



Fig.14 Performance of ZooKeeper—Async operations

图 14 ZooKeeper 异步操作性能

4.4 迁移开销

在实验过程中,我们持续测量了虚拟机动态迁移的时间以及动态迁移执行过程中的性能干扰.我们测量到单台虚拟机的动态迁移时间在 10s~15s 之间,对网络带宽的占用平均为 40%.我们测量了在虚拟机动态迁移过程中执行的 Hadoop 计算密集型 and I/O 密集型应用的任务执行时间.受益于优化的迁移顺序以及对迁移速度的控制,对 Hadoop 任务的执行时间的影响平均为 7%.这一额外开销在大规模长时间的工作负载的场景下是可以接受的.

5 相关工作

现有的缓存资源管理的相关工作主要从缓存本身出发,以缓存的特点及相关关键指标驱动缓存资源管理,最终实现性能提升或降低后端存储系统负载的目的.如在 SSD 和 HDD 构成的混合存储系统中考虑 SSD 应对不同类型 I/O 负载的差异性,进行选择性的数据缓存^[18]以提升性能;或使用本地磁盘介质作为网络存储系统的缓存^[19],以降低网络存储系统的负载,提升系统性能.

许多研究工作考虑 SSD 缓存本身的特点进行缓存分配.RAF^[20]引入成本收益模型,以缓存对 SSD 而言价值较高的随机读写数据,降低 SSD 的响应时间,并提升寿命.Centaur^[6]将 Hypervisor 上的 SSD 缓存进行分区并分配给不同的虚拟机,通过各虚拟机的缓存大小,以满足诸如缓存 Miss 率或虚拟机 I/O 响应时间等具体性能指标的优化需求.S-CAVE^[9]基于缓存命中率和虚拟机频繁使用的缓存空间大小导出了虚拟机对缓存空间的需求,并以此实现 SSD 缓存资源分配.vCacheShare^[21]从虚拟机的 I/O 行为和特点出发,结合虚拟机的数据本地性以及缓存命中率和重用程度等特性,指导 SSD 缓存资源分配.这些工作都是以 SSD 缓存的关键指标作为调整依据,面向单台 Hypervisor 的场景,并没有从全局角度考虑 SSD 缓存资源的供给能力,也难以在 SSD 缓存出现资源争用时进行有效应对.

一些研究工作考虑了缓存资源出现争用的情况并加以解决.CloudCache^[8]提出了一种基于 Reused Working Set 的 SSD 缓存方法,可以在缓存命中率相当的前提下有效降低需要缓存的数据大小,从而提高缓存的利用率.此外,CloudCache 也提出了一种以缓存容量为导向的虚拟机动态迁移策略,在虚拟机对缓存容量的需求超过 SSD 总容量时触发虚拟机动态迁移.然而,CloudCache 没有考虑到 SSD 作为存储介质本身对带宽和 IOPS 能力的约束,也没有考虑到应用对虚拟机放置的倾向性,因此,可能在满足缓存容量约束的前提下出现虚拟机对 SSD 的带宽和 IOPS 的争用,也可能在执行迁移的过程中对虚拟机进行了错误的放置,影响了虚拟机的性能或虚拟机上承载应用的可靠性.

此外,一些研究工作考虑到了应用内的工作负载,并以此指导了 SSD 缓存分配.Capo^[22]面向虚拟桌面的场景,考虑到了用户虚拟机中的不同目录和文件的使用模式和对缓存的不同需求.Capo 为用户磁盘内的不同目录设置了不同的缓存策略,以此提高缓存利用率,避免不必要的缓存操作,降低存储系统的负载.文献[23]构建了一个原型文件系统,在底层对 I/O 请求进行分类,针对不同类型的 I/O 请求设置不同的缓存策略,从而实现缓存命中

率和虚拟机性能的提升.这些研究工作对虚拟机内运行的工作负载进行了建模,从而可以有效地进行应对,但它们未能从全局的角度考虑多台虚拟机组成的应用以及应用内部虚拟机关联对缓存资源管理的影响.

6 结论与未来的工作

本文提出了虚拟化环境下面向多目标优化的自适应 SSD 缓存系统,构建了一个自适应闭环,通过持续监测并感知模式变化以驱动虚拟机的动态迁移,最终在容量规划之外实现了对 SSD 缓存利用率、应用性能和应用可靠性的多目标优化.系统在监测时重点关注了虚拟机和 SSD 缓存的性能指标,并感知虚拟机上部署的应用的边界、应用内虚拟机的关联以及应用本身对虚拟机放置的倾向性;之后,使用聚类算法获得优化放置方案,并给出了合理的迁移顺序以降低开销.

这一工作的主要不足之处在于,对应用类型的覆盖范围较小,目前只完整支持 Hadoop 和 ZooKeeper 两类应用,且依赖于一定的先验知识来获得应用对虚拟机放置的倾向.此外,系统的监测粒度也相对有限,未能深入大数据处理应用内部去感知用户代码的行为,以此指导 SSD 缓存负载均衡和对应用性能和可靠性的优化.

未来我们将刻画应用行为以及使用 SSD 缓存时的共性,从这两个角度对应用进行自动分类,更合理地感知应用对 SSD 的需求,从而支持虚拟化环境下更多类型的应用.此外,还将实现更深层次的应用感知,从用户代码层面考虑应用的行为和对 SSD 缓存的使用情况,从而支持更灵活的 SSD 缓存资源管理.

References:

- [1] Gulati A, Shanmuganathan G, Zhang X, Varman P. Demand based hierarchical QoS using storage resource pools. In: Proc. of the 2012 USENIX Conf. on Annual Technical Conf. Boston: USENIX Association, 2012. 1–13.
- [2] Hansen JG, Jul E. Lithium: Virtual machine storage for the cloud. In: Proc. of the 1st ACM Symp. on Cloud Computing. Indianapolis: ACM Press, 2010. 15–26. [doi: 10.1145/1807128.1807134]
- [3] Ye L, Lu G, Kumar S, Gniady C, Hartman JH. Energy-Efficient storage in virtual machine environments. In: Proc. of the 6th ACM SIGPLAN/SIGOPS Int'l Conf. on Virtual Execution Environments. Pittsburgh: ACM Press, 2010. 75–84.
- [4] Lu L, Pillai TS, Arpaci-Dusseau AC, Arpaci-Dusseau RH. WiscKey: Separating keys from values in SSD-conscious storage. In: Proc. of the 14th USENIX Conf. on File and Storage Technologies. Santa Clara: USENIX Association, 2016. 133–148. [doi: 10.1145/3033273]
- [5] Kim J, Lee D, Noh S H. Towards SLO complying SSDs through OPS isolation. In: Proc. of the 13th USENIX Conf. on File and Storage Technologies. Santa Clara: USENIX Association, 2015. 183–189.
- [6] Koller R, Mashizadeh AJ, Rangaswami R. Centaur: Host-Side SSD caching for storage performance control. In: Proc. of the 2015 IEEE Int'l Conf. on Autonomic Computing. Wurzburg: IEEE Computer Society, 2015. 51–60. [doi: 10.1109/ICAC.2015.44]
- [7] Oh Y, Lee E, Hyun C, Choi J, Lee D, Noh S H. Enabling cost-effective flash based caching with an array of commodity SSDs. In: Proc. of the 16th Annual Middleware Conf. Vancouver: ACM Press, 2015. 63–74. [doi: 10.1145/2814576.2814814]
- [8] Arteaga D, Cabrera J, Xu J, Zhao M. CloudCache: On-Demand flash cache management for cloud computing. In: Proc. of the 14th USENIX Conf. on File and Storage Technologies. Santa Clara: USENIX Association, 2016. 355–369.
- [9] Luo T, Ma S, Lee R, Zhang X, Liu D, Zhou L. S-CAVE: Effective SSD caching to improve virtual machine storage performance. In: Proc. of the 22nd Int'l Conf. on Parallel Architectures and Compilation Techniques. Edinburgh: IEEE Computer Society, 2013. 103–112. [doi: 10.1109/PACT.2013.6618808]
- [10] Shvachko K, Hairong K, Radia S, Chansler R. The hadoop distributed file system. In: Proc. of 2010 IEEE the 26th Symp. on Mass Storage Systems and Technologies (MSST). Incline Village: IEEE Computer Society, 2010. 1–10. [doi: 10.1109/MSST.2010.5496972]
- [11] Vavilapalli VK, Murthy AC, Douglas C, Agarwal S, Konar M, Evans R, Graves T, Lowe J, Shah H, Seth S, Saha B, Curino C, O'Malley O, Radia S, Reed B, Baldeschwieler E. Apache hadoop YARN: Yet another resource negotiator. In: Proc. of the 4th Annual Symp. on Cloud Computing. Santa Clara: ACM Press, 2013. 1–16. [doi: 10.1145/2523616.2523633]
- [12] Junqueira FP, Reed BC, Serafini M. Zab: High-Performance broadcast for primary-backup systems. In: Proc. of the 2011 IEEE/IFIP 41st Int'l Conf. on Dependable Systems&Networks. Hong Kong: IEEE Computer Society, 2011. 245–256. [doi: 10.1109/DSN.2011.5958223]

- [13] Hunt P, Konar M, Junqueira FP, Reed B. ZooKeeper: Wait-Free coordination for Internet-scale systems. In: Proc. of the 2010 USENIX Conf. on USENIX Annual Technical Conf. Boston: USENIX Association, 2010. 11–24.
- [14] Intel. Intel solid state drive 750 series. 2016. <http://www.intel.com/content/dam/www/public/us/en/documents/product-specifications/ssd-750-spec.pdf>
- [15] WD. WD black PC HD series specification sheet. 2016. https://www.wdc.com/content/dam/wdc/website/downloadable_assets/eng/spec_data_sheet/2879-771434.pdf
- [16] Barham P, Dragovic B, Fraser K, Hand S, Harris T, Ho A, Neugebauer R, Pratt I, Warfield A. Xen and the art of virtualization. In: Proc. of the 19th ACM Symp. on Operating Systems Principles. Bolton Landing: ACM Press, 2003. 164–177. [doi: 10.1145/945445.945462]
- [17] Hunt P. ZooKeeper smoketest. 2016. <https://github.com/phunt/zk-smoketest>
- [18] Yang PY, Jin PQ, Yue LH. A time-sensitive and efficient hybrid storage model involving SSD and HDD. Chinese Journal of Computers, 2012,35(11):2294–2305 (in Chinese with English abstract). [doi: 10.3724/SP.J.1016.2012.02294]
- [19] Yin Y, Liu ZJ, Xu L. Cache system based on disk media for network storage. Ruan Jian Xue Bao/Journal of Software, 2009,20(10):2752–65 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/3427.htm> [doi: 10.3724/SP.J.1001.2009.03427]
- [20] Liu Y. Research on caching and prefetching technologies for hierarchical hybrid storage systems [Ph.D. Thesis]. Wuhan: Huazhong University of Science and Technology, 2013 (in Chinese with English abstract). [doi: 10.7666/d.D608789]
- [21] Meng F, Zhou L, Ma X, Uttamchandani S, Liu D. vCacheShare: Automated server flash cache space management in a virtualization environment. In: Proc. of the 2014 USENIX Conf. on USENIX Annual Technical Conf. Philadelphia: USENIX Association, 2014. 133–144.
- [22] Shamma M, Meyer DT, Wires J, Ivanova M, Hutchinson NC, Warfield A. Capo: Recapitulating storage for virtual desktops. In: Proc. of the 9th USENIX Conf. on File and Storage Technologies. San Jose: USENIX Association, 2011. 3–17.
- [23] Mesnier M, Chen F, Luo T, Akers JB. Differentiated storage services. In: Proc. of the 23rd ACM Symp. on Operating Systems Principles. Cascais: ACM Press, 2011. 57–70. [doi: 10.1145/2043556.2043563]

附中文参考文献:

- [18] 杨濮源,金培权,岳丽华. 一种时间敏感的 SSD 和 HDD 高效混合存储模型. 计算机学报, 2012,35(11):2294–2305. [doi: 10.3724/SP.J.1016.2012.02294]
- [19] 尹洋,刘振军,许鲁. 一种基于磁盘介质的网络存储系统缓存. 软件学报, 2009,20(10):2752–2765. <http://www.jos.org.cn/1000-9825/3427.htm> [doi: 10.3724/SP.J.1001.2009.03427]
- [20] 刘洋. 层次混合存储系统中缓存和预取技术研究[博士学位论文]. 武汉: 华中科技大学, 2013. [doi: 10.7666/d.D608789]



唐震(1990 -),男,江苏苏州人,博士生,主要研究领域为网络分布式计算与软件工程.



魏峻(1970 -),男,博士,研究员,博士生导师,CCF 高级会员,主要研究领域为网络分布式计算,软件工程.



吴恒(1983 -),男,博士,副研究员,CCF 专业会员,主要研究领域为网络分布式计算,软件工程.



黄涛(1965 -),男,博士,研究员,博士生导师,CCF 高级会员,主要研究领域为网络分布式计算,软件工程.



王伟(1982 -),男,博士,副研究员,CCF 专业会员,主要研究领域为网络分布式计算,软件工程.