VMware云资源池业务连续性设计

刘承罡
13581900001

什么是云资源池的业务连续性？

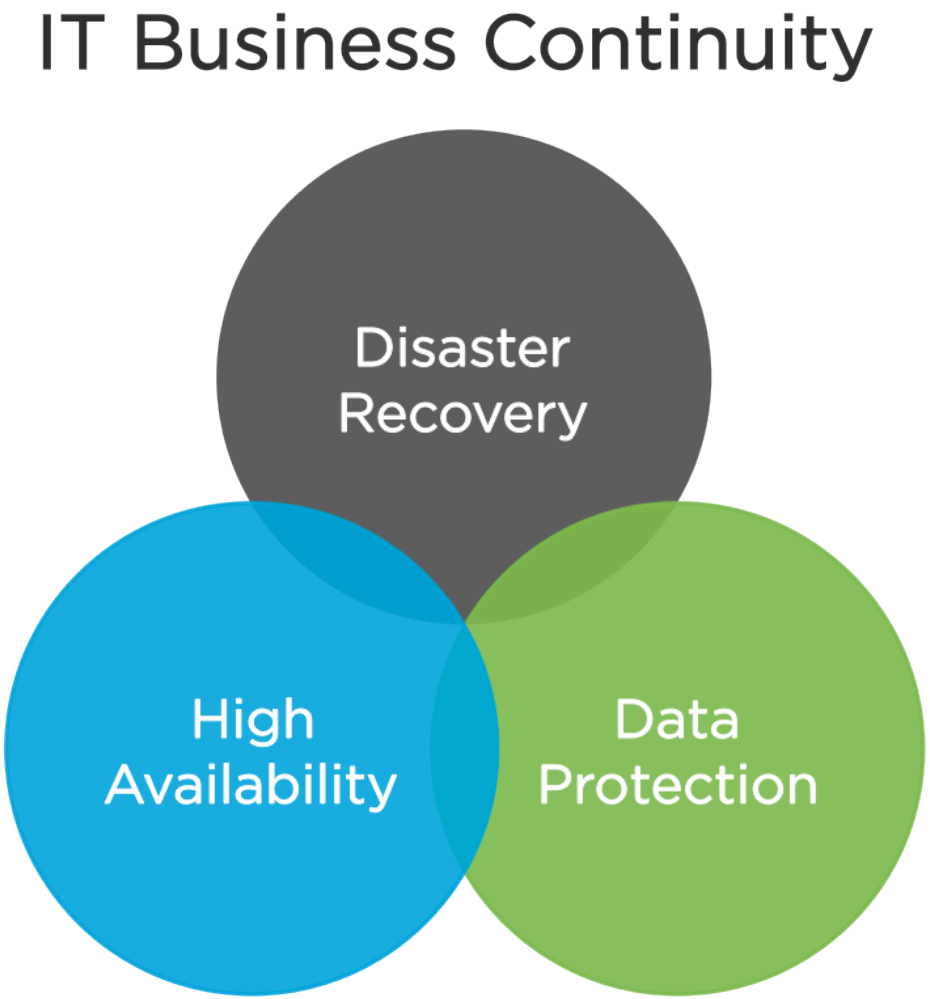

理解DR和DA的区别

- **Disaster Recovery（DR）** – 在灾难发生后的一整套恢复程序,一般都会恢复一份过去数据的完整的、一致的数据和业务拷贝。发生在业务中断之后，有服务、OS重启操作，最终用户有感知的，有RTO/RPO的概念：HA/DP/SRM

- **Disaster Avoidance（DA）-** 在灾难发生之前进行预测，并提前预防防止业务中断，根据技术选择的不同，用户一般无感知，无需用户业务、OS的重启操作，典型的DA应用如：vMotion

按照业务的QOS等级实现设计业务连续性方案

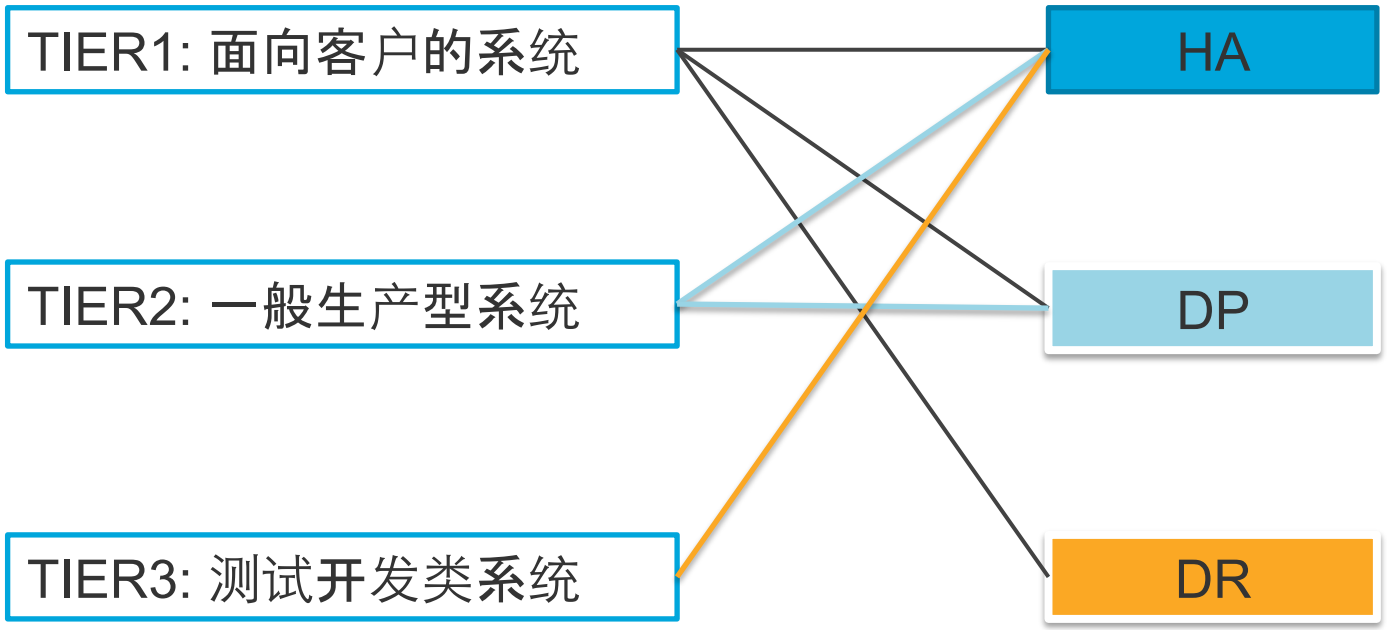

传统物理机与虚机环境对系统和数据的保护不同

物理机环境中系统和数据的保护

- 系统磁盘和数据采用不同的方式来保护
- 为了确保恢复的成功率，一般要求采用相等的硬件设施
- 需要非常复杂的流程才能实现保护成功

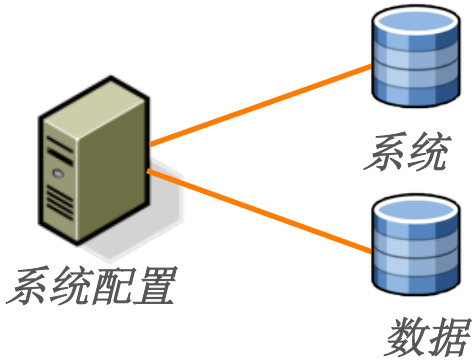

虚拟架构下系统和数据的保护

- 系统磁盘和数据采用同样的方式来保护
- 系统也是数据
- 保护系统的同时就保护了数据，反之亦然

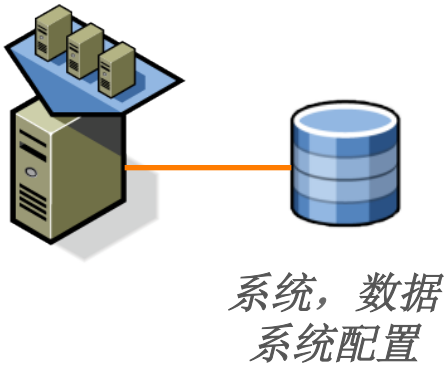

虚拟架构是化繁为简的根本原因

虚拟机既存储系统也存储数据

- 整个系统封装在文件中:
  硬件配置，操作系统，应用及数据

影响

- 系统即数据
  - 使用保护数据的同样的方法和流程来保护系统
- 虚拟机是存储系统最简单灵活的方法

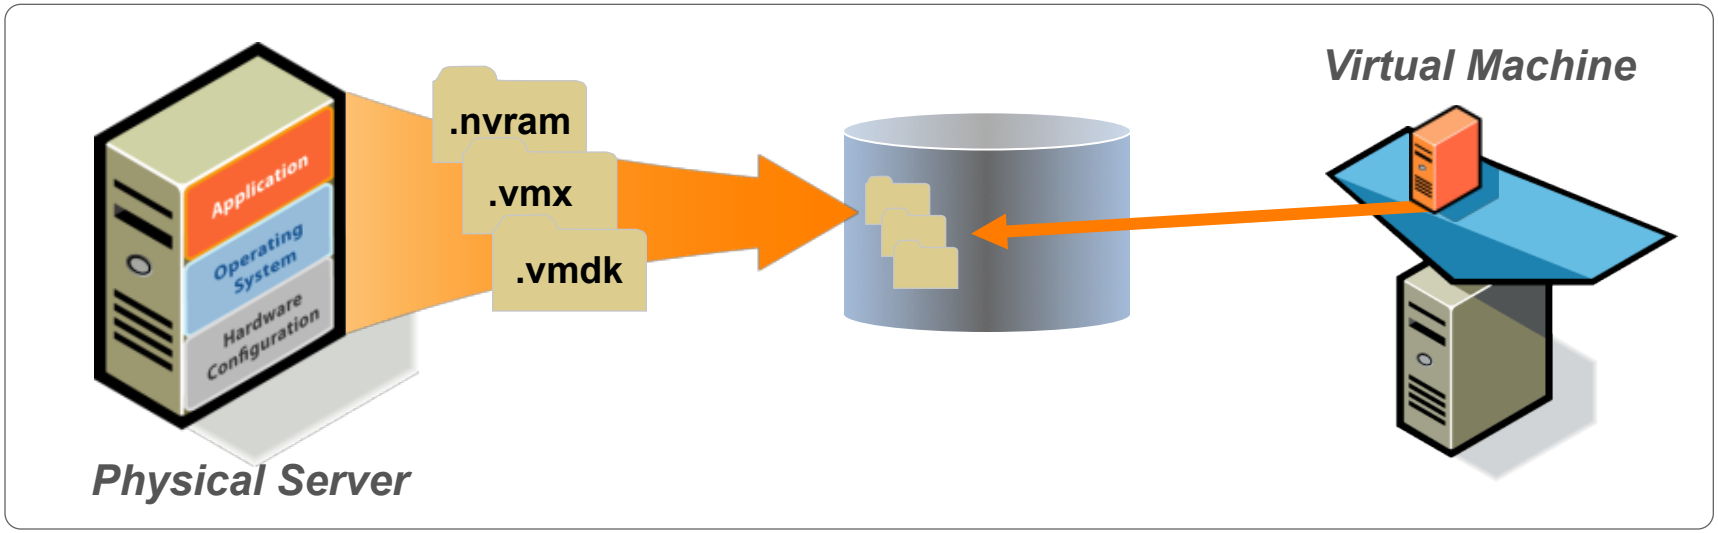

云资源池下的高可用

通过VMware HA确保系统高可用

通过VMware HA可以方便地提高任何应用的高可用性

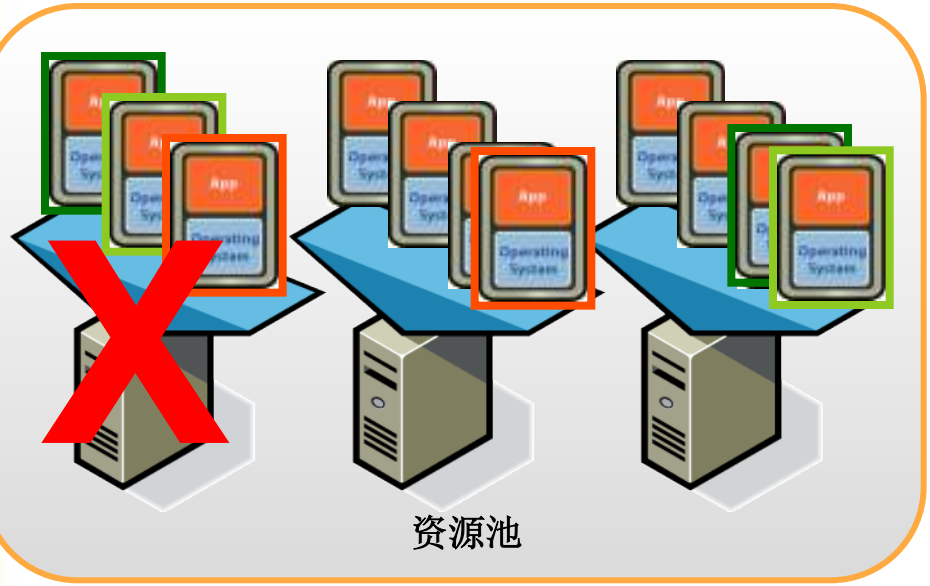

VMware HA是什么？

- VMware HA就是发生服务器故障是在其他的物理服务器上自动重启虚拟机

客户优势

- 对所有的应用实现了高可用性，并且成本很低
- 实现硬件/OS级别的Monitor
- 不需要完全一致的重复硬件
- 比传统的集群有更高的成本优势，同时**易于使用和操作**

vmware

高可用方案的选择

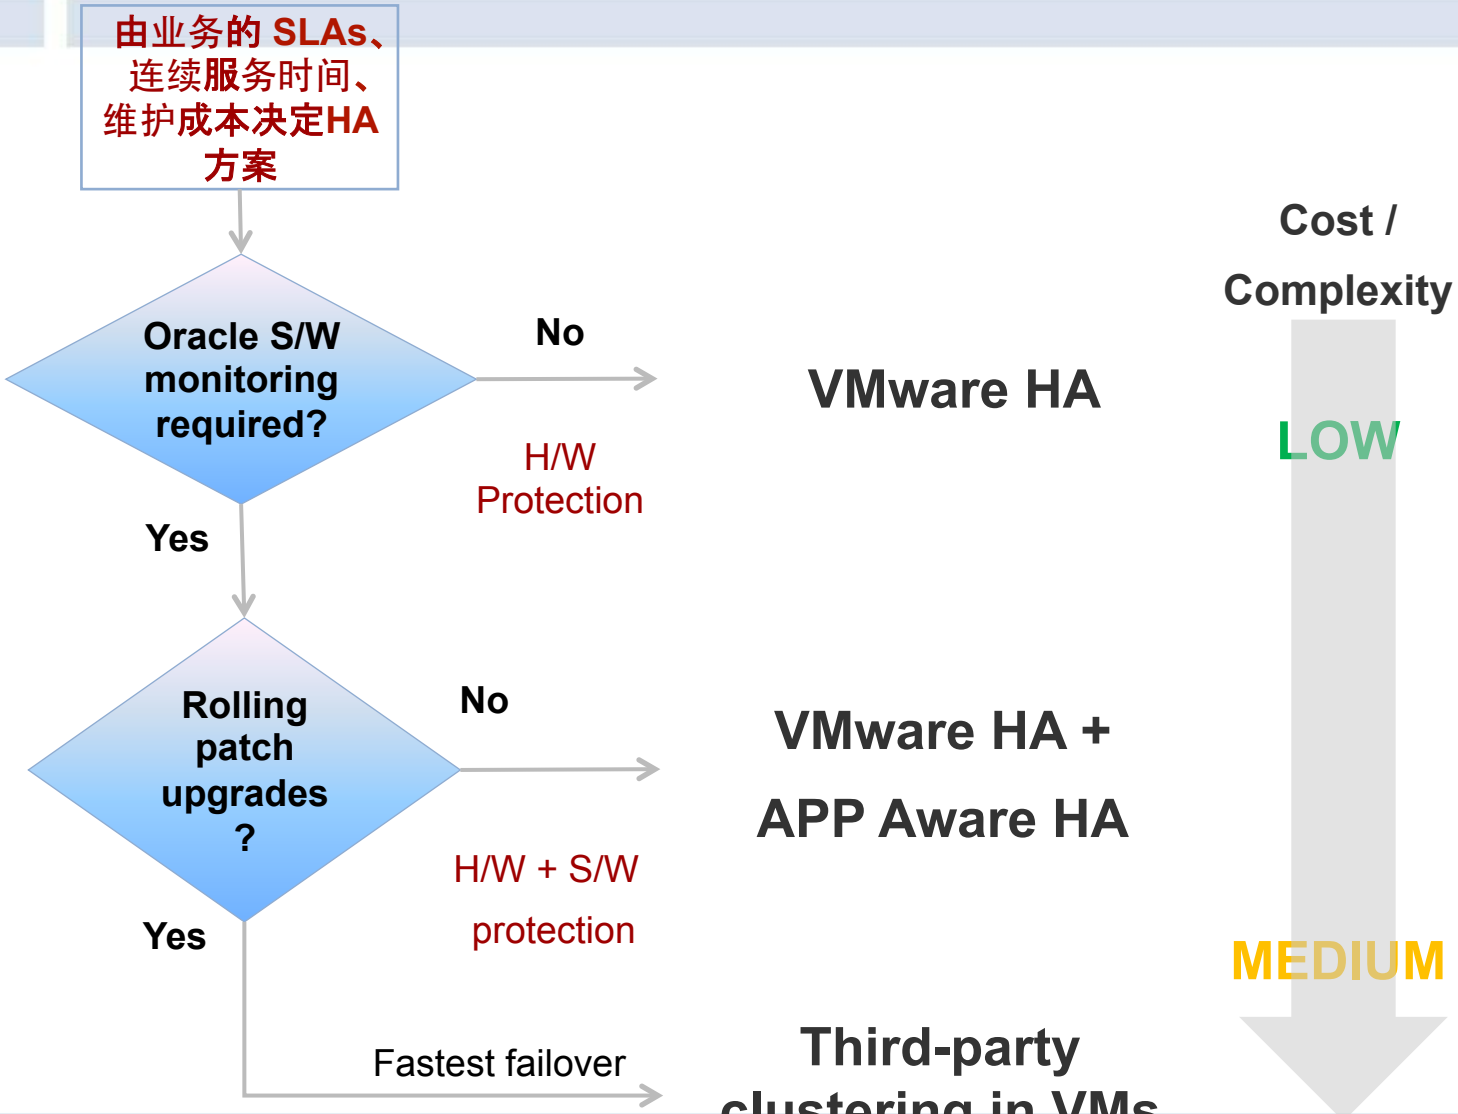
由业务的 SLAs、连续服务时间、维护成本决定HA方案
Oracle S/W monitoring required?
No
H/W Protection
Yes
Rolling patch upgrades ?
No
H/W + S/W protection
Yes
Fastest failover
VMware HA
VMware HA + APP Aware HA
Third-party clustering in VMs
Cost / Complexity
LOW
MEDIUM

其他更高SLA等级的高可用设计（如Oracle RAC等）

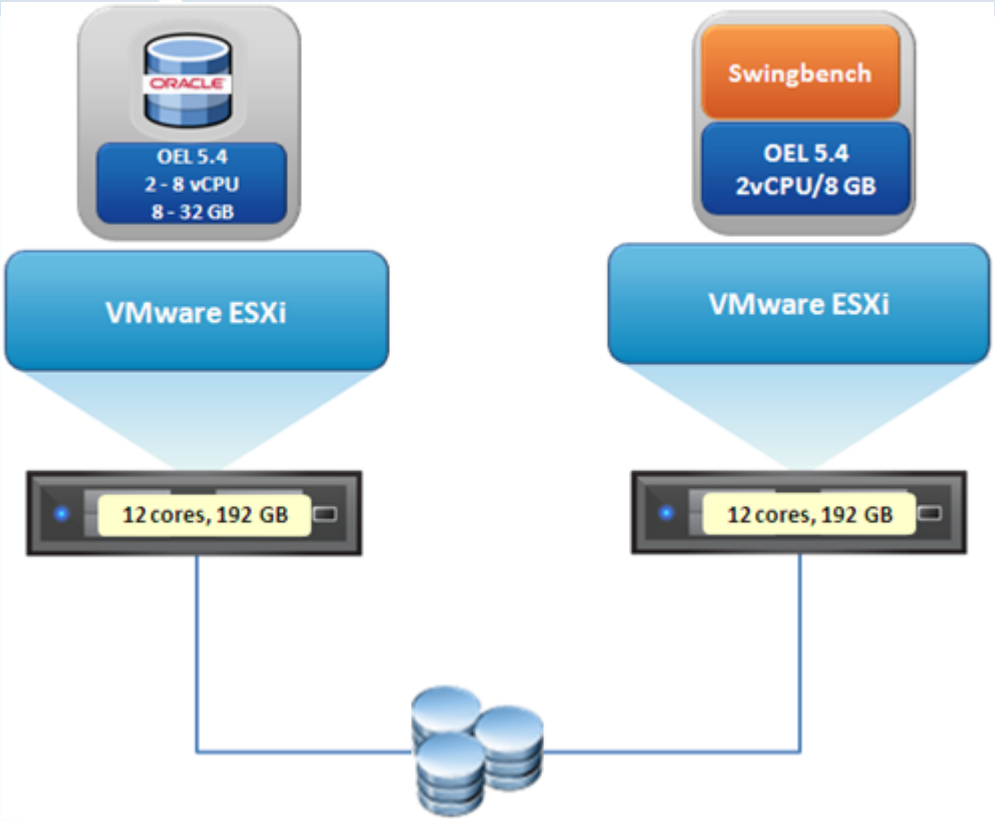

典型场景：

- **云平台上部署多个数据库服务器，满足数据库服务器高可用需求**

存在的问题：

- **云平台如何透过云平台的存储虚拟化功能实现底层Lun的共享**
- **如何保障共享disk的前提下，仍能够使用热迁移、负载均衡的功能**

vmware

HA总结

优势：

- 配置简单
- 能实现硬件、Hypervisor、OS、应用级别的高可靠

问题：

- 所有的业务数据、系统数据、应用存放在共享存储上，一旦共享存储发生故障，系统无法恢复

2种常见的的存储故障之一：人祸:VMFS分区表丢失

分区表丢失：一般是zone 或者 lun masking不当，让物理主机和虚拟化主机的存储没有合理分区造成的

- 物理主机（比如Windows ）将vmfs文件系统格式化

2种常见的的存储故障之一：天灾：物理存储硬件故障

物理存储发生故障、整个存储故障、链路故障或者LUN故障

APD: all path down, 在5.0里面一般表示整个storage都发生了故障，在5.0之前，APD会造成整个hostd无法连接，vcenter和主机失去连接，viclient无法连接，5.0之后viclient可以连接，但是速度缓慢

PDL: Permanent device lost，在5.0里面一般表示一个lun发生故障，esxi主机从storage侧获得一个scsi探测信息，会隔离错误，vcenter不会断开

如何解决？

云资源池下的数据备份与恢复

VDPA 备份的架构

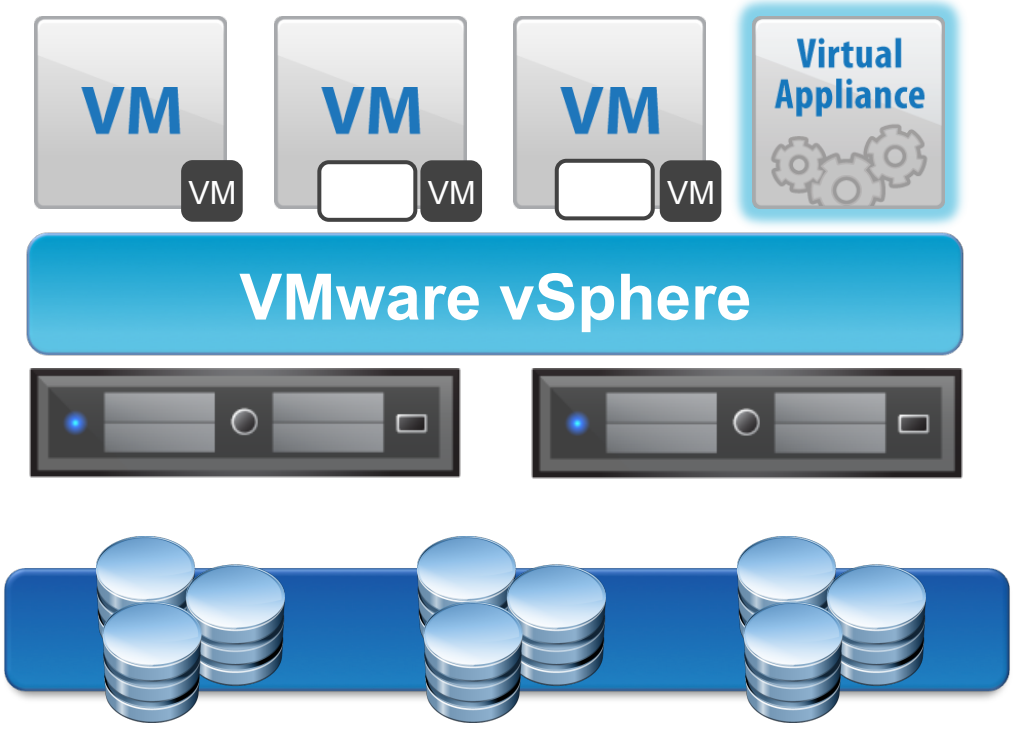

vCenter and SSO

vSphere Web Client

云资源池的数据备份与恢复

VDP Advanced

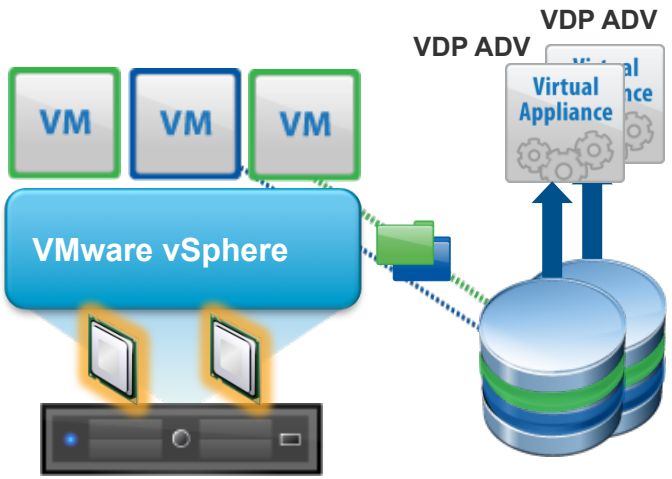

Overview

主要特点

- 支持重复数据删除、增量备份、全量备份、备份Schedule等
- 最大支持8T*10的重复数据删除后的容量
- 通过VSS支持应用的备份：SQL Server等
- 支持文件级别的恢复：各个VM可以自服务
- LAN FREE + SERVER LESS的备份

适用场景

- 用户数据的错误删除后的恢复，和快照相比有周期性等特点，且不会影响性能
- 对RTO要求不高的业务连续性要求
- 业务数据可以恢复到过去一个月甚至一年任意一个时间

VDPA 备份整个VM或者应用

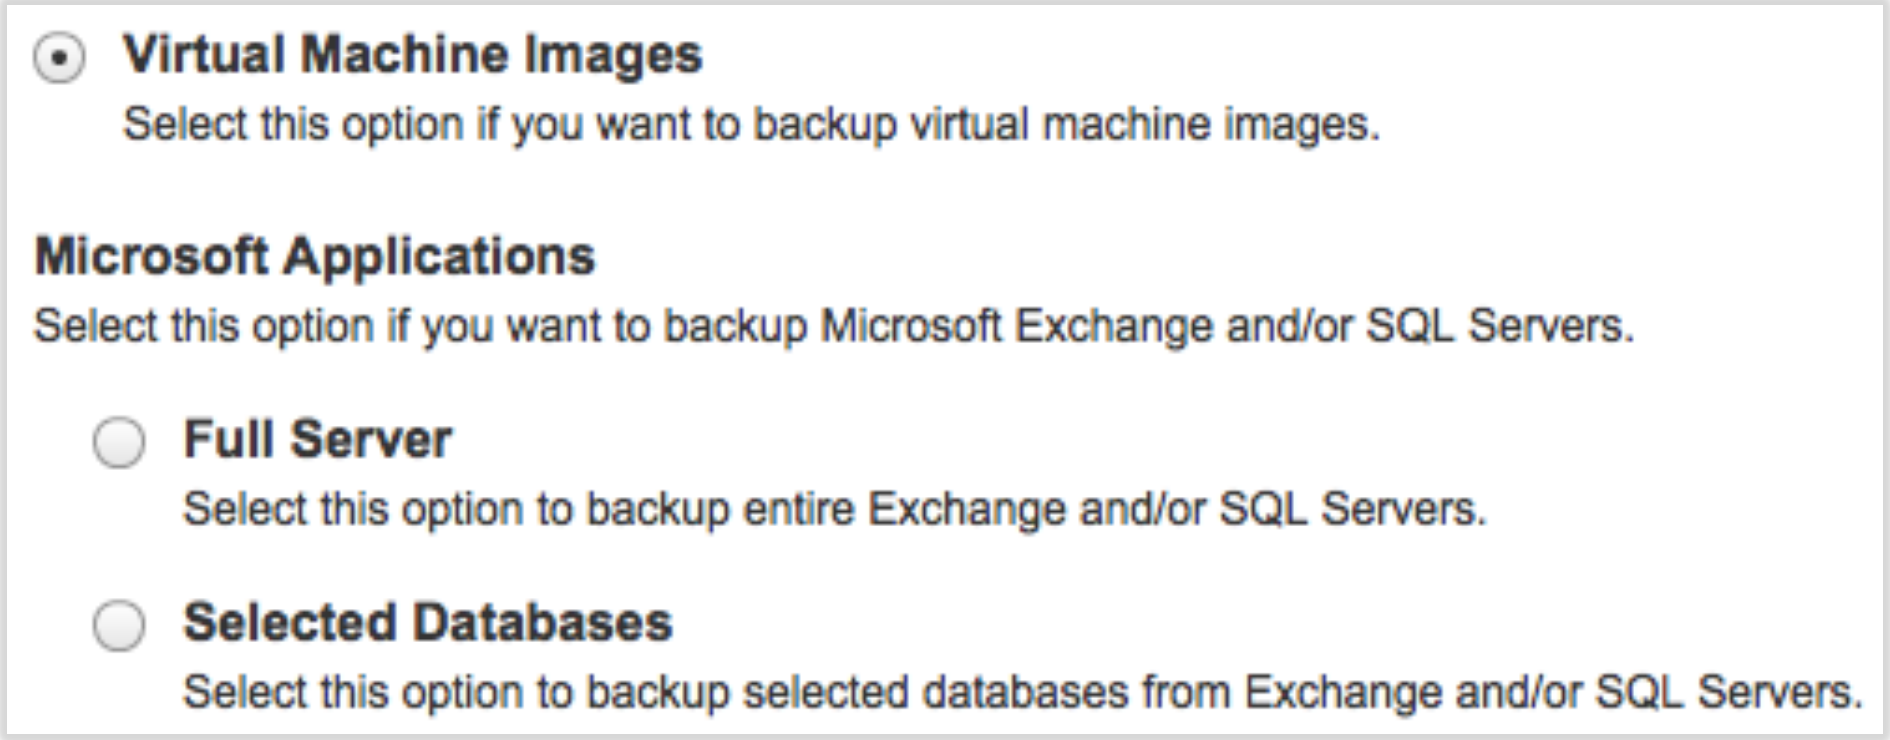

Create Backup Job – Image

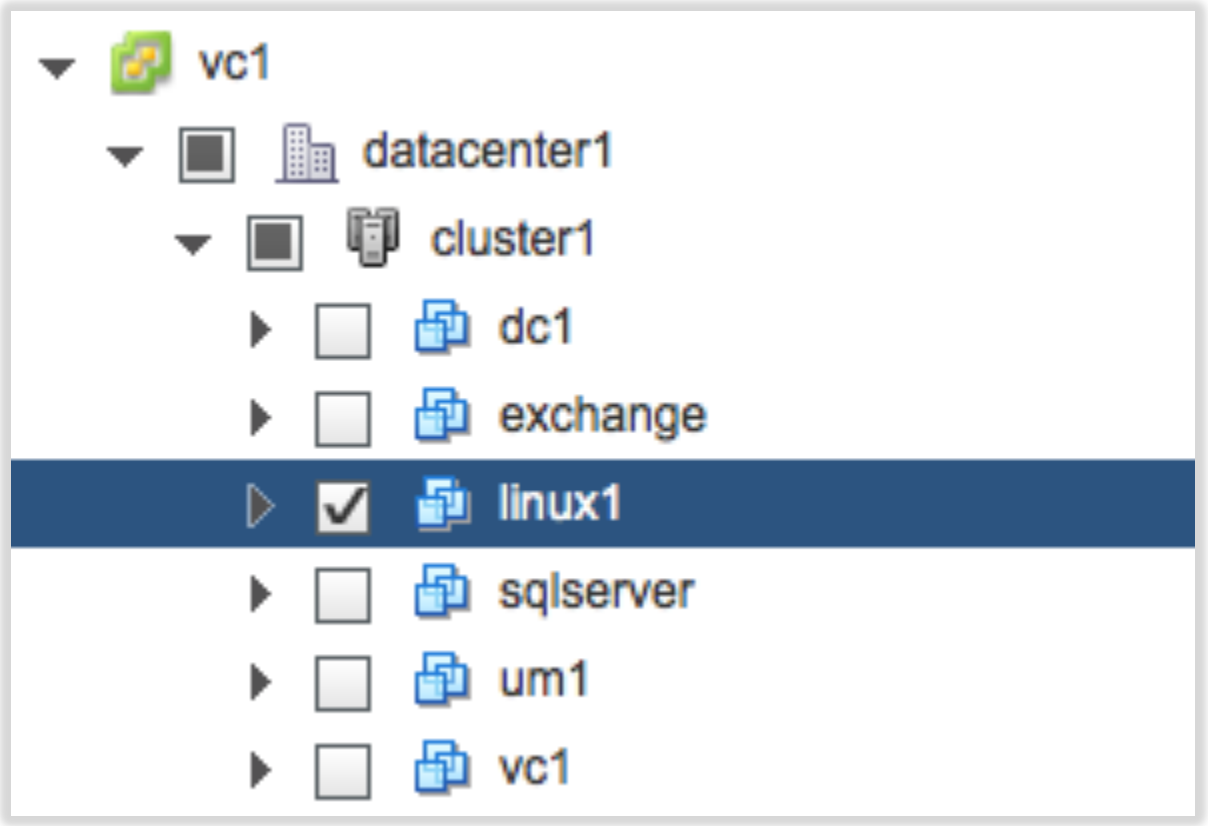

Create Backup Job – Image

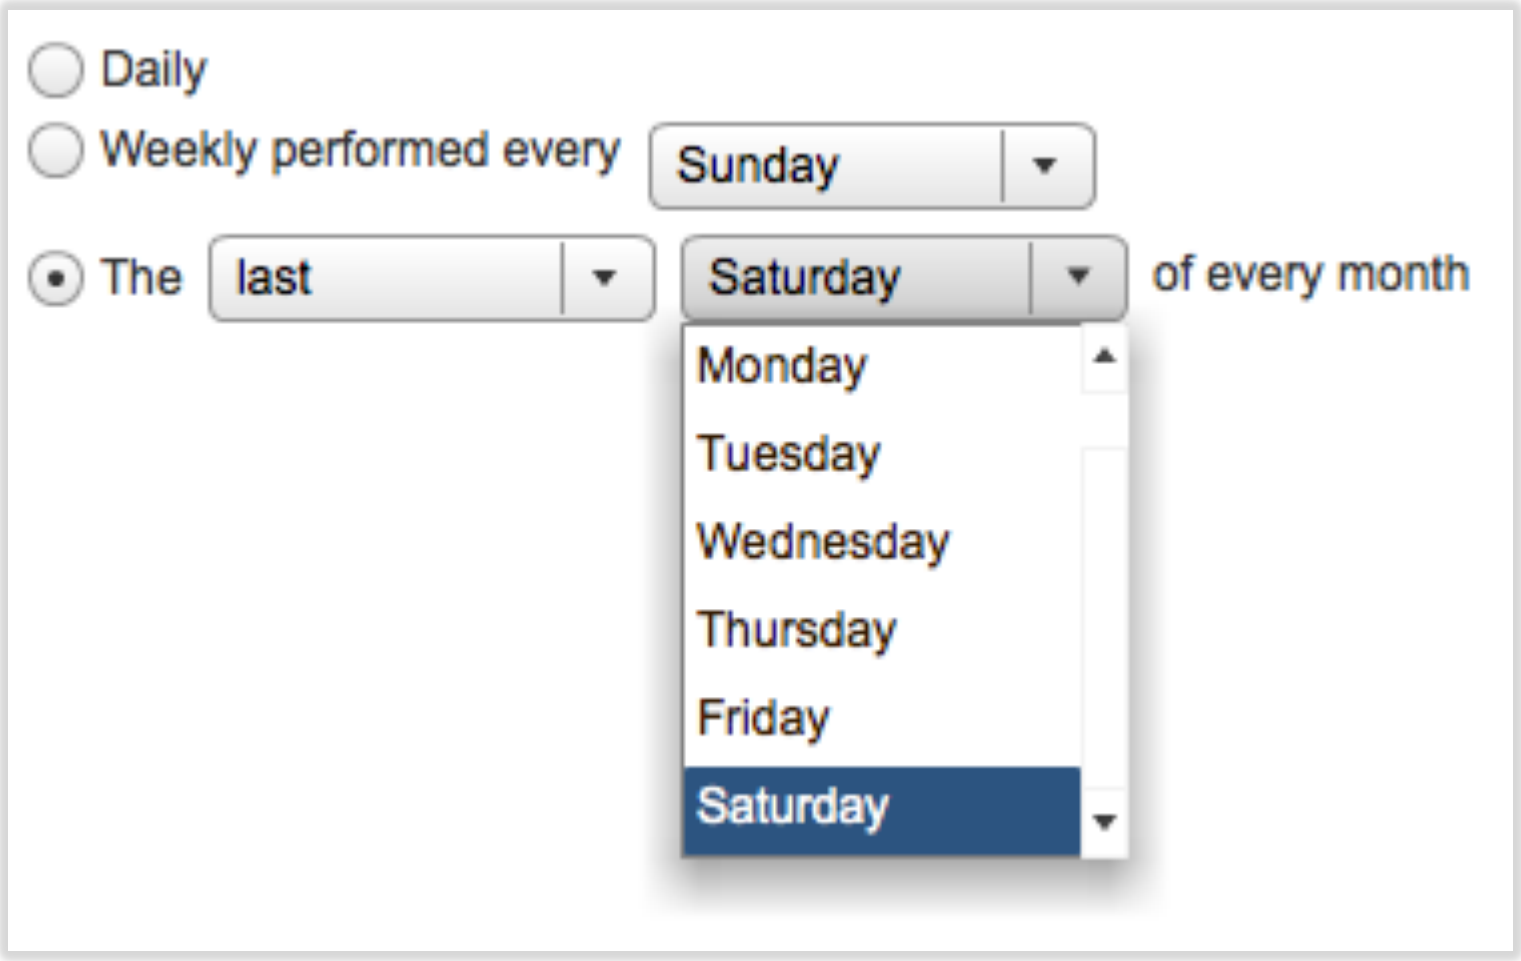

备份周期

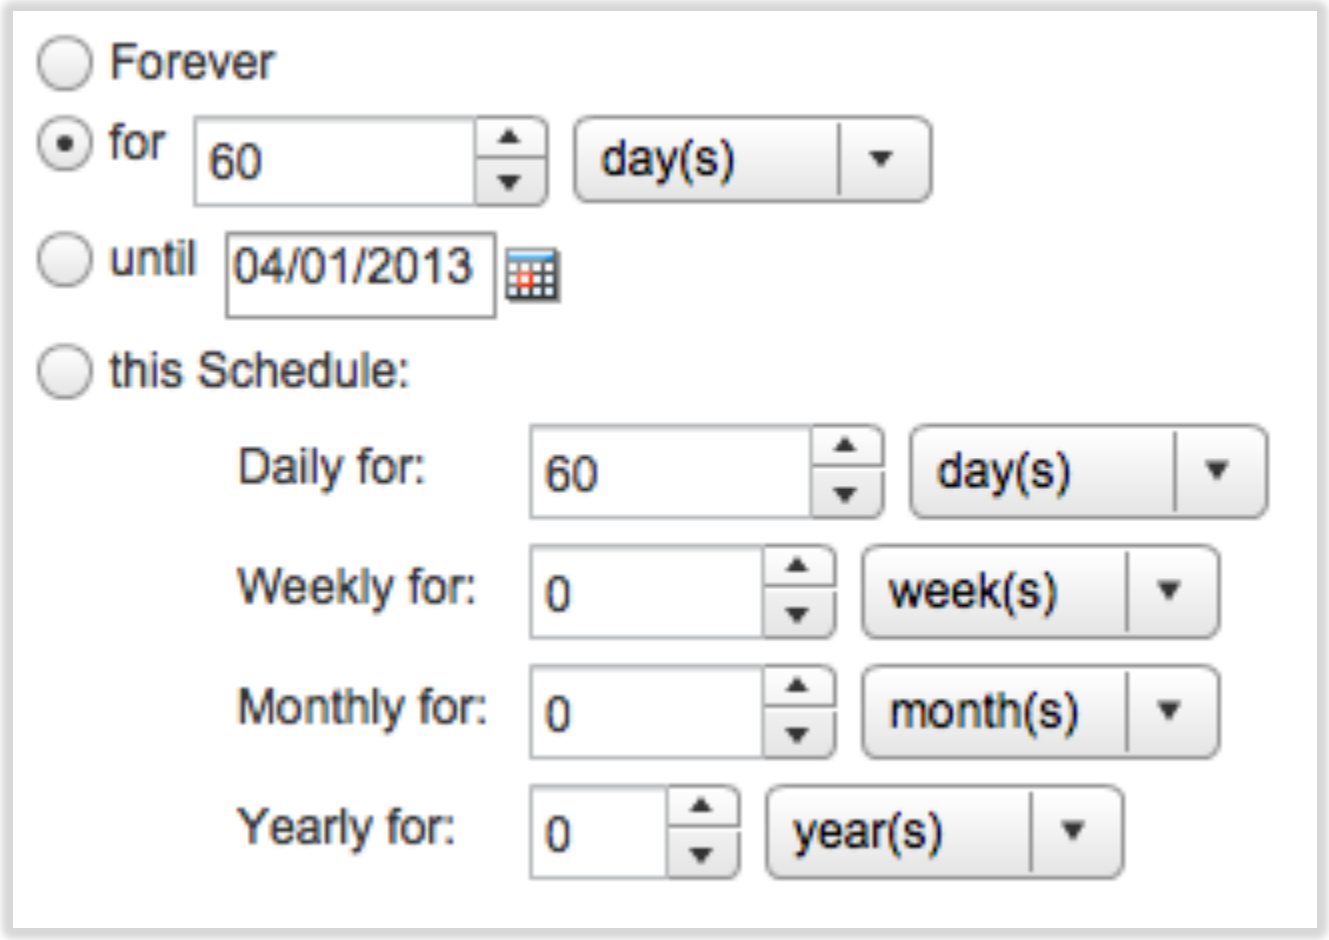

恢复整个虚拟机

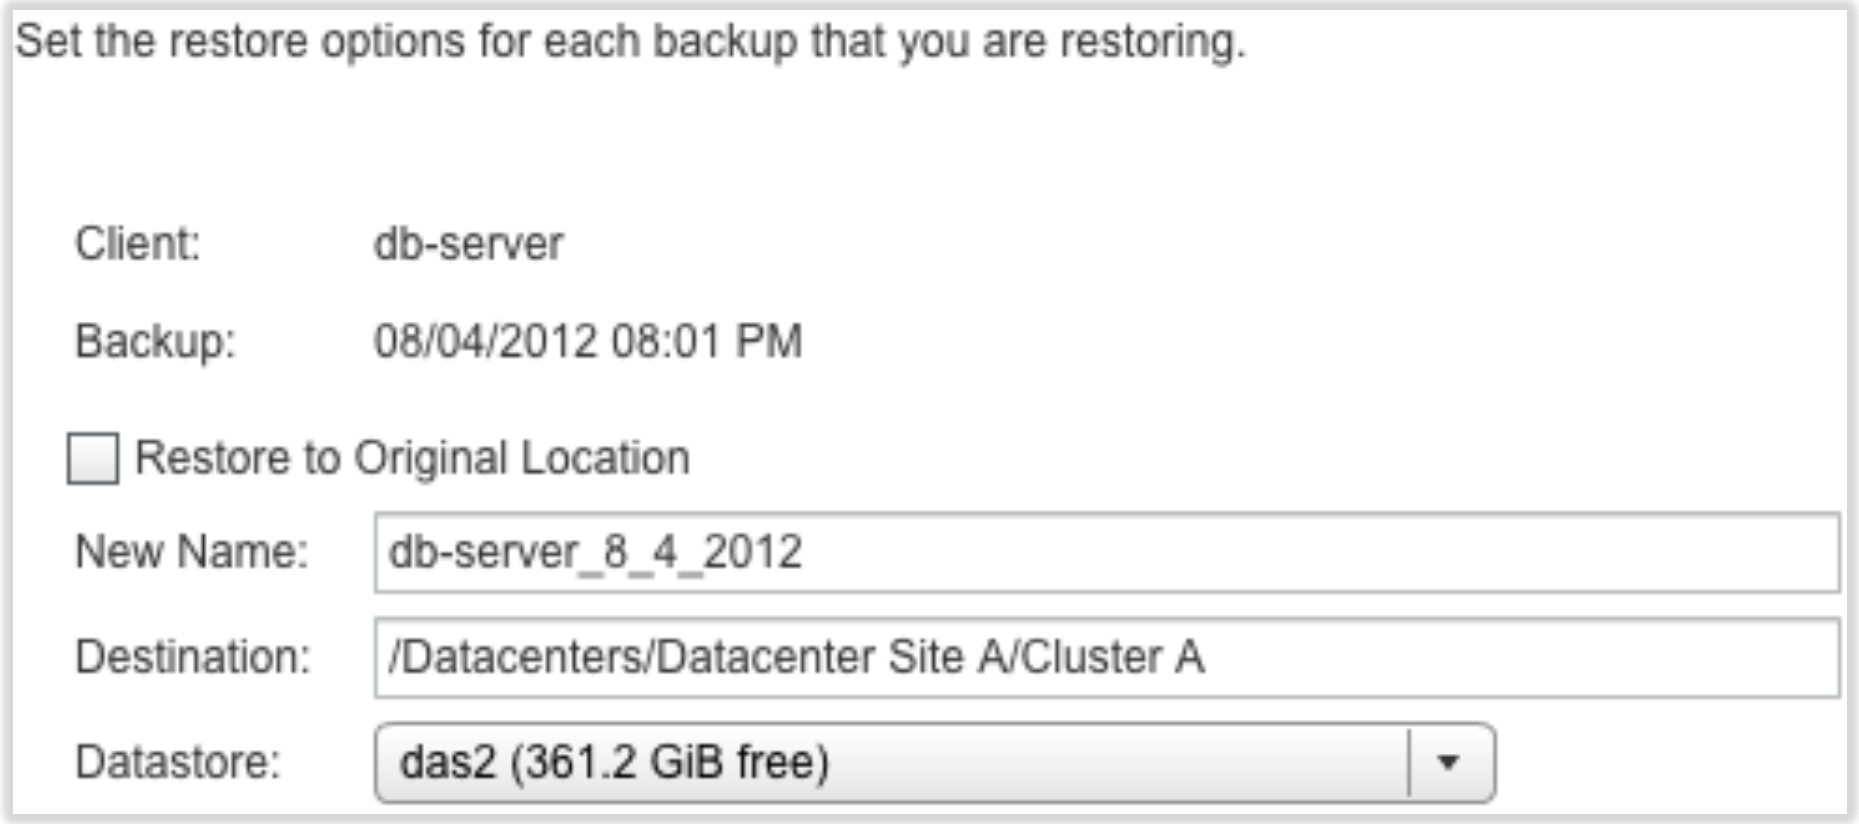

文件级别的恢复(FLR)

最终用户进行自服务的文件恢复

通过WEB浏览器登录VDP Restore Client 进行文件恢复

- 用户无需安装备份和恢复使用的客户端
- https://<VDP appliance IP address>:8543/flr

Linux的用户和windows的用户都可以使用文件级别的恢复

File Level Restore (FLR)

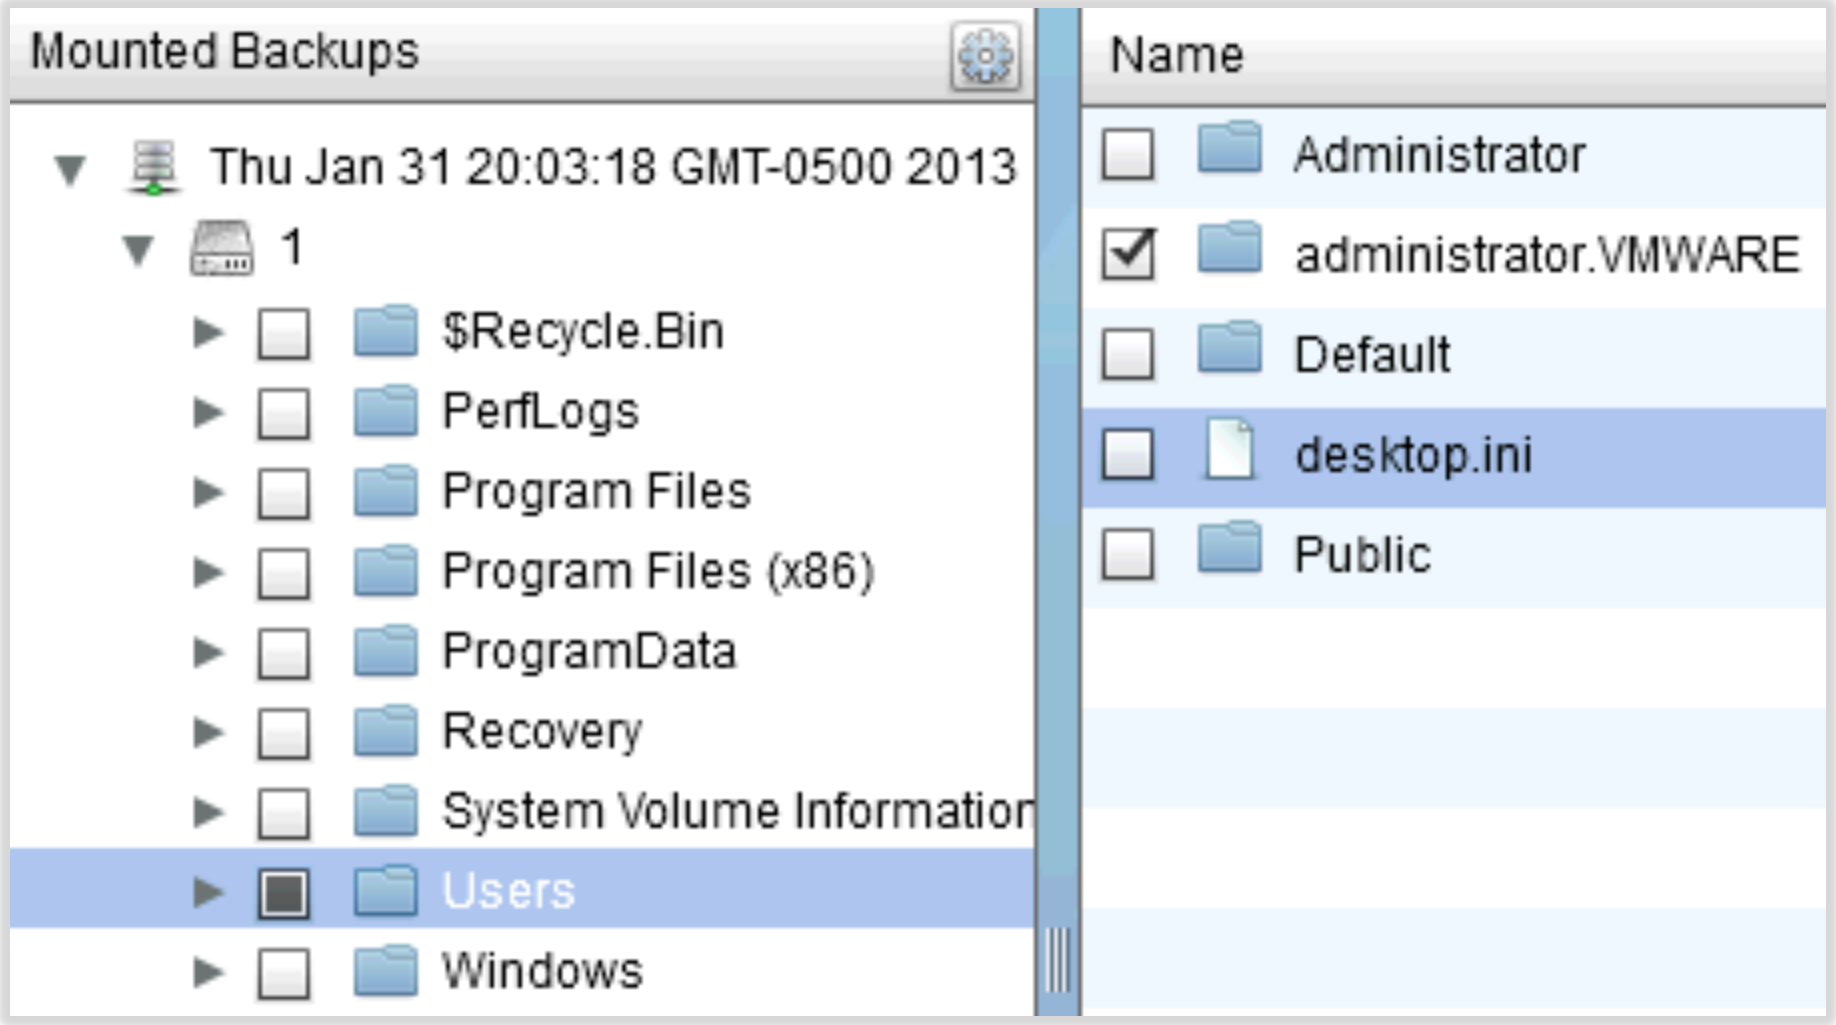

DP总结

优势：

- 根据备份的策略，能够恢复到过去一段时间内（一般为半年）内任意一个时间段内的虚拟机和文件

问题：

- 一旦发生大规模的存储硬件故障，VM的恢复速度受到存储写入速度的影响，大大限制了业务的恢复时间
- 无法解决站点级别的故障

云资源池下的灾难恢复

利用SRM实现站点级业务连续性

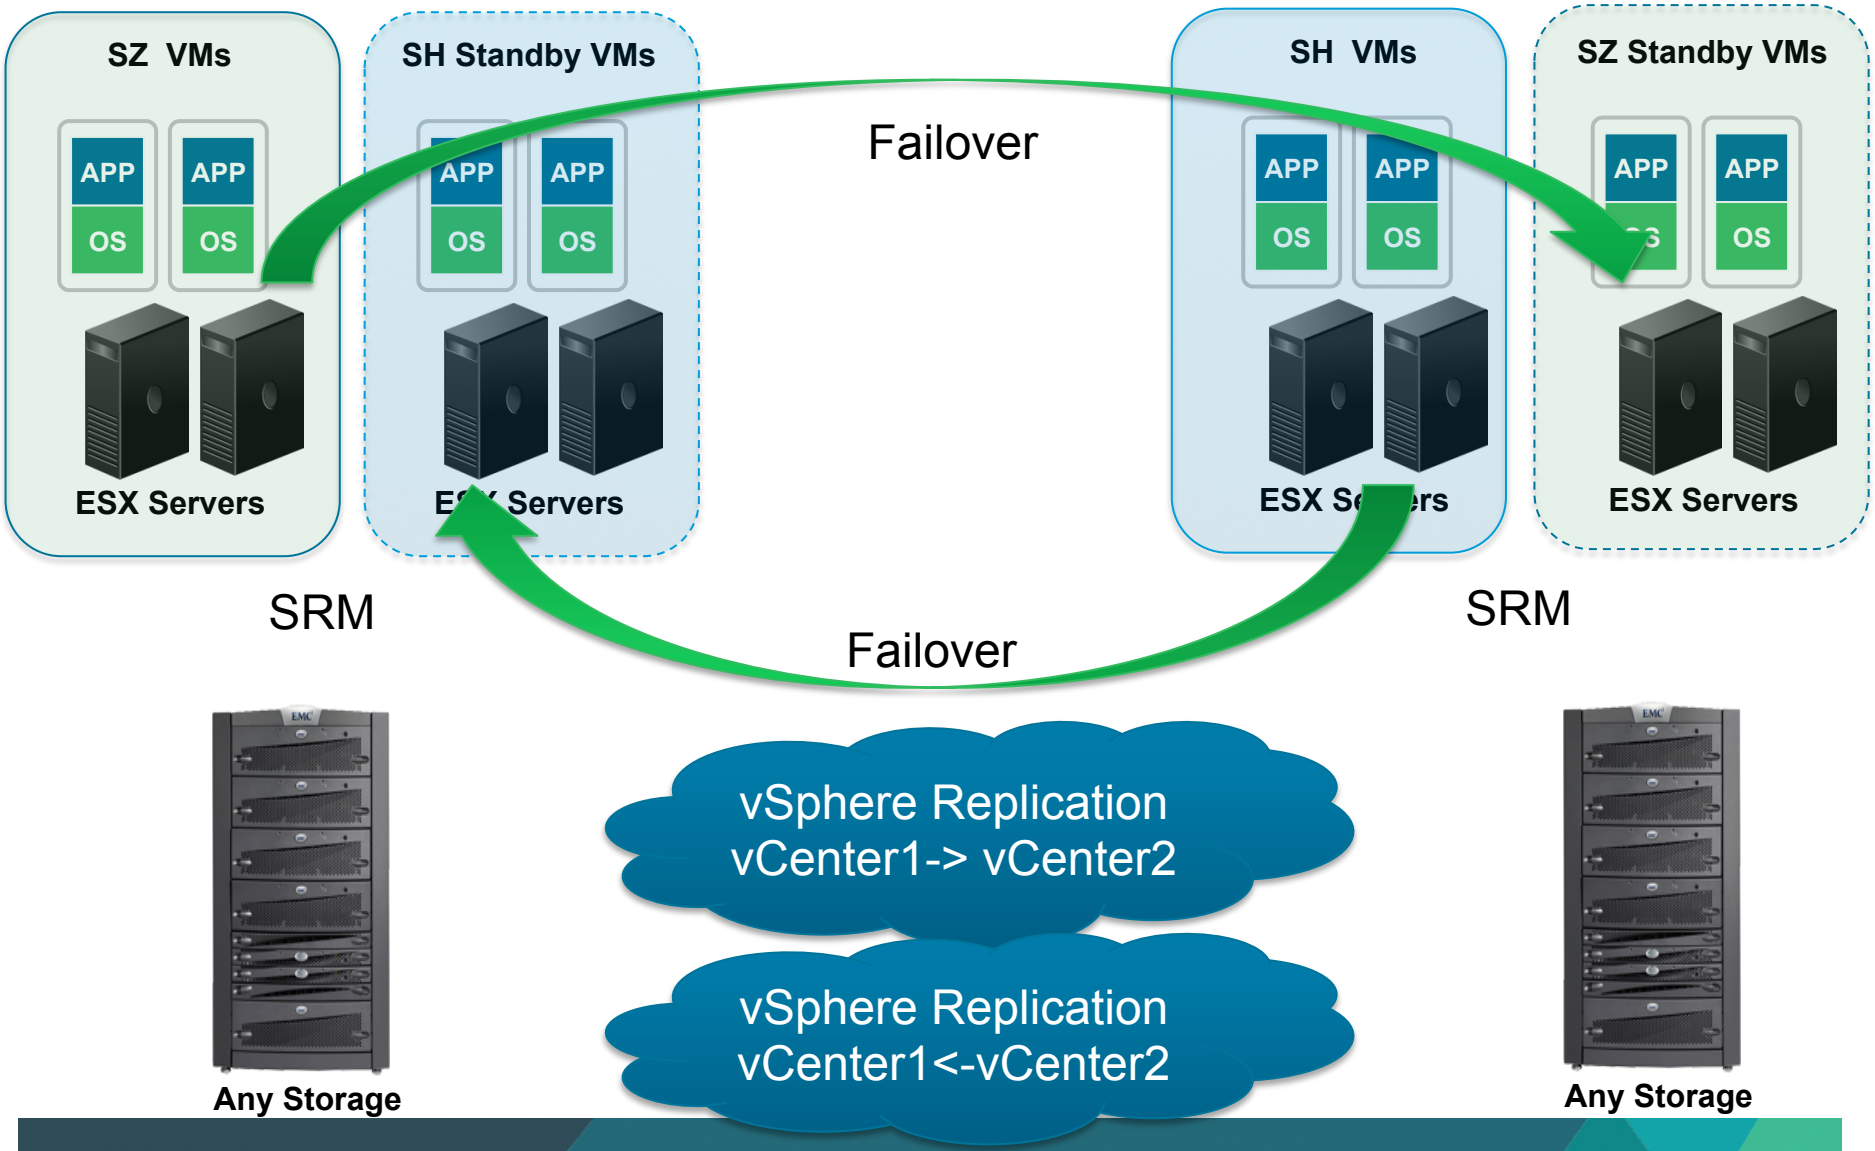

SRM实现业务连续性

主要特点

- 异构存储的数据复制：RPO=0~15分钟
- 快速的业务恢复：500个虚拟机RTO=30分钟
- 数据的增量备份
- 虚拟机粒度的DR，节省存储空间
- 快速可靠容灾演练
- 数据只保留一次最近的

适用场景

- 存储的硬件故障：整个存储单点发生故障，必须进行整个资源池的整体切换，防止关键业务的长时间停机
- 站点的网络故障整体切换
- 站点的计算资源故障整体切换

SRM 5.x总体架构

Required at both protected and recovery sites

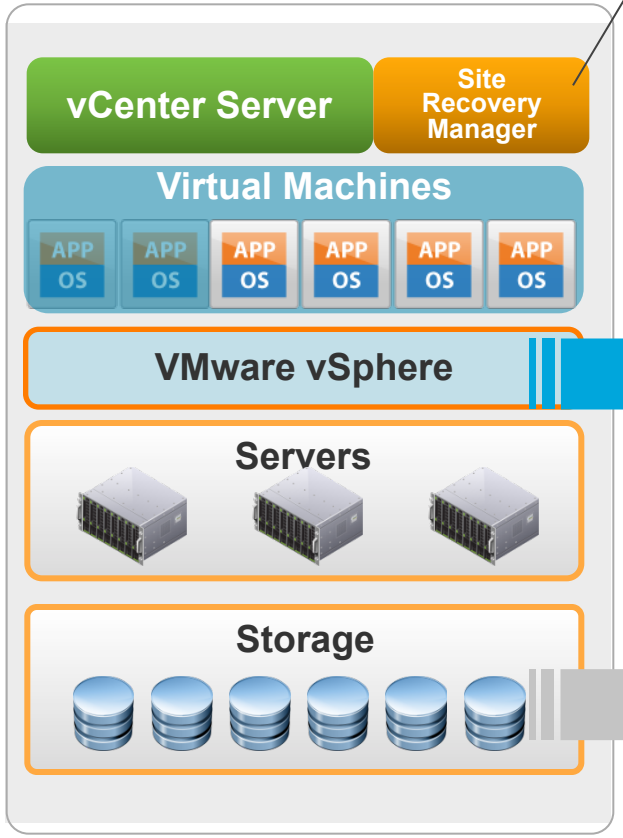

Site Recovery Manager

- 管理恢复计划、容灾演练
- 自动化failovers and failbacks
- 整合vcenter和复制计划

复制机制选择

vSphere Replication

- Part of vSphere platform
- Replicates virtual machines between vSphere clusters

Storage-Based Replication (3rd party)

- Provided by replication vendor
- Integrated via replication adapters created, certified and supported by replication vendor

3PAR · EMC² where information lives · FalconStor Software · hp invent · Hitachi Data Systems · Xiotech · DELL EqualLogic · FUJITSU · LSI · IBM · NetApp · compellent

vmware

SRM 5.x 提供了复制选项的广泛选择

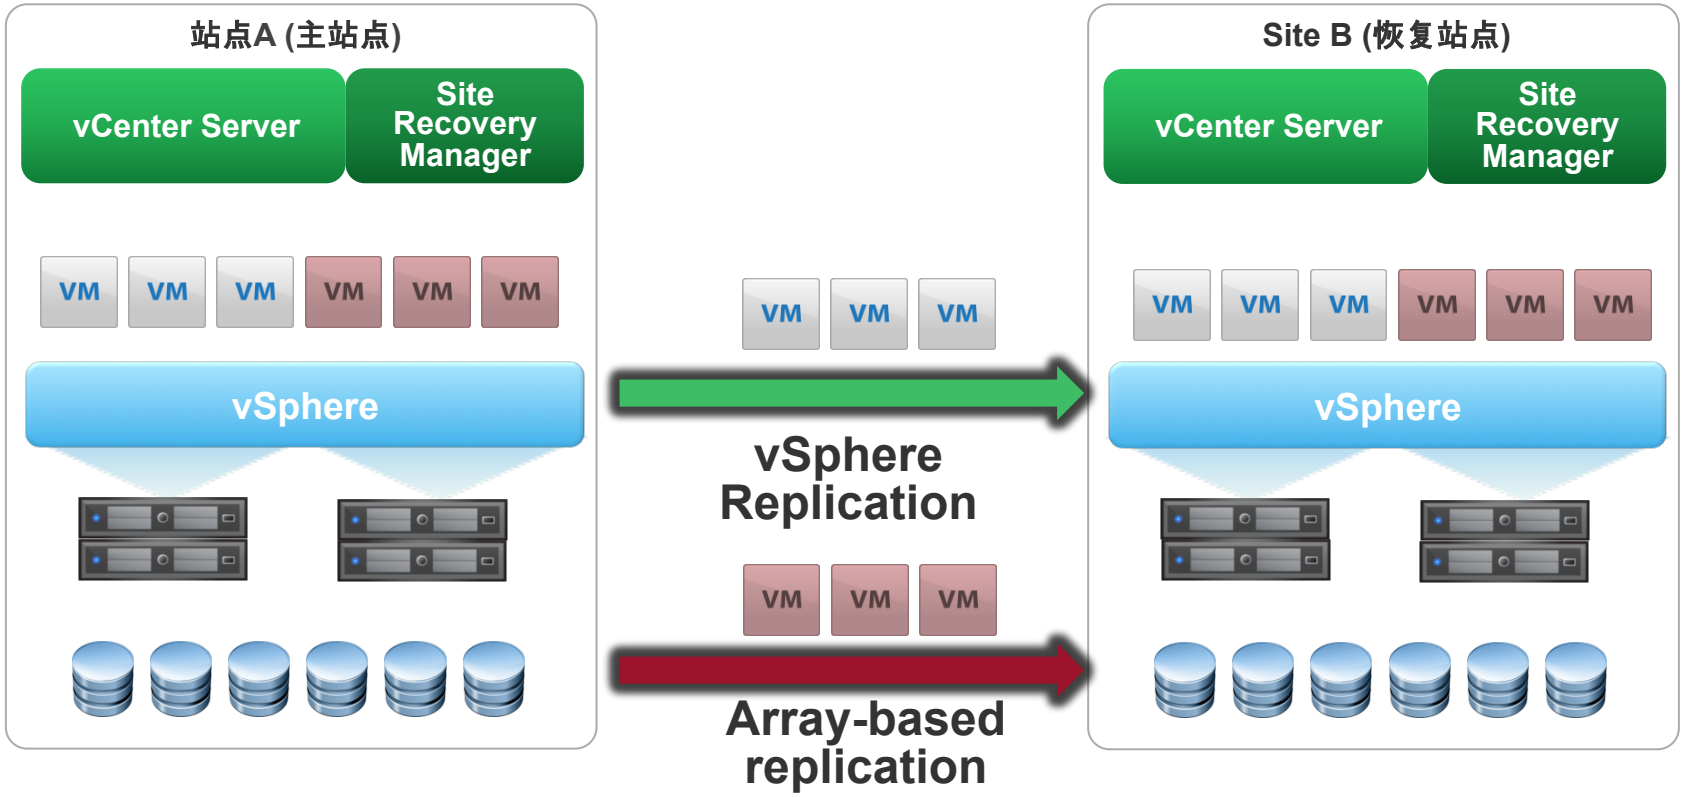

采用存储厂商的复制技术（SRA: Storage Replication Agent）

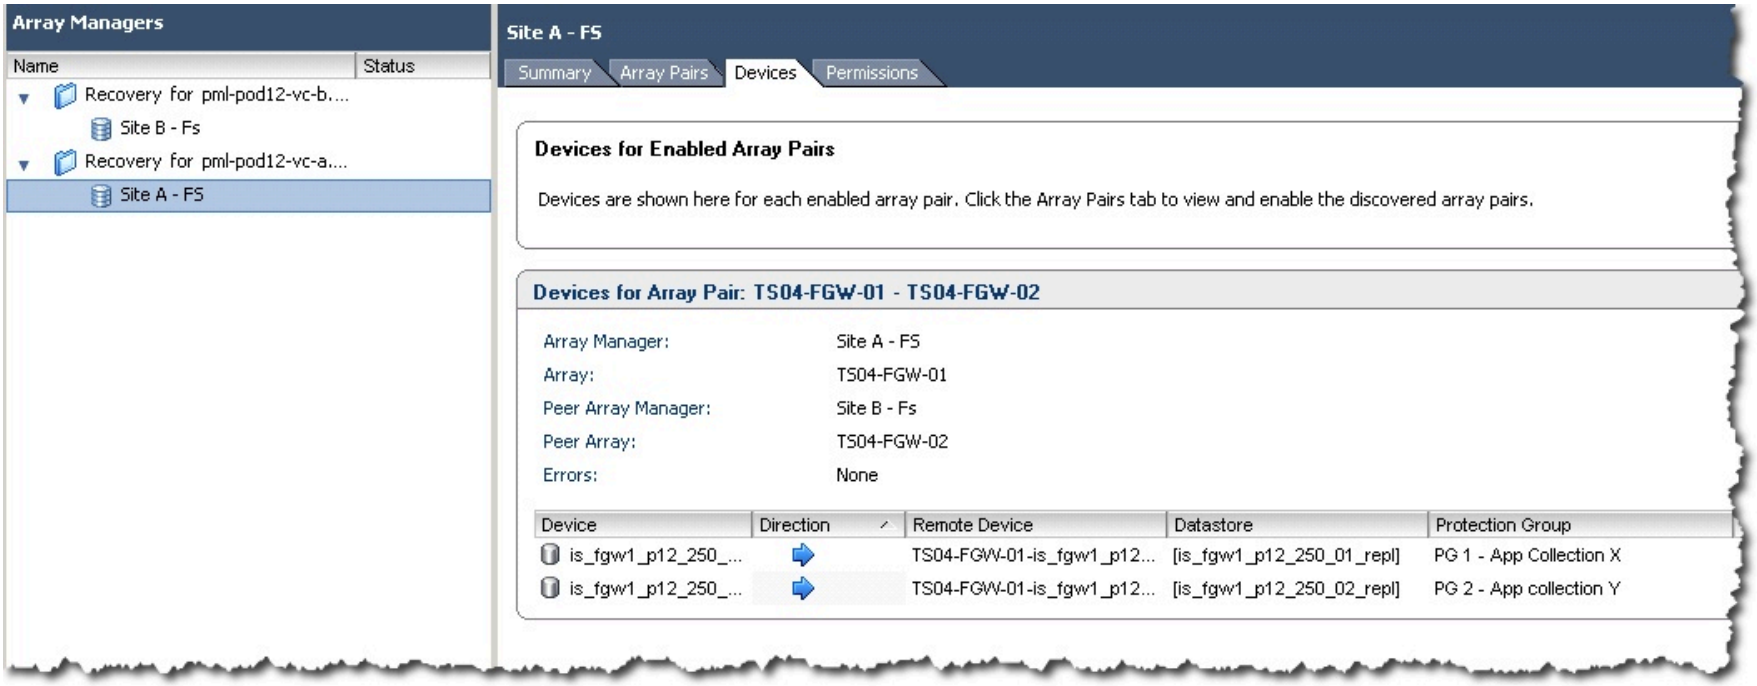

SRAs show detailed storage specific data in the SRM GUI：基于LUN

采用vSphere Replication – VM 粒度

Track replication status through either web client or SRM

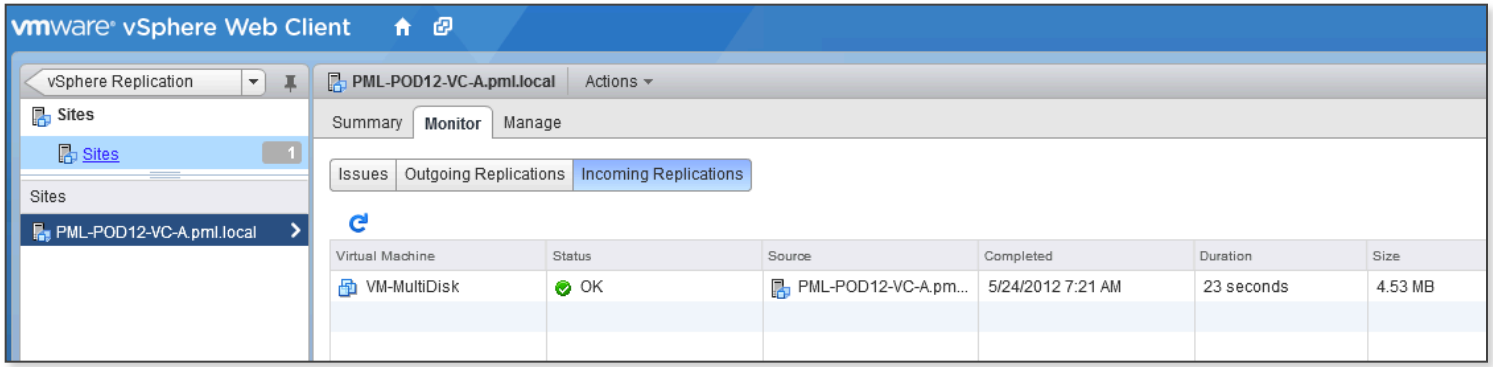

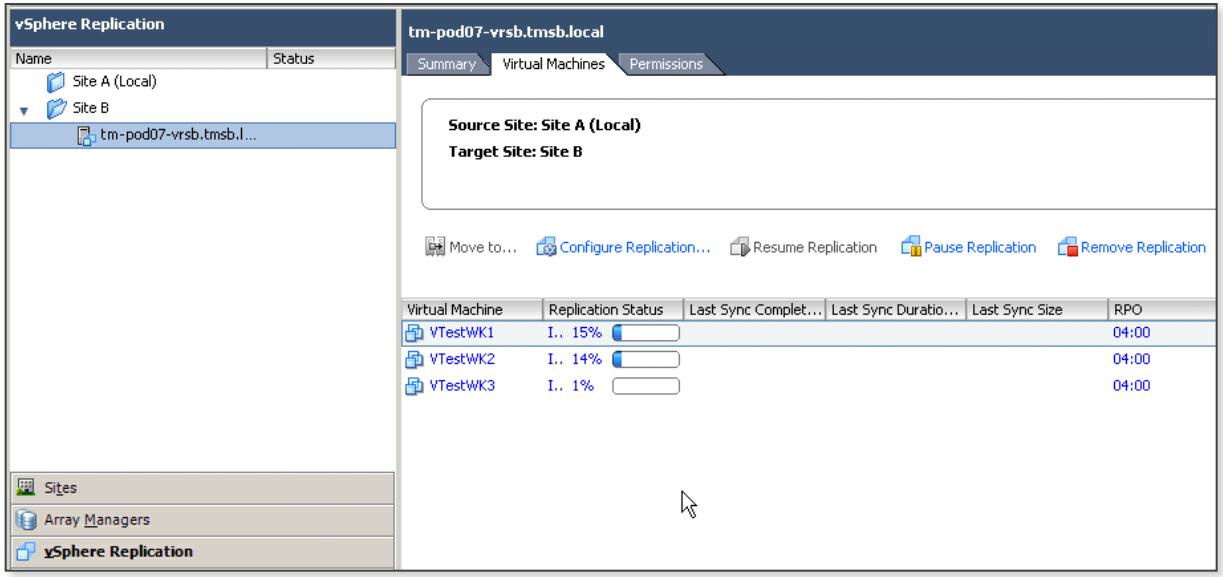

Manage VR replication through SRM

vmware

SRM Architecture with vSphere Replication

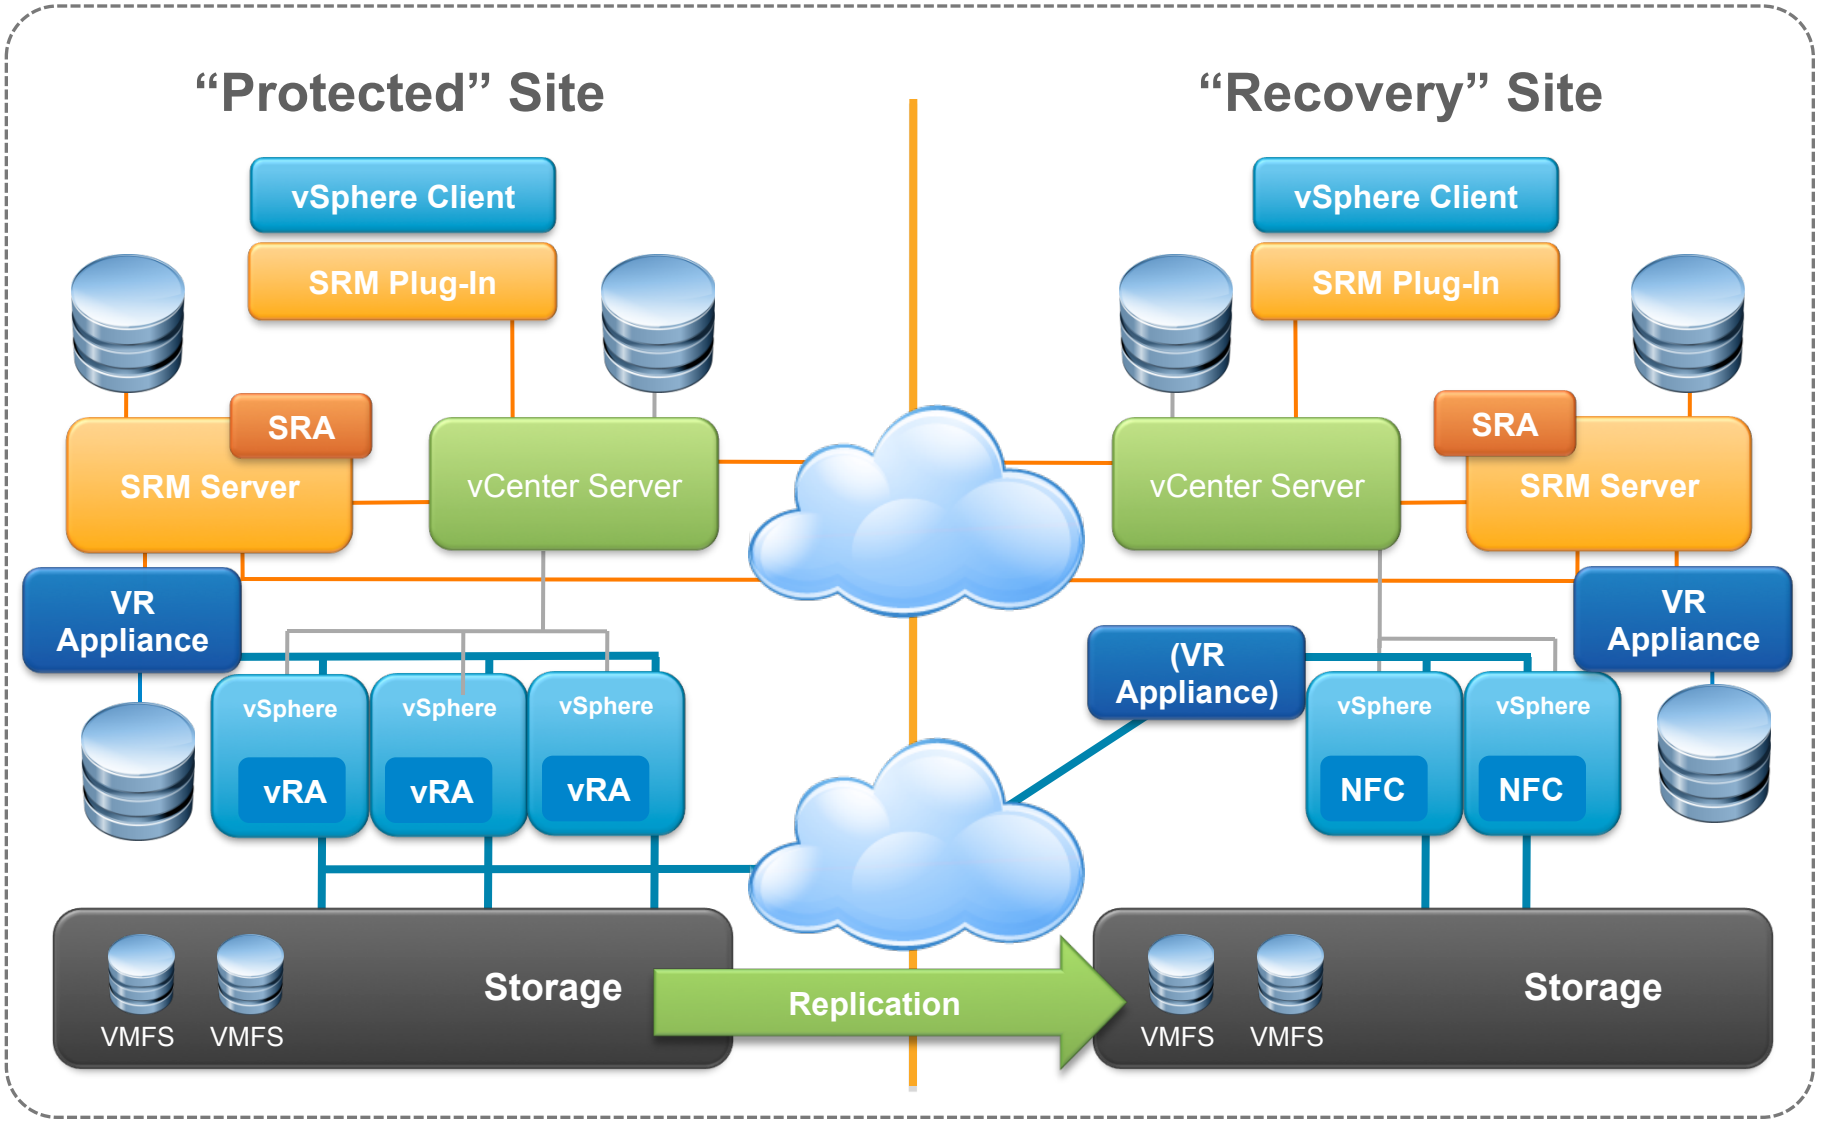

vmware

远程复制中的关键技术

- **VR redo log技术：**
  - VR通过一种轻量级的虚拟机快照，即redo log来记录上次RPO到本次RPO之间改变的数据块。假设虚拟机有多块虚拟磁盘，redo log可以保证多块虚拟磁盘之间的数据一致性。Redo log是通过虚拟SCSI过滤器来纪录数据块的读写情况，通过bitmap标记更改了的数据块，以便下次同步时传输。

DR技术信心的来源： 容灾演练

Test

Test

API

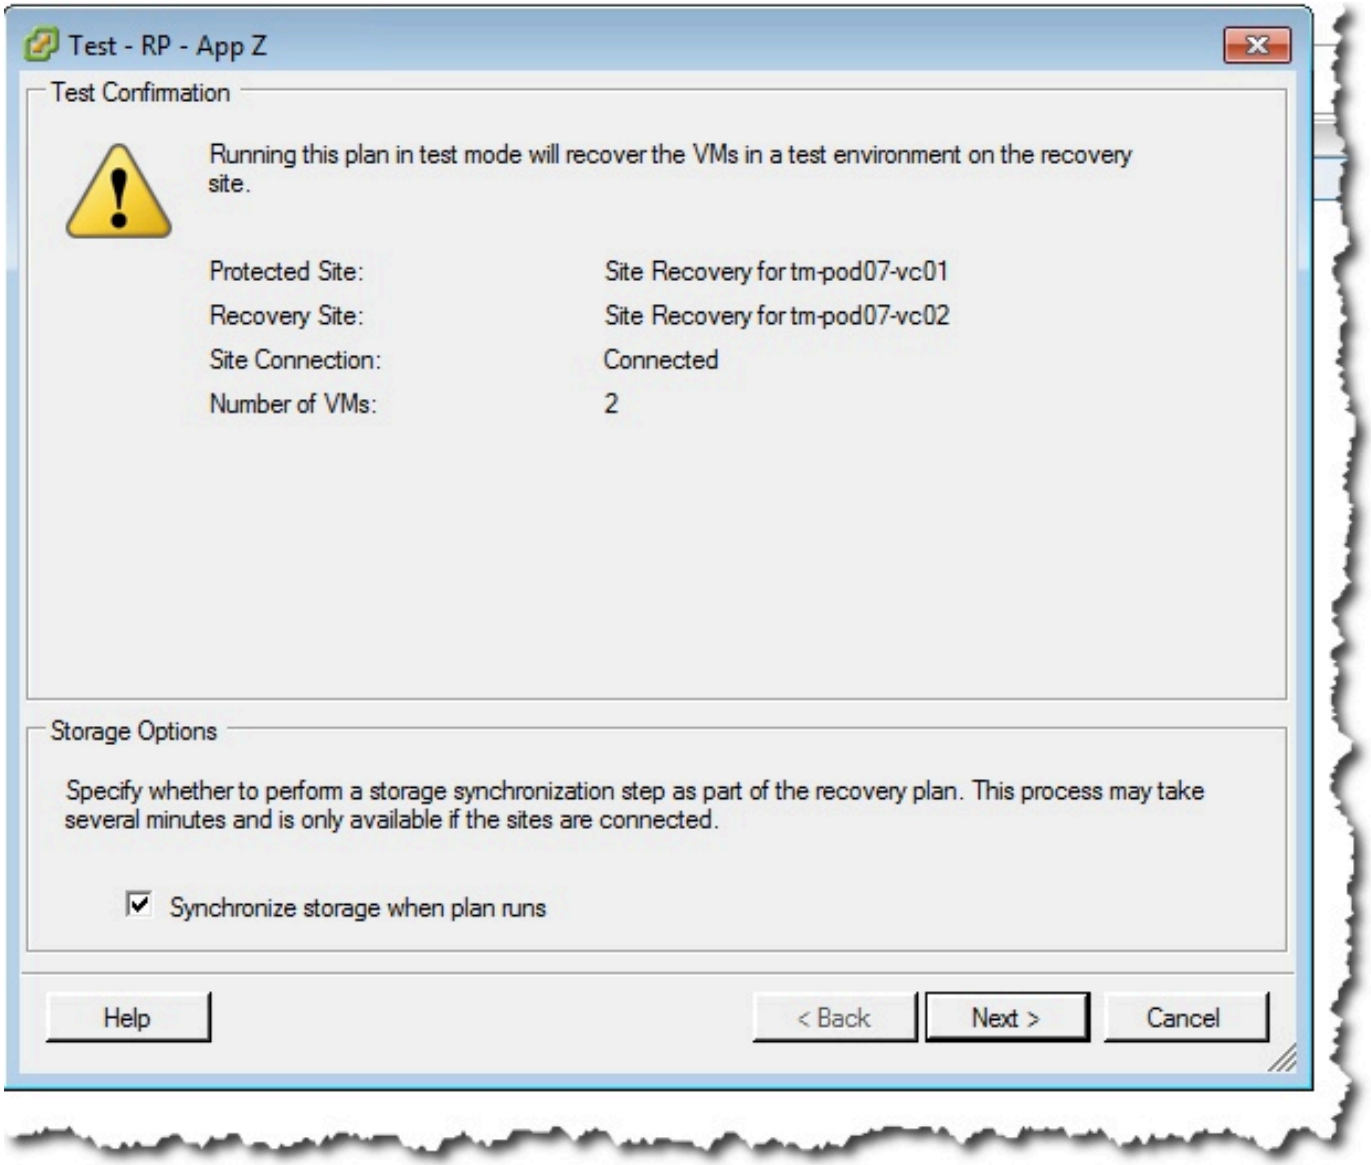

vmware

容灾演练 – 存储层/网络层

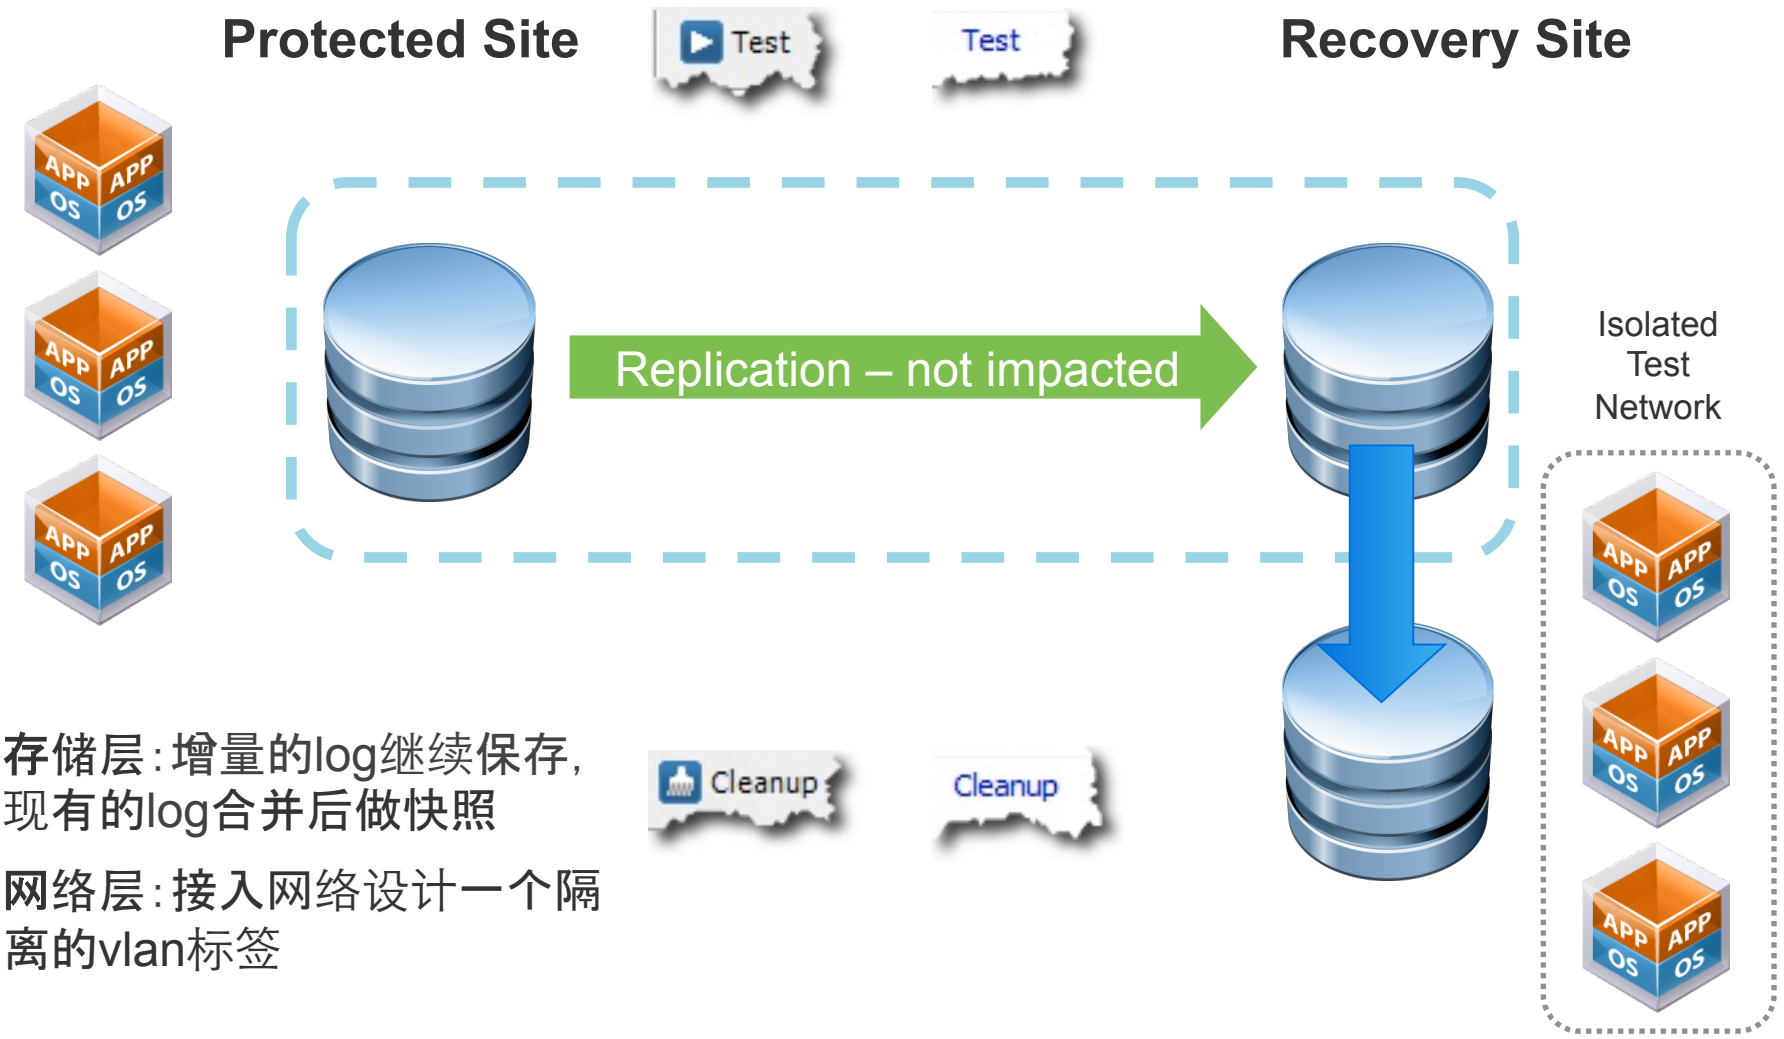

存储层：增量的log继续保存，现有的log合并后做快照

网络层：接入网络设计一个隔离的vlan标签

容灾演练监控

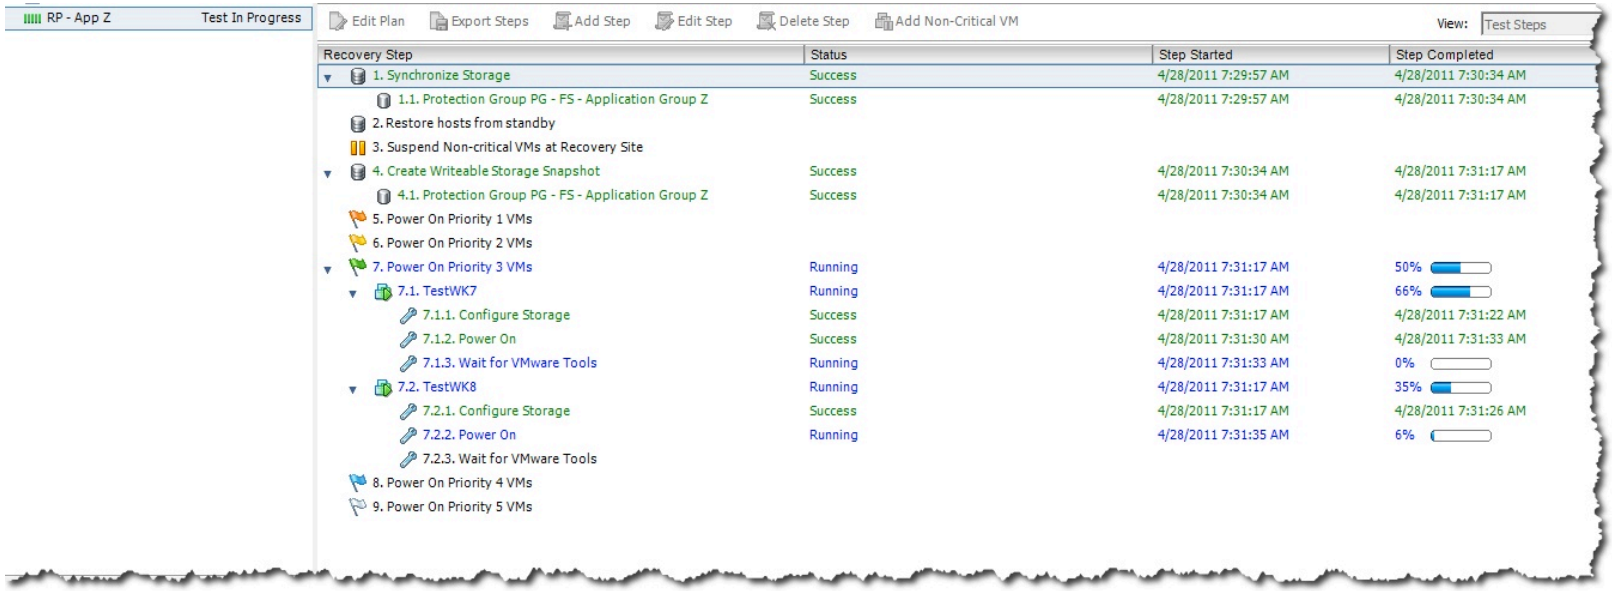
RP - App Z
Test In Progress
Edit Plan
Export Steps
Add Step
Edit Step
Delete Step
Add Non-Critical VM
View:
Test Steps
Recovery Step
Status
Step Started
Step Completed
1. Synchronize Storage
Success
4/28/2011 7:29:57 AM
4/28/2011 7:30:34 AM
1.1. Protection Group PG - FS - Application Group Z
Success
4/28/2011 7:29:57 AM
4/28/2011 7:30:34 AM
2. Restore hosts from standby
3. Suspend Non-critical VMs at Recovery Site
4. Create Writeable Storage Snapshot
Success
4/28/2011 7:30:34 AM
4/28/2011 7:31:17 AM
4.1. Protection Group PG - FS - Application Group Z
Success
4/28/2011 7:30:34 AM
4/28/2011 7:31:17 AM
5. Power On Priority 1 VMs
6. Power On Priority 2 VMs
7. Power On Priority 3 VMs
Running
4/28/2011 7:31:17 AM
50%
7.1. TestWK7
Running
4/28/2011 7:31:17 AM
66%
7.1.1. Configure Storage
Success
4/28/2011 7:31:17 AM
4/28/2011 7:31:22 AM
7.1.2. Power On
Success
4/28/2011 7:31:30 AM
4/28/2011 7:31:33 AM
7.1.3. Wait for VMware Tools
Running
4/28/2011 7:31:33 AM
0%
7.2. TestWK8
Running
4/28/2011 7:31:17 AM
35%
7.2.1. Configure Storage
Success
4/28/2011 7:31:17 AM
4/28/2011 7:31:26 AM
7.2.2. Power On
Running
4/28/2011 7:31:35 AM
6%
7.2.3. Wait for VMware Tools
8. Power On Priority 4 VMs
9. Power On Priority 5 VMs

容灾演练完成：测试成功

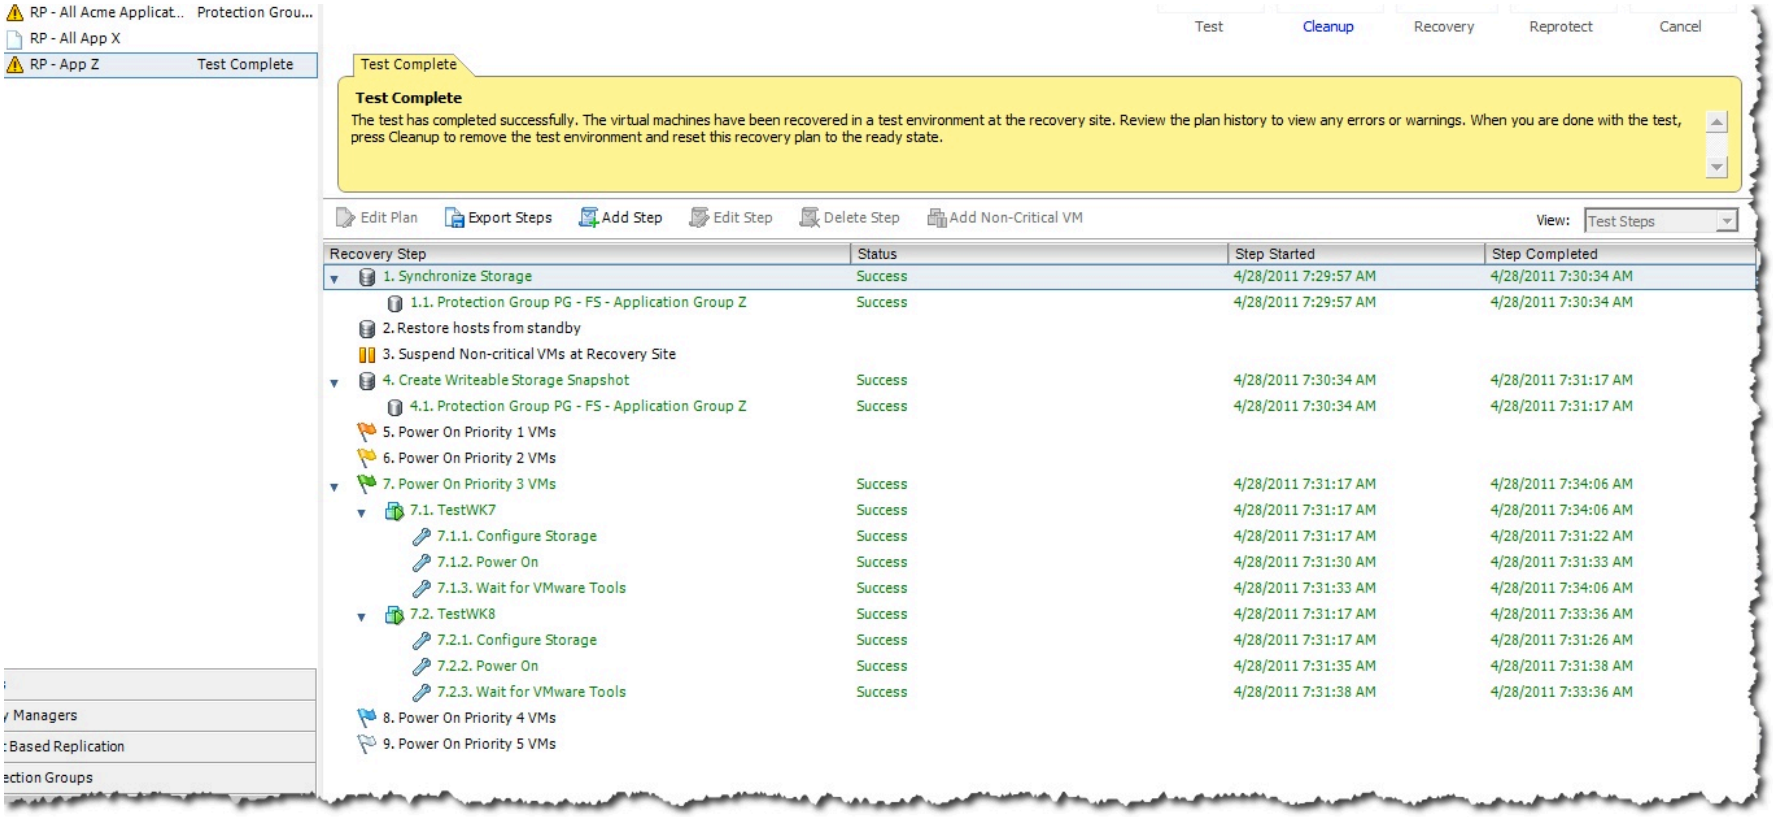

VM's are ready to be used now

vmware

清楚Test Recovery

- 存储层：删除快照
- 网络层：删除临时的VLAN标签，恢复容灾站点的VLAN标签

Disaster Recovery：两种方式

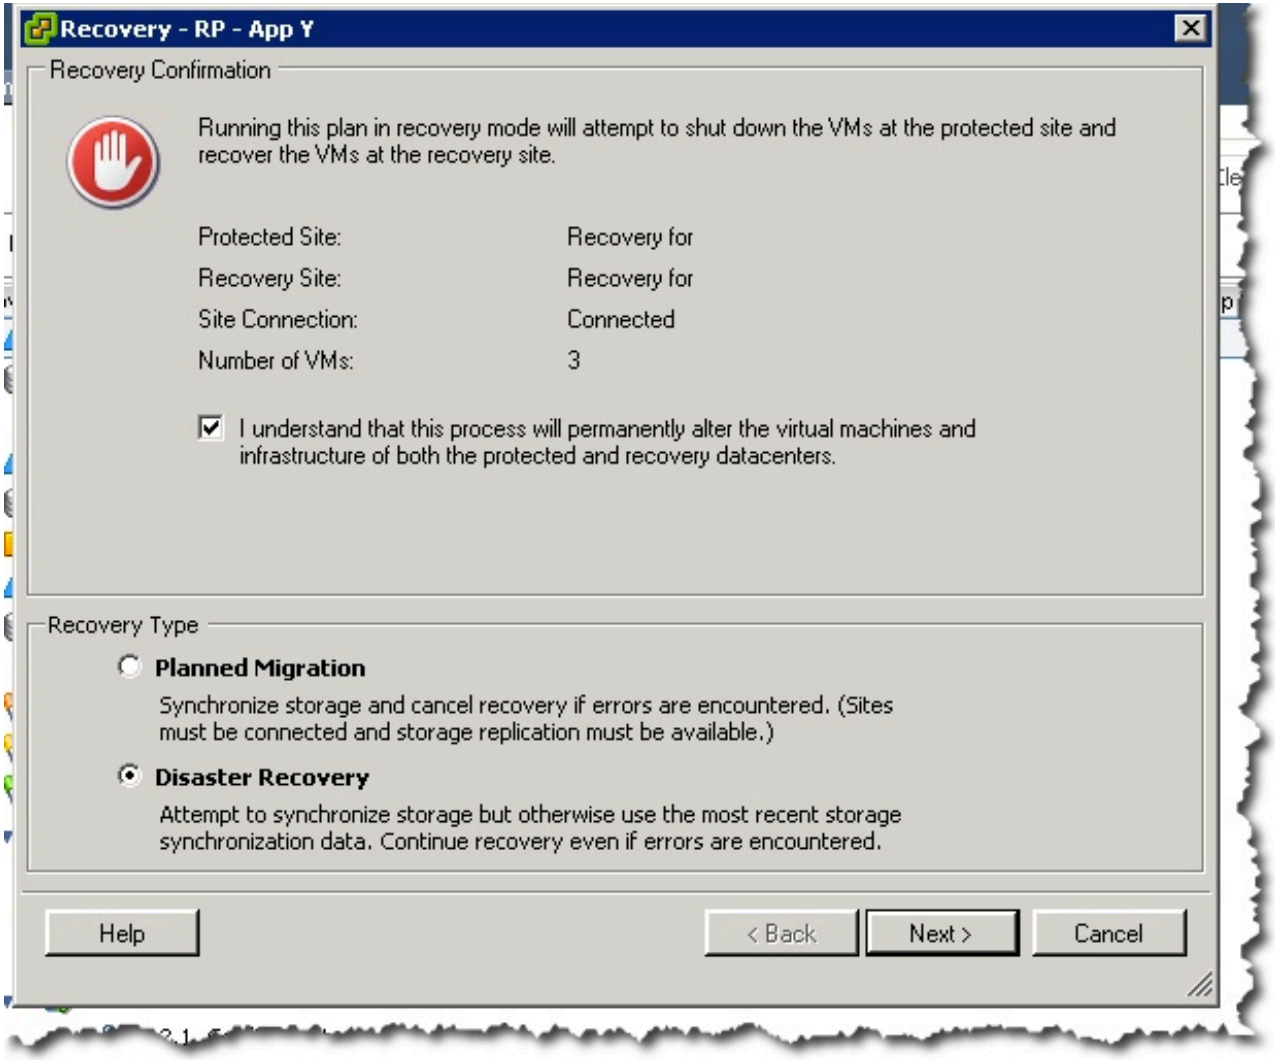

Will shutdown protected VM's, and than synchronize them IF it can!

Will NOT stop on errors and let you fix them!

IP 地址自定义

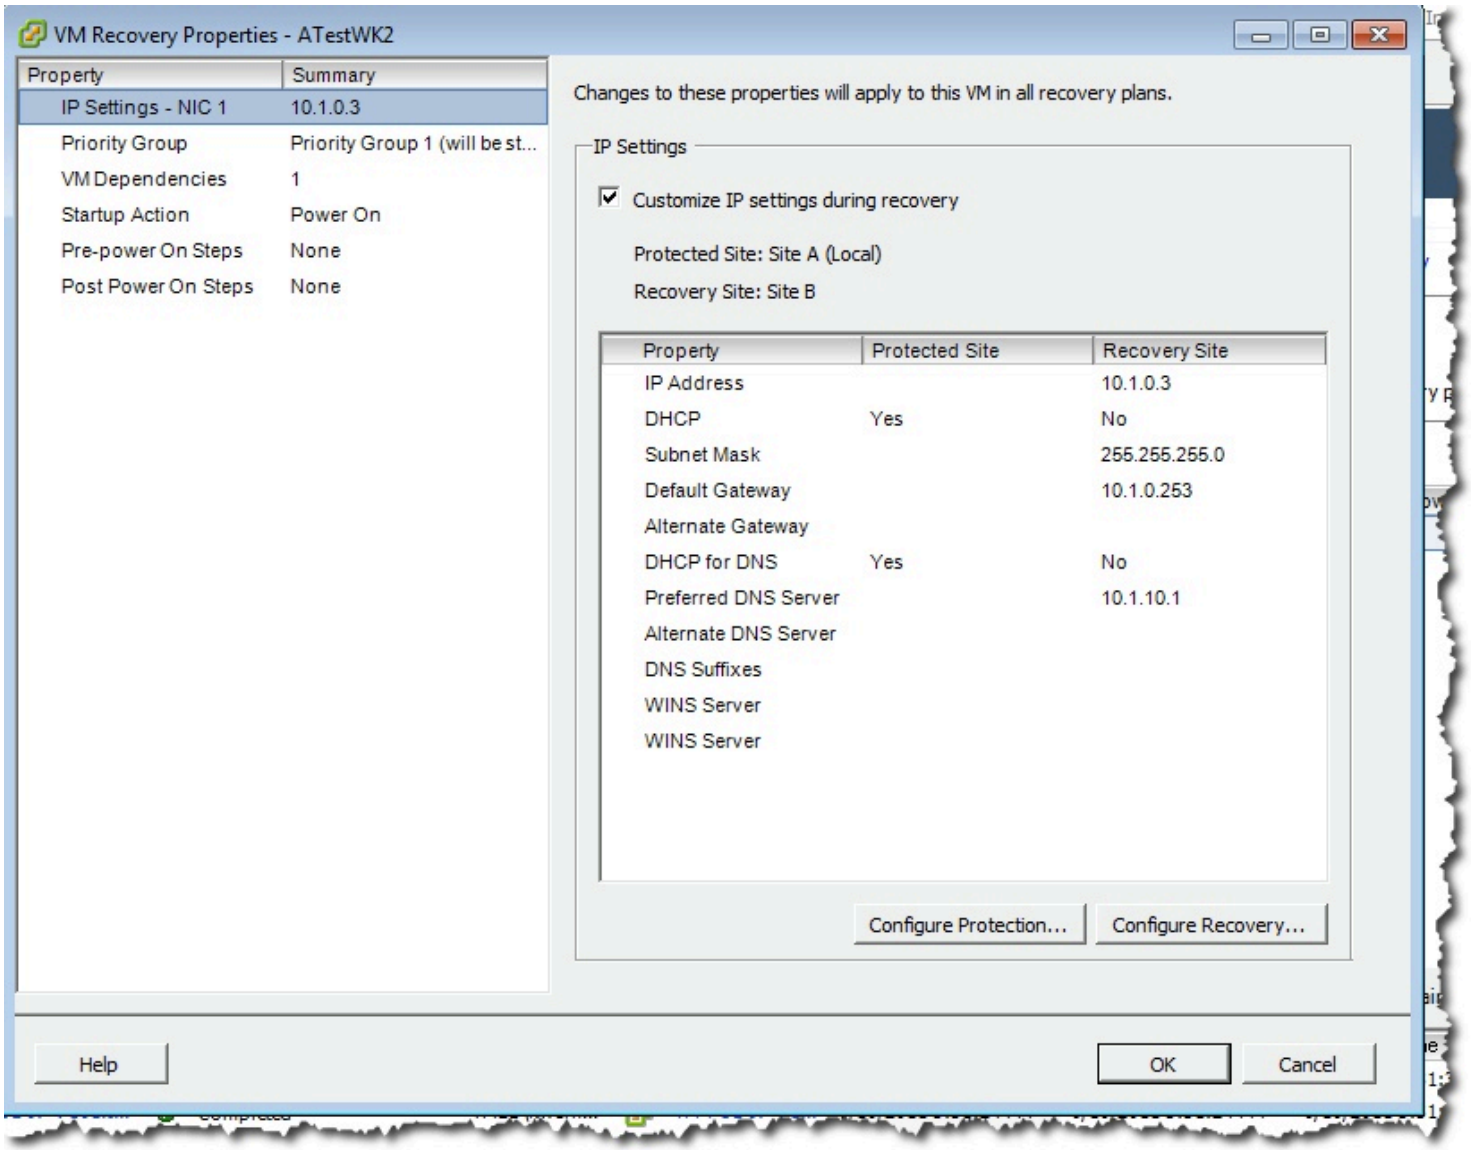

vmware

VM的关联性管理

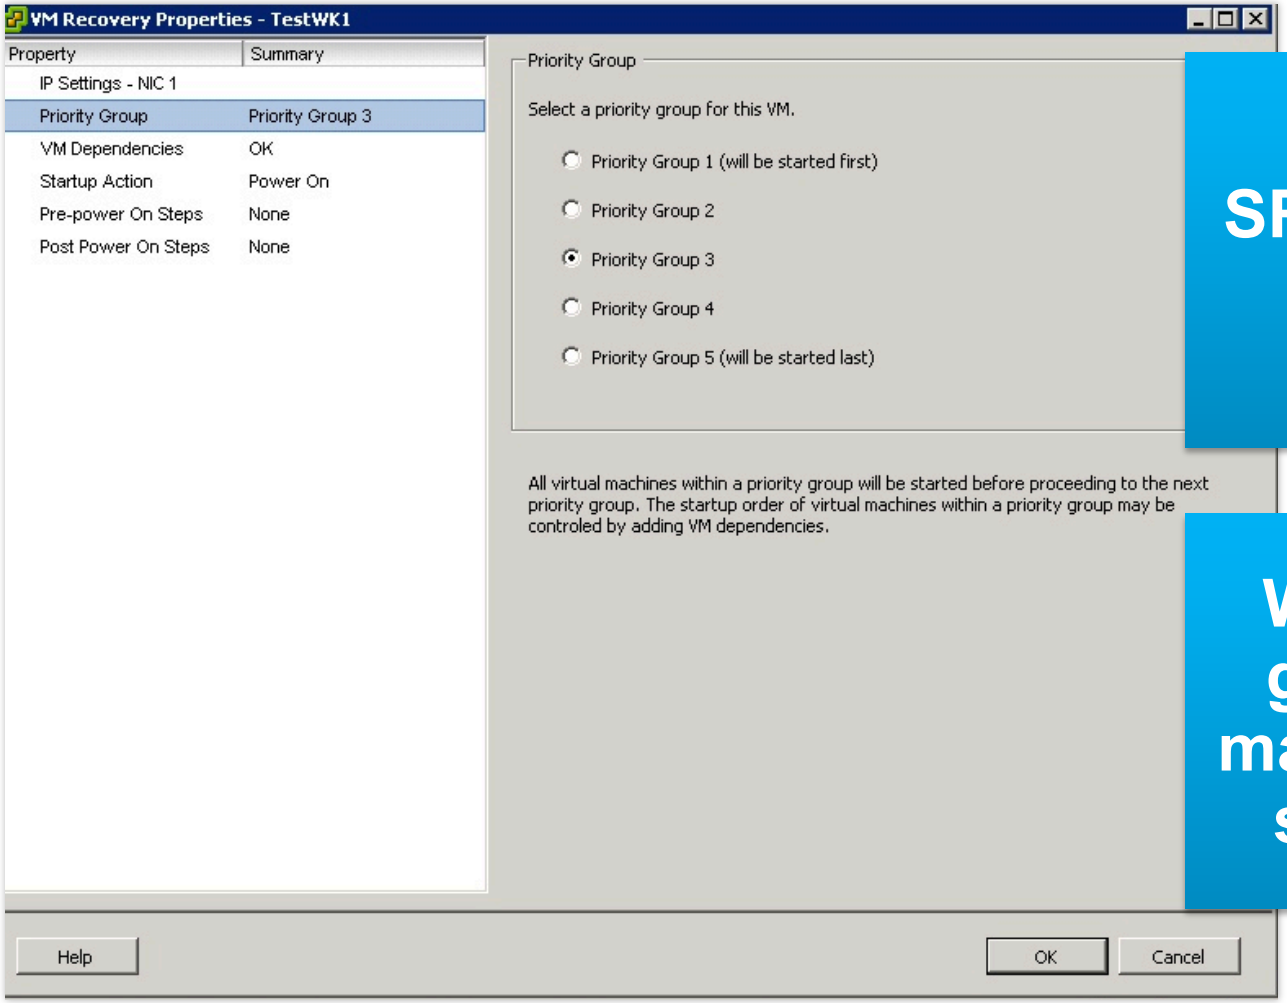

SRM has 5 priority levels

Within a priority group all virtual machines will start simultaneously

RTO: 恢复时间

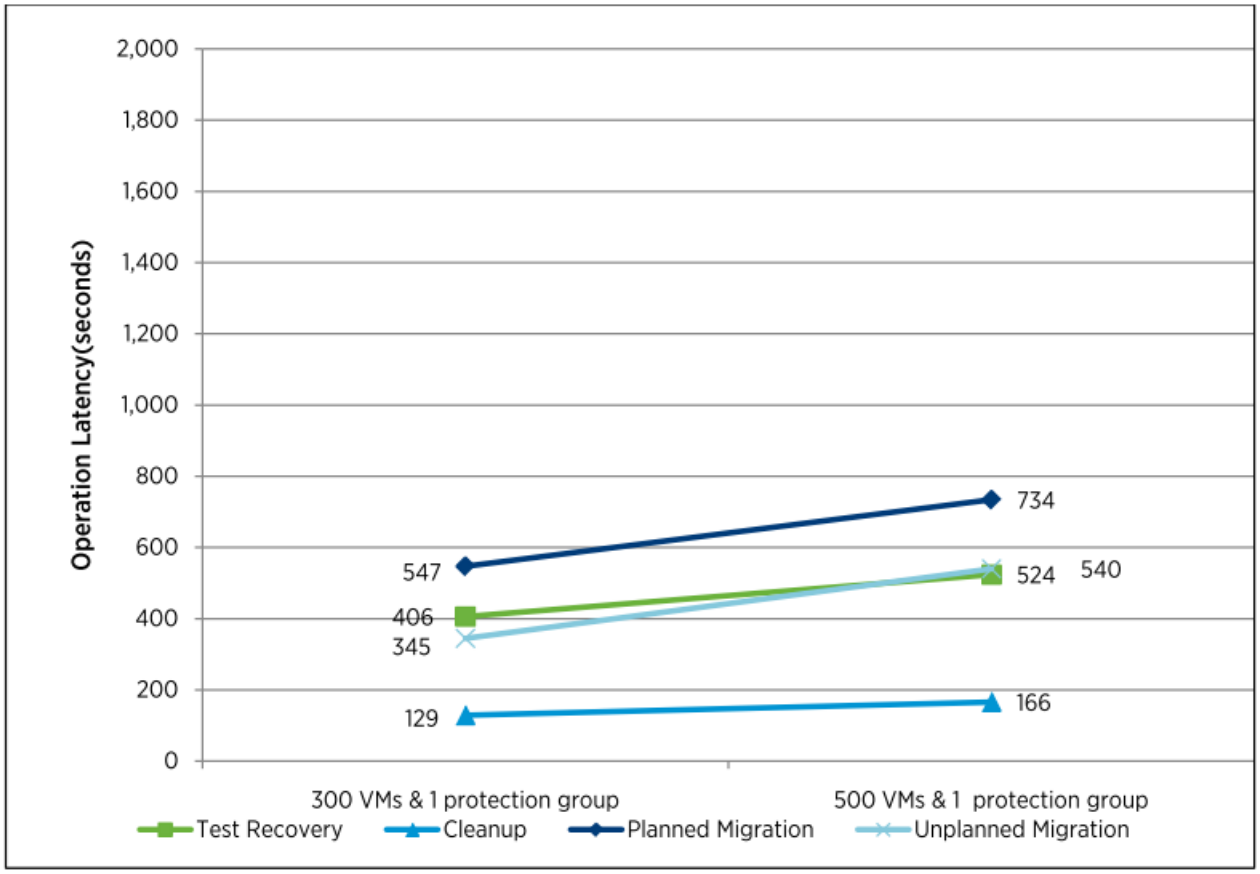

Figure 5. vSphere replication trending experiments: scaling with virtual machines

500个VM:

- 计划外容灾:

540s，全部切换启动

- 计划内容灾:

734s，全部切换

容灾是否一定需要大二层技术？LAN Extension

- SRM解决方案可以配置不用的业务系统VM在不同的站点使用的IP，所以和大二层技术没有因果关系
- 大二层技术必须配合路由优化技术使用
- 用户端访问数据中心可以通过域名的方式访问，可以通过三层方案实现DR
- 如果不使用域名访问业务，建议使用大二层+路由优化技术，或者发生容灾切换的时候修改业务访问地址

利用SRM实现数据中心“双活”方案特点

1. 实现两个数据中心同时提供服务，“双活”
2. 工作负载冷迁移，VM需要reboot
3. 无需两地同步存储投资低
4. 可以实现LAN Extenstion, 也可以做三层的方式，主要看用户的业务访问方式（IP/域名）
5. 对数据中心之间的网络环境要求较低,无延迟等要求
6. 在恢复站点可以实现定期的容灾演练

一个典型的VMware业务连续性解决方案

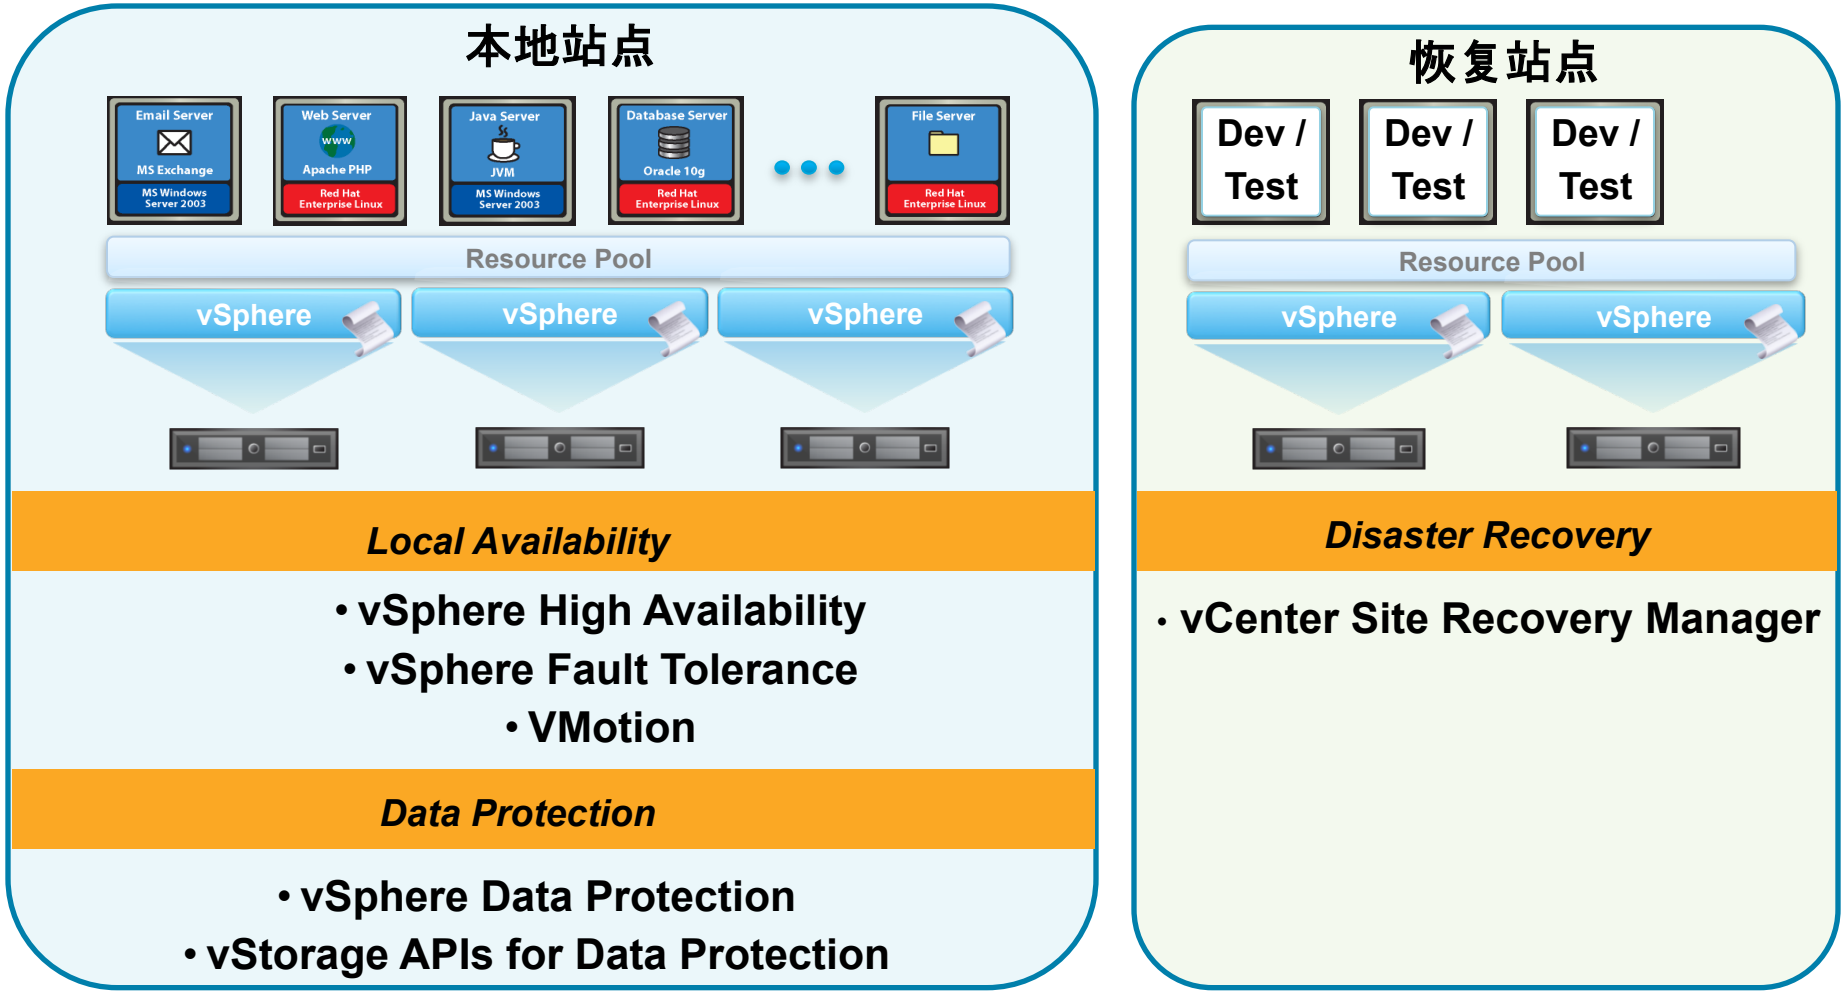

其他双活技术：VMware Metro Storage Cluster 数据中心双活方案

方案描述

跨数据中心HA/DRS

- 利用VMware HA，DRS Affinity 策略实现VM/主机绑定
- 需要分布式同步镜像存储
- 需要同一个二层网络
- 一个vCenter

用途

- 非计划性站点故障
- 存储故障
- 充分利用不同数据中心的计算资源

好处

- 实现跨数据中心工作负载的自动保护(Disaster Avoidance)
- 高可用的效果如同本地集群(e.g. vMotion, DRS)
- 跨数据中心工作负载高可用和动态资源调整

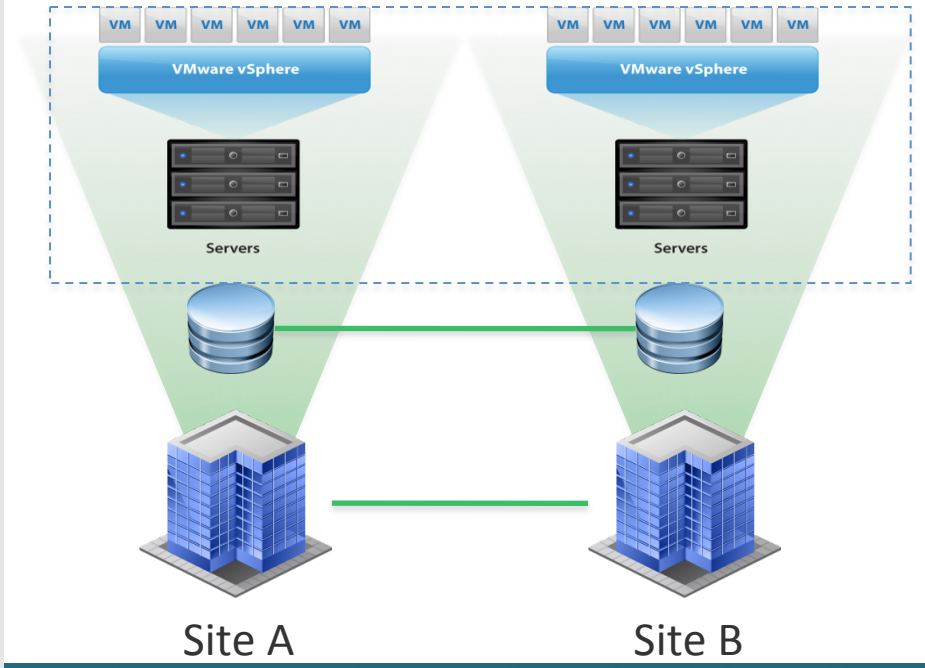

HA/DRS 集群

远程复制存储卷

二层网络扩展

vSphere Metro Storage Cluster 和长距离vMotion

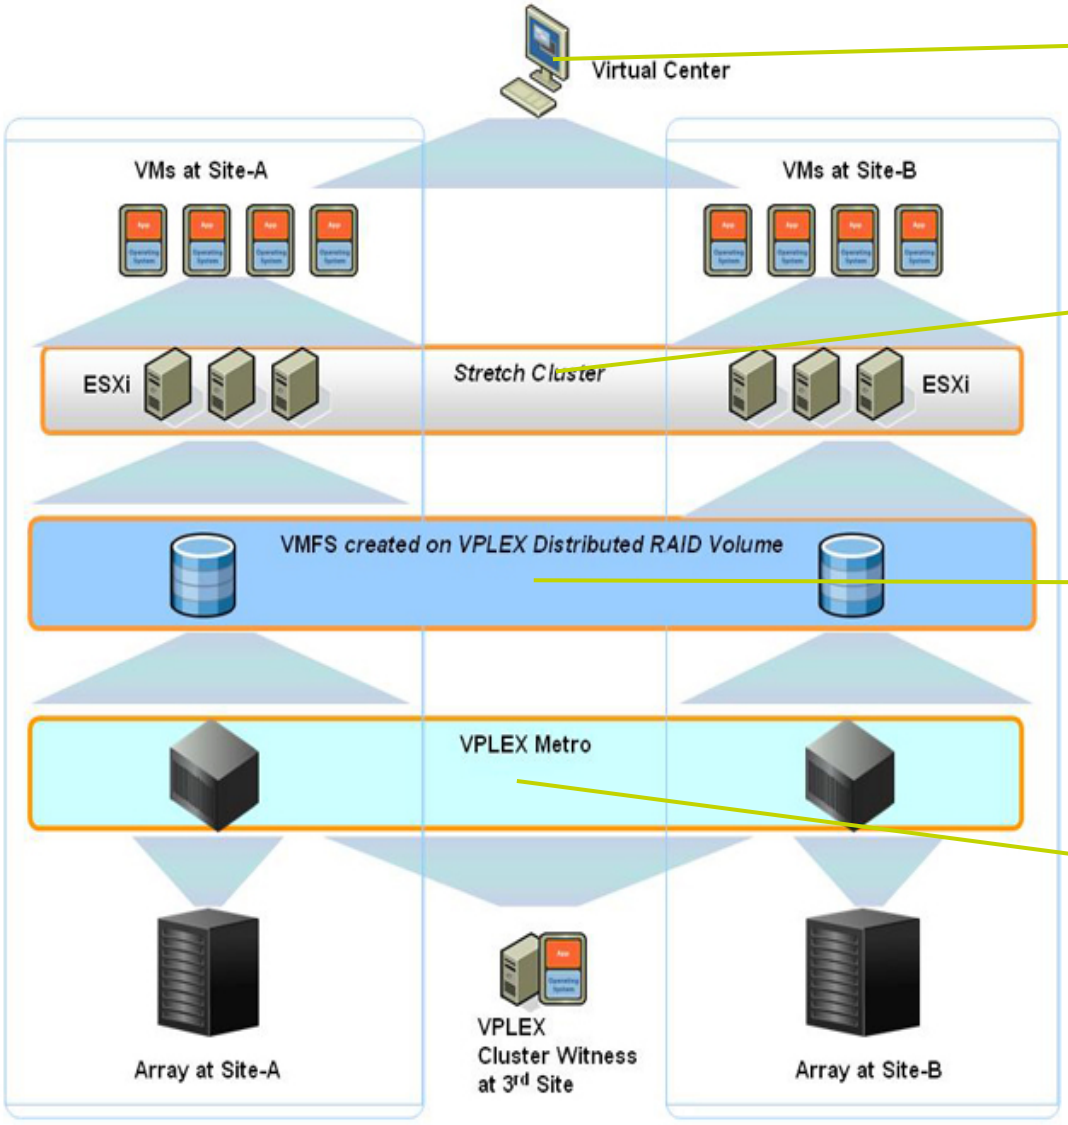

两数据中心ESXi主机由一套vCenter管理

VC Heartbeat 做vCenter保护

两数据中心ESXi主机(vMotion, IP存储)需要在同一个二层(IP)网段，<100KM

两数据中心之间须采用同步镜像存储，支持FC 或者iSCSI

两数据中心之间存储网络互联，支持FC 或者iSCSI，一般通过是光纤或者DWDM互联

“Uniform Access” Stretched Storage Model

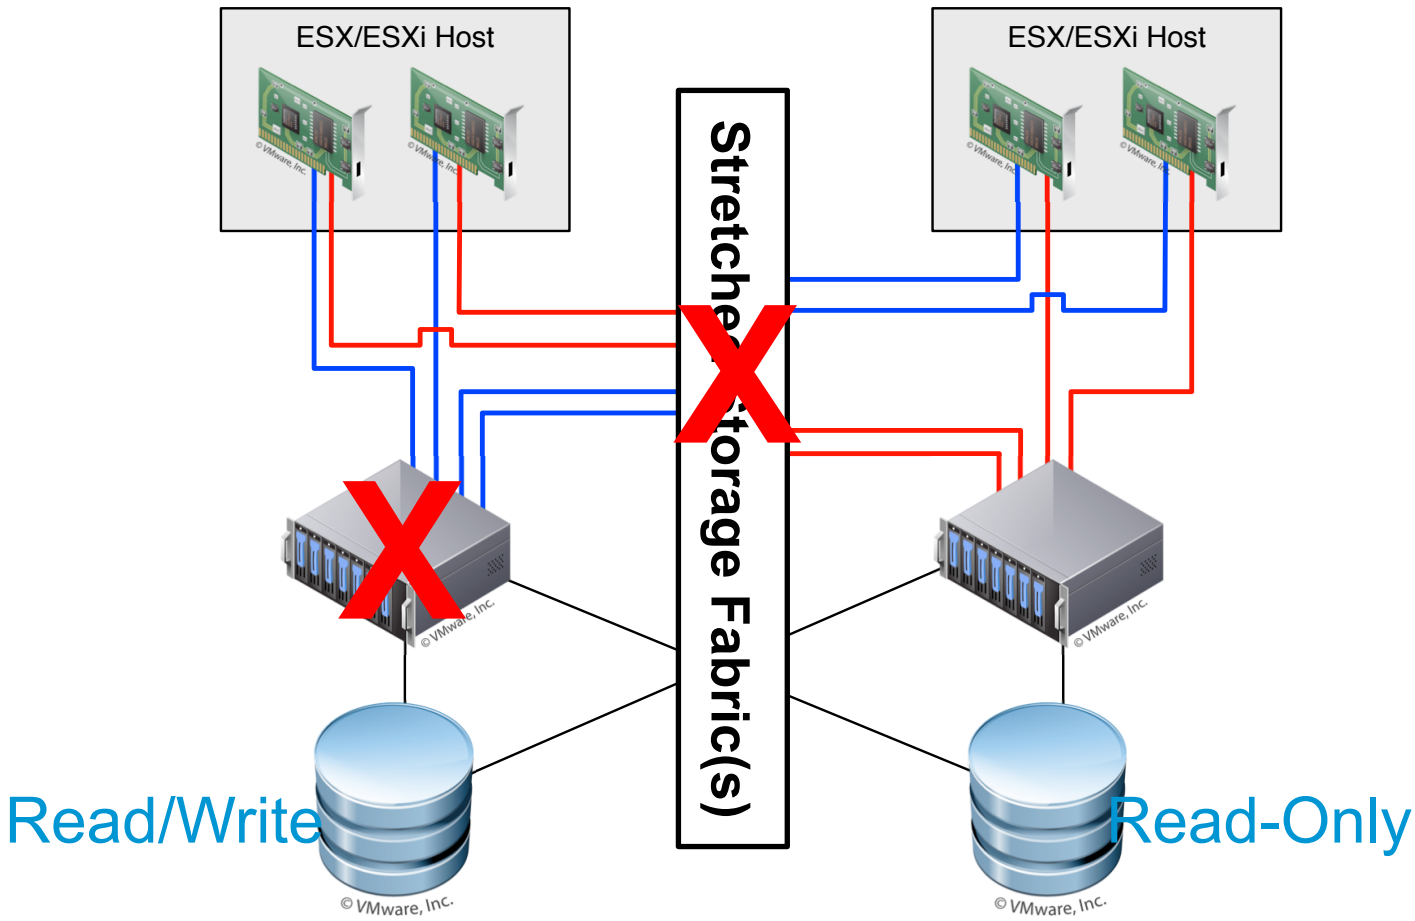

“Non-Uniform Access” Stretched Storage Model

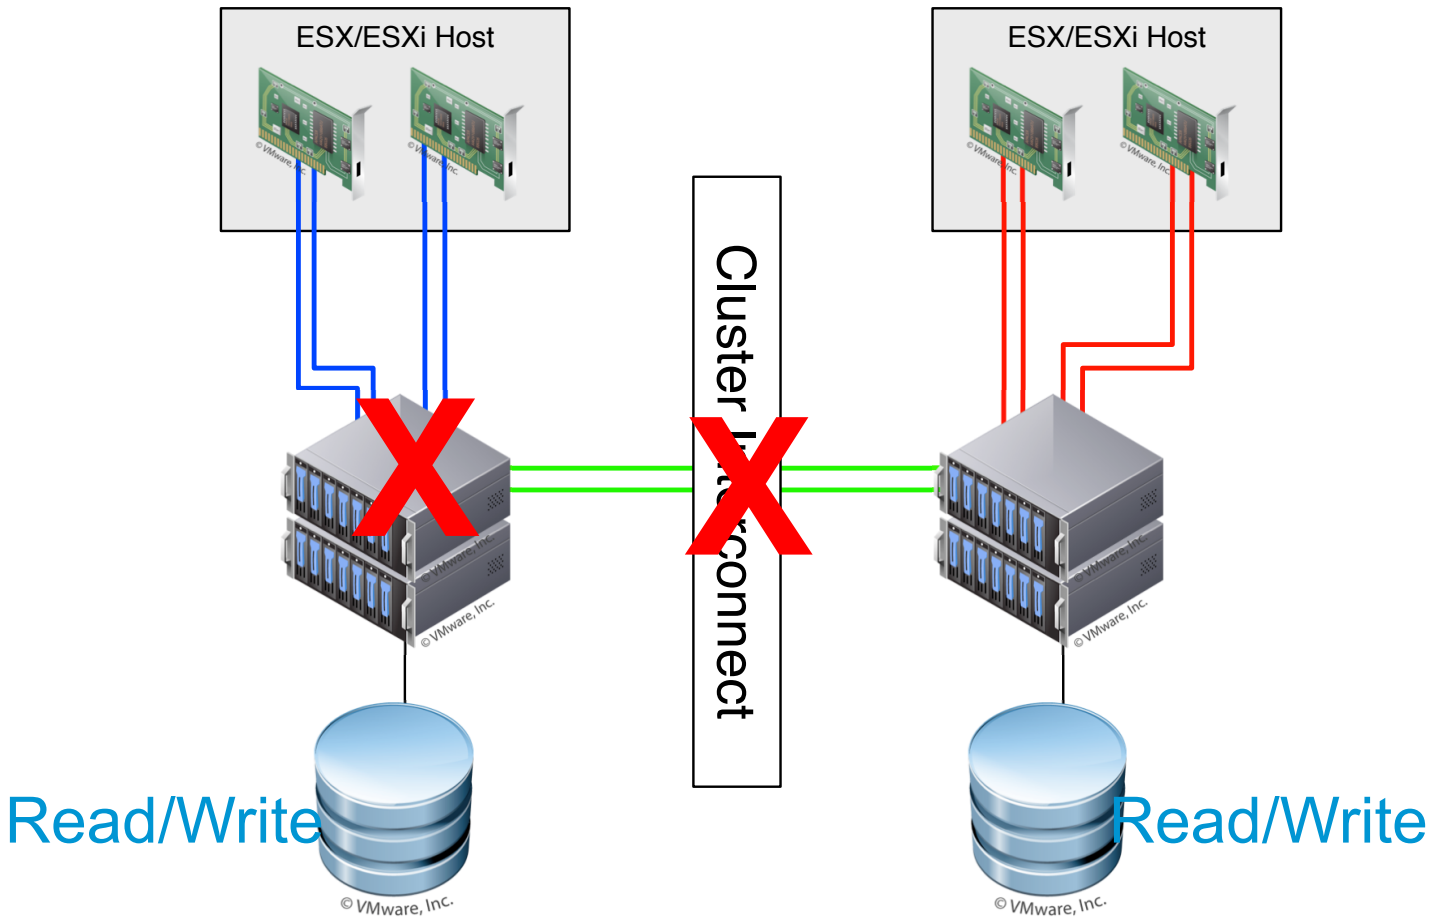

利用vSMC实现数据中心“双活”方案特点

1. 实现两个数据中心同时提供服务，“双活”
2. 工作负载热迁移，VM不需要停机
3. 两地同步存储投资高，目前支持6-7种存储
4. 必须实现LAN Extenstion
5. 对数据中心之间的存储网络环境和以太网网络环境要求较高（以太网要求RTT 延迟<10ms; 存储网各个厂商的设备要求不同，一般3-5ms的RTT延迟）
6. 数据中心广域网出入流量优化必须做！
7. 这种双活技术实际上是一种HA+DRS技术