


大模型-AI集群 (存)

大模型遇到存储



ZOMI

大模型业务全流程



存储的现状

- 数据存储经历了文件存储、数据库存储、大数据存储、数据湖存储、湖仓一体存储、云原生存储等不同发展阶段。

存储的新技术点

- 从而带来新的存储技术点，存算一体、存内计算、异构存储、多模态存储、小文件存储、分布式存储、高性能存储、增量存储、向量存储等。
- 但是对于 AI 大模型而言，有些是 AI 的未来，有些并不是 AI 所需要的，有些只是作为增值服务，有些是落后的技术，因此需要了解 AI 对于存储的需求。

关于本内容


• 内容背景

- AI 集群 + 大模型

• 具体内容

- **数据存储现状和场景**：存储软件类型、存储硬件类型的发展
- **大模型对存储的挑战**：存储性能指标、存储遇到大模型挑战与新机会点
- **大模型训练CKPT优化**：大模型训练过程、CKPT过程分解、CKPT优化
- **大模型时代对存储的思考**：什么样的存储架构才是AI大模型时代的选择？

关于本内容



存储使用场景变化

1. 存储系统随着应用的发展在不断进化

- 从早期的数据库应用催生的集中式存储
- Web2.0 应用催生分布式存储架构
- 电商、视频等移动应用产生软件定义存储、融合存储架构

2. 面向 AI 大模型时代产生新应用和海量数据，对数据存储带来怎样的挑战和机遇？ 存储系统面向AI 的新场景应该如何进化？



增长的存储主要靠数据中心和存储服务器拉动

存储 技术 架构

存储连接

SAN

NAS

DAS

存储架构

集中式存储

分布式存储

存储协议
存储协议

文件存储

NFS

HDFS

块存储

NVMe

SCSI

对象存储

Tensor

Vector

其他

Table

组网方案

IP 网络

FC 组网

ROCE 组网

存储介质

磁带


光盘

机械硬盘

固态硬盘

增长的存储主要靠数据中心和存储服务器拉动

存储 技术 架构



Reference 引用&参考

1. <https://www.linkedin.com/pulse/dram-scaling-challenges-grow-aken-cheung>
2. https://nn.wikipedia.org/wiki/Random_Access_Memory
3. <https://www.youtube.com/watch?v=OwtV0NrTLHA>
4. <https://www.agrade.com.cn/IndustryNews/683.html>
5. <https://www.cnblogs.com/FireLife-Cheng/p/17183491.html>
6. <https://www.wpgdadatong.com/blog/detail/43099>
7. https://www.sohu.com/a/476456430_121149658
8. <https://www.programmersought.com/article/66421832717/>
9. <https://blog.router-switch.com/2021/03/storage-architecture-nas-vs-san-vs-das/>
10. <https://www.linkedin.com/pulse/dram-scaling-challenges-grow-aken-cheung>
11. <https://36kr.com/p/1933583910734464>
12. <https://lvxixiao.gitbook.io/blog/os/store/hardware>
13. <https://www.redhat.com/zh/topics/data-storage/network-attached-storage>
14. <https://community.fs.com/cn/case-study/the-common-types-of-storage.html>
15. <https://help.aliyun.com/zh/ecs/user-guide/nvme-protocol>
16. <https://blog.csdn.net/fgf00/article/details/52592651>



Thank you

把AI系统带入每个开发者、每个家庭、
每个组织，构建万物互联的智能世界

Bring AI System to every person, home and
organization for a fully connected,
intelligent world.

Copyright © 2023 XXX Technologies Co., Ltd.
All Rights Reserved.

The information in this document may contain predictive statements including, without limitation, statements regarding the future financial and operating results, future product portfolio, new technology, etc. There are a number of factors that could cause actual results and developments to differ materially from those expressed or implied in the predictive statements. Therefore, such information is provided for reference purpose only and constitutes neither an offer nor an acceptance. XXX may change the information at any time without notice.



Course chenzomi12.github.io

GitHub github.com/chenzomi12/DeepLearningSystem