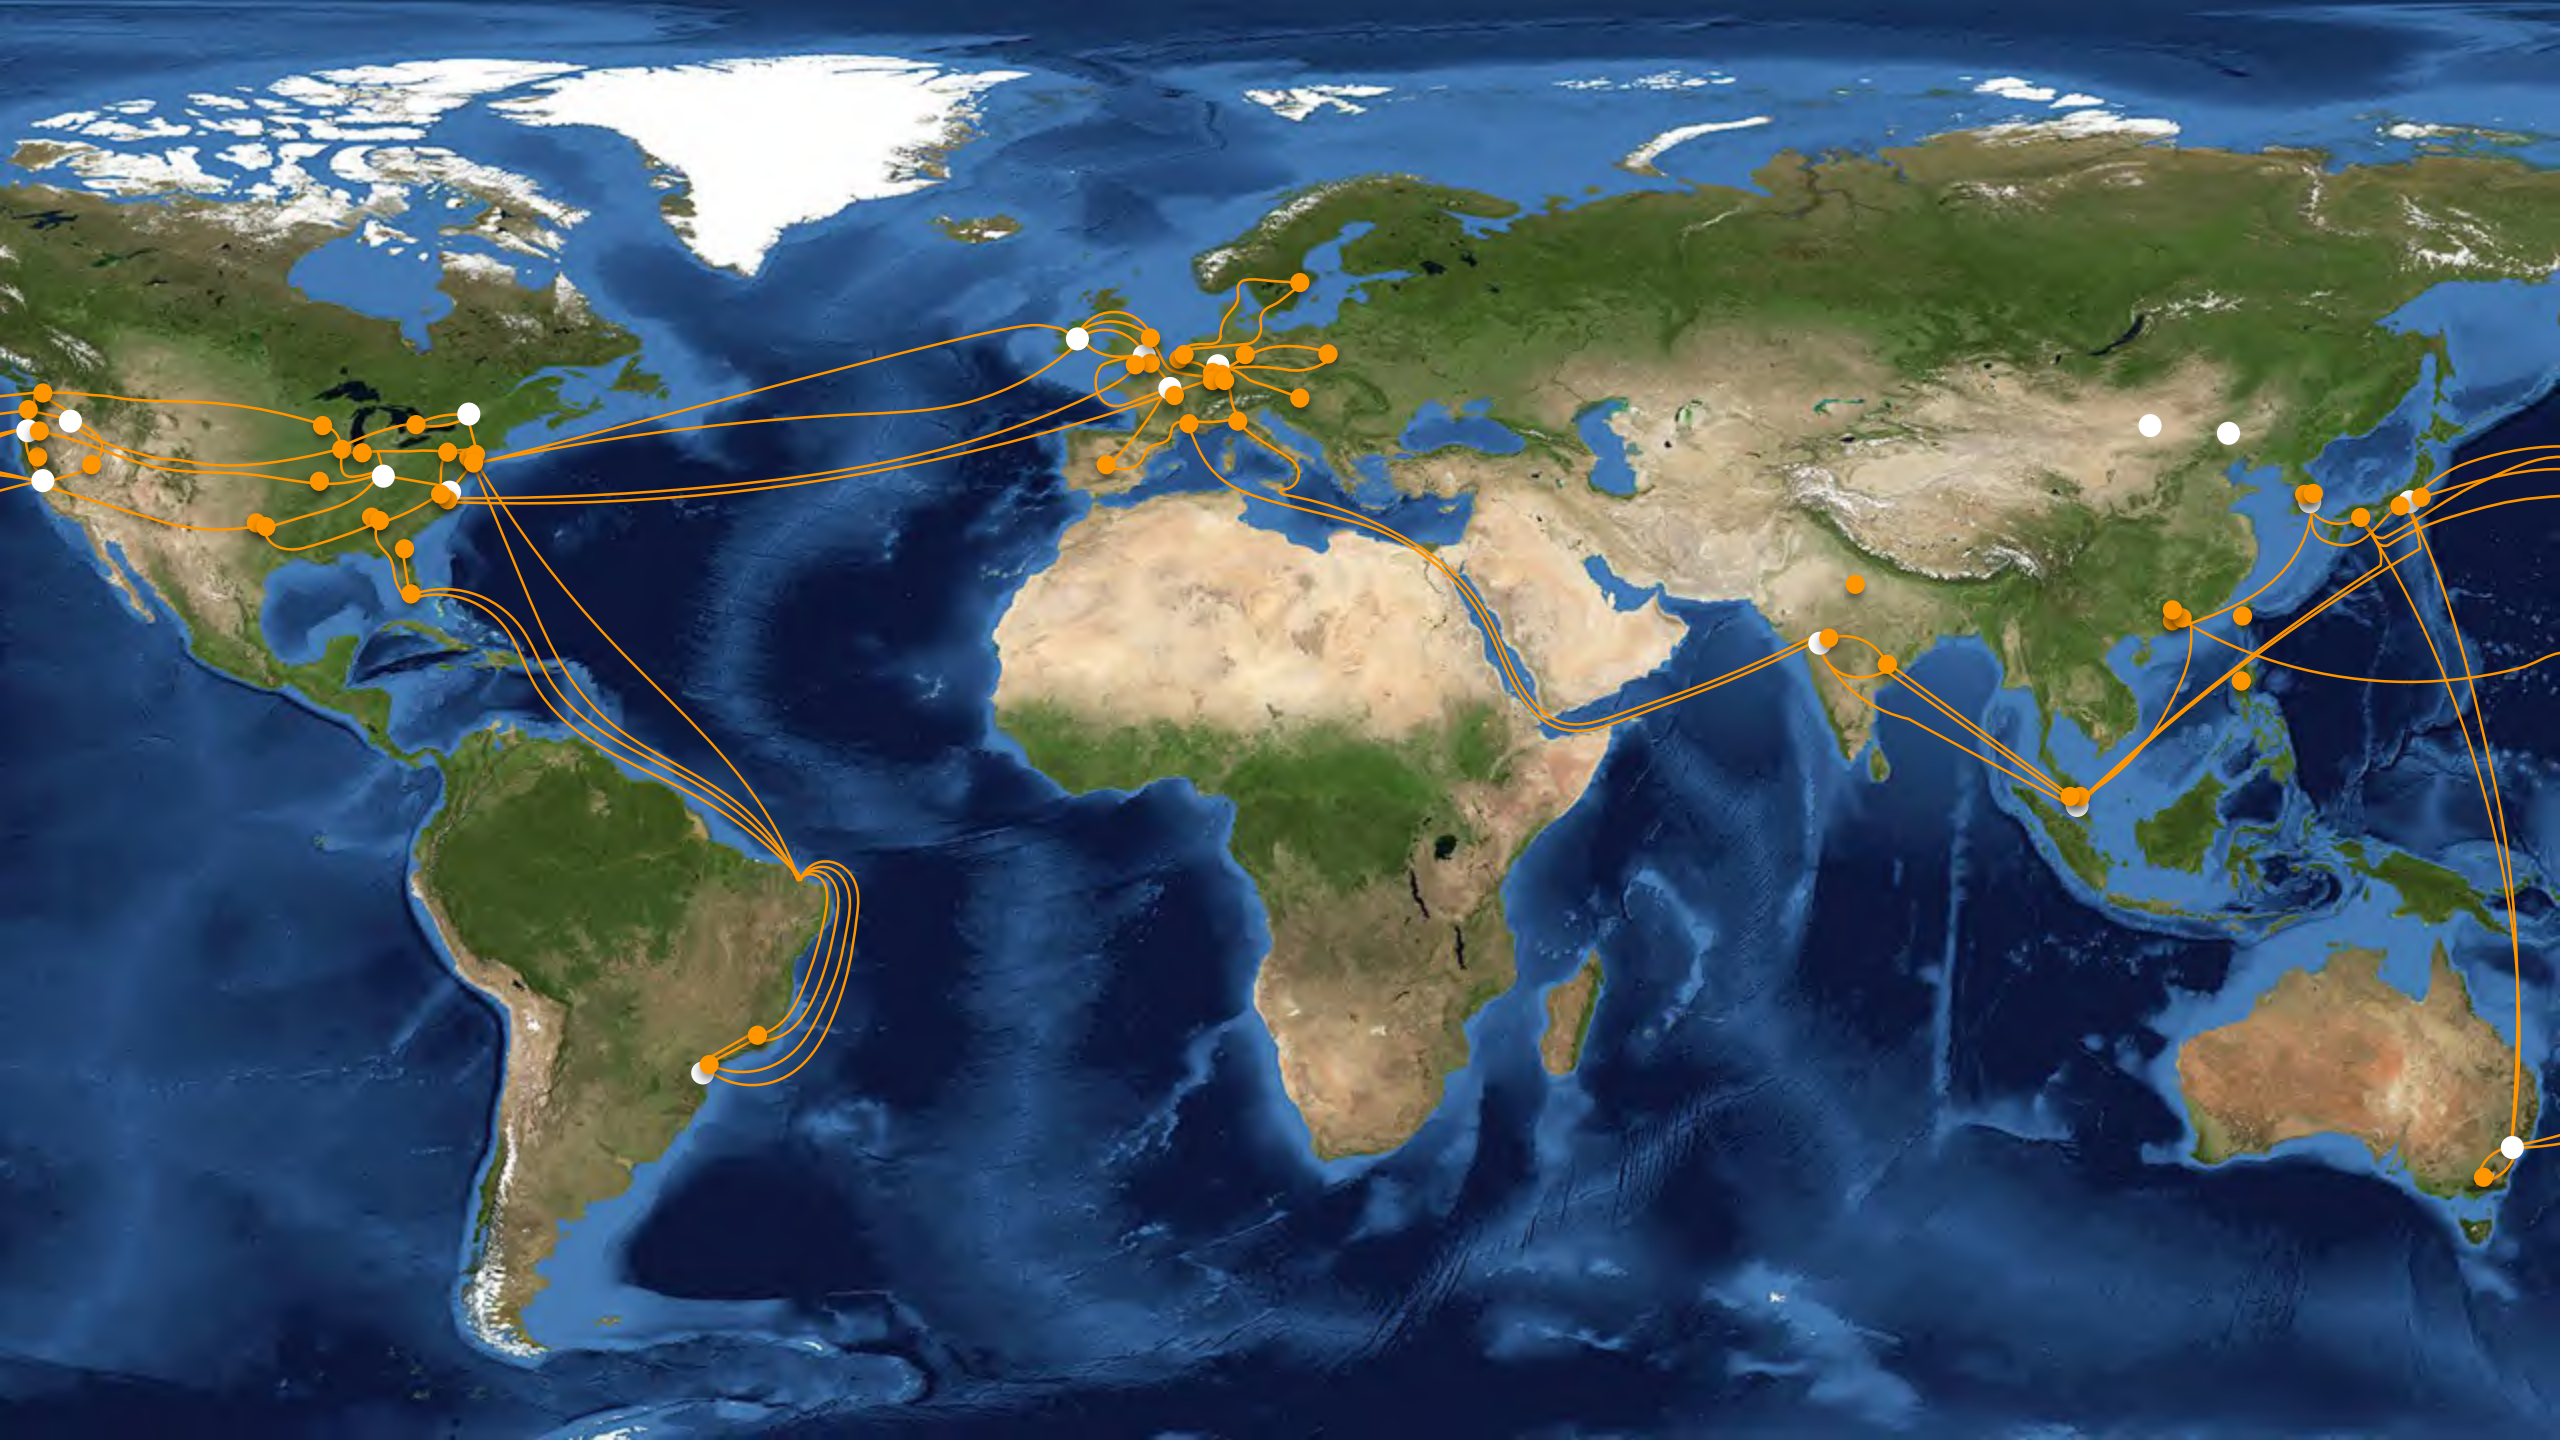

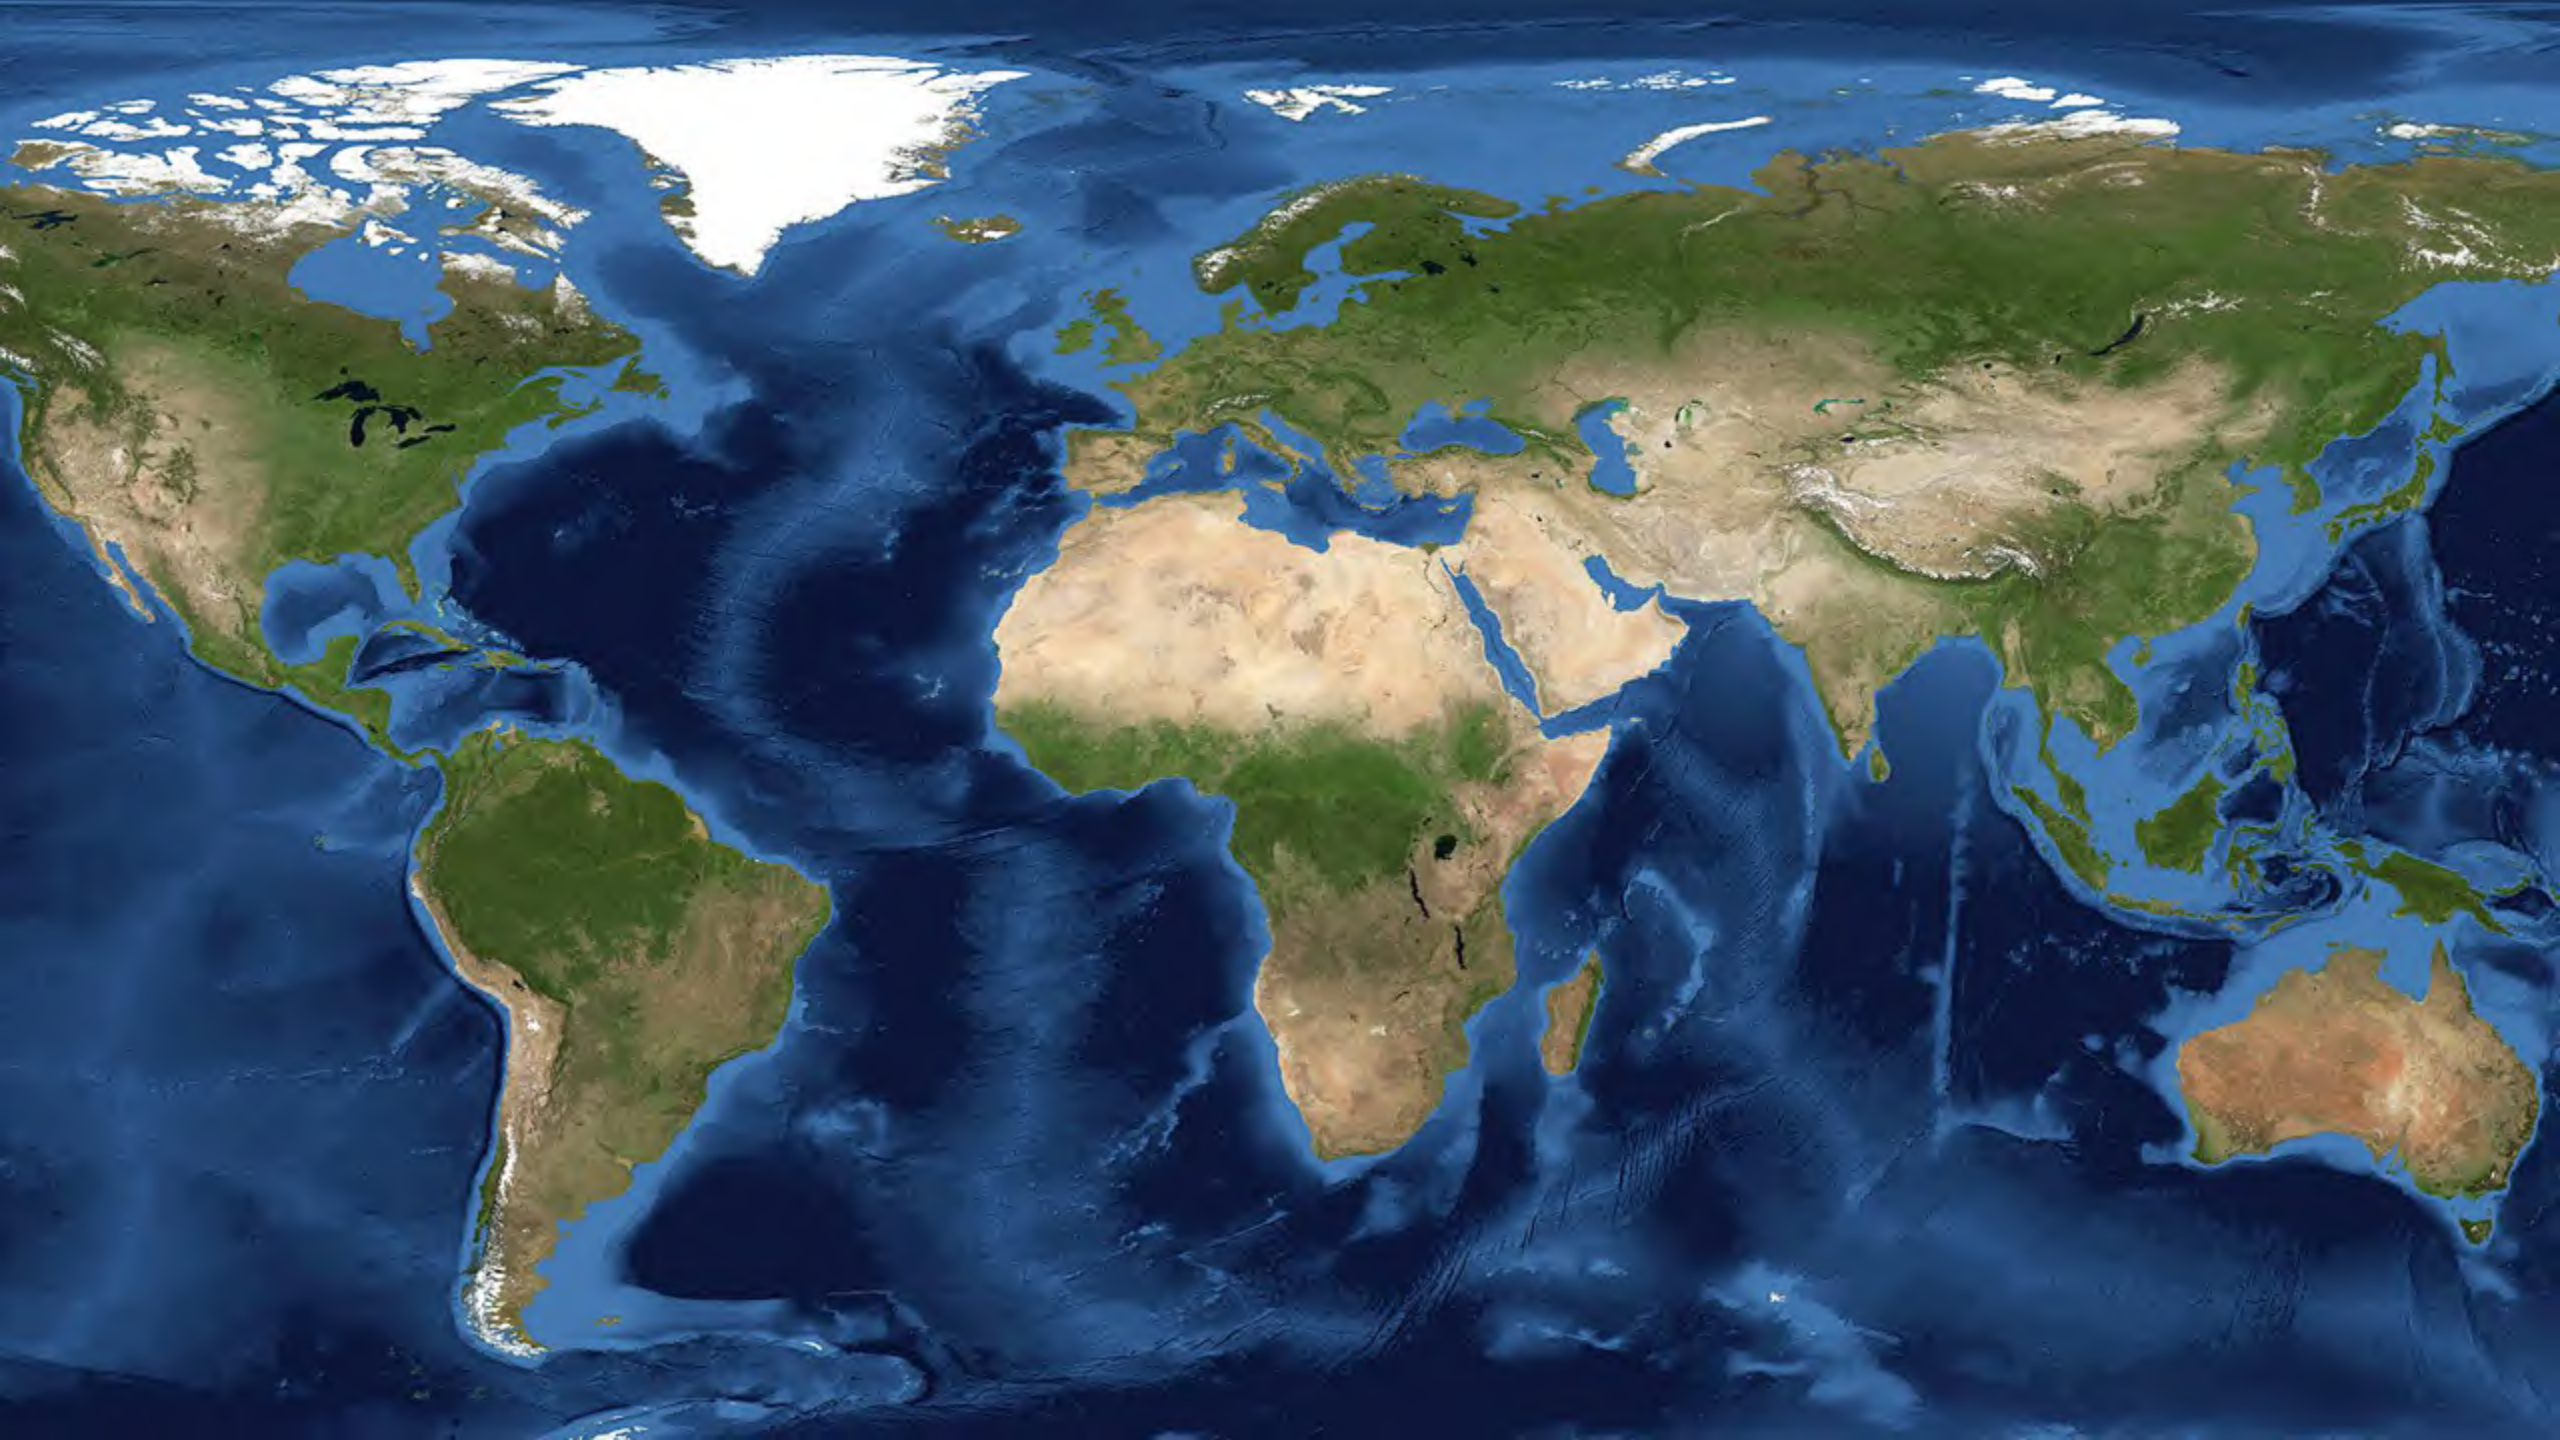

转接中心

- 每个区域拥有2个冗余的转接中心
- 高速互联的基础设施

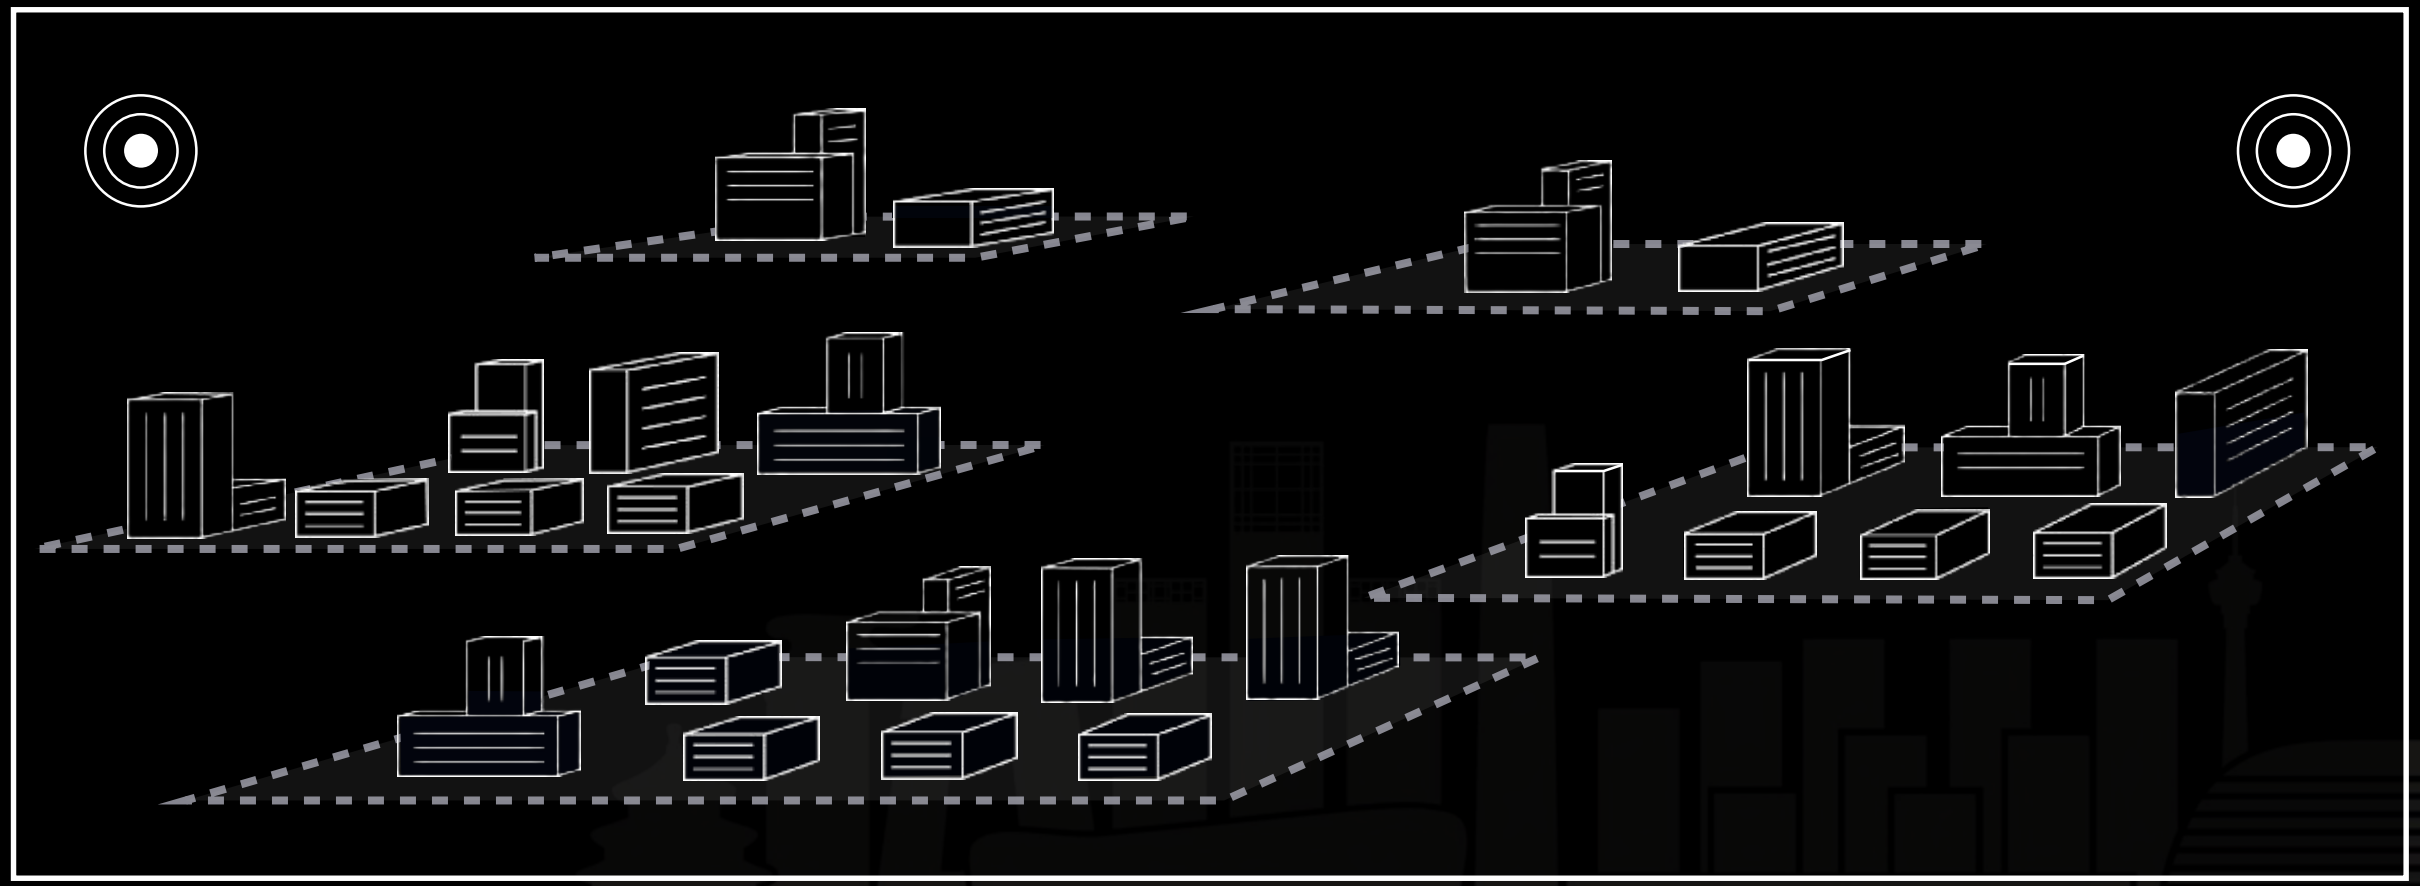

城域光纤网络

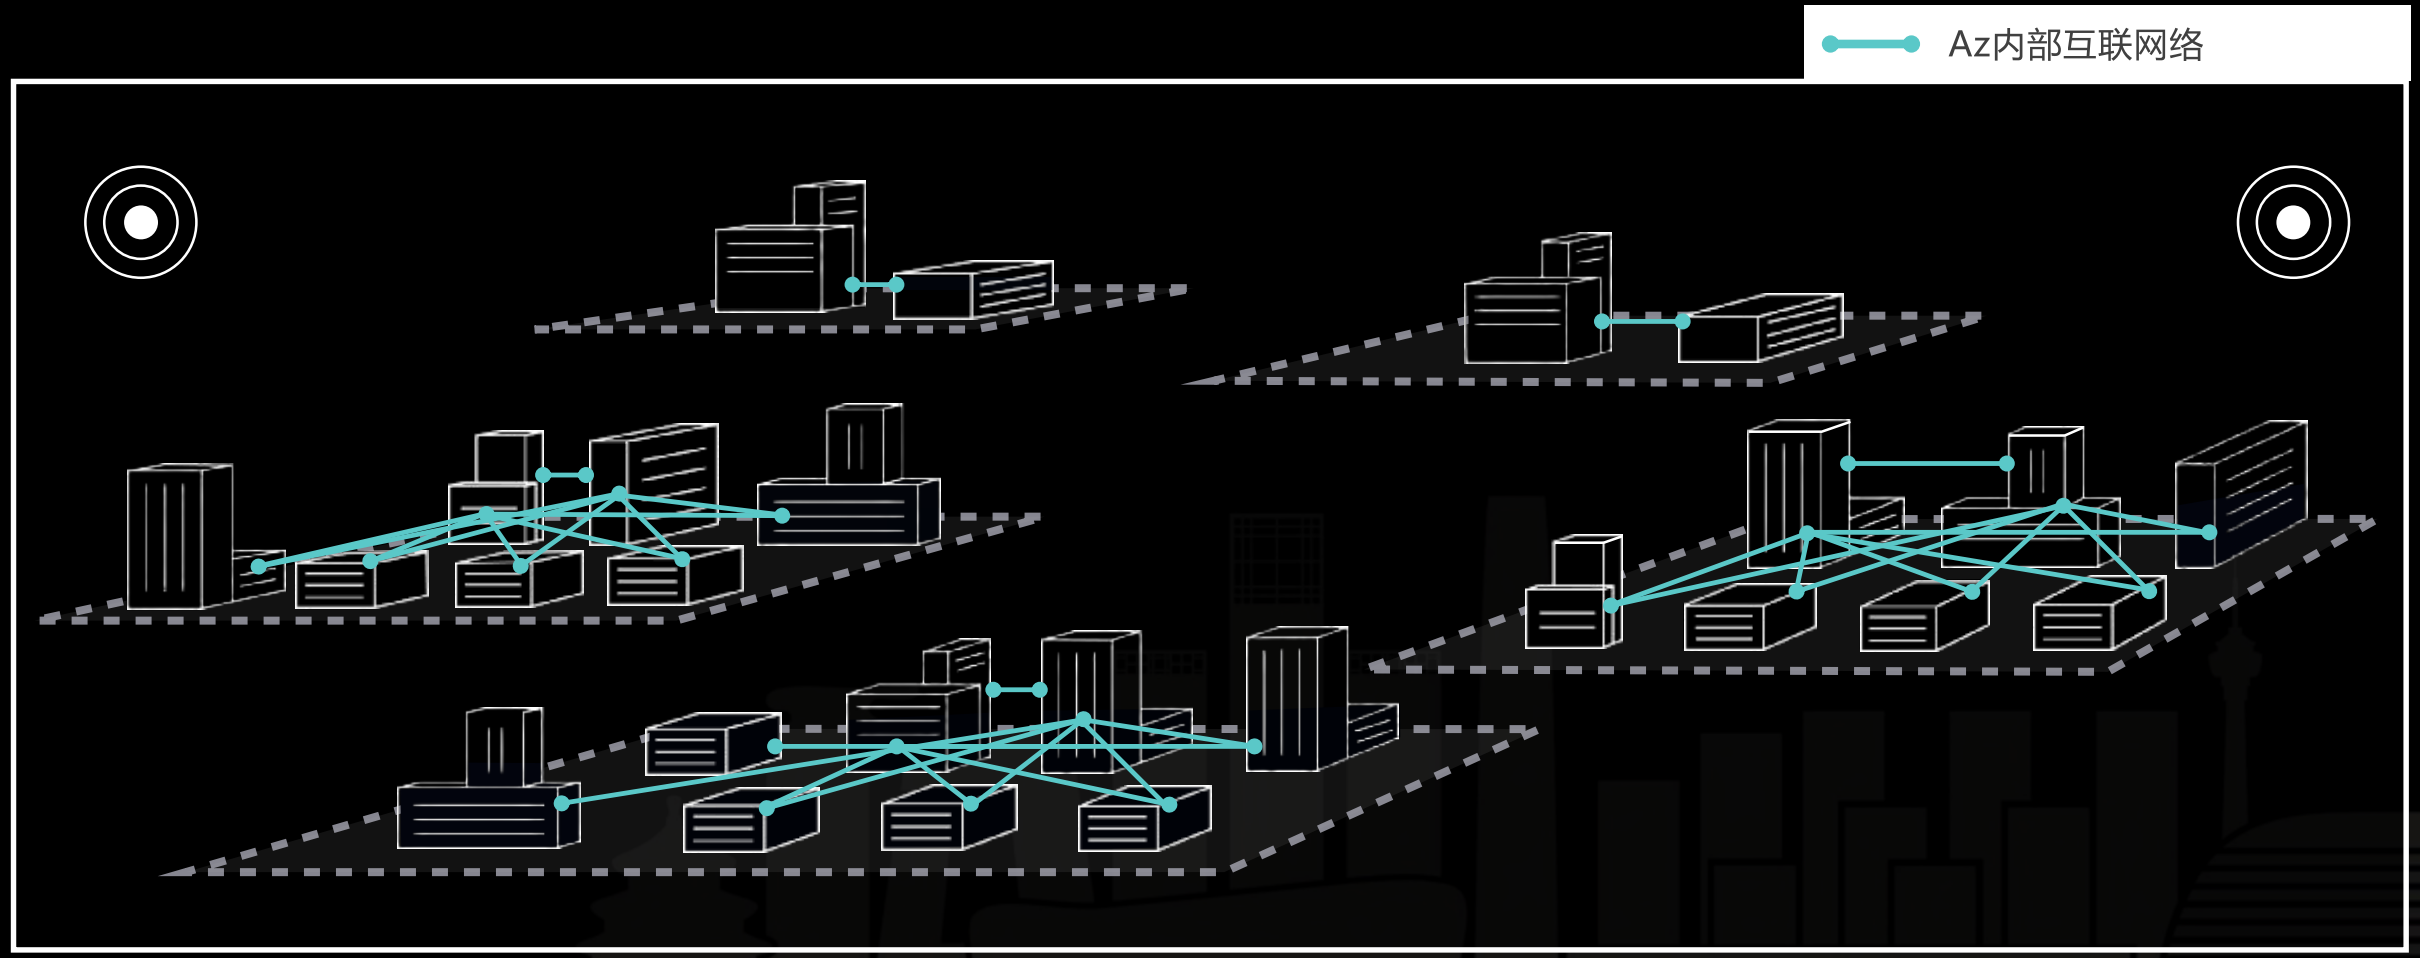

城域光纤网络

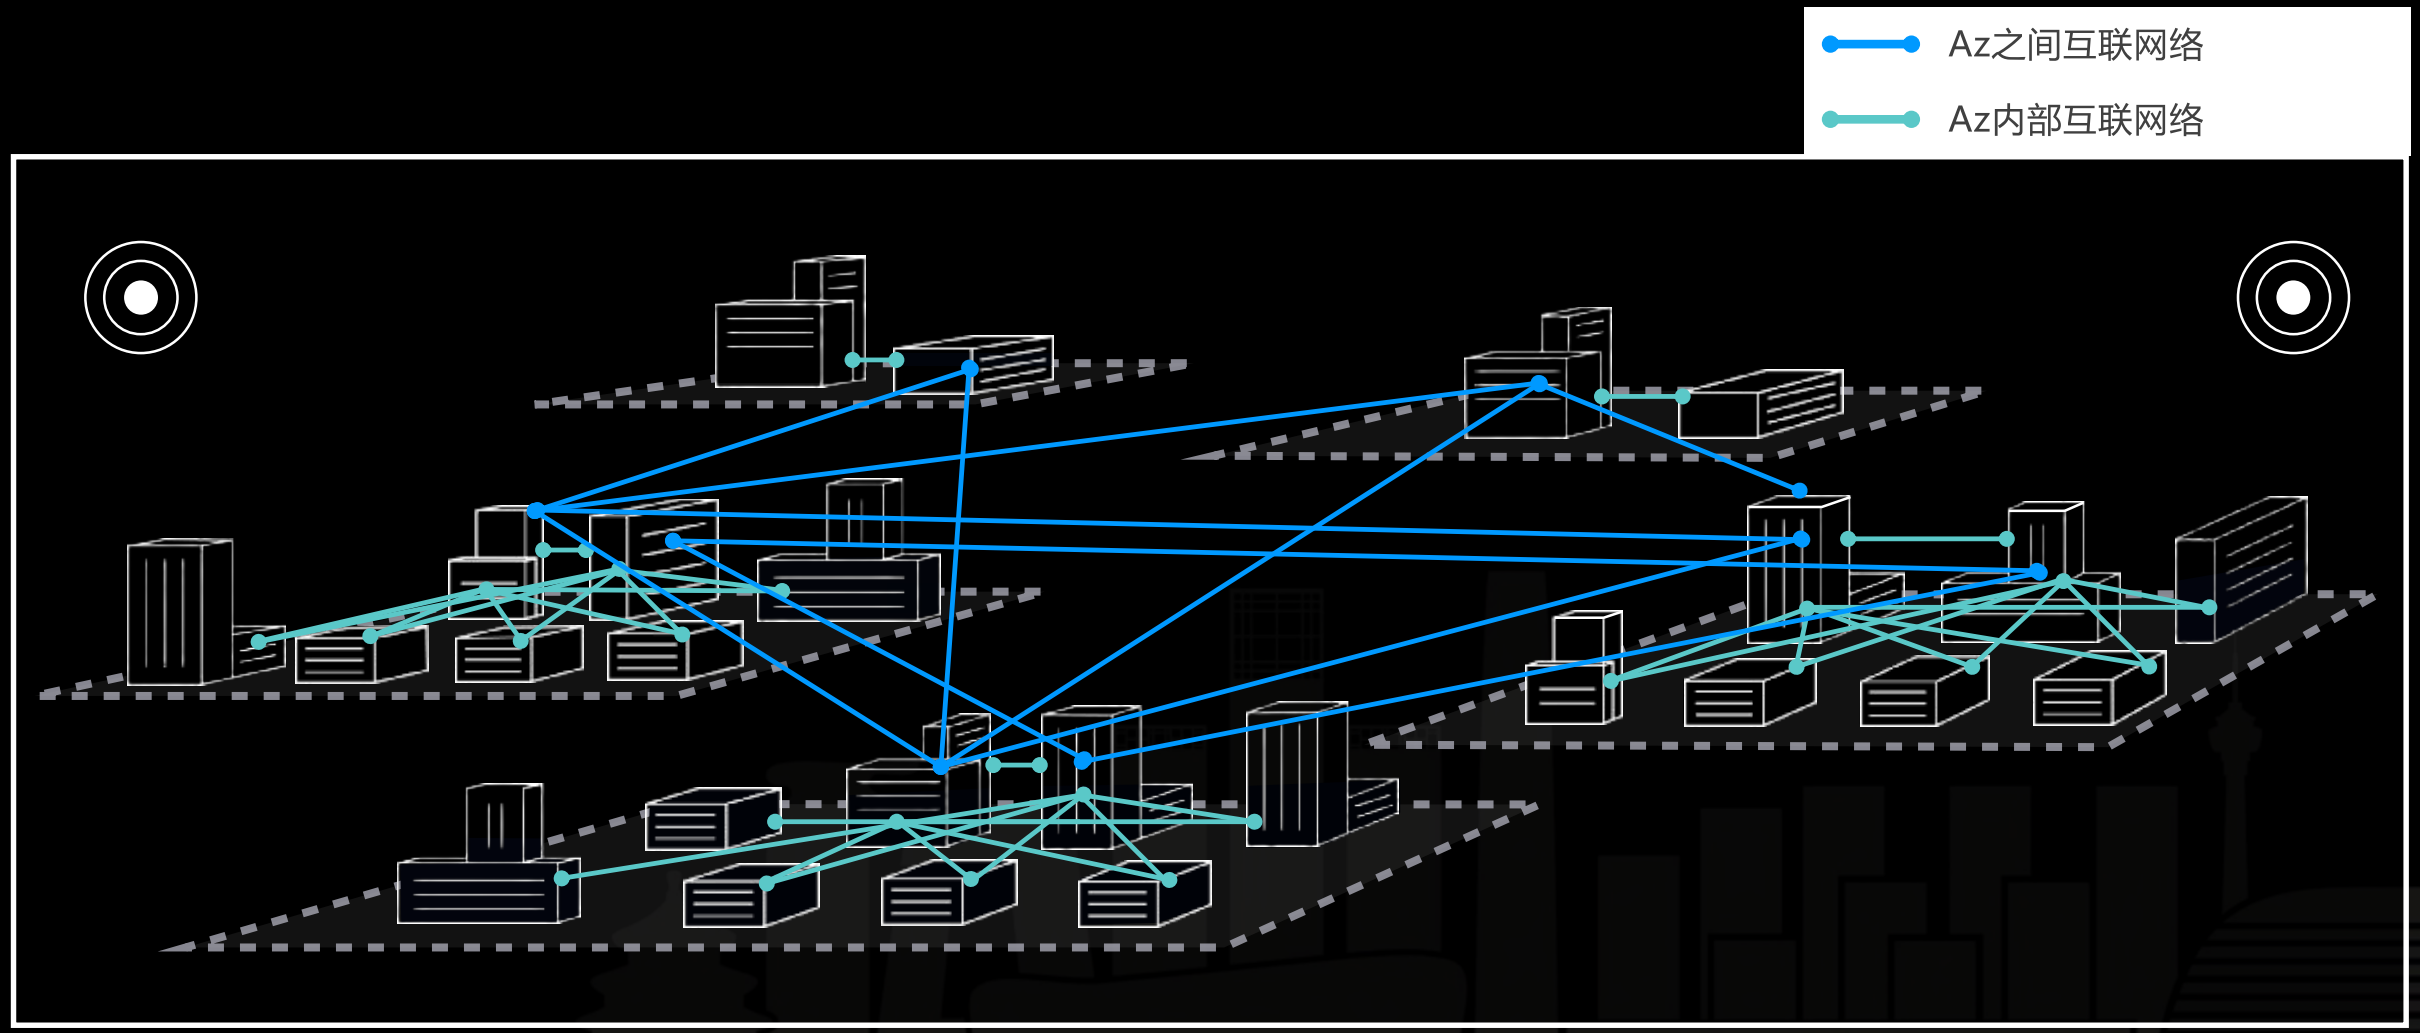

城域光纤网络

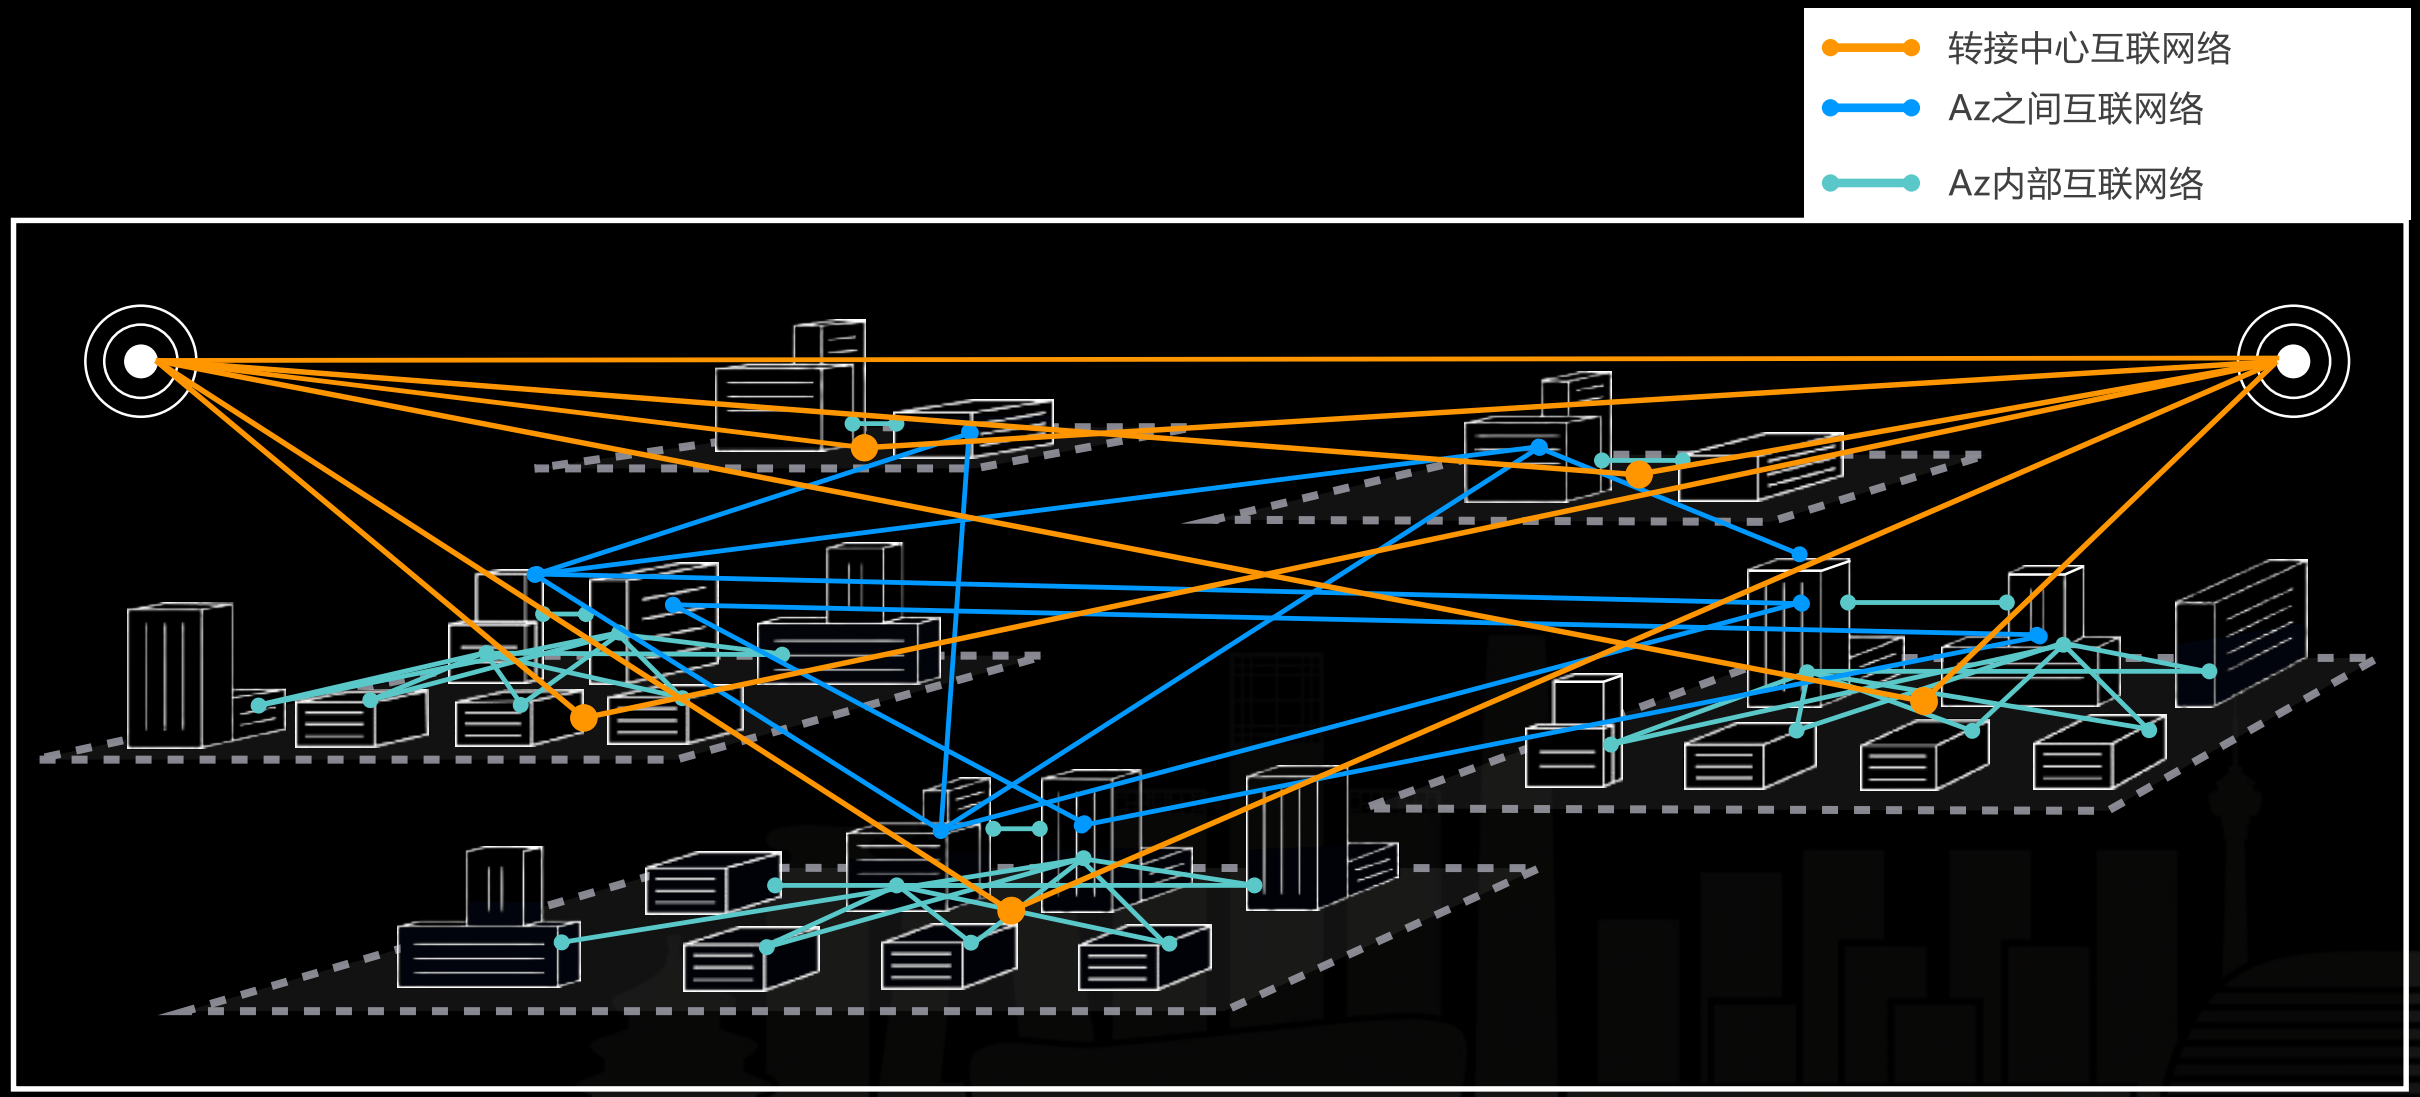

高度可扩展的可用区设计

- 每个可用区包含1个以上的数据中心
- 某些可用区包含多达8个数据中心
- 数据中心之间通过冗余的光纤互联
- 部分可用区拥有超过30W台规模的服务器

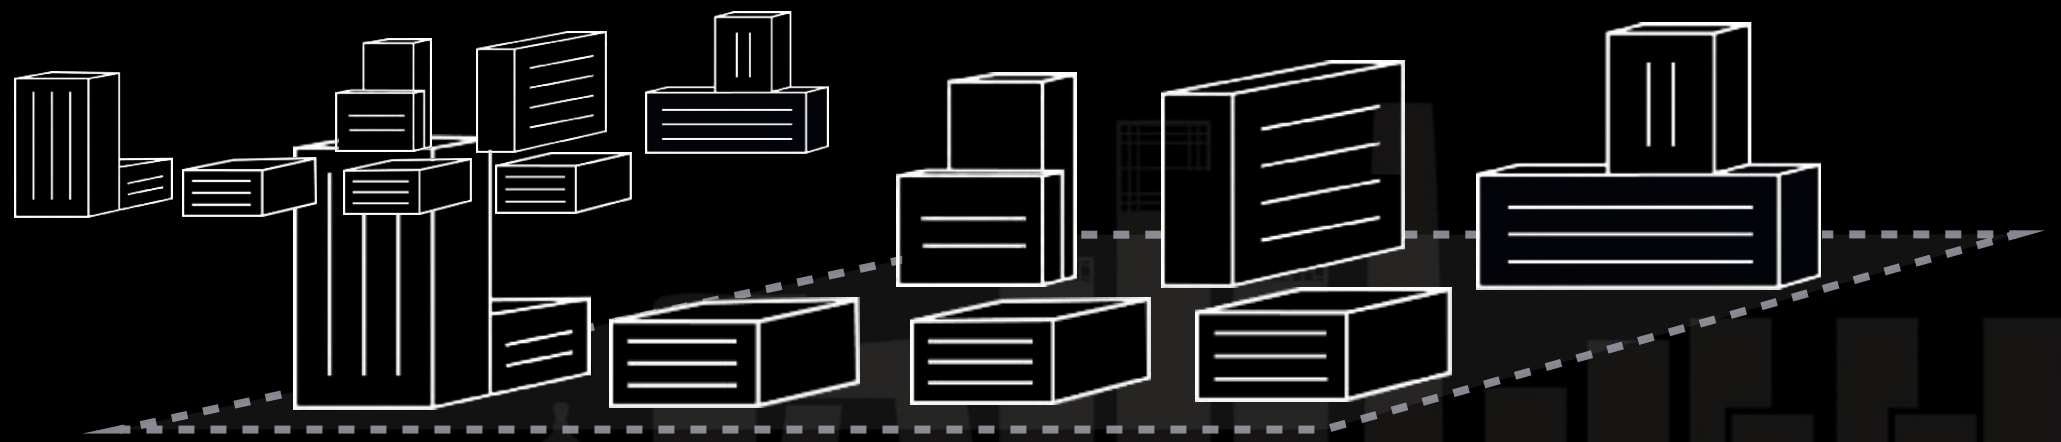

数据中心设计

- **很容易实现60–120MW或者更大规模的数据中心**
- 更大规模的数据中心会带来过大的故障域

AWS定制化路由器

- 市场上销售的路由器
  - 功能复杂，可靠性低
  - 售价昂贵
  - 故障修复缓慢（6个月）
- AWS定制化路由器
  - 硬件基于AWS标准制造
  - 软件协议由AWS定制开发
- 设计之初便遵循25GbE路线
  - 业界处于10GbE & 40GbE
  - 光模块供应短缺
- 40GbE实际上由4对10GbE光纤构成
- 50GbE (2x 25GbE)拥有比40GbE更低的成本及更高的速度

AWS定制化路由器

- 市场上销售的路由器
  - 功能复杂，可靠性低
  - 售价昂贵
  - 故障修复缓慢（6个月）
- AWS定制化路由器
  - 硬件基于AWS标准制造
  - 软件协议由AWS定制开发
- 设计之初便遵循25GbE路线
  - 业界处于10GbE & 40GbE
  - 光模块供应短缺
- 40GbE实际上由4对10GbE光纤构成
- 50GbE (2x 25GbE)拥有比40GbE更低的成本及更高的速度

AWS定制化路由器

- 市场上销售的路由器
  - 功能复杂，可靠性低
  - 售价昂贵
  - 故障修复缓慢（6个月）
- AWS定制化路由器
  - 硬件基于AWS标准制造
  - 软件协议由AWS定制开发
- 设计之初便遵循25GbE路线
  - 业界处于10GbE & 40GbE
  - 光模块供应短缺
- 40GbE实际上由4对10GbE光纤构成
- 50GbE (2x 25GbE)拥有比40GbE更低的成本及更高的速度

AWS定制化路由器

- 基于Broadcom Tomahawk芯片
  - 70亿个晶体管
  - 128个25GbE端口
  - 1RU, 22lbs, <310W
- Amazon Annapurna ASIC
  - 支持第二代增强型网络
  - AWS控制芯片、硬件和软件
  - 更快地迭代创新
- EC2实例的最大带宽高达20GbE
  - 小机型的最大带宽可以达到10GbE

AWS定制化存储

- 2014: 880块磁盘/机架
- 下一代设计:
  - 1,110块磁盘/机架
  - 最初设计容量8.8PB (目前实际高达11PB)
  - 2,778 lbs of storage

AWS定制化服务器

- 1RU设计
- 散热及电源效率为导向
- PSU & VRD >90%效率

VPC基本概念

分布式映射服务

Server 192.168.0.3

10.0.0.2

10.0.0.2

Server 192.168.0.4

10.0.0.4

10.0.0.5

Server 192.168.1.3

10.0.0.3

10.0.0.4

Server 192.168.1.4

10.0.0.3

分布式映射服务：

VPC ID

a2b3c4d

传统二层以太网的通信机制

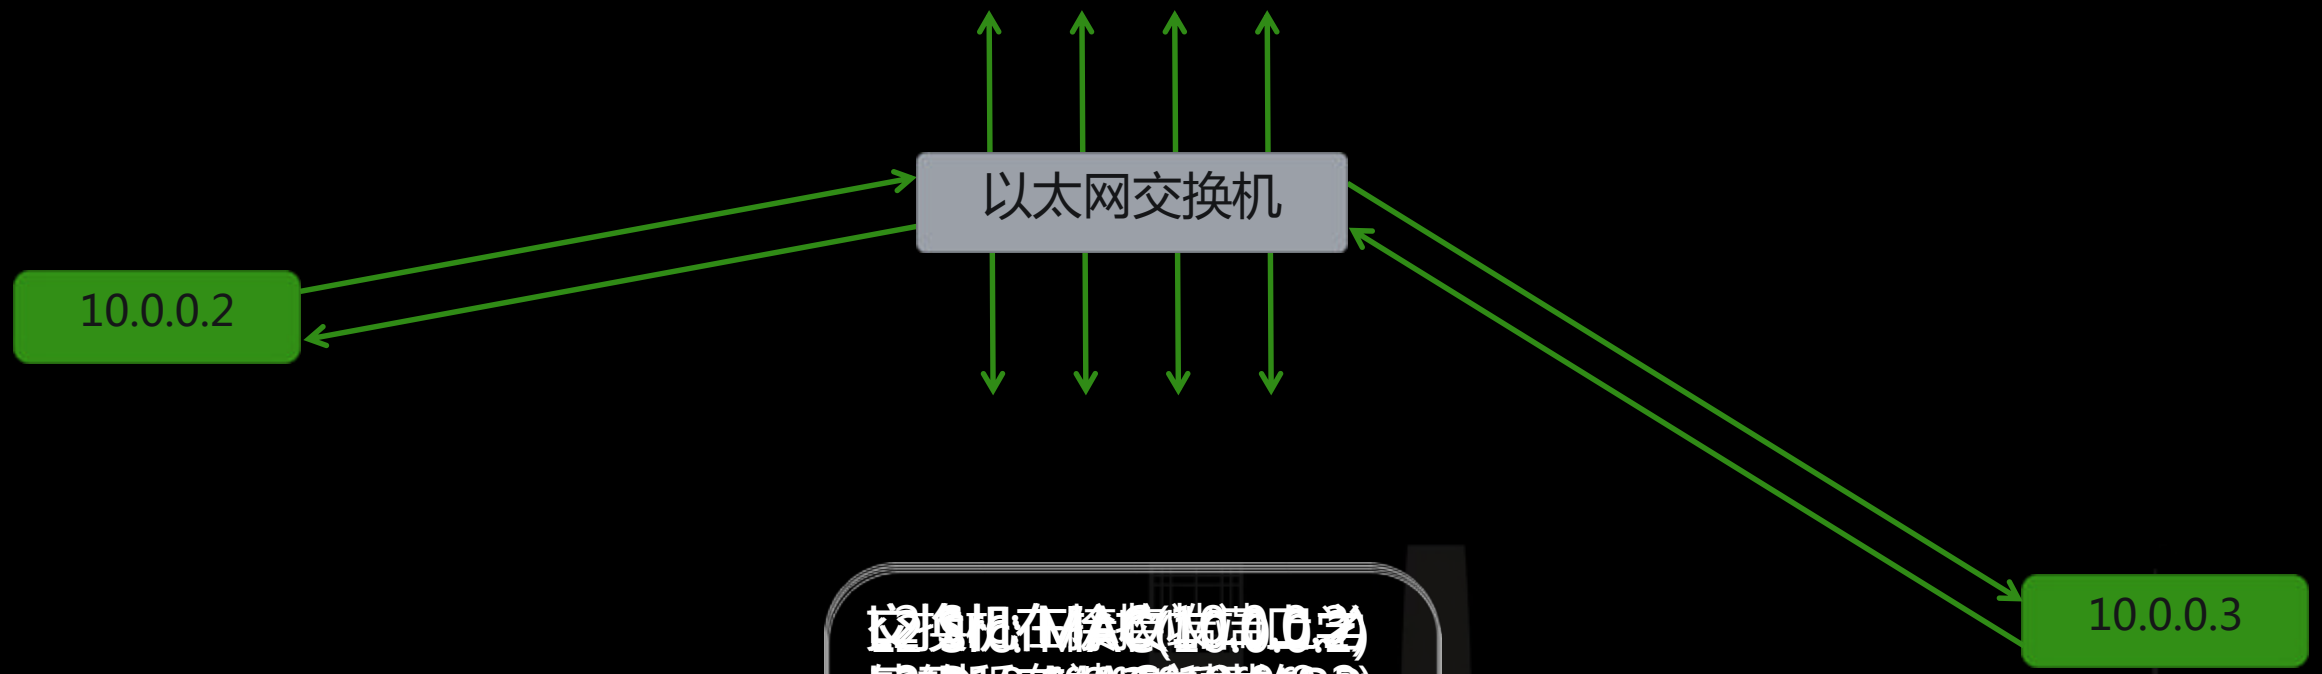

L2 Src: MAC(10.0.0.2)
L2 Dst: MAC(10.0.0.3)
L3 Src: 10.0.0.2
L3 Dst: 10.0.0.3 更新MAC
ARP请求：10.0.0.3主机
的MAC地址是多少？
ICMP/TCP/UDP/...

VPC中的二层通信机制

VPC中的二层通信机制

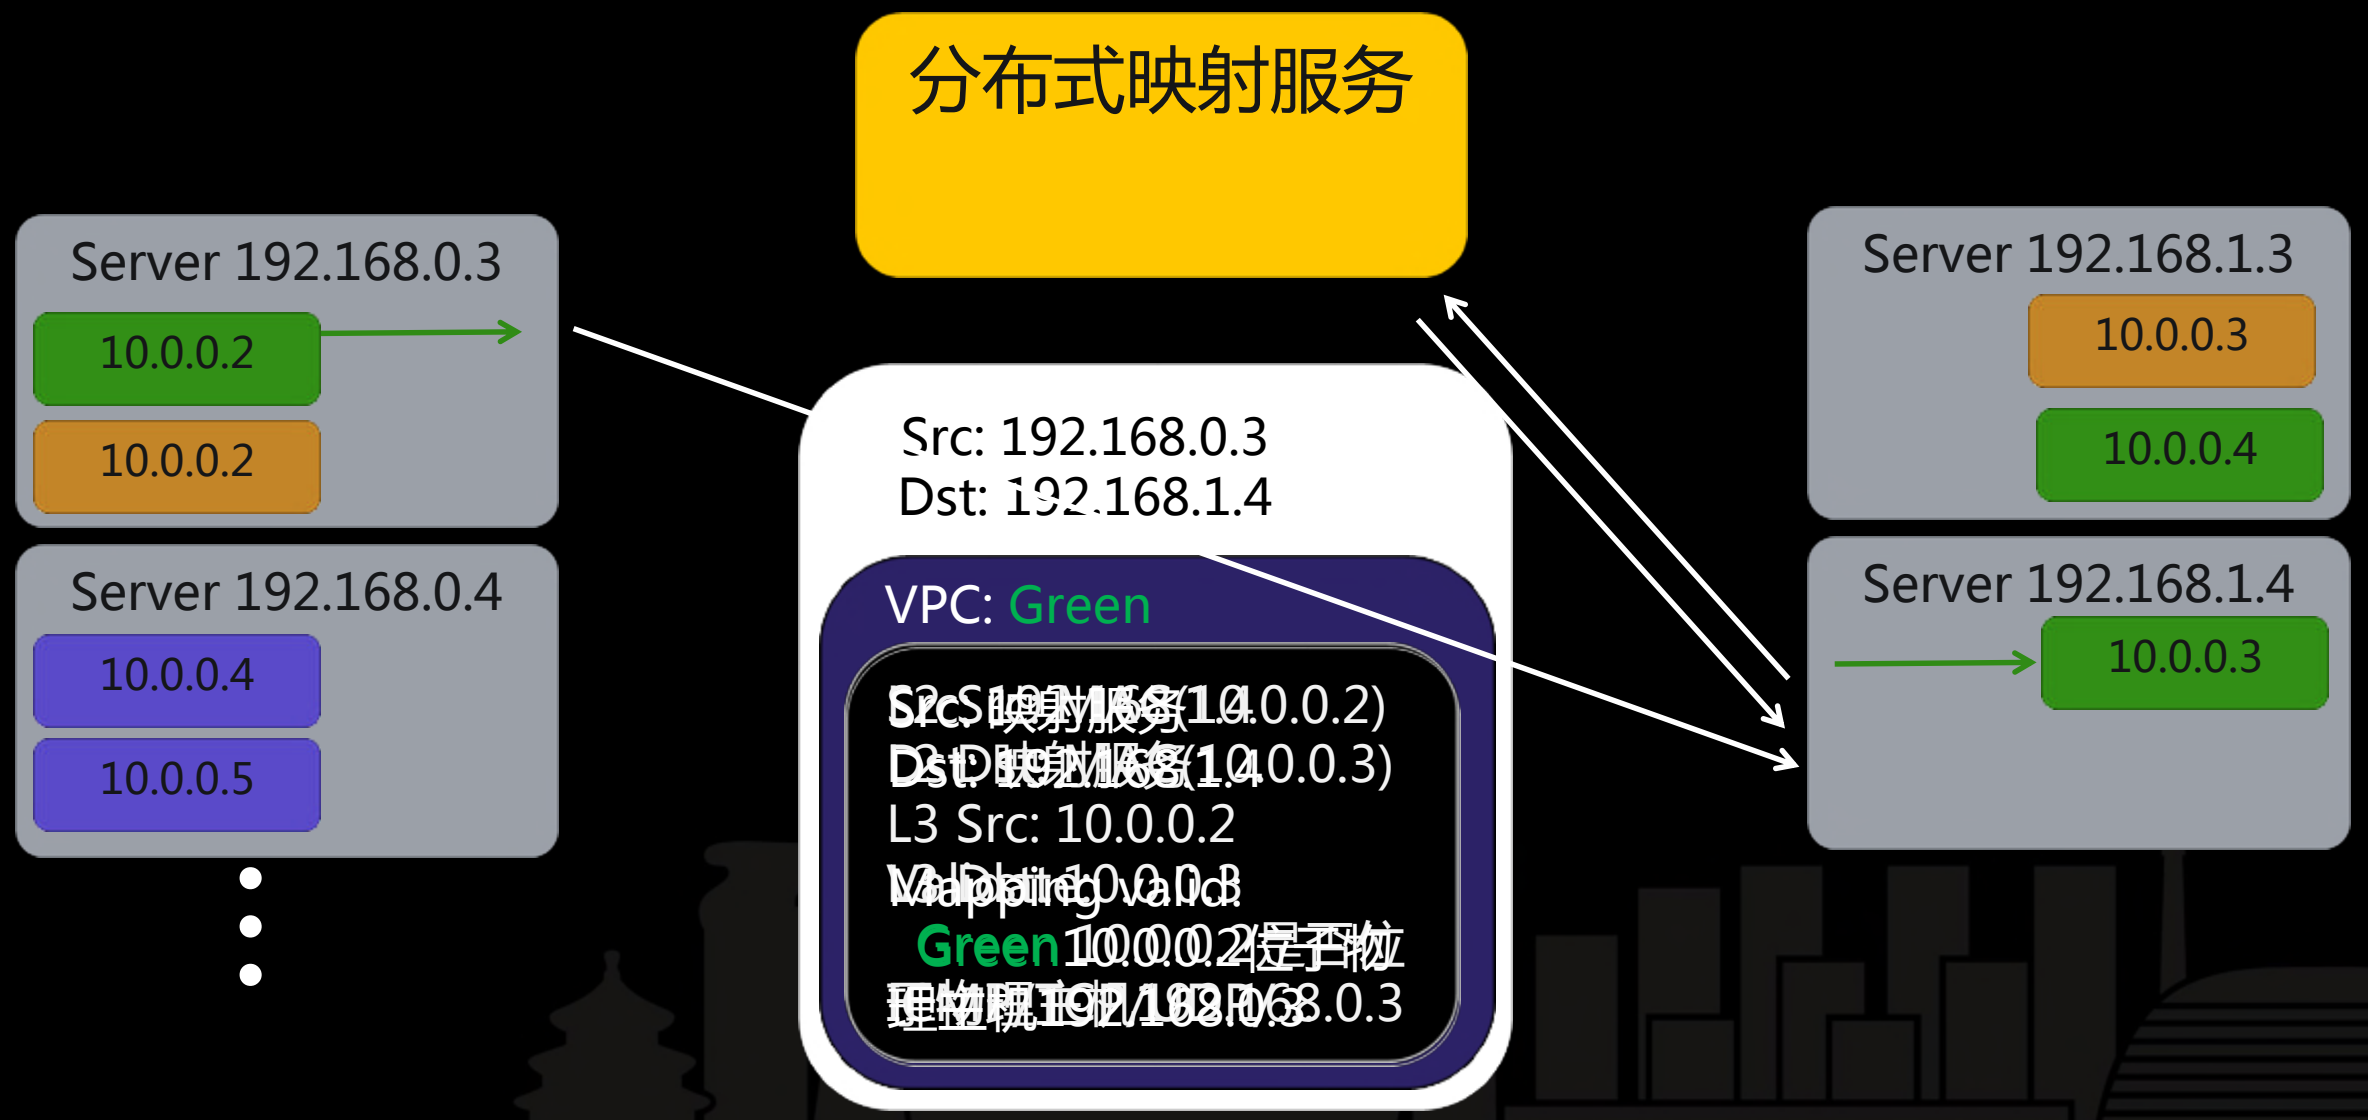

VPC隔离机制

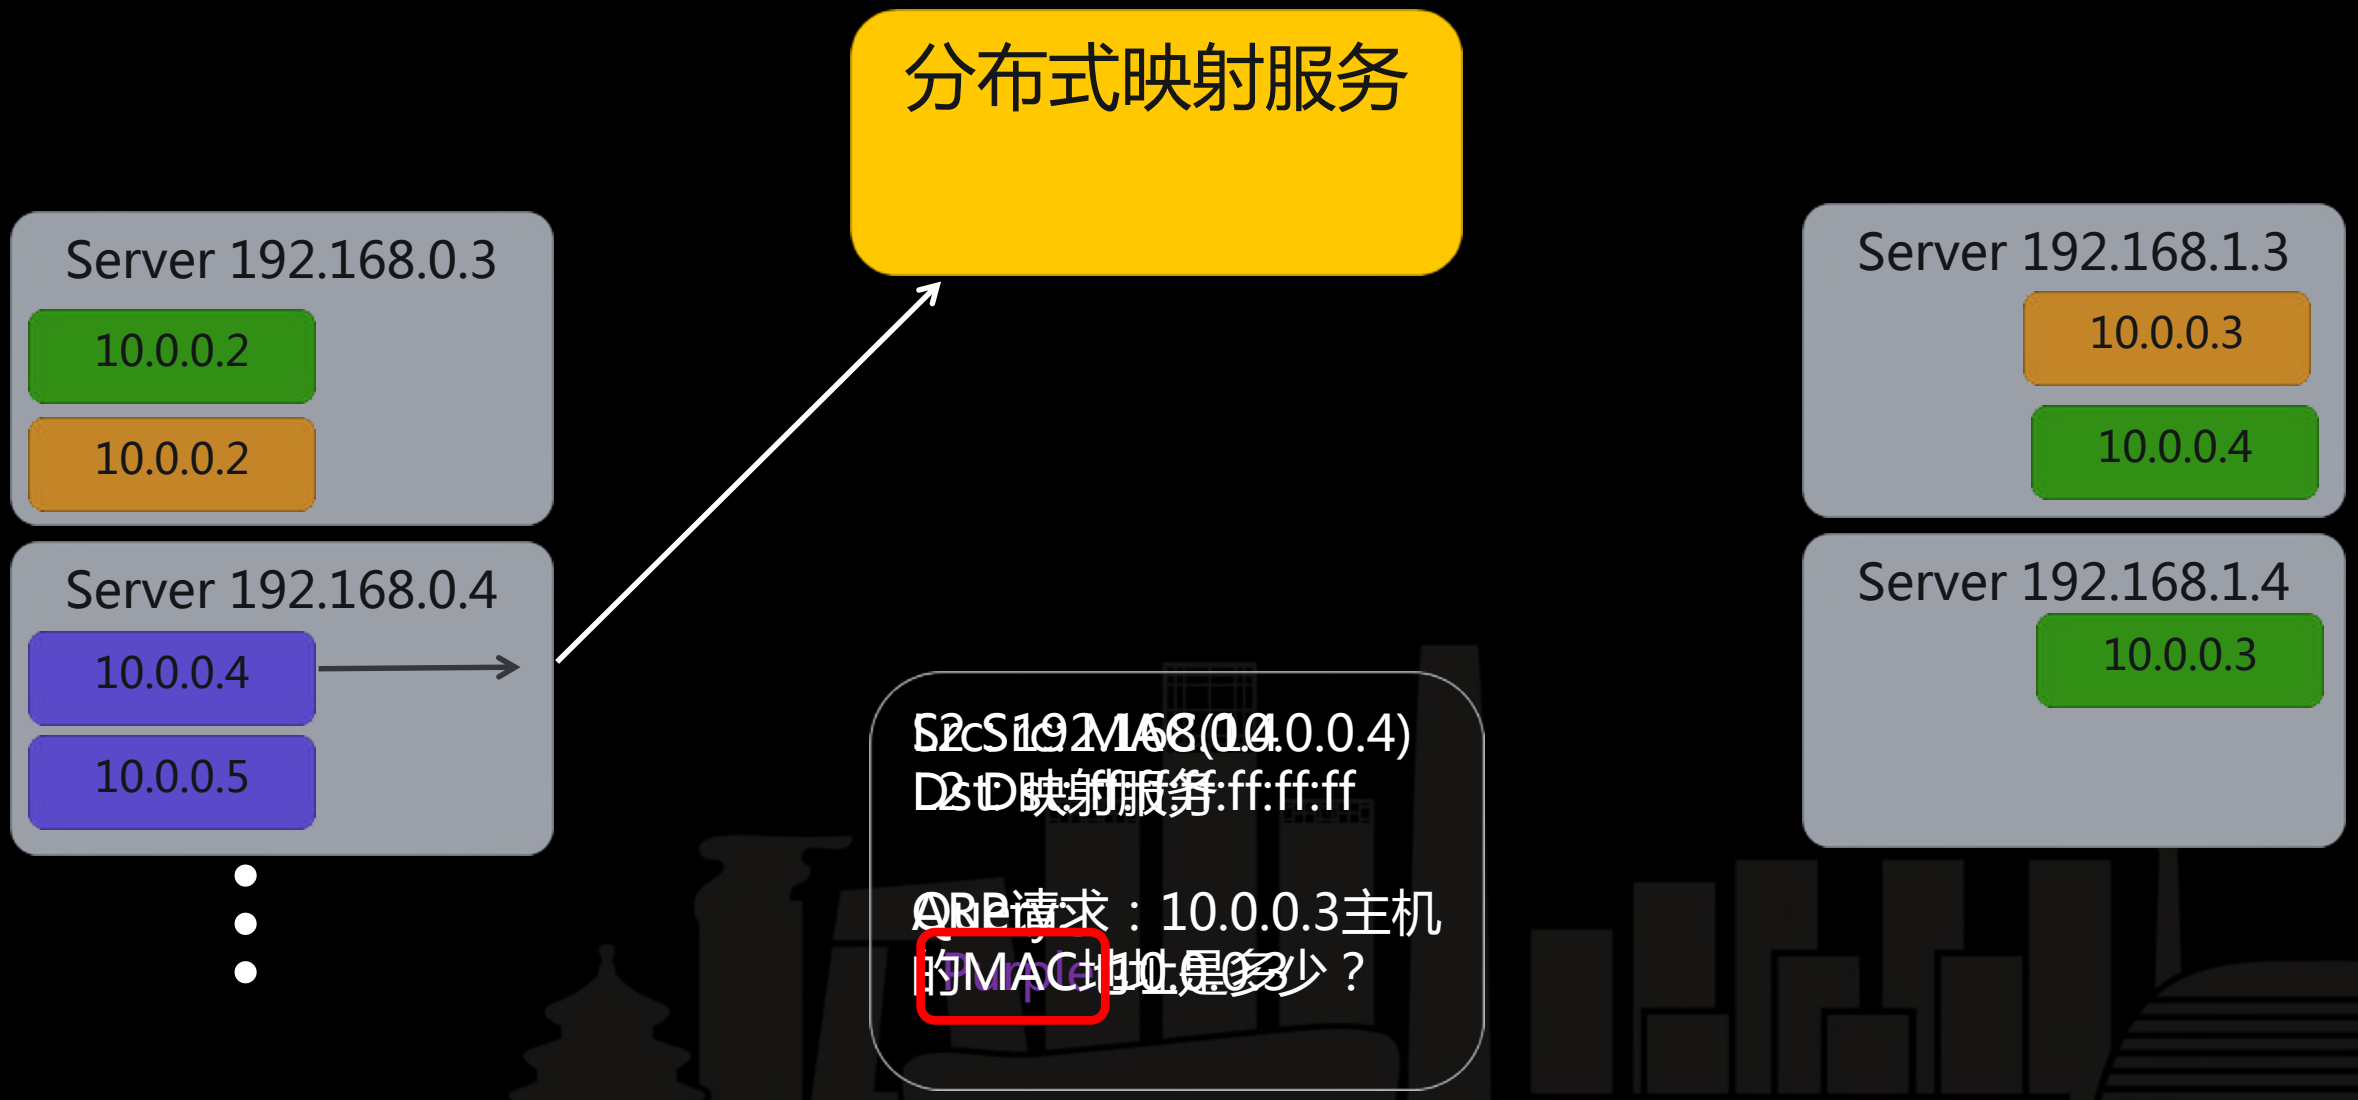
分布式映射服务
Server 192.168.0.3
10.0.0.2
10.0.0.2
Server 192.168.0.4
10.0.0.4
10.0.0.5
Server 192.168.1.3
10.0.0.3
10.0.0.4
Server 192.168.1.4
10.0.0.3
ARP请求：10.0.0.3主机的MAC地址是多少？

VPC隔离机制

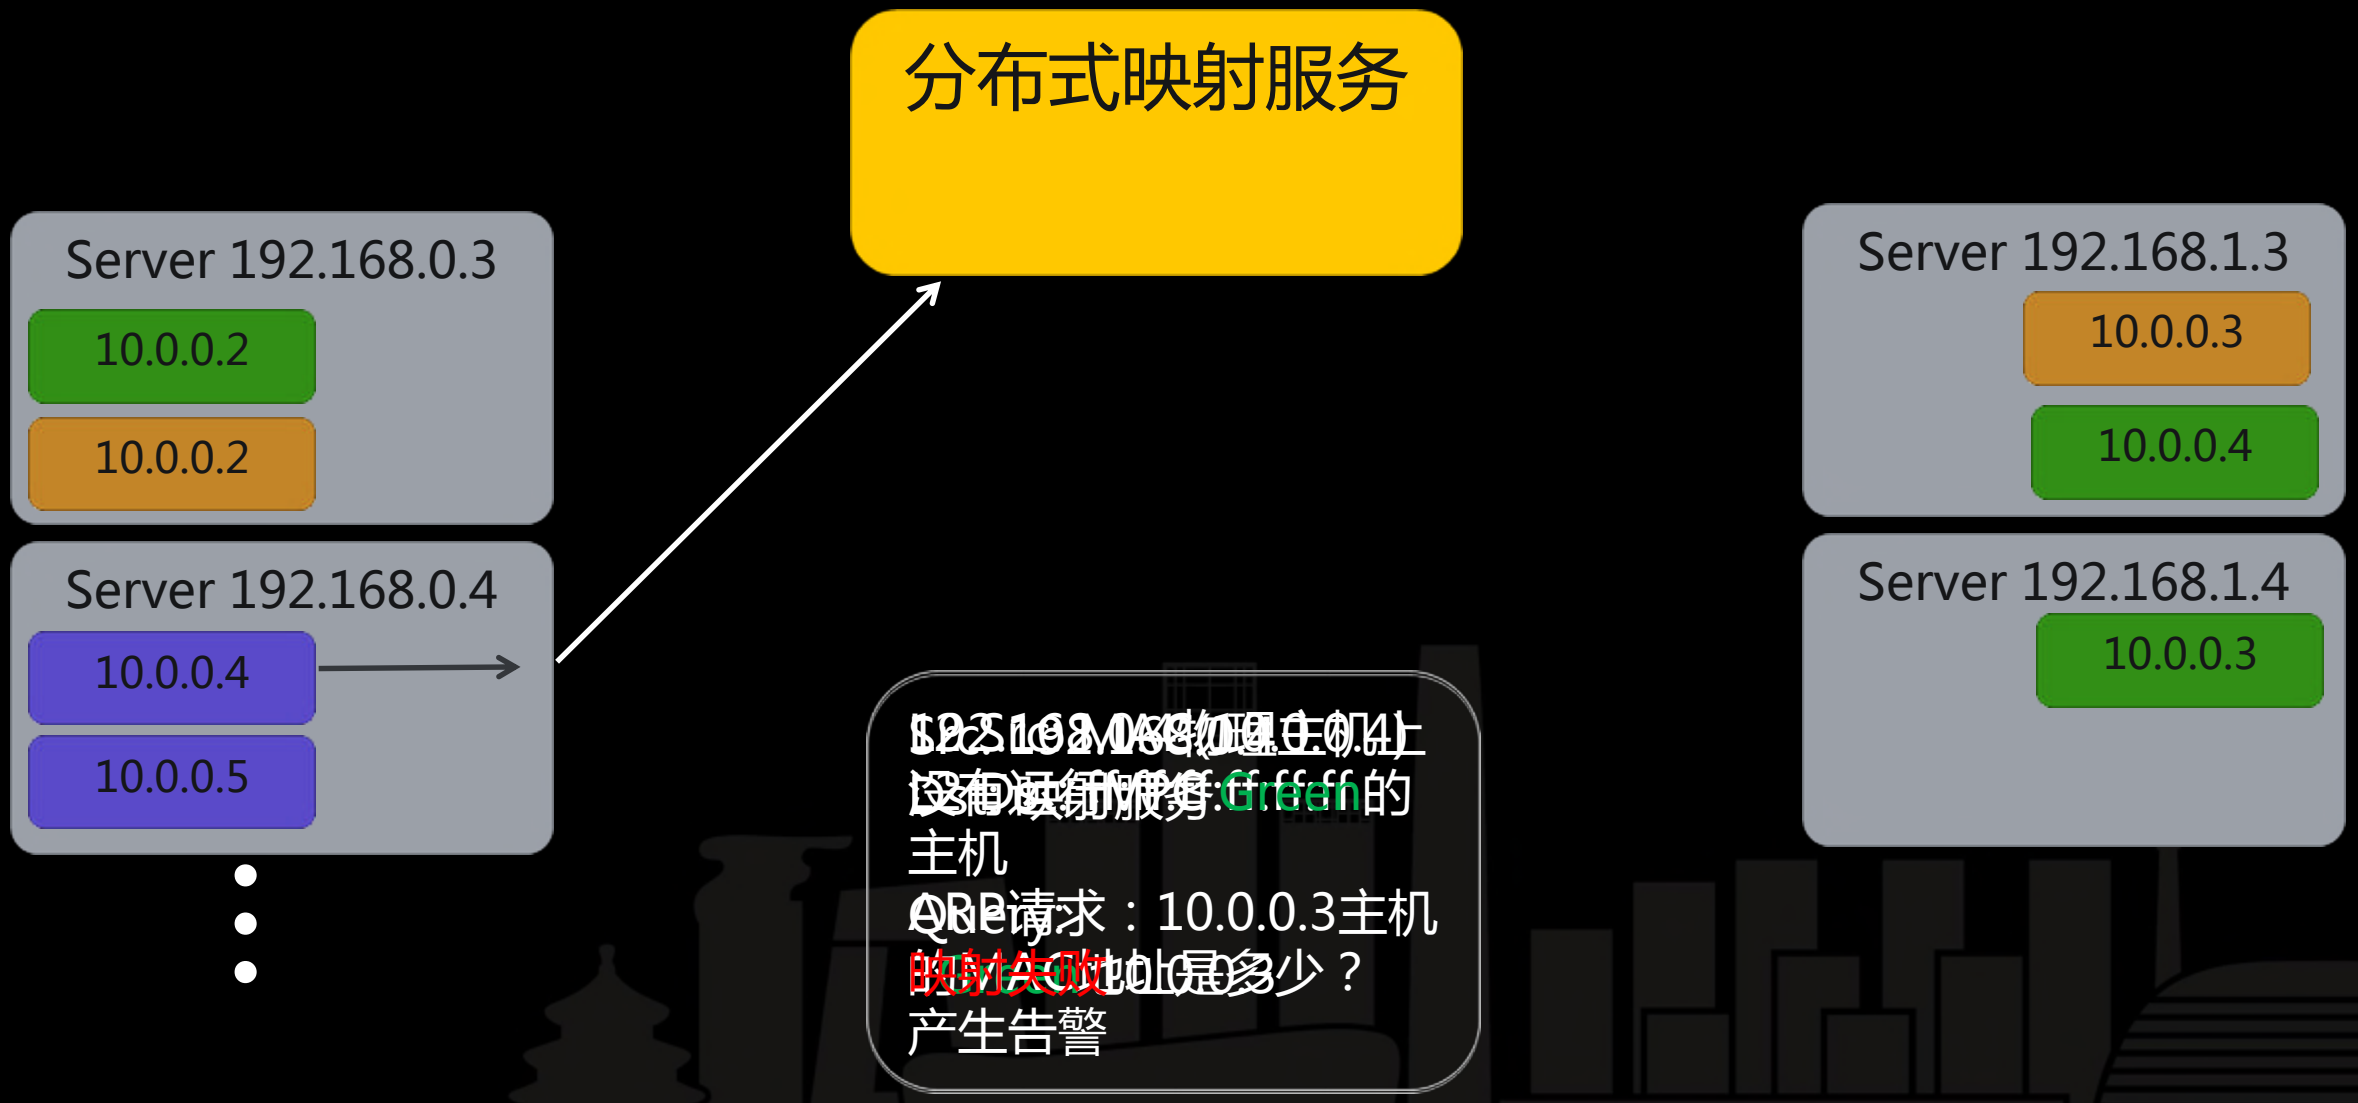
分布式映射服务
Server 192.168.0.3
10.0.0.2
10.0.0.2
Server 192.168.0.4
10.0.0.4
10.0.0.5
Server 192.168.1.3
10.0.0.3
10.0.0.4
Server 192.168.1.4
10.0.0.3
Green
Query：10.0.0.3主机
的mac地址是多少？
映射失败
产生告警

VPC隔离机制

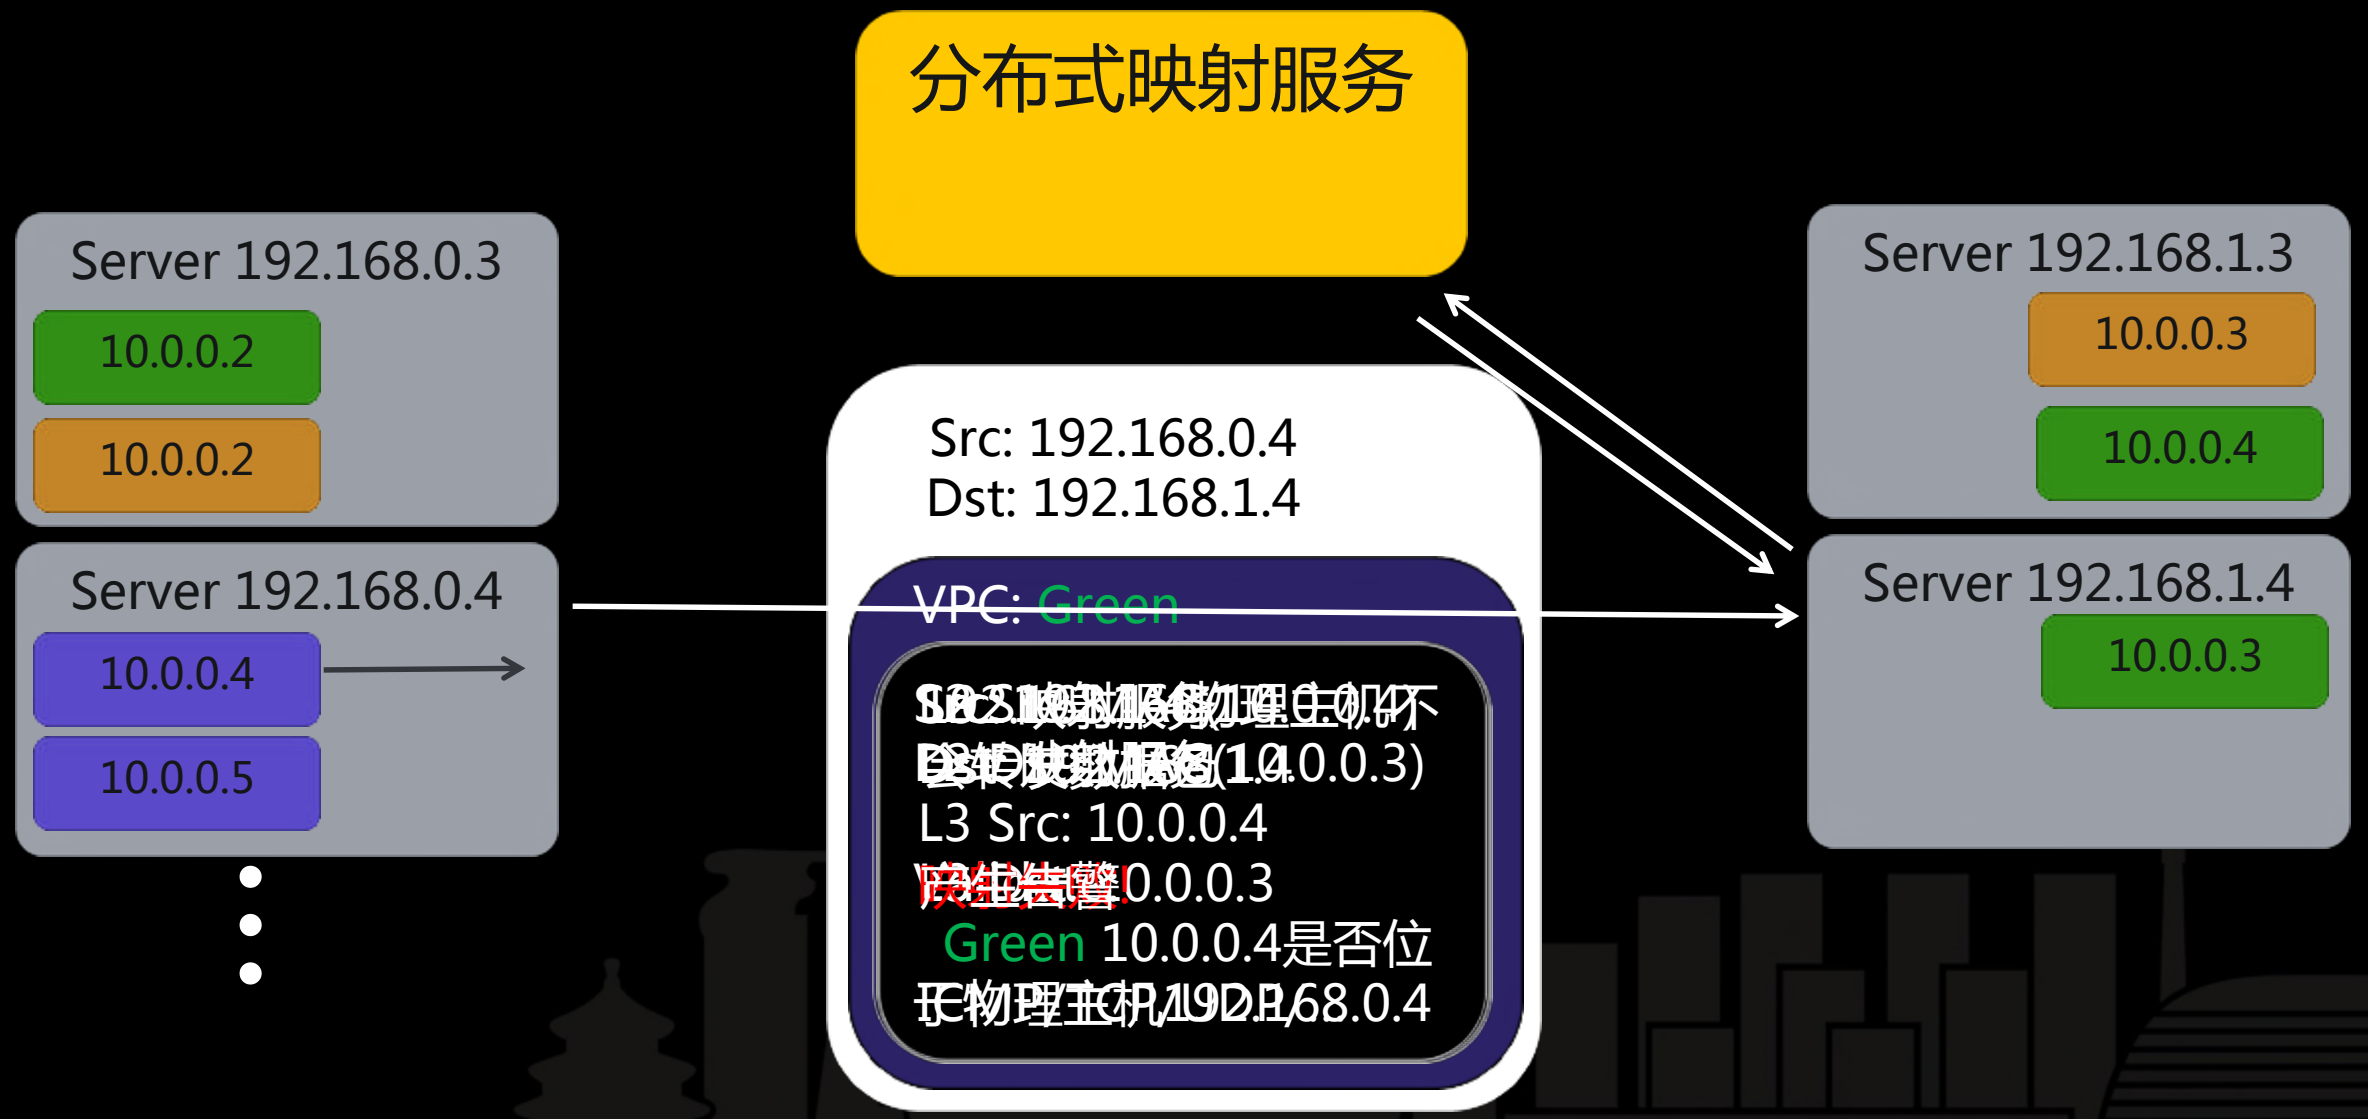
分布式映射服务
Server 192.168.0.3
10.0.0.2
10.0.0.2
Server 192.168.0.4
10.0.0.4
10.0.0.5
Src: 192.168.0.4
Dst: 192.168.1.4
VPC: Green
L3 Src: 10.0.0.4
Green 10.0.0.4是否位于物理主机192.168.0.4
Server 192.168.1.3
10.0.0.3
10.0.0.4
Server 192.168.1.4
10.0.0.3

传统三层路由的通信机制

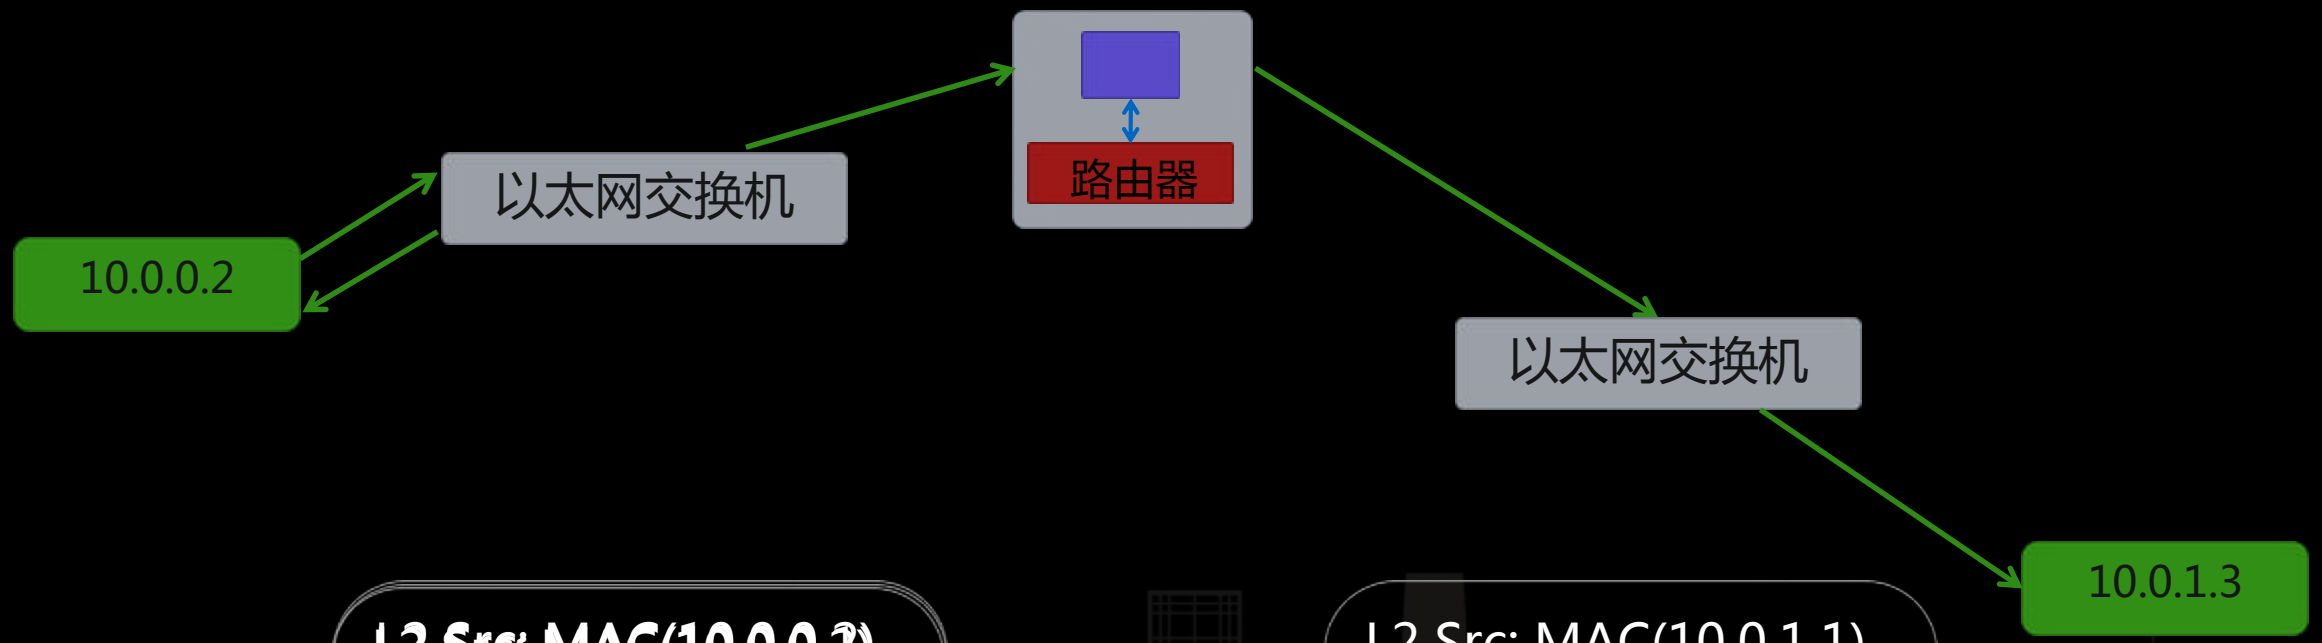

L2 Src: MAC(10.0.0.2)
L2 Dst: ff:ff:ff:ff:ff:ff
L3 Src: 10.0.0.2
L3 Dst: 10.0.1.3
ICMP/TCP/UDP/...

ARP请求10.0.0.1的MAC地址是多少？

L2 Src: MAC(10.0.1.1)
L2 Dst: MAC(10.0.1.3)
L3 Src: 10.0.0.2
L3 Dst: 10.0.1.3

ICMP/TCP/UDP/...

VPC中的三层通信机制

VPC中的三层通信机制

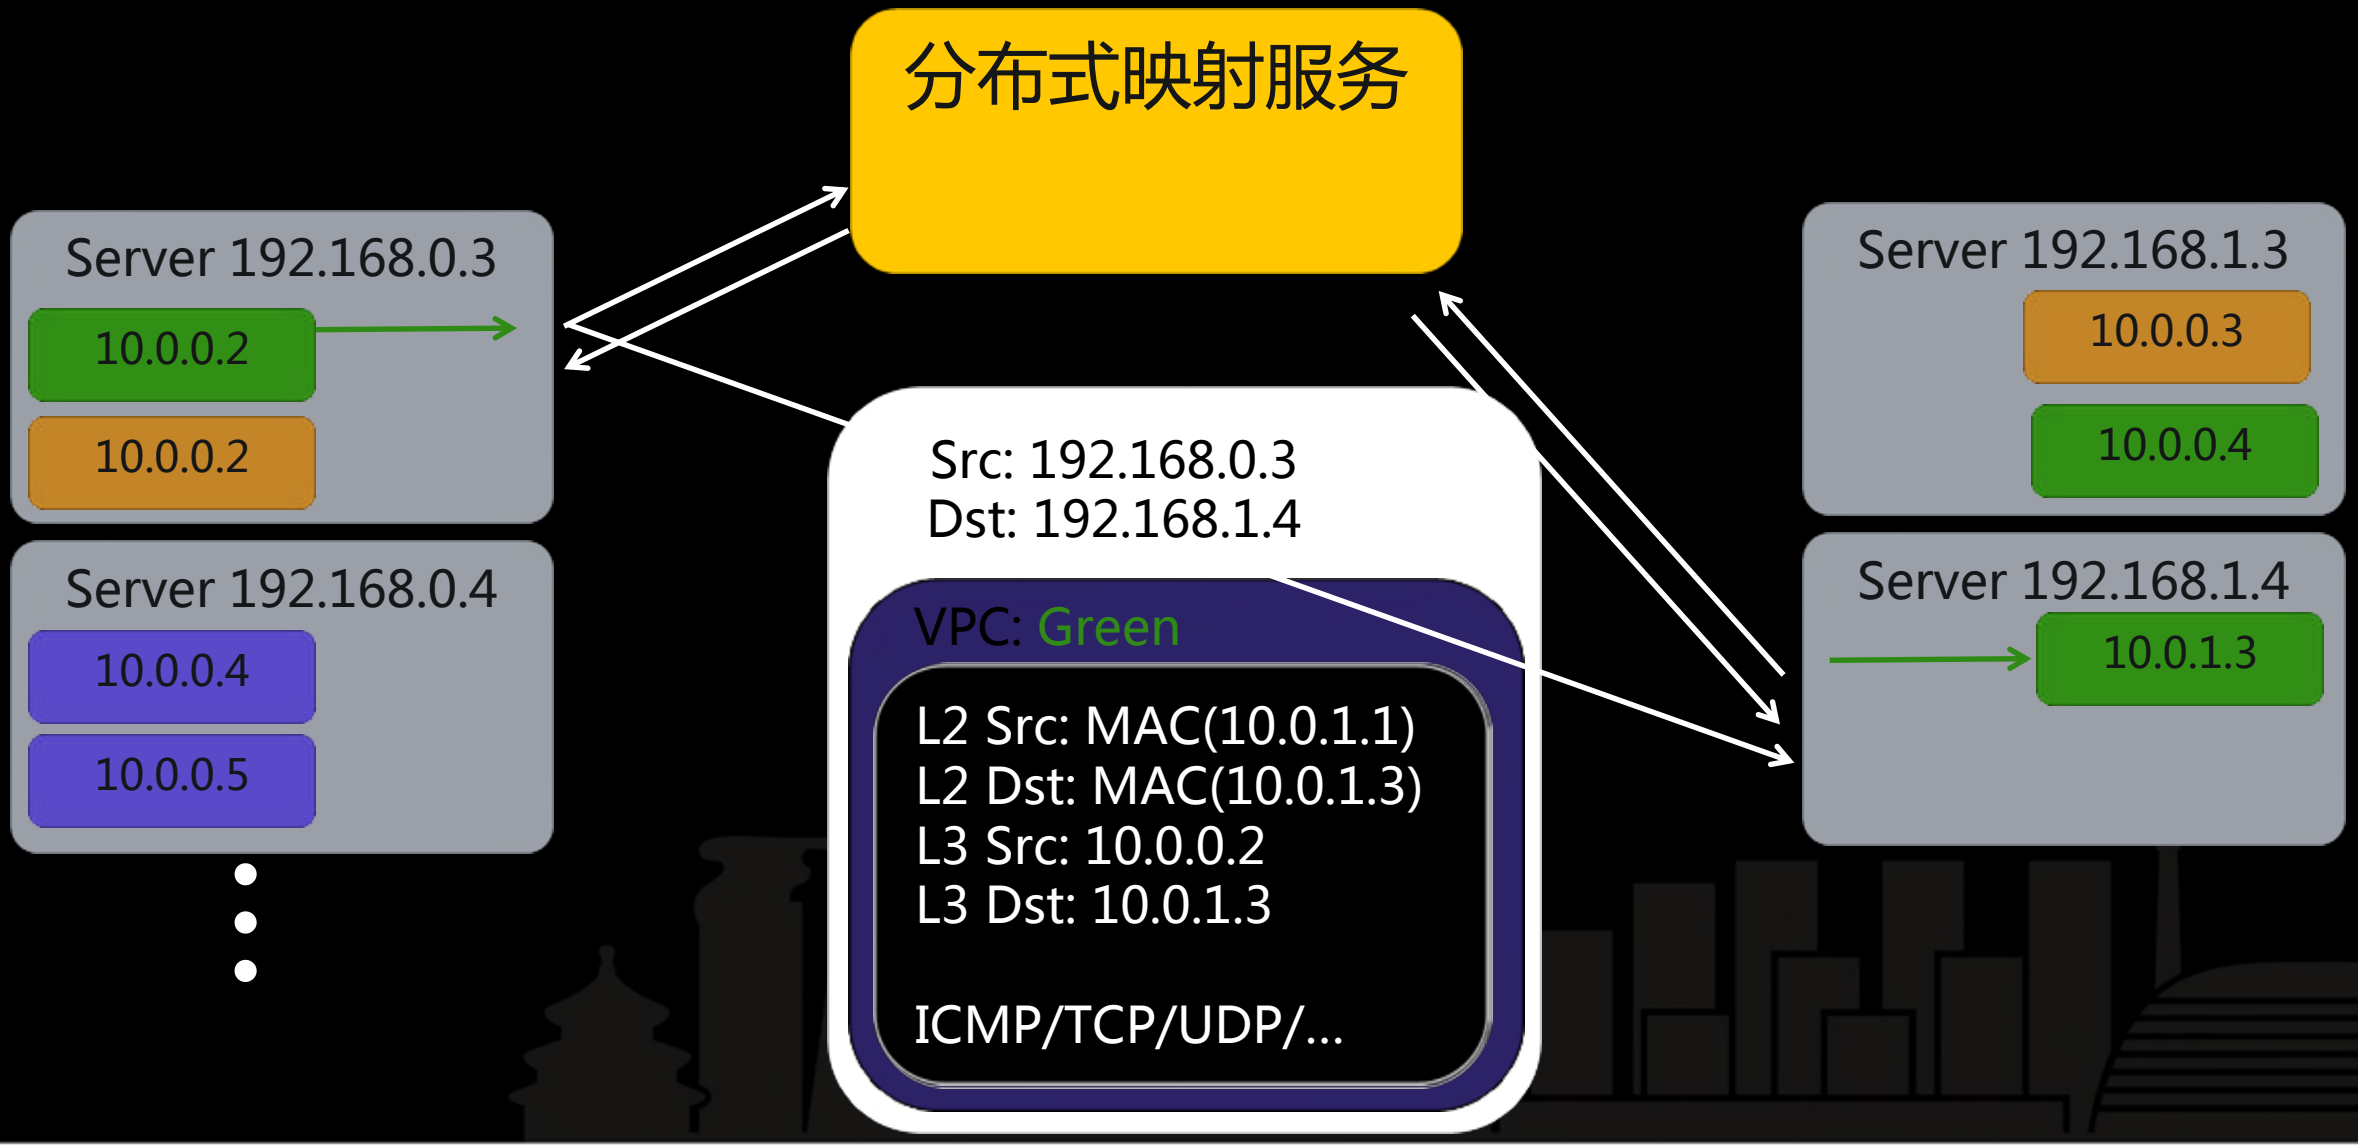

映射缓存

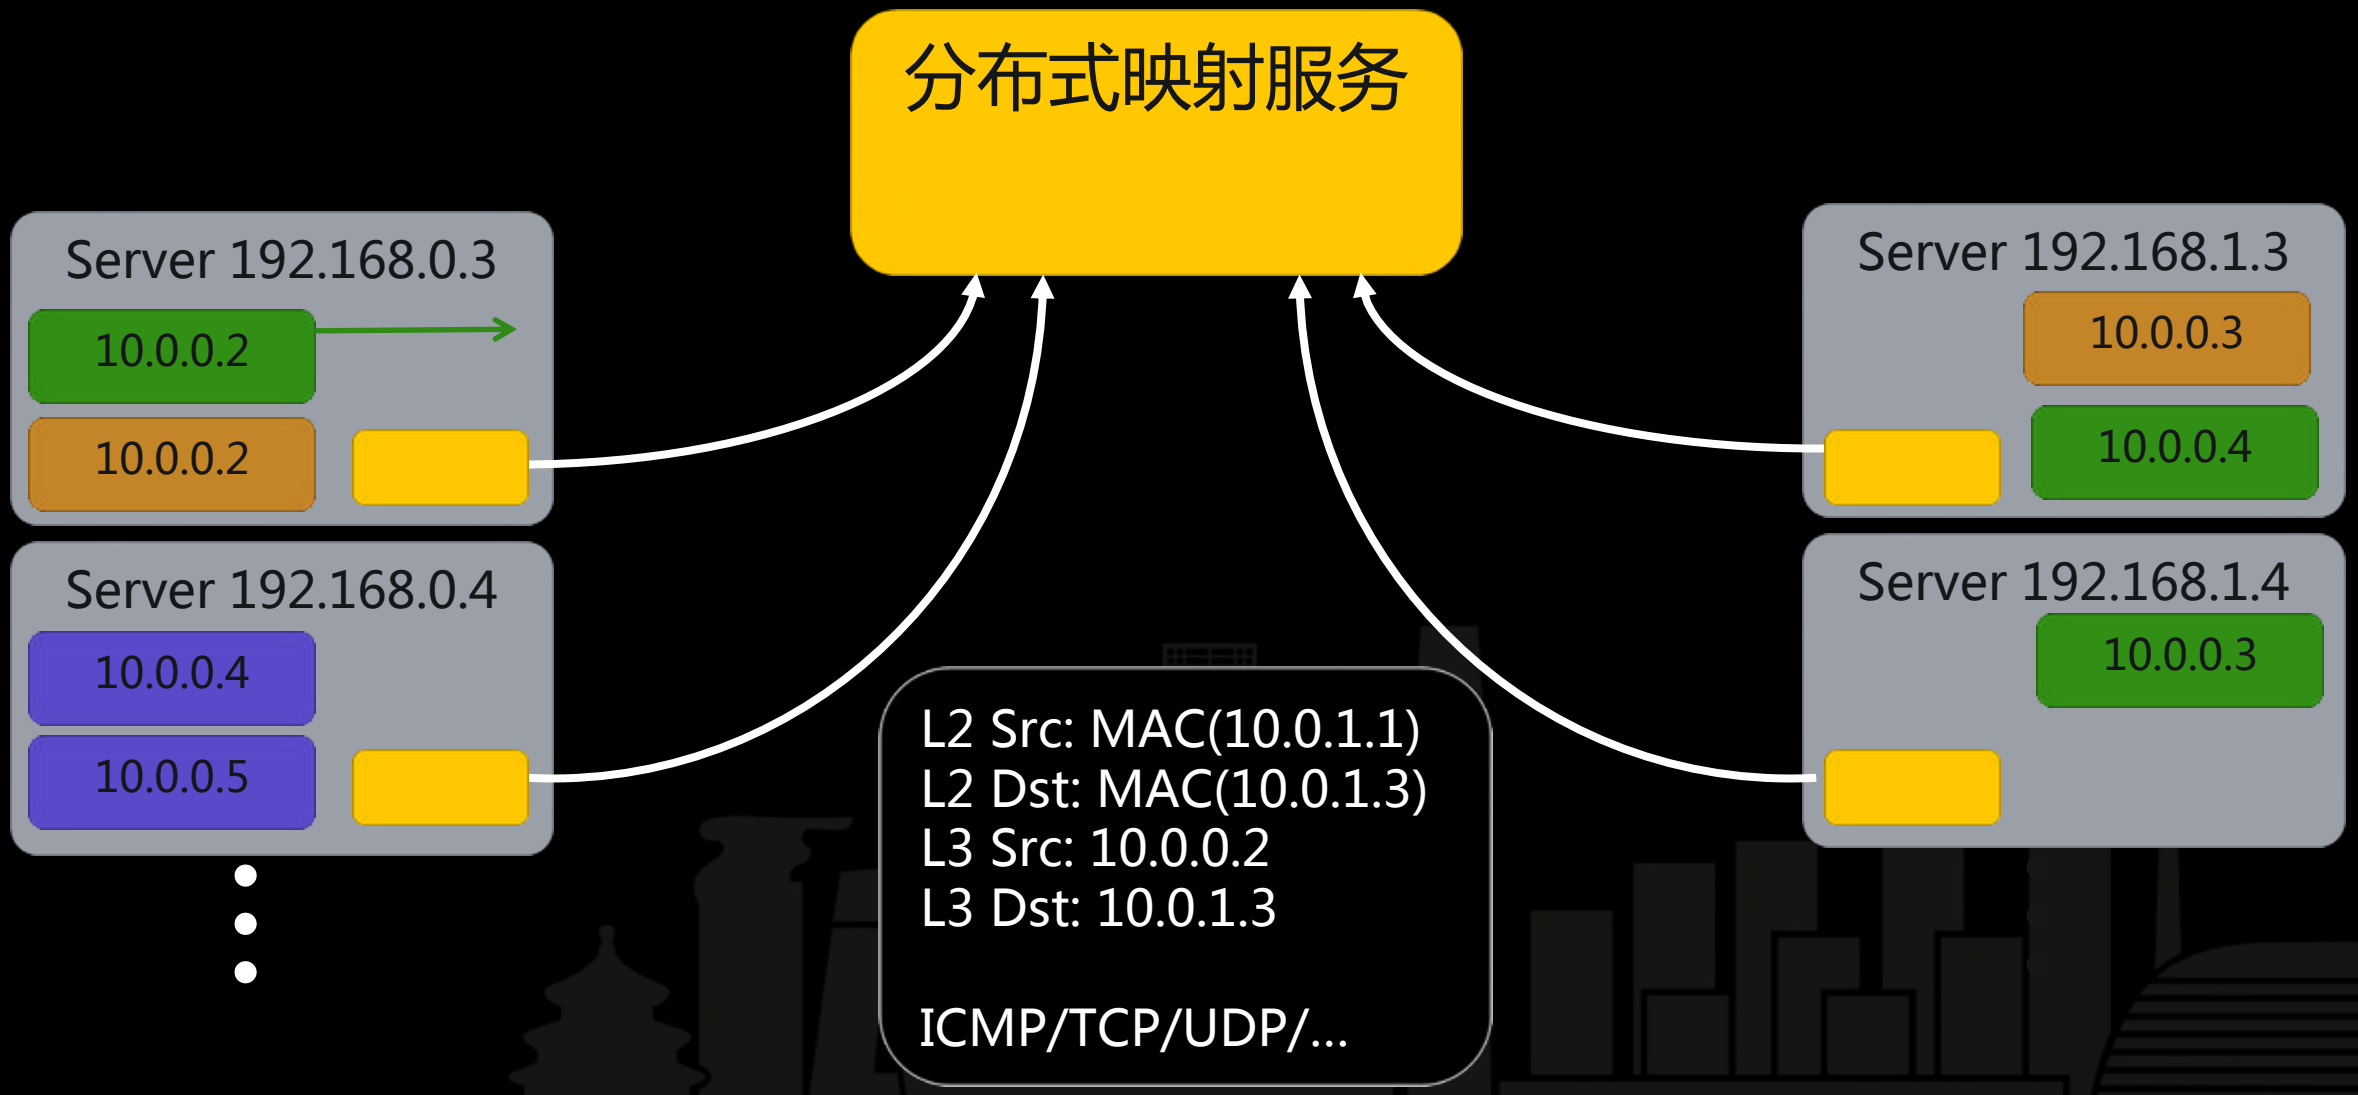
分布式映射服务
Server 192.168.0.3
10.0.0.2
10.0.0.2
Server 192.168.0.4
10.0.0.4
10.0.0.5
Server 192.168.1.3
10.0.0.3
10.0.0.4
Server 192.168.1.4
10.0.0.3
L2 Src: MAC(10.0.1.1)
L2 Dst: MAC(10.0.1.3)
L3 Src: 10.0.0.2
L3 Dst: 10.0.1.3
ICMP/TCP/UDP/...

访问VPC外部资源

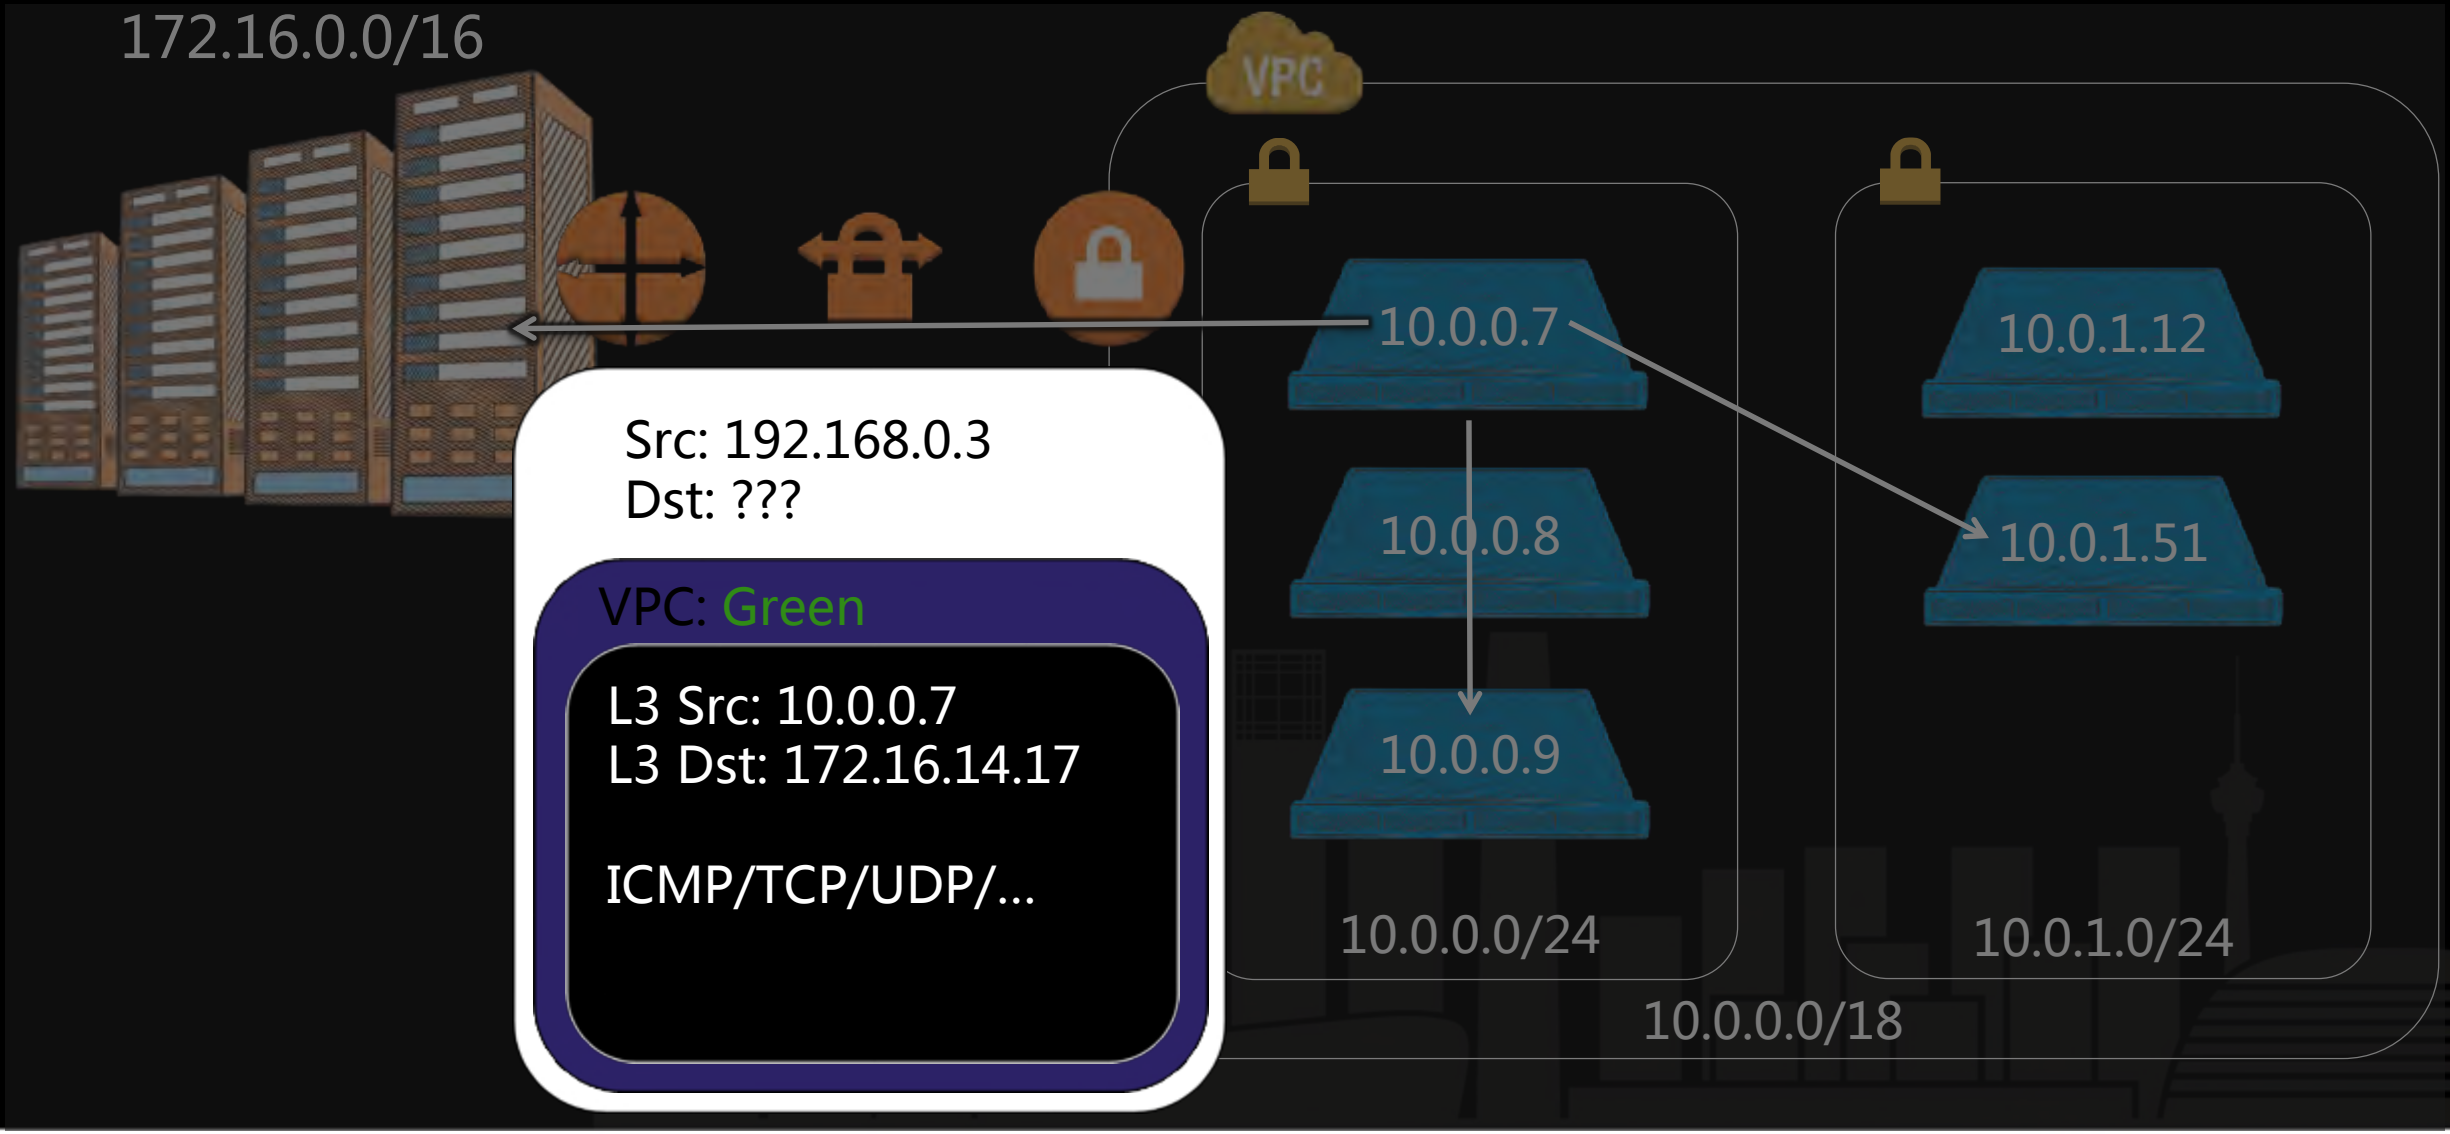
172.16.0.0/16
VPC
10.0.0.7
10.0.0.8
10.0.0.9
10.0.0.0/24
10.0.1.12
10.0.1.51
10.0.1.0/24
10.0.0.0/18
Src: 192.168.0.3
Dst: ???
VPC: Green
L3 Src: 10.0.0.7
L3 Dst: 172.16.14.17
ICMP/TCP/UDP/...

VPC出口服务

分布式映射服务

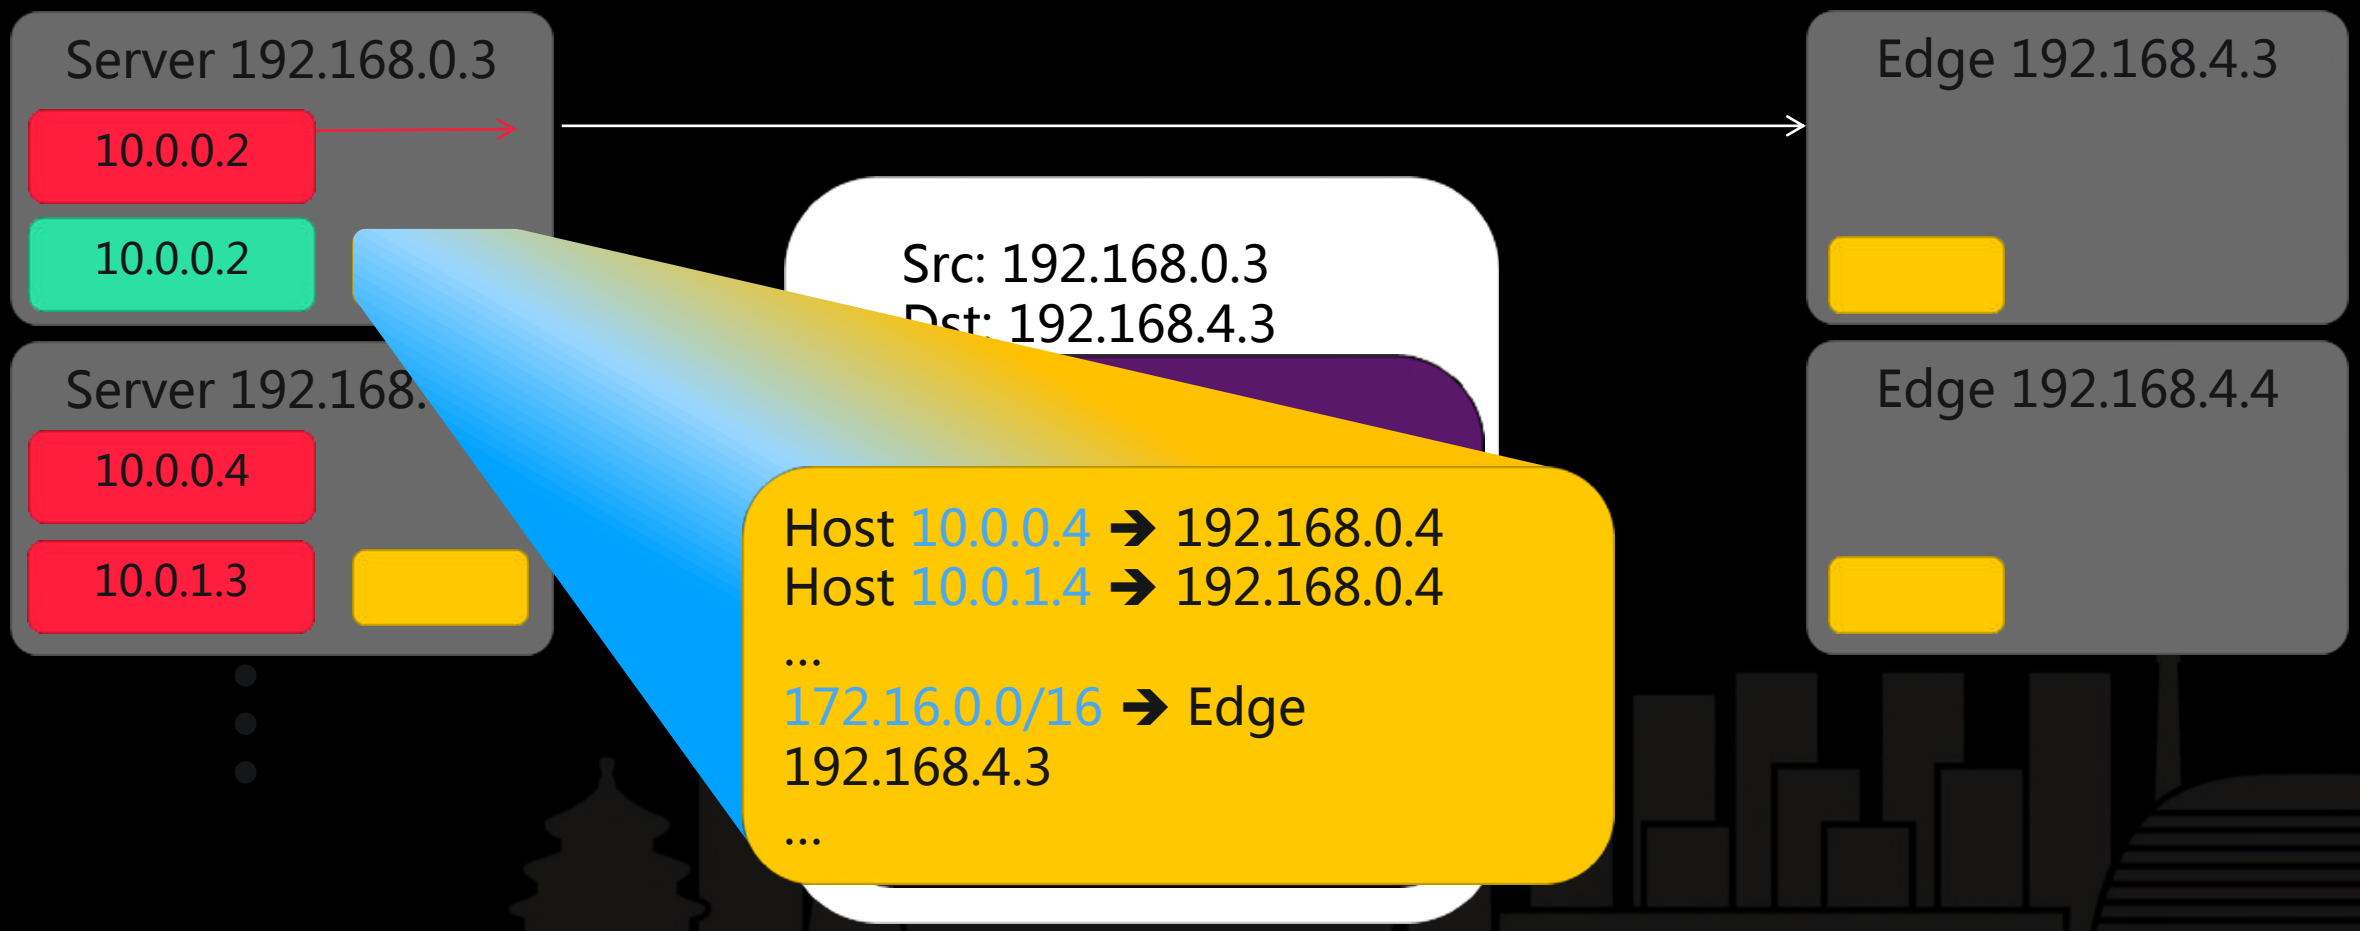

VPC出口服务—VGW

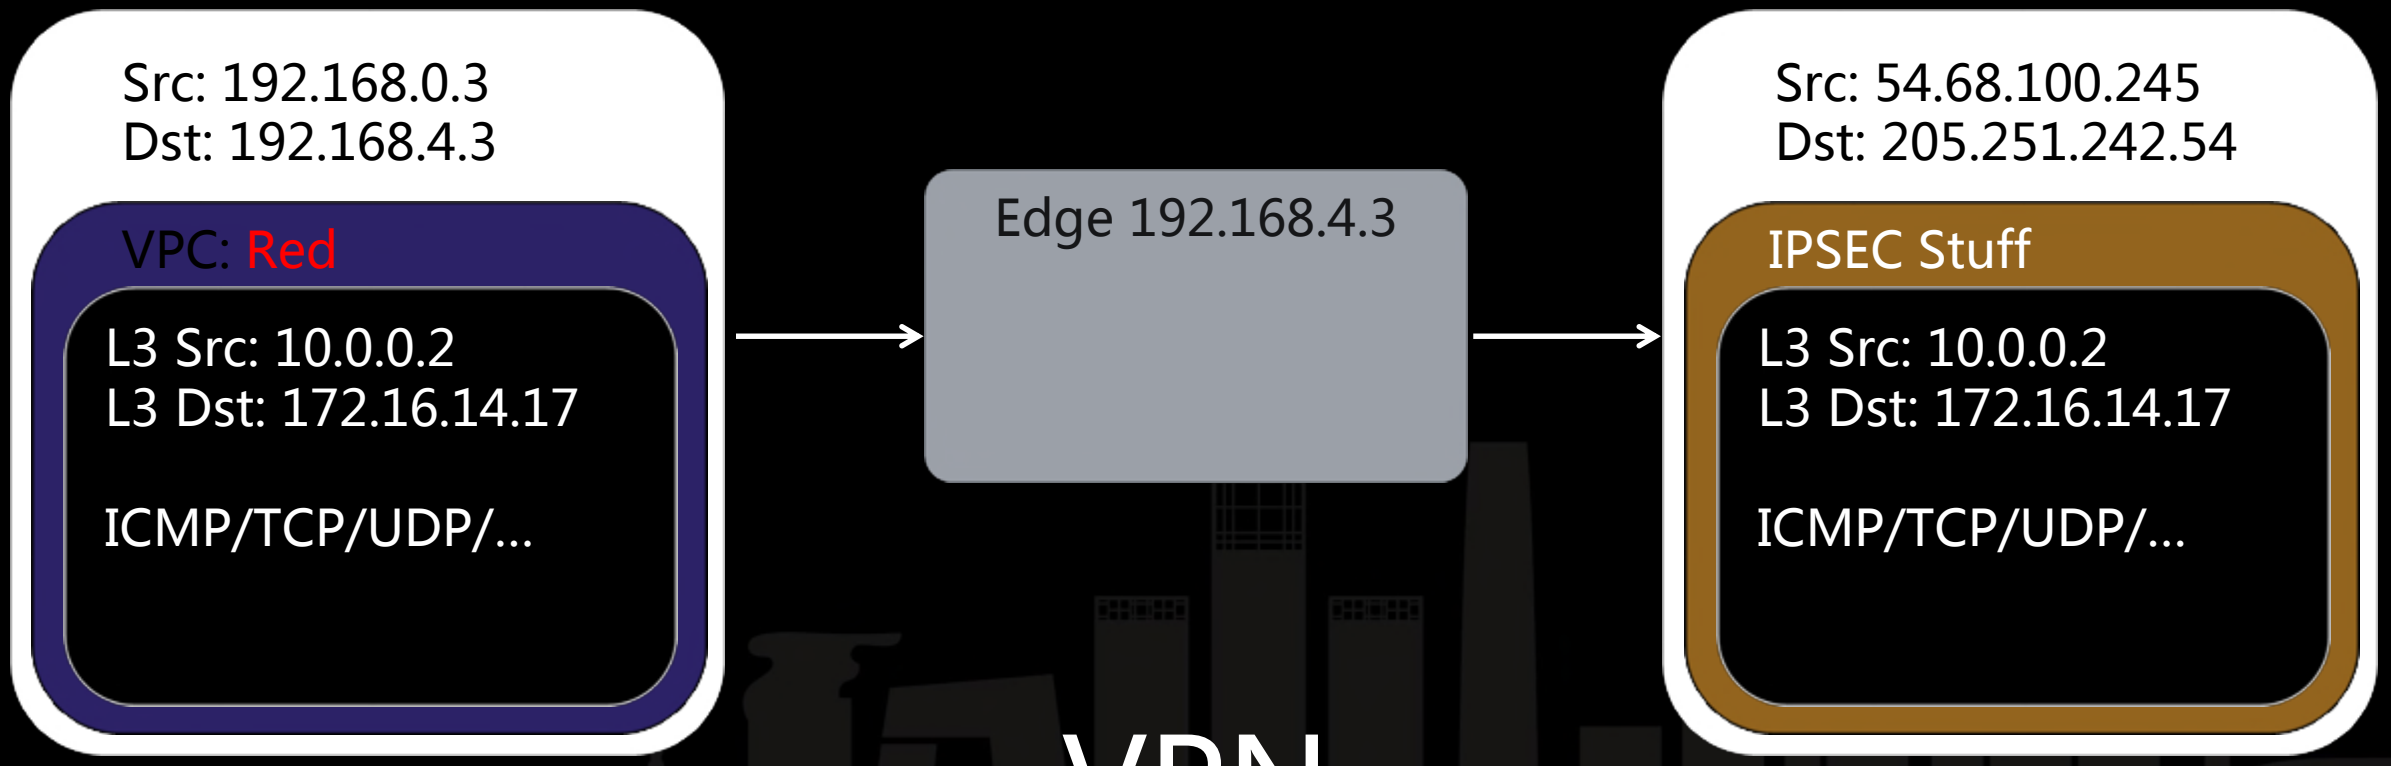

VPN

VPC出口服务—VGW

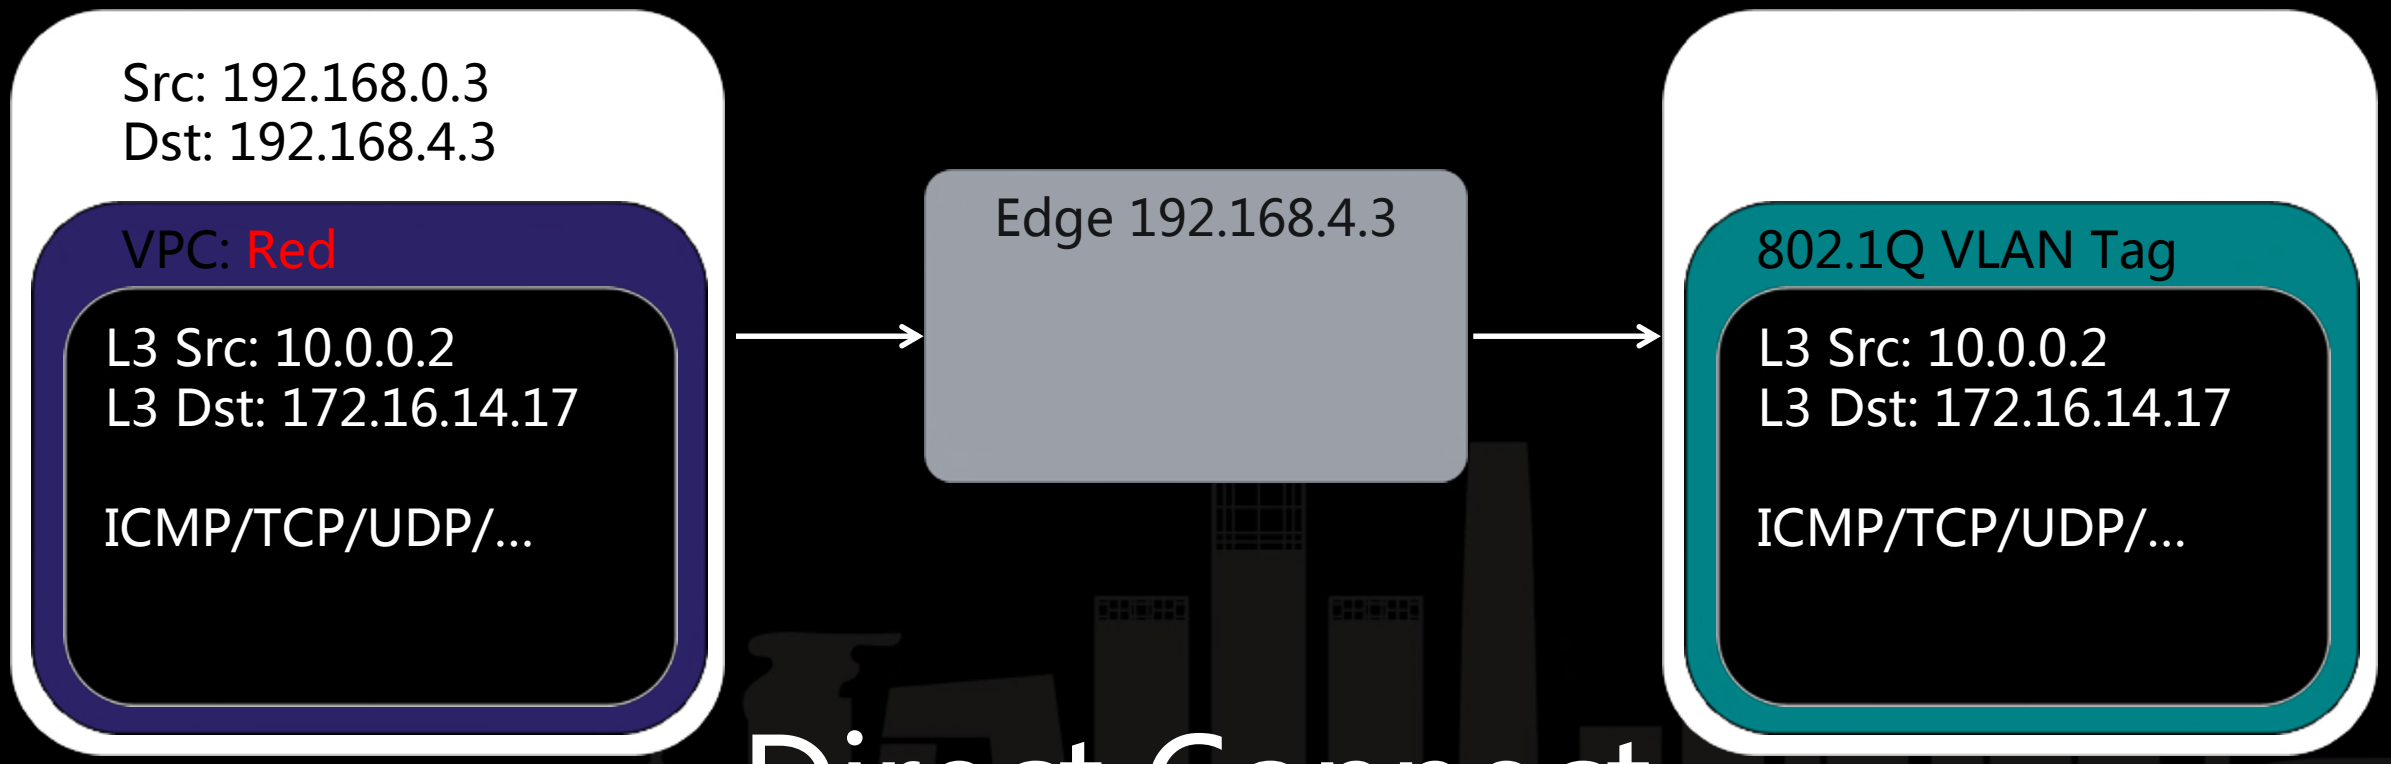

Direct Connect

VPC出口服务—IGW

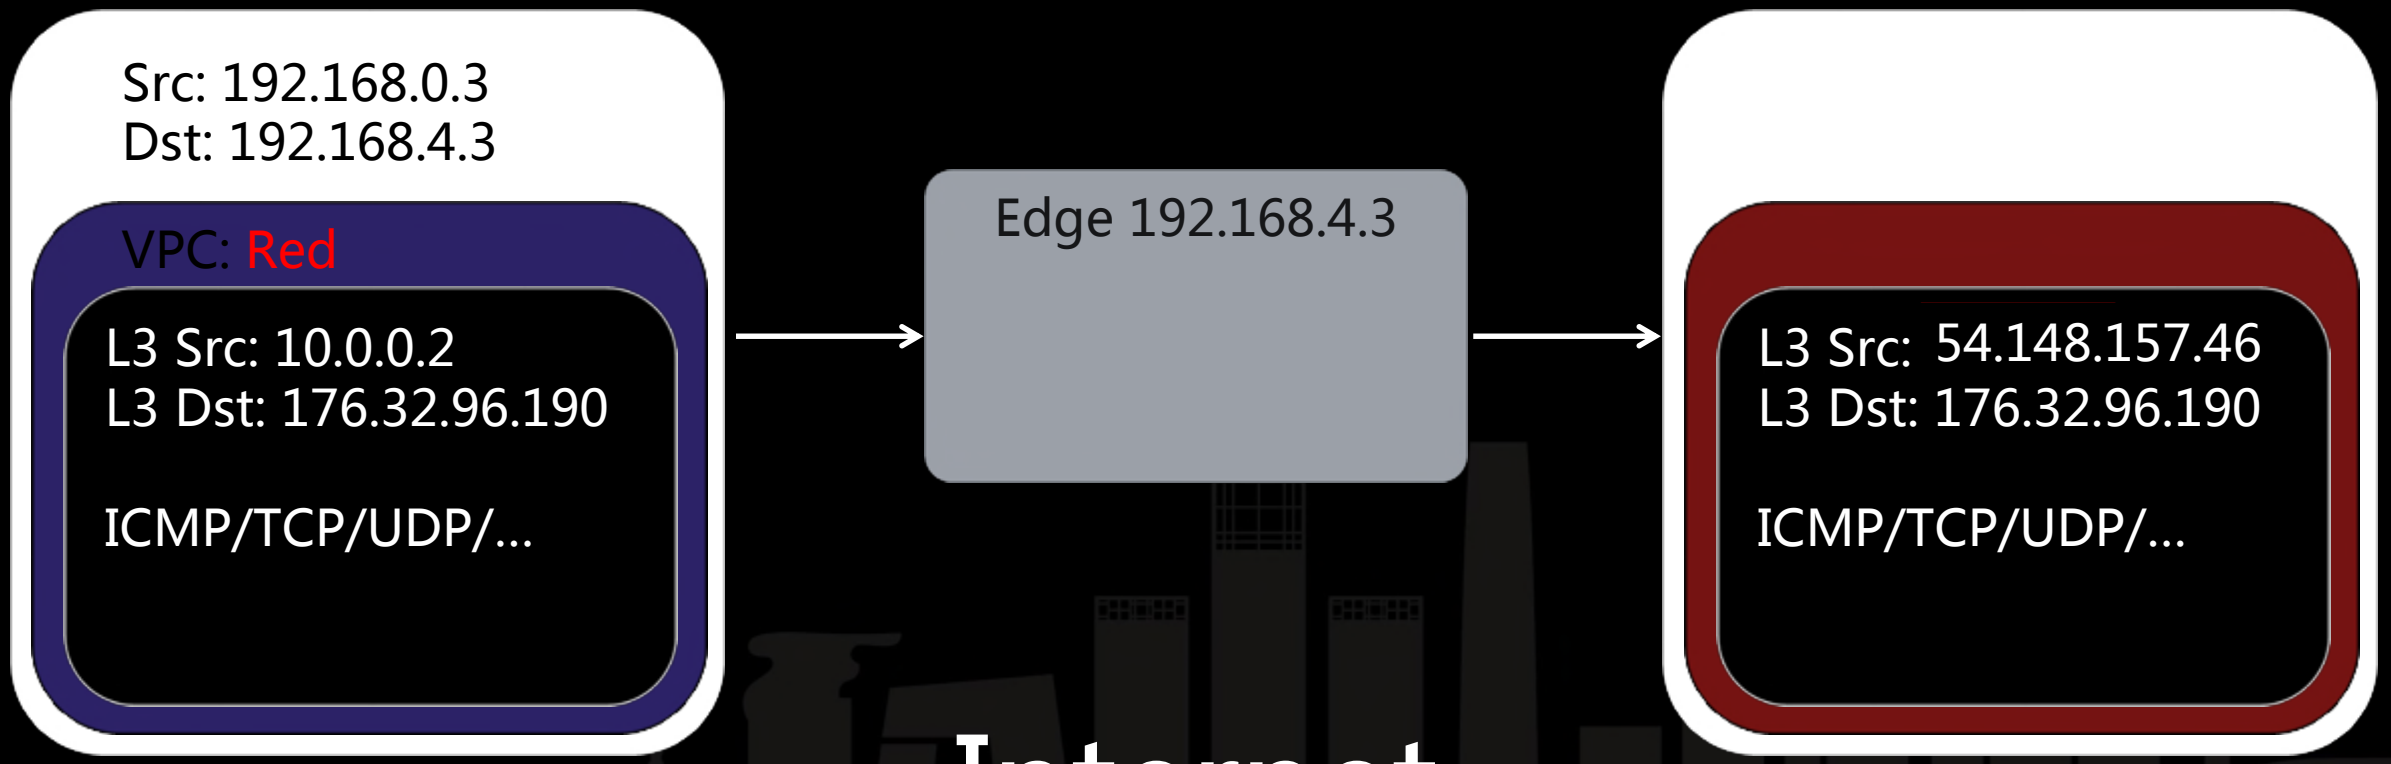

Internet

VPC总结

- 通过分布式映射服务实现VPC id+实例ip与物理服务器ip之间的映射
- 通过全局唯一的VPC id实现租户之间的隔离
- 通过外层封装实现数据包的寻址
- 通过边界服务实现对外访问

关注QCon微信公众号，
获得更多干货！

Thanks!

INTERNATIONAL SOFTWARE DEVELOPMENT CONFERENCE

主办方 Geekbang. 极客邦科技 InfoQ