

[概要](#)

[简介](#)

[开始之前](#)

[VSAN 限制](#)

[一、网络设计](#)

[二、存储设计](#)

[2.1 磁盘组](#)

[2.2 缓存盘设计](#)

[2.2.1 读缓存](#)

[2.2.2 写缓存](#)

[2.2.3 PCIE闪存盘 和 SSD的选择](#)

[2.2.4 闪存寿命](#)

[2.2.5 快照开销](#)

[2.3 磁盘\(容量层\)设计](#)

[2.3.1 磁盘总容量设计](#)

[2.3.2 文件系统格式开销](#)

[2.4 I/O 控制器设计](#)

[三、存储策略](#)

[3.1 对象和组件](#)

[3.2 存储策略中的设置](#)

[3.3 虚拟机主页\(VM namespace\)及交换文件\(Swap\)考量](#)

[3.4 快照](#)

[3.5 动态调整策略](#)

[3.6 有可用空间不代表可以置备出虚拟机](#)

[四、主机设计](#)

[4.1 CPU 设计](#)

[4.2 内存设计](#)

[4.3 启动设备设计](#)

[4.4 尽量不要使用只提供计算资源的主机](#)

[4.5 刀片服务器及外置磁盘柜支持](#)

[4.6 电源管理](#)

[五、集群设计](#)

[5.1 2/3 节点设计](#)

[5.2 vSphere HA](#)

[5.3 故障域](#)

[5.4 去重和压缩设计](#)

[六、确定工作负载是否适合使用VSAN](#)

[七、使用 View planner 进行VSAN规划](#)

[八、VMware infrastructure Planner - VIP](#)

[九、设计案例一](#)

[十、设计案例二](#)

[十一、下面是一些网站链接：](#)

[VMware Ready Nodes](#)

[VMware 兼容性指南](#)

[博客](#)

[文档库](#)

[VMware 支持](#)

[日志文件](#)

[更多阅读](#)

此文章假设读者已有基础VSAN知识或实施经验。

写了一半，感觉完全是在写VSAN考试大纲...

花了两个月时间学习并总结这个文档，期间VSAN项目中也遇到不少问题，学习完这个文档才发现VSAN并没有想象中的那么简单，所以非常建议做VSAN设计的人员能学习下此文章(或原文档)，避免规划出现问题。

概要

此文章遵照[原参考文档](#)的目录，着重介绍了存储、存储策略、主机和集群的设计。

- 其中存储部分包括磁盘组设计、缓存盘(SSD, nvme, PCIE闪存盘)和HDD (SAS, SATA, NL-SAS) 选择、VSAN文件系统的开销、RAID卡的设计等。
- 存储策略着重介绍了当前VSAN 6.2的所有策略功能及对物理存储使用情况的介绍，以及默认VSAN中虚拟机目录、交换文件、快照等的存储占用情况。
- 主机着重介绍VSAN下启动设备的选择、刀片服务器支持、外置磁盘柜支持、电源管理等。
- 集群着重介绍2/3 VSAN节点的使用、HA、故障域及去重、压缩
- 最后为两个较为详细的配置案例，其中纠正了原文档中的一些小错误

简介

Virtual SAN 是一个集成在Hypervisor中，与VMware vsphere高度集成的软件定义存储产品。VSAN可以将一个vSphere cluster集群中主机上的直连硬盘整合起来，创建出一个分布式共享存储。它使用策略(文中会有策略的详细描述)驱动，简化了存储的置备和管理。

VSAN 当前有两种配置选项，混合配置(hybrid)及全闪配置(all-flash)；混合配置下一个磁盘组使用一个SSD做读写缓存(容量7/3划分)，机械硬盘存储数据。全闪模式下使用寿命高的SSD作为写缓存盘(100%空间用于写缓存，最大只能使用600G空间)，使用读性能较好、寿命不高但价格低廉的SSD作为数据存储盘。

解读：

每个VSAN存储对应一个集群，一一对应，一个集群中所有主机都会开启VSAN功能（需要手动配置VSAN网络），一个集群只能有一个VSAN，所有硬盘都在这一个VSAN中，VSAN中的存储不能直接供其他集群直接使用，需要通过创建NAS存储的方式对外提供存储服务。

VSAN 基于 storage policies，通过策略可以定义每个虚机副本数(以此决定主机/硬盘最大故障数)，还有资源预留、条带等很多参数设置。

开始之前

- 请通过VMware兼容性指南认真检查所使用的服务器、RAID卡、PCIE flash、SSD、机械硬盘是否

在兼容列表内。

- 请确保使用的软件、驱动及固件在兼容列表内，兼容列表内还会提供最佳的驱动、固件版本号。
- 在执行全新部署前，确保vSphere安装了所有补丁程序。可以考虑对已有部署进行升级。
- 建议群集中所有主机使用相同的配置。
- VSAN 可以通过添加硬盘实现纵向扩容，添加主机实现横向扩容。在进行扩容时要考虑到缓存/容量盘的容量比。**更换SSD硬盘会导致一整台主机上的所有数据重建**，所以前期最好规划好SSD容量。而HDD添加/更换影响的只是单个盘上的数据。
- VSAN最少需要三台ESXi主机或者两个ESXi主机加一个VSAN见证。当有主机故障时，VSAN会自动尝试修复虚拟机的文件，一个对象至少两份数据一个见证共三个组件，因此三台主机的VSAN环境如果有一台ESXi故障，那么其中损坏的组件是无法被恢复的。主机处于维护模式时，为保证虚拟机数据正常，需要将维护模式主机上的数据迁移到其他可用ESXI上，三台主机VSAN环境也不能实现这点。
- VSAN 通过策略实现虚拟机数据保护，其中一个策略为FTT(允许的故障数)，此策略控制虚拟机数据存放的副本数。在进行VSAN设计时，需要根据虚拟机冗余程度确定整体容量。

VSAN 限制

- VSAN最少需要三台ESXi主机，最大支持64台主机
- VSAN 6.0 每台主机上可以存放200台虚拟机，整个集群最大支持6400个虚拟机。
- VSAN 6.0 每个集群最大可以通过HA保护6400个虚拟机
- 每台VSAN主机最大可有5个磁盘组，每个磁盘组最大可以有7个容量磁盘，一个缓存磁盘
- 虚拟机在VSAN上以对象的形式存在，例如一个VMDK文件就是一个对象，一个快照文件就是一个对象，VM目录是一个对象。这每一个对象都由多个组件(component)组成，组件的数量由存储策略决定，例如FTT=1时，会有两份component。VSAN 5.5 最大支持3000各组件。VSAN 6.0每台主机最大支持9000个组件。
- 每个对象的最大条带数是12，最小是1，但是有些情况下存储策略中没有设置条带时，VSAN也会自动设置一个对象的条带。原因有多种，例如VSAN规定一个组件最大为255G，如果一个对象(vmdk)大于255G时，VSAN自动将这个对象拆成多个组件。因此当有一个2T的vmdk文件时，它很可能会由8个或者更多个组件组成RAID-0(FTT=1时，一个vmdk会包含一个witness，两个RAID-0)。在设计时，需要根据设置的条带数确定硬盘数够不够。
- FTT 最大为3， 默认存储策略FTT=1
- FlashReadCacheReservation 最大为100%，表示一定会给vm预留匹配大小的缓存，此策略只适用于混合模式VSAN
- ObjectSpaceReservation 最大100%，表示虚拟机会被置备为厚模式。
- VSAN 6.0最大VMDK支持64T，但是每个对象依然有组件大小255G的限制

- 混合模式下网络支持1G和10G，当使用1G时需要独占网卡，10G时可以让VSAN流量和其他流量混跑。全闪存只支持10G及以上链路，也可以让VSAN流量和其他流量混跑，但是建议使用Qos限制每种流量的带宽占用。
- VSAN不支持多链路负载均衡，多链路只能实现高可用（即使使用了LACP）。
- 使用Jumbo Frame可以减少CPU负担改善带宽，但是效果很小，因为vSphere有TSO和LRO（更多信息请看[KB2055140](#)）提供类似的功能。另外不建议在Jumbo Frame支持不好的交换机上开启（例如开启后交换机CPU利用过高）
- 全闪模式下建议最好开启Jumbo Frame
- 交换机必须支持组播功能，建议采用高端的企业级交换机
- 可以使用NIOC(Network I/O control)进行Qos，对VSAN流量进行带宽保证或者限制。此功能仅支持VDS。

一、网络设计

另起文章：[VSAN 6.2 网络设计](#)

一句话总结：保持一个VSAN集群在一个二层网络内，之间使用全线速交换机(交换机堆叠)连接。

二、存储设计

2.1 磁盘组

关键词：磁盘组数量及容量，同时考虑未来纵向扩展(加磁盘组)

磁盘组可以看做VSAN的容器，一个磁盘组至少包含一个SSD和一个HDD。如果希望提高缓存和容量比，可以在一个主机上创建多个磁盘组，多个磁盘组可以提高IOPS，减少故障域(即，在相同缓存容量比下，单个磁盘组SSD一定是大容量，IOPS有上限，且当此SSD损坏时，相当于整个主机故障。多个磁盘组用多个SSD，IOPS有可能会更高，且随意一个SSD故障，只影响所在磁盘组的数据)。

2.2 缓存盘设计

关键词：容量(考虑未来使用及未来纵向扩容)，寿命

缓存大小应该根据工作中热点数据的量决定，但是这个值不好统计，可能随着时间变化而不同，VMware建议缓存/容量比至少为1:10（混合模式及全闪模式均适用，且计算方法一样）。

缓存的计算应该不考虑FTT，按照实际使用容量计算，例如：1000台虚拟机，每台瘦置备100G空间，但是平均使用空间为20GB，那么总使用容量为 $1000 \times 20G = 20T$ ，按照1:10的比例，总闪存盘大小为2TB，如果是4个节点VSAN，则每个主机可能要安装600G的SSD。但是，考虑到未来增长，可能VM实际占用空间会增加到30G、40G，这样缓存盘就需要更大的了，前期一定要做好一定量的预留。

全闪存VSAN下，每个磁盘组的缓存盘最大只能使用600G(All-flash自身限制，因此容量过大就是浪费)，全被作为写缓存。写缓存可以减少容量层SSD的写操作，延长这些磁盘的寿命。在全闪模式下，一定要注意flash(缓存)层磁盘的寿命！

2.2.1 读缓存

读缓存仅在混合模式有效。VSAN将vm最近读取的数据块保存在闪存中，减少读取延迟，提高读取效率。

当有VM有多个副本时，VSAN均衡地从每个副本读取数据块放在SSD中。

如果需要读取的数据块不在一个SSD中，VSAN directory service会在其他主机的SSD中搜索此块，如果最终未找到，则出现一个read cache miss，数据直接从磁盘去读取。

2.2.2 写缓存

写缓存在混合模式和全闪存模式中都存在，可以增加性能，提高全闪存时容量层SSD的寿命。

当OS中有应用发起写入请求时，此请求会被复制到存有此对象的主机的SSD上，因为SSD是非易失性存储，所以在一个主机故障时不会引起数据丢失。

混合配置下，SSD上的数据会定期往容量层去写。

而全闪配置下，所有写操作先经过SSD，但是并不会定期往容量层回写数据，只有当SSD上数据不再是热点数据(不再变化)时才会往容量层写，由此提高容量层SSD寿命。

2.2.3 PCIE闪存盘 和 SSD的选择

关键词：性能需求，预算，容量

在计划使用PCIE闪存盘(nvme)时需要从价格、性能及容量三个方面考虑：

SSD 使用SATA接口，因此目前受限于SATA的6Gb/s接口(虽然SAS口可以达到12Gb/s，但是兼容SATA也就只有6Gb/s)。PCIE的闪存盘使用PCIE接口，接口类型为3.x时最大可达到32GB/s的带宽(PCIE闪存盘可以使用16个通道传输数据，每个通道单向有效带宽为1GB/s，双向2GB/s，更多详情请查看[PCI-E百科](#), [Wiki](#))。

使用PCIE闪存盘也可以减少存储控制器的负载，因此有助于提高VSAN性能。

NVMe 在 VSAN6.1 开始受支持，NVMe相比SSD 延迟低，速度快，但是价格也更高。NVMe体积也一般比SSD大，容量可以做到更大，现在有6.4T的NVMe，而SSD才是4T（当然这一数据随着闪存发展会变化很快）。

PCIE 选择时也要注意服务器PCIE可用插槽位，当服务器磁盘组设计过多，加上NIC、HBA卡等，服务器自身的PCIE插槽可能不够用。

但如果使用SSD，SSD会占用HDD的槽位，如果服务器数量有限，但要求大容量，则可能选择nvme会好些。

2.2.4 闪存寿命

在VSAN6.0之后，使用TBW(TB字节写入)来计算寿命，而在此之前使用DWPD(每日整盘擦写的次数)来算寿命。

当使用TBW替代DWPD时，VMware允许在容量层使用DWPD不大，但是容量较大的盘替代DWPD较大，但是容量小的盘。

举个例子：一块200G的盘DWPD为10的盘，可以用一块400G，DWPD为5的盘代替，因为他们TBW是相等的。

而如果没有引入TBW的概念，VSAN规定SSD的DWPD要达到10，DWPD=5的盘则不会通过VSAN认证。

对于全闪存VSAN，VSAN要求缓存盘的TBW要达到4/每天，按照5年的使用寿命，总TBW为7300 (Intel数据中心级硬盘S3610可以达到10PBW)。容量层的SSD则可以根据需求使用寿命较低的盘。

2.2.5 快照开销

根据[这篇文章](#)，vSphere建议快照只保留24-72小时，最多32个快照，为了保证性能建议只留2-3个快照。

VSAN 6.0混合模式下，创建多个活动的快照可能很快将缓存耗尽，影响性能。VMware建议在快照使用频繁的场景下，将10%的缓存调整为15%。

2.3 磁盘(容量层)设计

关键词：类型、容量、数量、速度、价格

VSAN兼容列表里，有三种磁盘可以做容量层：SAS、NL-SAS、SATA盘。

按照最大容量对比：SATA 可达4T，NL-SAS 可达2T，SAS最大1.2T。

价格对比：SAS > NL-SAS > SATA

存储策略中有一项：**条带宽度**，如果对此项进行了设置，则必须要考虑磁盘的数量。条带宽度为1时，一个大小10G的object会产生一个component，放在一个磁盘上。如果条带宽度为2，则这一个object可能被分成两个5G的component放在两个不同的磁盘上；

举一个极限的例子：三主机VSAN，每个主机一个磁盘组，每磁盘组一个SSD一个HDD，如果将条带宽度设置为2，则此虚拟机不能被创建，因为VSAN无法将虚拟机的一个对象拆成两个组件(组成逻辑上的RAID0)存放在不同磁盘中，磁盘数量不够。

VSAN最大支持64TB的虚拟机，如果环境中存在大虚拟机时，要考虑VSAN能不能存的下这个虚拟机，以一个三节点VSAN为例：剩余空间200T，按理是可以存下62T的虚拟机(只占用 $62 \times 2 = 124$ T空间)，但是主机A剩余50T，主机B 50T，主机C 100T，这个VSAN环境是不能创建62T的虚拟机。

VSAN可以达到90%的读命中率，意味着有10%的读操作需要从HDD中去读取，所以HDD的数量多了，可以提高读操作的IO性能。

设计考虑：如果考虑到性能，建议优先采用10K以上的SAS盘。总容量不变的情况下，多个小容量HDD会比几个大容量组成的VSAN环境有更好的性能。一个环境最好使用相同型号的HDD！

2.3.1 磁盘总容量设计

关键词：30% 容量冗余

VSAN 总容量一般由需要的空间和FTT决定。当客户需要100T实际空间时，当FTT=1，那么裸磁盘总容量则为200T。

但是！还需要考虑到冗余，即当一台主机挂掉后，原来存在于这台主机上的数据需要能够在其他主机上恢复(rebuild或是resync)。

FTT=1时，就有很大风险，其他任意一个HDD或主机损坏，VSAN则会出现数据丢失。

VSAN 规定，当磁盘使用率达到80%的时候，会自动进行重平衡(Rebalance)操作，将磁盘上一部分数据转移到其他磁盘上，维持集群内磁盘使用率均衡的状态。VMware建议我们的总空间使用率比80%再低10%，也就是70%。当然不一定这样严格，只是要知道总容量使用多于80%的时候，会有Rebalance 操作，会对性能造成一定影响。

所以按照开头的例子，实际裸容量要设计为285T左右。

2.3.2 文件系统格式开销

VSAN有自己的文件系统格式，到目前6.2使用v3版本，v3版本的开销为1%+duplication metadata，而Duplication metadata随着数据类型而变动很大。VMware依然建议预留30%空间。

Virtual SAN version	Format Type	On-disk version	Overhead
5.5	VMFS-L	v1	750MB per disk
6.0	VMFS-L	v1	750MB per disk
6.0	VSAN-FS	v2	1% of physical disk capacity
6.2	VSAN-FS	v3	1% + deduplication metadata

2.4 I/O 控制器设计

关键词：每I/O controller支持的磁盘数、数量(考虑到单点故障及性能)、队列深度、直通模式

首先，所选择的I/O controller一定要在VSAN兼容列表内

VSAN支持多IO controller的ESXi主机，每个主机上最多35块硬盘(5个磁盘组，每个磁盘组7个hdd)。

有些控制器支持挂16个硬盘，一台主机安装两个这样的控制器能支持32个硬盘，几乎达到最大磁盘限制。

有些控制器只有8个接口，那么就需要4~5个控制器才能满足35个盘。

当主机有单个控制器，即使配置了多个磁盘组，单个控制器会引起单点故障。多个控制器则可以避免这一点，同时也会提高性能。

控制器队列深度，如果队列深度过小，在VSAN重同步数据的时候可能会影响性能。建议选择队列深度至少为256的，越大越好。

VSAN 支持**RAID0**和**直通硬盘**。推荐使用直通 (JBOD) 模式，使用RAID0时需要做很多额外的操作，例如virtual group创建，在更换硬盘时也需要相同的操作。

控制器最好没有缓存，因为VSAN有自己的缓存机制，所以无需在控制器上设置缓存，如果有些RAID卡必须设置缓存，那么请设置成100% read。

高级特性：有些控制器有高级特性，例如HP有个叫Smart Path的功能(LSI的fast path)用来做加速。VMware建议关掉这些高级功能。

三、存储策略

3.1 对象和组件

一个虚拟机由多个对象组成，例如一个VM主目录，vmdk文件，swap文件，快照文件。

在VSAN 5.5中，每个组件会产生 2M 的metadata，在VSAN6.0中，如果使用v2格式，每个组件占用4M空间。但是相比组件，这点开销很小，所以一般不予考虑。

在VSAN 5.5中，如果FTT ≥ 1 ，则每个对象必须有一个仲裁(witness)，仲裁不存储数据，只存储元数据(metadata)，它在故障发生时裁决集群中是否存在满足FTT的数量的组件。5.5的仲裁规则是“**大于50%的组件**”，即要保证一个对象可用，可用组件数必须大于50%。

在VSAN 6.0中，决策方法变了。6.0中每个组件都含有一个投票值(a number of votes)，值 ≥ 1 。然后，规则变为“**大于50%的投票**”做裁决。因此会出现多个组件分布式存储，没有仲裁，但是依然能够保实现容错。但是，通常在6.0中很多对象还是会有仲裁的。

3.2 存储策略中的设置

关键词: 条带数、内存预留、强制置备不要随意使用！

VSAN中有5个必须的策略(前五项):

1. 每个对象的磁盘带数(NumberOfDiskStripesPerObject):

它定义一个VSAN对象的每个副本最少跨越多少个HDD进行存储。实际中VSAN的条带可能会多于策略所定义的数量(原因看前文，每组件大小限制)。

条带会有助于提升某些高 I/O 需求虚拟的性能，但是并不能确保提高性能。VMware建议普通场景下不做设置，保持默认的1，针对特殊性能需求的虚机，可以适量调整大，但是一定要考虑到FTT及主机上硬盘数。

2. 闪存读缓存预留(FlashReadCacheReservation):

之前我们提到建议缓存/容量比为1:10以上，这些缓存是平均地给所有虚拟机来使用。在VSAN中可以通过读缓存预留策略给一个或多个虚拟机预留缓存。(此策略仅对混合模式VSAN有效)

此预留策略是以虚拟机逻辑空间(也就是置备的空间)大小的百分比来定义的(因此如果设置100%预留，则缓存大小就是VM大小，会很浪费)，请慎重使用此策略，仅在读性能明显很差的虚拟机上使用。

风险举例：用户需要10台VM，每台瘦置备200G空间，但是实际占用100G。按照10%的缓存/容量比，用户需要购买100G闪存，其中70G作为读缓存。但是如果用户需要给每个虚拟机强加5%的读缓存预留，那么所有虚拟理论上会被分配到 $5\% \times 200G \times 10 = 100G$ 读缓存，明显会比正常设计的读缓存大。这种情况下反倒会影响虚拟机性能。

3. 允许的故障数(number Of Failures To Tolerate):

一个基本概念：FTT=n，则在VSAN中每个对象会有n+1个副本，需要 $2n+1$ 台主机才能满足这个策略。例如FTT=2，每个对象会有3个副本，至少需要5台主机组成的集群。

FTT最大为3最小为0(但是生产环境不会用0)，当vmdk大于16T时，FTT只能为1。

VSAN 6.0中加入了故障域的概念，允许将几台相同属性的主机(例如使用同一个PDU，在同一个机柜)加入一个故障域中，允许他们同时故障。在此之前每台主机是一个故障域，而现在可以将一组主机视为一个故障域。所以当FTT=1时，至少需要3个故障域(每个故障域至少一台主机)，关于故障域后面有更详细的介绍。

4. 强制置备(Force Provisioning):

强制置备允许VSAN忽略FTT、条带宽度、读缓存预留等策略来创建虚拟机。

如果VSAN当前资源不满足需要创建虚拟机的策略，VSAN会使用极为简单的策略：FTT=0，条带宽度=1，读缓存预留=0来创建这个虚拟机。也就是说这个虚拟机只有一份数据(对象空间预留策略也会被忽略)。

VSAN并不会尽最大程度创建尽可能满足policy的虚机，而是直接创建上述简单策略的虚机。例如FTT=2时，VSAN发现环境无法满足此策略，它不会去创建一个FTT=1的虚拟机，而是直接创建FTT=0的虚机。再如FTT=1，条带宽度=10，VSAN可以满足FTT=1，但是不能满足条带宽度=10，所以VSAN直接创建FTT=0，条带宽度=1的虚机。

当VSAN集群中的资源可以满足虚拟机的policy时，VSAN会立即占用这些资源去满足虚拟机的policy。

在6.0中，VSAN允许在主机进入维护模式(或者移除磁盘，磁盘组)时将数据完整迁移(**Full data evacuation**)。如果某个对象因为强制置备而成不合规的状态，那么完整迁移的操作等同于**保证数据可访问(ensure accessibility)**，即允许对象减少可用性。

5. 对象空间预留(object space reservation):

系统管理员始终要注意超额置备的问题。默认VSAN以瘦置备的方式创建虚拟机，对象空间预留(OSR)用于指定一个对象在逻辑预留多大空间(也就是类似于厚置备)。此策略值的范围在0%~100%之间，0%是默认的值，等同于瘦置备，100%可以视为等同于厚置备延迟置零。

VSAN有机制可以防止超额分配，例如当主机上可用存储空间不能满足FTT或是条带宽度要求，虚拟机创建会报错。

6. 对象的IOPS限制(IOP Limit For Object):

使用此策略可以限制一个对象或是一台虚拟机的IOPS占用。

有两种情况可以用此策略实现：限制一些非重要业务的IOPS，保证其他虚拟机的性能；实现同一资源池，分层的服务。

IOPS限制使用32KB的读写操作作为基准，即进行16KB的读写操作时，VSAN视为一个IO，当进行64KB的读写操作时，VSAN视为两个IO。

7.禁用对象校验(Disable Object Checksum):

自VSAN 6.2之后，VSAN引入了对象检验功能，用于避免读写操作时由于硬件、软件(内存、驱动器等)导致的数据损坏。在VSAN 6.2(VSAN存储格式为v3)此功能默认开启的。每个读操作都会进行校验。同时每年scrubber会对所有一年内未读写的块进行校验。scrubber的校验周期可以改短，但是要注意这个操作是有额外后台开销的。

此功能会有额外的内存、CPU和存储开销，如果觉得没有意义可以启用此策略，关闭校验。

8.容错方法(Failure Tolerance Method):

6.2之前的VSAN版本只支持RAID1，6.2全闪存模式下支持RAID5/6。

RAID 1有更好的性能，但是容量需求较高，RAID5/6在提供冗余的同时，相比RAID1更能节省空间。

当FTT=1时，使用RAID5/6(纠错码)大致占用1.33倍空间，使用RAID1则占用2倍空间。假如一个虚拟机为20G，使用RAID5/6实际占用27G，使用RAID1占用40G。

当FTT=2时，使用RAID5/6(纠错码)大致占用1.5倍空间，使用RAID1则占用3倍空间。假如一个虚拟机为20G，使用RAID5/6实际占用30G，使用RAID1占用60G。

和传统使用RAID5/6的存储一样，这样的容错方式会有额外的开销，但是VSAN仅在全闪配置下支持，SSD的性能很好所以做RAID5/6的开销可以忽略不计。

另外使用RAID5/6时，需要的主机数也有所不同。

FTT=1，做RAID5至少需要4台主机。

FTT=2，做RAID6至少需要6台主机(四台主机存放数据，两台做校验)。

3.3 虚拟机主页(VM namespace)及交换文件(Swap)考量

关键词：Swap文件为厚置备，可能占用很多空间。计算容量时需要考虑内存快照。

在VSAN中虚机以对象的形式保存，每个虚拟机都会有一个namespace。同时当虚拟机开机时，一个swap对象会被创建。namespace和swap这两个对象都不会继承存储策略，他们有自己的策略设置，会影响VSAN存储容量的设计。

VM namespace：VM namespace在VSAN中是个256G的瘦置备对象。因为一些策略(如对象空间预留，闪存读缓存预留)对于namespace没啥用，所以namespace可以忽略这些设定。默认namespace采用如下设置：

每个对象的磁盘带数：1

闪存读缓存预留：0%

FTT：继承VM的策略设置

强制置备：继承VM策略设置

对象空间预留：0%

下图是一个FTT=1时，虚拟机namespace的截图，可以看到它有一个RAID1，含有镜像的两个组件。还有一个保存在第三个主机的仲裁。

The screenshot shows the 'Manage' tab selected in the navigation bar. Under 'VM Storage Policies', the 'base-sles' VM is selected. The 'Physical Disk Placement' section is expanded, showing the following details:

Type	Component State	Host	SSD Disk Name	SSD Disk
RAID 1				
Component	Active	esx-01a.corp....	VMware Serial Attached SCS...	523119
Component	Active	esx-05a.corp....	VMware Serial Attached SCS...	52ec78
Witness	Active	esx-02a.corp....	VMware Serial Attached SCS...	522c4a

VM Swap

VM Swap也有自己的默认策略：

每个对象的磁盘带数：1

闪存读缓存预留：0%

FTT：1

强制置备：开启

对象空间预留：100%(厚置备)

在VSAN 6.2中有一个高级选项可以禁用VM Swap的厚制备，禁用后swap文件预留空间为0%，可以极大的节省空间（想象你环境中500台虚拟机，每台4GB内存，如果都开机光Swap文件会占用4T空间）。需要在虚拟机关机后设置此选项。

```
esxcfg-advcfg -s 1 /VSAN/SwapThickProvisionDisabled
```

更多关于如何进行此高级设置，请看[此文章](#)。

3.4 快照

关键词：快照会占用空间，在快照使用较多的环境请注意容量预留

对VSAN上的虚拟机进行快照时，创建的Delta盘和母盘使用相同的policy。

如果对虚机进行内存快照，则会产生内存快照文件，在VSAN5.5时，内存快照保存在namespace中，因为namespace有255G的限制，所以需要内存小于255的虚拟机才能完成内存快照操作。在VSAN6.0后，内存单独拿出来成为一个对象保存。在做VSAN设计时需要考虑到内存快照的容量。

3.5 动态调整策略

VSAN支持动态调整策略，调整策略时可能会临时占用VSAN部分空间。如果系统资源不满足修改后的策略，reconfiguration会失败。

例如，将VM的FTT=1修改为FTT=2时，**VM原有的各对象和组件都不会变**，只是再增加一个副本。

但是如果修改了每对象磁盘带数，例如将1修改为2，很可能虚拟机对象的组件大小会发生变化，原来一个10G的组件可能拆分为两个5G的组件保存在不同的磁盘上。这时候，原虚拟机占用20G空间，调整策略时，临时会多占用20G空间。在策略应用完成后，原来的对象会被丢弃。

3.6 有可用空间不代表可以置备出虚拟机

VSAN的各种策略可能让虚拟机创建失败。例如磁盘不够时，每对象磁盘带数过大会导致置备失败。FTT结合每磁盘带数也可能导致置备失败。VSAN磁盘利用不均衡，导致实际可用磁盘数/主机数不能满足策略要求（有手动均衡磁盘利用的命令）。

四、主机设计

4.1 CPU 设计

每主机CPU数，CPU核数，VM的vCPU需求量，vCPU-CPU融合比，为VSAN预留10%的CPU资源。

4.2 内存设计

VM的内存需求量。当VSAN满配(5个磁盘组，每个磁盘组7块硬盘)时，需要至少32G内存。

4.3 启动设备设计

关键词：建议使用 SATADOM作为 启动盘

更多详细介绍见 [这里](#) 以及 [这里](#)。

VSAN 5.5开始支持从USB设备或者SD卡启动。

VSAN 6.0除了支持USB和SD，还支持SATADOM。

在将ESXi安装在USB和SD卡上后，ESXi的日志文件及VSAN traces(默认保存在scratch目录下，但此目录挂在RAM disk中)会保存在易失性存储RAM disk中，因此重启后日志就会丢失。

VSAN环境下也不建议将日志放在VSAN存储上，因为如果VSAN存储故障，则上面的日志也会丢失，为未来排错造成困难。

SATADOM相比SD卡和U盘有更高的寿命和性能，所以日志可以保存在这些设备，但是对设备有些要求：容量 \geq 16G，寿命：512-1024 TBW (VSAN 6.1及之前) */ 384 TBW (VSAN 6.2)。

关于日志重定向及scratch文件夹重定向请见[此KB1033696](#)。

4.4 尽量不要使用只提供计算资源的主机

因为VSAN有每主机最大组件数限制 (VSAN 5.5最大3000, 6.0最大9000)，所以可能置备的虚拟机数量会受到限制。

4.5 刀片服务器及外置磁盘柜支持

VSAN支持刀片服务器，但是受刀片服务器自身的限制，本地能够提供的容量有限。在VSAN 6.0之后开始支持外置磁盘柜，因此使用刀片服务器做VSAN变成一种可以落地的方案。如果机架式服务器本地硬盘有限，也可以外挂磁盘柜进行容量扩充。

VSAN 6.0支持的外置磁盘柜型号有限，如果需要使用此方案请务必检查VMware兼容性列表。

4.6 电源管理

关键词：建议关掉节能功能

电源管理会影响整体的性能，这个在虚拟化中一直被提及。当启用电源管理时，某些对处理性能延迟感知很明显的应用实际性能会不如预期。最佳时间建议将电源管理模式修改为'balanced'，避免服务器进入节能模式。更多详细请看<https://kb.vmware.com/kb/1018206>

五、集群设计

5.1 2/3 节点设计

关键词：建议一套VSAN环境至少配置4节点

VSAN支持2节点及3节点配置，这样的配置和4节点及以上的表现会不一样。尤其是，当有主机宕机后，没有富余的资源重建丢失的组件，来保证FTT，在单台主机故障期间，容不得再有任何故障发生，否则数据会丢失。

另外使用2、3节点配置，如果有主机进入维护模式，无法使用“full data mirage”

所以，我们建议VSAN环境至少4台主机起，且一定要有足够的资源预留。

5.2 vSphere HA

VSAN可以和vSphere HA结合使用。效果和使用传统存储时一样。

在网络隔离的情况下，vSphere HA有感知 VSAN 对象的功能，但是这里要注意，vSphere HA与VSAN网络隔离并无绝对关系，VSAN网络隔离不会触发vSphere HA（解决此问题的办法要么从物理角度避免VSAN网络中断，要么将管理网络和VSAN网络运行在同一个vDS中，或者修改HA的高级参数，将VSAN地址作为HA隔离检测地址）。

在HA发生且出现网络隔离时(比如一个主机所有网络中断)，如果一个VM原来所在的主机无法访问此VM需要的组件，它会被HA移动到可以访问此VM需要的组件的主机上，也就是说，HA能检测出来将虚拟机放在哪个分区合适，而不是随机去在任意一台主机上开机。

vSphere HA和VSAN搭配时有以下几点需求：

- 1、vSphere HA需要使用VSAN的网络进行通信
- 2、在开启VSAN之前需要关闭集群的HA，在VSAN创建完成后再打开集群的HA
- 3、vSphere HA不使用VSAN datastore作为存储心跳

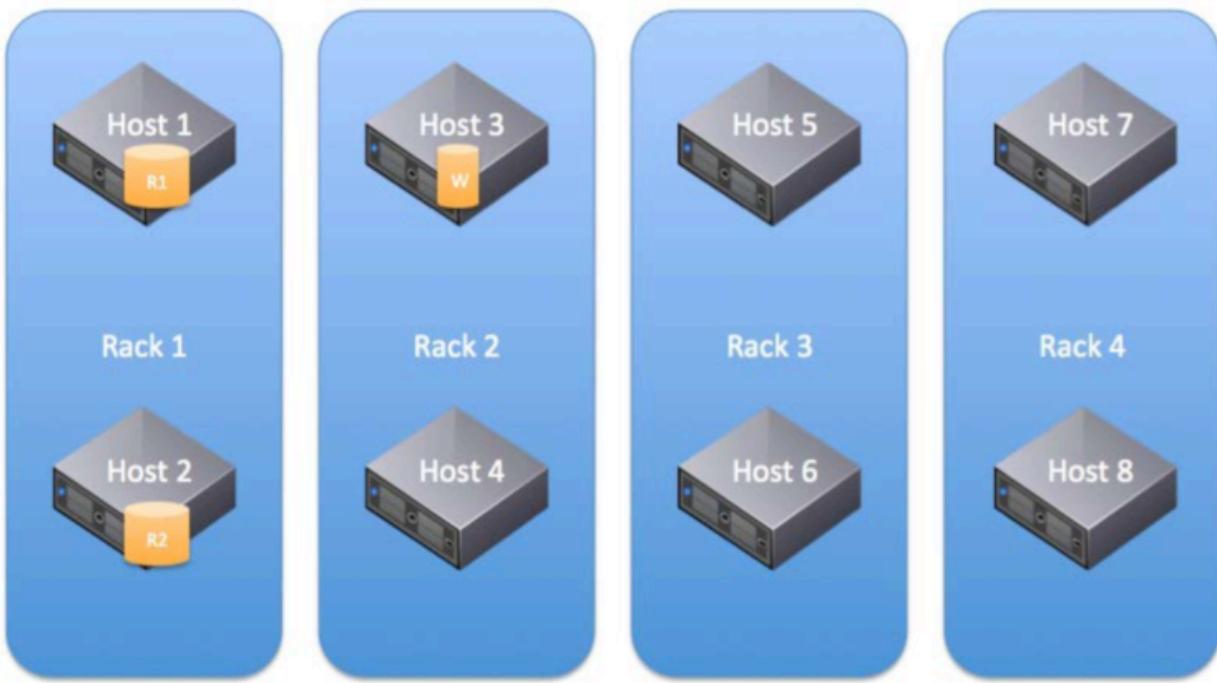
VSAN 和 vSphere HA是解耦和的，一般开启vSphere HA时，vSphere会检查是否有足够的CPU和内存资源满足HA，使用VSAN时，HA不会去检查是否有足够的存储资源。当单个主机故障(组件是absent的情况下)，VSAN等待60分钟，60分钟后会在其他剩余存储资源上重建损坏主机上的组件，让虚拟机变成合规状态。

5.3 故障域

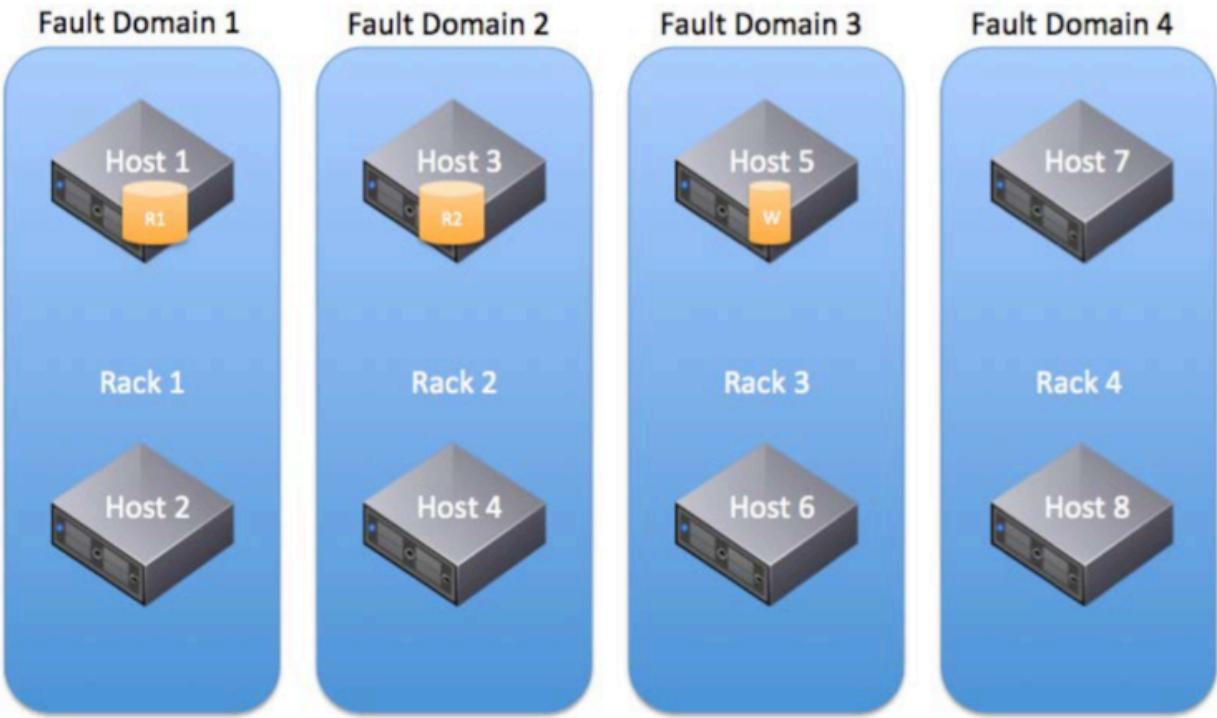
关键词：建议在较大环境(多个机柜)使用故障域

使用FTT来避免故障存在一种问题，就是当多个主机在同一个机架(通常会使用同一个PDU，同一个置顶交换机)时，整个机架故障会存在很大风险，如下图：

一个虚机很可能将数据以以下方式保存，所以当Rack1整个故障时，虚拟机失效组件>50，将会变成不可用状态。



如果引入故障域的概念，将一组主机作为一个故障点存在，那么VSAN则会避免将一个虚机的多个副本和仲裁保存在同一个故障域内。设置后虚机的数据会以下列方式存放。



在较大环境中，VMware推荐使用故障域避免单个机架故障。此时，同普通的设计一样，要考虑整个机架的故障后有可用资源接管。

5.4 去重和压缩设计

VSAN 全闪配置下支持去重和压缩。可以减少容量层磁盘空间的使用。它针对集群开启，只能在全闪配置下开启。

当启用此特性后，组件会平均分布在磁盘组中所有容量盘上。这样就避免了组件的重平衡，也无需为了均衡随机读性能而调整条带宽度。

当在开启去重和压缩后，使用对象空间预留策略，那么预留的空间不会被进行压缩及去重。

六、确定工作负载是否适合使用VSAN

关键词：在工作负载较重的场合，使用全闪存配置的VSAN

通常VSAN适用于大部分工作场合。

在使用混合配置时，需要注意应用程序如何使用缓存，有少部分应用对缓存的使用并不友好(没有固定热点数据、缓存命中率低)，例如：数据库的完整扫描，一个较大的数据库负载，内容很多的资源库，备份及恢复，等等类似的工作负载。

在遇到这些工作负载的时候，性能会取决于容量层磁盘的性能，例如有多少个可用的磁盘，他们速度如何，他们还承载了多少其他的工作负载。

相反，全闪配置总是可以提供很高的性能、较低的延迟，不会因工作负载而影响太多。

VSAN Ready Node 文档中介绍了Ready node服务器的一些参数，包括可以支撑的虚拟机数，能提供的IOPS等。

七、使用 View planner 进行VSAN规划

当 VSAN 用于 View 桌面环境时，可以使用View Planner 工具进行工作负载的模拟，进而得出较为真实合理的 VSAN 配置需求。

View planner可以模拟几种不同的工作场合(基础任务，办公，和高级用户)。进行模拟时，它会随机打开一些 Windows 常用的软件，模拟用户的操作，例如打开、保存、关闭、最小/最大化窗口；查看网页，编写文档、表格、ppt、观看视频、收发邮件、压缩文件等。View Planner使用专有的 watermark 技术量化用户的体验，测量应用延迟。

更多关于 View Planner 的信息请看[这里](#)。View Planner 的使用案例请看[这里](#)。

八、VMware infrastructure Planner - VIP

当前很多企业使用了 VMware 服务器虚拟化，更进一步，可能会发展成虚拟化、池化和自动化，即 SDDC。

VMware Infrastructure Planner 可以收集一个虚拟化环境中各种资源的使用量，告诉用户如果部署 vCloud 等 SDDC 产品后可以节省出多少资源。VIP提供直观的图表，能够展示不同资源的使用情况。

更多软件信息请看[这里](#)。

九、设计案例一

客户计划部署100台虚拟机，使用混合配置。

每台虚拟机8GB RAM、2vCPU、单个100G vmdk。

使用VSAN 6.0 v2格式。CPU融合比为5: 1。

预计系统及应用会占用50%的存储资源，但是最终要提供100%的存储资源。

使用的存储策略为 FTT=1， 其他都使用默认策略。

ESXi 装在SD卡上。

在此规划中， 不计组件元数据及仲裁的开销， 它们可以忽略不计。

CPU

主机数：>=3

总CPU数：300vCPU/5=40 核

考虑到VSAN自身占用10%的资源， 总需要44核。

客户计划购买**两路， 12核CPU**， 按照三台主机算会有72核CPU， 远远满足需求， 且当一台服务器宕机后， 其他两台有足够资源启动原主机上的VM。

内存

总内存需求：800G

平均每台需要300G内存。考虑到其中一台主机宕机后其他两台要接管， 需要将每台主机内存增加到512G。

此处需要注意服务器能够安装这么多的内存。

磁盘容量

因为是三节点**VSAN**这样的最小配置， 所以不需要考虑主机容量的冗余。

存储空间需求(不考虑FTT)： $100\text{GB} \times 100 = 10\text{TB}$

存储空间需求(考虑FTT)： $100\text{GB} \times 1002 = 20\text{TB}$

存储空间需求+虚拟机swap文件 (考虑FTT) : $(10\text{T} + 100\text{G}) \times 2 = 21.6\text{T}$

因为vmdk都是瘦置备的， 所以在计算缓存层的容量时， 使用瘦置备的容量来计算。

预计需要使用缓存的容量(不考虑FTT)： $50\% \times 10\text{TB} = 5\text{TB}$

缓存需求： $5 \times 10\% = 500\text{G}$

预计快照需求：本例暂不考虑

前面提到至少要有30%的空间预留：

需要的总裸容量*70%=存储空间需求

即， 需要的总裸容量= 存储空间需求/ $0.7 = 21.6/0.7 = 30.9\text{TB}$

使用VSAN v2格式，文件系统的开销 = 1% * 总裸未格式化容量。

总结出公式：总裸未格式化容量=需要的总裸容量+(总裸未格式化容量*1%，即开销)

总裸未格式化容量=需要的总裸容量/99%

总裸未格式化容量=30.9/0.99=31.2TB

考虑到实际购买，则每服务器需要 10.5 T 左右的容量，可以是 10 块 1.2 T 10K 的 SAS 盘。（此处粗略计算 1.2T 可用容量约 1.1T）

磁盘组可以设计成两个，两个 IO 控制器。

两个 SSD，每个 100G。

组件数考虑

VSAN 6.0 支持每主机最大 9000 个组件。

当前 100 台虚拟机，每个虚拟机至少包含如下组件：

1 X VM namespace

1 X VMDK

1 X swap

0 X snapshot

算上 FTT=1，及仲裁：

2 X VM namespace + witness

2 X VMDK + witness

2 X swap + witness

0 X snapshot

总计 $100 \times 9 = 900$ 个组件，远小于 9000 / 主机的限制。

十、设计案例二

客户计划部署 400 台虚拟机，使用混合配置。

每台虚拟机 12GB RAM、1vCPU、100G 启动磁盘，200G 数据盘。

使用 VSAN 6.0 v2 格式。CPU 融合比为 4: 1。

预计系统及应用会占用 75% 的存储资源，但是最终要提供 100% 的存储资源。

使用的存储策略为 FTT=1，条带宽度=2，其他都使用默认策略。

ESXi 装在磁盘上。

在此规划中，不计组件元数据及仲裁的开销，它们可以忽略不计。

CPU

主机数：>=3

总CPU数：400vCPU/4=100 核

考虑到VSAN自身占用10%的资源，总需要110核。

客户计划购买两路，**12核CPU**，按照5台主机算会有120核CPU，刚好满足需求。

但是当一台服务器宕机后，其他服务器没有足够资源启动原主机上的VM，如果再增加一台主机即总6台则满足冗余需求。

内存

总内存需求：400*12=4.8T

总六台主机，平均每台需要800G内存。考虑到其中一台主机宕机后其他服务器要接管，需要将每台主机内存增加到1TB。

此处需要注意服务器能够安装这么多的内存。

磁盘容量

因为是三节点VSAN这样的最小配置，所以不需要考虑主机容量的冗余。

存储空间需求(不考虑FTT)：300GB*400=120TB

存储空间需求(考虑FTT)：120TB*2=240TB

存储空间需求+虚拟机swap文件（考虑FTT）：(10T+400*12)*2=249.6TB

因为vmdk都是瘦置备的，所以在计算缓存层的容量时，使用瘦置备的容量来计算。

预计需要使用缓存的容量(不考虑FTT)：75% * 120 TB = 90TB

缓存需求：90*10%=9TB

预计快照需求：每个虚拟机两个快照，但是快照增量不超过vm总容量的5%。

总快照占用：5% * 240T=12T

总裸容量：249.6+12=261.6T

前面提到至少要有30%的空间预留：

需要的总裸容量*70%=存储空间需求

即， 需要的总裸容量= 存储空间需求/0.7 = $261.6/0.7 = 373.7 \text{ TB}$

使用VSAN v2格式， 文件系统的开销 = 1% * 总裸未格式化容量。

总结出公式：**总裸未格式化容量=需要的总裸容量+(总裸未格式化容量*1%， 即开销)**

总裸未格式化容量=需要的总裸容量/99%

总裸未格式化容量= $373.7/0.99=377.5\text{TB}^{**}$

存储配置一：

6台主机， 每台平均需要63T， 1.5T 的SSD

我们可以选择使用4T的SATA盘， 虽然速度慢一些， 但是应该可以满足需求。每主机需要17块(考虑4T实际容量3.7T左右)。

因为每磁盘组7个磁盘的限制， 至少需要三个磁盘组。

三个磁盘组意味着三块SSD， 每个SSD 500G。为了未来考虑， 可以选用容量更大一些的。

IO 控制器可以多选购一个。

共20块磁盘， 因此可用磁盘插槽至少需要20 (如果使用PCIE闪存，则至少需要17个插槽)。

ESXi 装在磁盘上， 还需要额外的一个插槽， 所以是至少21(或者18)。

但是， 如果要考虑单个主机故障后重建组件的容量需求。就需要将主机数加到7台(这样考虑最简单了， 实际可以主机数依然为6， 提高每台上的存储容量)。

一开始计算CPU和内存是按照6台算的， 主机数变成7台后相应的需要调整。CPU资源不好调整， 可以适度减少每台主机上内存以节约成本。

存储配置二：

上种配置中， 使用了7200rpm的SATA盘， 性能可能满足不了业务需求， 因此可以考虑购买1.2T 10k RPM的SAS盘。

总共需要315块磁盘， 每个主机最大能有7*5个磁盘， 提供42T的容量。

至少需要10台服务器(考虑1.2T实际可用容量1.1T)。

需要考虑IO控制器是否能接管所有硬盘。

此种大容量需求， 也可以考虑使用外置磁盘柜。

10台主机共需要9T的闪存盘， 每主机5个磁盘组， 需要5*200G的闪存盘。

刚才算过每主机需要35个安装HDD， 需要再加5个插槽安装SSD(如果使用PCIE闪存则只需要考虑PCIE槽位数是否足够)

ESXi 安装在磁盘上， 需要外一个插槽， 即 41个。

设计11台保证冗余。这时候CPU和内存就需要重新进行设计，将原来6台的总量均分到11台服务器上。

CPU每主机可以选购8核的，内存每主机640G足够。

存储配置三-全闪配置(这部分原文很混乱，没考虑swap，且有错误)：

上述配置中，为了满足性能使用SAS盘，但受容量限制导致需要更多服务器来承载。第三种配置我们使用全闪配置，看看使用RAID5/6以及去重压缩能节省多少容量。

预计的启动盘去重压缩率为4x，因为虚拟机会使用链接克隆技术创建。数据盘压缩率2x。

单个启动盘的容量需求(FTT=1， RAID5， 去重压缩率4x)：

$$100\text{G} \times 1.33/4 = 33.25\text{GB}$$

单个数据盘的容量需求(FTT=1， RAID5， 去重压缩率2x)：

$$200\text{G} \times 1.33/2 = 133\text{GB}$$

Swap的容量需求(FTT=1， RAID5， 去重压缩率1x)：

$$12 \times 1.33/1 = 15.96\text{GB}$$

总裸容量需求（不含swap）： $(33.25\text{GB} + 133\text{GB}) \times 400 = 66.5\text{ TB}$

总裸容量需求（含swap）： $66.5 + 15.96 \times 400 = 72.9\text{ TB}$

预计快照需求：每个虚拟机两个快照，但是快照增量不超过vm总容量的5%。

总快照占用： $5\% \times 66.5\text{T} = 3.325\text{ T}$

总裸容量： $72.9 + 3.325 = 76.3\text{ T}$

在全闪配置时也是按照vmdk占用容量计算。

预计需要使用缓存的容量： $75\% \times 120\text{ TB} = 90\text{TB}$

缓存需求： $90 \times 10\% = 9\text{TB}$

前面提到至少要有30%的空间预留：

需要的总裸容量 \times 70% = 存储空间需求

即，需要的总裸容量 = 存储空间需求/ $0.7 = 76.3 / 0.7 = 109\text{ TB}$

使用VSAN v2格式，文件系统的开销 = 1% * 总裸未格式化容量。

总结出公式：总裸未格式化容量 = 需要的总裸容量 + (总裸未格式化容量 * 1%，即开销)

总裸未格式化容量 = 需要的总裸容量 / 99%

总裸未格式化容量 = 109/0.99 = 110 TB

按照CPU和内存计算需要6台服务器，但是呢，要保证数据冗余，此处CPU和内存已经是冗余状态，再增加一台主机显得多余，所以可以将110T平均到5台服务器上，每台提供22T，然后第六台增加22T的容量，这样总共132T空间。一台主机故障后，CPU、内存。

22T/主机的容量，SSD容量范围也比较大，可以选择20块1.2T的，15块1.6T的等等(考虑到硬盘实际容量小一些)。

缓存/容量比为1:10，但是全闪配置下每个磁盘组又有600G的容量限制，所以以1.2T为例，每主机需要4个磁盘组。共24个磁盘组，每磁盘组400G SSD做缓存，共9.6TB满足计算的9TB。

最后检查组件数

当前400台虚拟机，每个虚拟机至少包含如下组件：

1 X VM namespace

2 X VMDK

1 X swap

2 X snapshot

算上FTT=1，条带宽度=2，及仲裁：

2 X VM namespace + witness =3

(2X2 X VMDK + 3 witness) *2 = 14

2 X swap + witness=3

(2X2 X snapshot + 3 witness) *2 = 14

总计 $400 \times 34 = 13600$ 个组件，按6台主机每主机约2267个，满足9000的大小上限。

即使当一台主机宕机，剩余5台时，每主机2720也满足。

对比一下三种配置方案：

使用SATA时性能不好，但是需要的主机可以比较少，唯一需要注意的是每台服务器是否能安装1T内存

使用SAS盘时，会需要很多主机来安装硬盘，从经济角度考虑可能并不推荐。此方案可以考虑使用外置磁盘柜扩充。

使用全闪配置时，容量需求会小很多，且SSD单盘容量可以很大，因此能非常容易地满足需求。

十一、下面是一些网站链接：

VMware Ready Nodes

<http://www.vmware.com/resources/compatibility/search.php?deviceCategory=vsan>

VMware 兼容性指南

<http://vmwa.re/vsanhclc>

vSphere 社区中的VSAN板块

<https://communities.vmware.com/community/vmtn/vsan>

博客

<http://cormachogan.com/vsan/>

<http://www.yellow-bricks.com/virtual-san/>

<http://www.virtuallyghetto.com/category/vsan>

<http://www.punchingclouds.com/tag/vsan/>

<http://blogs.vmware.com/vsphere/storage>

<http://www.thenicholson.com/vsan>

文档库

<http://www.vmware.com/products/virtual-san/resources.html>

<https://www.vmware.com/support/virtual-san>

VMware 支持

<https://my.vmware.com/web/vmware/login>

<http://kb.vmware.com/kb/2006985> - 如何获得帮助

<http://kb.vmware.com/kb/1021806> - VMware 产品位置

日志文件

<http://kb.vmware.com/kb/2032076> - ESXi 5.x 日志文件

<http://kb.vmware.com/kb/2072796> - 收集 Virtual SAN 支持日志

更多阅读

<http://blogs.vmware.com/vsphere/files/2014/09/vsan-sql-dvdstore-perf.pdf> - Microsoft SQL Server 性能学习

<http://www.vmware.com/files/pdf/products/vsan/VMW-TMD-Virt-SAN-Dsn-Szing-Guid-Horizon-View.pdf> - Horizon View VDI 设计指南

<http://www.vmware.com/files/pdf/products/vsan/VMware-Virtual-SAN-Network-Design-Guide.pdf> - VSAN网络设计指南