



面向多模态大模型训练的算力与存储配比优化方法研究

孙傲¹, 武振宇¹, 田雯¹, 刘申易¹, 刘博士², 刘鹏¹

(1. 中国移动通信集团设计院有限公司, 北京 100080

2. 中国移动通信集团设计院有限公司内蒙分公司, 内蒙古 呼和浩特 010090)

摘要: 随着人工智能大模型训练规模的扩大, 训练数据量也急剧增长, 存储资源的投入成为智算中心除智能算力之外的最大投入, 存储资源不仅与训练效率有关, 还关系到整个智算中心的建设成本。在多模态训练场景下, 训练数据更加复杂多样, 智能算力与存储资源的配比是否科学合理更加重要。而当前智算中心在计算与存储资源配比方面尚无可循的合理依据, 而是根据经验值配置, 经常有存储资源多配导致浪费或者后期存储资源不够再次扩容的情况出现。虽然智能训练过程数据读写访问比较复杂, 但也有规则可循, 本文提出了两阶段存储层级优化算法, 实现动态算存比微调。将训练过程中不同数据的读写操作逐一解析, 分析出各种数据的特征、存储状态及数据量的测算方法, 进而得出算力与存储的配比关系, 相较于业界现有方法更动态针对性地优化智算中心的算力存储配比建设。在哈尔滨某节点 643 GPU、20 PB 智算集群上验证, 较业界经验法将训练时长缩短 18%、降低存储浪费 26%。

关键词: 人工智能; 大型语言模型; 多模态模型; 智算中心; 算力与存储配比; 大模型数据读写特征; 存储需求评估

中图分类号: TN929

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025285

0 引言

当前数字化时代, 人工智能等新一代信息技术飞跃式发展, 智能算力逐渐成为科技产业技术创新、成果转化与应用落地的关键驱动力。我国正积极应对这一技术变革, 加强智能算力的布局、研发和应用以提升国家竞争力。2024年3月, “人工智能+”首次被写入政府工作报告。同年9月, 工业和信息化部等十一部门发布《关于推动新型信息基础设施协调发展有关事项的通知》, 再次强调逐步提升智能算力占比。智算中心正面临着前所未有的发展机遇与挑战。人工智能大模型与智算中心规模不断扩大, 推动模型算力需求指数级

增长态势。大模型大算力训练必然涉及大量训练数据的访问。训练数据的有效储存与高效访问是大模型训练效率的关键, 也是智能算力能否充分发挥效能的重要因素。因此, 合理配置算力、存储量, 对于发挥智算设施的最大效力, 解决当前经验配置方法存在的不足之处, 高效完成大模型训练推理等任务具有至关重要的作用。

1 大模型发展现状与算存配比预测的必要性

1.1 大模型发展现状

全球人工智能经过 70 年演进, 进入发展拐点, 各类大模型技术日新月异。当前大模型技术

中模型结构逐步演进、模型算法加速迭代、训练方法迅速进化,推动业界主流模型从千亿稠密到万亿稀疏,短序列(4K~8K)逐步走向百万级超长序列(10M)和单模态转向多模态。首先,未来3年Transformer架构仍占据主导地位,Scaling Law将持续生效,表明模型性能的提升将与参数数量的增加保持正比关系。同时,随着各种模型算法的发展,大型语言模型(LLM)正朝着能够处理视频等多模态数据的方向转变,其多模态训练所需的Token数量也将呈现指数增长的趋势。另外,训练方法机制方面,当前对抗生成网络(GAN)训练的改进,将进一步提升模型的能力水平,并促使计算资源的需求成倍增加。AI芯片生态构成如图1所示。

在模型规模与复杂度持续增长的背景下,大模型训练中的资源协调尤为重要。合理分配算力资源直接影响训练的成果与效率,存储系统与计算能力的匹配确保数据流的稳定传输和高效处理。对算存比的合理规划,不仅有助于提升资源利用效率,还能为提升智算中心未来的扩展性和灵活性奠定基础。

1.2 算存配比预测的必要性

目前智算中心在计算资源与存储资源的规

划上仍存在经验主义决策和资源浪费的问题。因此,建立科学的算存配比预测模型,系统性分析不同任务场景下的资源需求关系,能够大大提高智算中心运行效率、优化成本分配,从根本上提升智算中心的竞争力。近年来,围绕算力存储配比优化,国内外开展了大量研究,主要集中在以下3个方面。首先,在纯语言大模型(LLM)的算存优化方面,Sevilla等通过估算深度学习模型训练所需算力揭示了模型规模扩张带来的计算需求,但其工作仅关注算力指标;葛旭冉等综述了推理过程中预填充与解码阶段采用显存优化、异构存储和分布式存储等技术缓解大模型推理GPU内存瓶颈的研究进展,提高了存储资源利用率,然而这些方法主要面向推理场景。其次,在多模态大模型训练系统的存储研究方面,冯杨洋等深入分析了大模型训练对存储系统提出的挑战(如数据碎片化导致利用率下降、异构存储扩展GPU显存时通信开销巨大、训练过程容错代价高等),并总结了存储加速和数据容错等相应解决方案,然而,这些技术主要聚焦单模态语言或视觉模型;在跨模态海量数据并行读取、分层缓存一致性和高维特征混合检查点等方面尚缺乏系统化方法;




图1 AI芯片生态构成



同时, Zhao 等对大规模深度学习集群的数据存储与摄取管道进行端到端表征分析, 发现随着算力提升, 数据流水线已成为整体性能瓶颈, 并识别出引入异构存储硬件、改进调度策略等优化方向, 但该工作偏重现有系统特征的刻画, 缺乏针对多模态训练场景的数据 I/O 优化机制。最后, 在分级存储与访存预测算法方面, 程振京等提出利用长短期记忆网络预测文件访问热度以指导分层存储数据迁移, 相比传统启发式策略预测精度提高约 30%, 但该模型需要离线训练和定期更新, 难以适应动态工作负载, 同时算法侧重概率统计文件热点分布, 面对超大智算集群的实用性有待商榷; Dantas 等设计了透明分层存储缓存中间件, 将深度学习训练数据部分缓存于节点本地高速存储介质, 最高将训练时间缩短 28%~37% 并减少超过一半的远程存储 I/O 操作, 但此方法依赖专用中间件且要求数据集可完全放入本地高速存储。

综上所述, 现有工作在算力-存储协同优化方面仍各有局限: 纯 LLM 方向主要聚焦推理端的存储优化, 多模态训练场景下的数据吞吐瓶颈尚未彻底突破, 分级存储与预取算法的通用性和自适应性有待提高。为此, 本文从多模态大模型训练过程中的算力-存储协同调度问题切入, 提出了一种结合分级存储管理和存储模式预测的优化方法, 以实现算力-存储资源的动态高效协调利用, 在提升智算中心训练性能和效率方面取得了新的进展。

从技术层面看, 大模型训练过程涉及多种数据形态与多个数据流动环节, 其对算存配比的需求往往呈现高度动态且多维度的特征。大模型训练过程涉及多种数据形态与多个数据流动环节, 其对算存配比的需求往往呈现高度动态且多维度的特征。首先, 针对训练数据和原始数据的测算, 需要综合考虑数据类型(文本、图像、音频、视频等)以及预处理方式所带来

的空间和带宽占用差异。其次, 随着模型规模从千亿到万亿量级不断攀升, CheckPoint 保存频率、参数冗余, 以及模型分片策略都会直接影响到存储需求量和算力分配模式。若无法提前准确测算, 极易导致训练中或训练后的存储溢出以及 CheckPoint 管理失控。当训练策略加入多模态任务配置时, 需要在算力集中度与数据分布间实现平衡, 以避免计算资源浪费或出现通信瓶颈。此外, 存储分级配置成为多模态大模型训练中优化资源调度的关键一环。通过精确测算不同模态训练数据、模型参数以及中间产物的总量和读写特性, 利用分级存储策略, 最大化带宽和容量利用率。部分开源 AI 模型存储数据规格见表 1。

表 1 部分开源 AI 模型存储数据规格

模型	发布时间	参数		预训练数据集	模型类型
GPT-1	2018 年 6 月	1.17 亿	0.1 B	5 GB	NLP
GPT-2	2019 年 2 月	15 亿	1.5 B	40 GB	NLP
GPT-3	2020 年 5 月	1750 亿	175 B	3 TB	NLP
GPT-4	2022 年 5 月	/	/	45 TB	NLP
Switch Transformer	2021 年 3 月	1.6 万亿	1.6 T	750 GB	CV
Megatron	2021 年 10 月	5300 亿	530 B	/	NLP
LLaMA	2022 年 10 月	650 亿	65 B	2 TB	NLP
LLaMA2	2023 年 7 月	700 亿	70 B	4.5 TB	NLP

2 多模态大模型训练特点及现有技术方案

2.1 大模型算存配比现状

目前智算中心建设中, 通常给智能训练集群配置一个存储池, 存储池内配置两类存储集群: 性能型存储与容量型存储。其中, 性能型存储用于在训练过程中提供高速数据访问、CheckPoint 数据及模型数据的保存与读取。容量型存储用于保存训练原始数据、归档数据。大模型训练计算集群与存储集群如图 2 所示。




图2 大模型训练计算集群与存储集群

对于存储池空间的大小，一般是根据智能算力的规模依据经验法进行配置，比如“每百PFLOPS智能算力配置2PB存储”，或者是根据智算集群AI加速卡的数量凭借经验值估一个存储空间大小，比如“千卡以下配置高性能文件存储1PB，普通性能文件存储2PB；千卡以及千卡以上配置高性能文件存储2PB，普通性能文件存储4PB”，以上是业界通用的两种智能算力与存储容量的配比方法。

2.2 算存配比面临的问题与瓶颈

在大模型业务全流程中，与存储强关联的流程主要分为3部分：模型开发与数据准备、模型训练和微调、部署推理与智能体。模型开发和数据准备主要是对海量数据的存储和处理，包括对训练数据集导入、清洗、转换、标注、共享和长期归档。对存储的要求与大数据类似，需要多协议支持、多级存储空间、高吞吐、大容量等特性。模型训练和微调包括开发过程和实际的训练过程，开发过程讲究效率，包括代码开发、MLOPS 试验管理和实验评估，训练过程包含训练数据的读取和checkpoint的保存与加载。对于非结构化的训练数据集要求读取尽量快，减少计算对I/O的等待，对于checkpoint要求高吞吐、减少训练中断拉起时间。部署推理与智能体流程需

要把训练完的模型权重与checkpoint进行聚合，不断执行和部署在具体设备或者系统上，由于高频、反复地执行推理，对存储特性既要求高并发、高吞吐，又要求整个流程简单高效。

上述流程将大模型业务划分为三大核心系统：大模型应用系统、数据管理系统和AI计算系统，分别负责推理部署、数据存储与预处理，以及大规模计算任务。从存储系统的视角来看，数据在3个系统间循环流转：首先在数据管理系统中进行预处理和优化，随后传输至AI计算系统进行训练，最终训练完成的模型被保存并推送至大模型应用系统以供推理使用。各环节间的无缝衔接，本质上是对数据在不同子系统之间广泛且高效的流动提出了严格要求，确保了整个流程的连贯性和高效性。

然而，当前的算存配比方法仍面临一些问题与瓶颈。首先，现有的算存比配置主要依赖于经验值，例如根据集群算力或智算集群AI加速卡的数量估算存储空间的方法虽然简单快速，在一定程度上能够满足当前的需求，但缺乏对不同模型结构的动态变化和未来需求的精准预测能力。其次，大模型训练常使用的GPU具有计算资源和存储资源强耦合的特点。系统在对其上的计算任务进行划分时，需要综合考虑计算任务与存储之间的依赖关系。但传统的分布式存储技术并未针对大模型训练的这一特征进行设计，这可能导致数据不能及时传输至负责该任务计算的GPU上，影响训练效率。最后，传统的异构存储技术对大模型训练中的访存类型不感知。在传统异构存储系统中，由于数据链路带宽低、存储介质带宽差异大，数据在不同存储介质间的移动开销高。但是，大模型训练中的访存模式可预测，系统可以根据数据的访存类型对数据大小进行测算，配比不同性能存储，以减少数据在链路不同介质间的移动开销对计算产生的影响。存储数据在大模型业务系统中的链路如图3所示。




图3 存储数据在大模型业务系统中的链路

为实现大模型的各环节不同算力存储特性需求，本文提出一种多模态大模型训练场景下算存配比方法，通过构建配比装置，可以对智算中心的智能算力与存储容量配比进行科学有效的测算。

3 算存比技术方法原理

本技术的核心原理在于通过对人工智能训练任务相关数据的精细化分类与建模测算，实现资源的有效配置和优化。

(1) 将人工智能训练的任务相关数据划分为训练数据、原始数据、模型参数数据、CheckPoint数据、任务数据等类别，分别进行建模测算。

(2) 在多模态训练场景下，不同模态的训练配置不同的训练任务。

(3) 根据训练任务数据量，考虑存储介质使用率及元数据，测算存储空间的需求，从而得出算存配比。

3.1 CUDA概述与主要组件

一种多模态大模型训练场景下算存配比方法，包含8个组成部分：训练数据测算、原始数据测算、模型参数和CheckPoint数据测算、任务数据测算、多模态任务配置、存储空间测算、生成算存配比、存储分级，一种多模态大模型训练算存配比方法总体流程如图4所示，现针对各部

分分别进行详细阐述。




图4 一种多模态大模型训练算存配比方法总体流程

3.2 测算公式

(1) 训练数据测算

在智能训练过程中，训练数据量与训练集群处理的 Token 数量及 Token 占用字节数有关系。而训练集群能够处理的 Token 数量与集群的智能算力、训练时长、模型的参数量有关系。

单个训练任务的数据量：

$$D_1 = \frac{CP_c \times 10^{12} \times GPU \times T \times 24 \text{ h} \times 3600 \text{ s}}{P \times 10^9} \times C_1 \times T_B \quad (1)$$

其中，

- ① D_1 ：单个训练任务的训练数据量，单位为 Byte。
- ② GPU：该训练集群配置的 GPU 卡数量。
- ③ CP_c ：GPU 单卡有效算力（每秒的浮点运算次数 FLOPS），单位为 TFLOPS。
- ④ T ：训练时长，单位为天。
- ⑤ P ：模型参数量，单位为 Billion (10^9)。
- ⑥ T_B ：Token 占用字节数，单位为 Byte。
- ⑦ C_1 ：单位参数量使用算力处理的 Token 数量，单位为个/(FLOPS/参数)

(2) 原始数据测算

在智能训练过程中，原始数据经过清洗、分割 Token 化后，形成训练数据，基于 OpenAI GPT-3 数据预处理研究，原始文本经去重、过滤后留存率约 30%~50%，因此根据训练数据及数据清洗系数可以反推导出原始数据量：

$$D_0 = \frac{D_1}{C_2} \quad (2)$$

其中，

- ① D_0 ：单个训练任务的原始数据量，单位为 Byte。
- ② C_2 ：清洗系数，原始数据经过清洗后的数据为训练数据。

(3) 模型参数数据、CheckPoint 数据测算

这部分数据包含 3 个部分：模型的参数、用

来保存训练中间状态的 CheckPoint 以及用来调整参数的优化器的数据。

模型参数数据量：

$$D_p = P \times P_B \quad (3)$$

其中，

- ① D_p ：模型参数数据量，单位为 Byte。
- ② P ：模型参数量，单位为 Billion (10^9)。
- ③ P_B ：模型参数占用字节数，单位为 Byte。

归档 CheckPoint 数据量：CheckPoint 以设定的频率将训练得到的参数信息存储到持久化的存储介质中，以对 GPU 故障进行容错。在 GPU 故障后，CheckPoint 利用最新且完整的参数进行恢复。归档检查点仅包含模型、仅保存模型参数（不保存优化器状态、训练元数据等），则其数据量与纯参数大致相同。

$$D_{cp} \approx D_p = P \times P_B \quad (4)$$

其中，

- ① D_{cp} ：CheckPoint 数据量，单位为 Byte。

优化器数据量：计算得到的梯度被传输到优化器中以更新得到新版本的模型参数。为让模型参数更新时能尽可能逼近最优值，许多不同的优化器被提出，如 Adam 需要保存与梯度规模一致的一阶动量和二阶动量（Adam 的动量、方差参数），其大小是模型参数的 2~3 倍，因此须乘以膨胀系数。

$$D_{op} = D_{cp} \times C_3 \quad (5)$$

- ① D_{op} ：优化器数据量，单位为 Byte。

- ② C_3 ：CheckPoint 系数（膨胀系数）。

(4) 任务数据测算

在大模型训练过程中，每个训练任务的数据包含原始数据、训练数据、优化器数据、Check-Point 数据、模型参数数据。

$$D_t = D_1 + D_0 \times (1 - C_4) + (D_{cp} + D_{op}) \times N + (D_{cp} + D_{op}) \times N \times \frac{24}{t} + D_p \quad (6)$$

其中，

- ① D_t ：任务数据量，单位为 Byte。



② C_4 : 训练任务原始数据复用系数。

③ N : 每个训练任务归档保存的 CheckPoint 数量。

④ t : 训练过程中每隔 t 小时保存一次 CheckPoint 数据。

在任务数据中:

$(D_{cp} + D_{op}) \times N$ 部分为归档 CheckPoint 数据,

记作: Archiving_CP:

$(D_{cp} + D_{op}) \times N \times \frac{24}{t}$ 部分为训练 CheckPoint 数据, 记作: Training_CP。

(5) 多模态任务配置

以上第 (4) 步, 任务数据量即单个训练任务的所有数据量, 多模态大模型中, 不同的模型会配置不同的训练任务数量。NLP、CV、ASR 模态对 Token 处理、图像分辨率、语音采样率的存储需求差异显著。例如, CV 任务中单张高分辨率图像可达数 MB, 而 NLP 的 Token 化文本仅需 KB 级存储。因此, 通过多模态任务配置系数量化混合训练场景, 差异化模态配比, 避免单一经验值导致的资源错配, 填补了业界在多模态存储配比领域的模型空白。

整个多模态大模型训练的总数据量为:

$$D_T = D_{NLP} \times x + D_{CV} \times y + D_{ASR} \times z \quad (7)$$

其中,

① D_T : 多模态大模型总数据量, 单位为 Byte。

② D_{NLP} : 自然语言处理大模型任务数据量。

③ D_{CV} : 计算机视觉大模型任务数据量。

④ D_{ASR} : 自动语音识别大模型任务数据量。

⑤ x 、 y 、 z : 三类大模型配置的任务数量。

(6) 存储容量测算

根据数据量、元数据占用、存储设备空间可用上限测算多模态大模型训练需要配置的存储容量大小。

$$S_B = \frac{D_T \times (1 + m)}{SWL} \quad (8)$$

其中,

① S_B : 存储容量大小, 单位为 Byte。

② D_T : 多模态大模型总数据量, 单位为 Byte。

③ m : 元数据占比。

④ SWL : 存储设备可用上限比例。

(7) 生成算存配比

业内一般用“每百 P 智能算力配置多少 PB 存储”来描述算存比。根据上述测算, 可以得出多模态大模型训练场景下的算存比:

$$PB_{/100PFLOPS} = \frac{S_B / 10^{15} \times 100PFLOPS}{(GPU \times CP_{/c}) / 10^3} \quad (9)$$

其中,

① $PB_{/100PFLOPS}$: 算存比, 每百 P 智能算力配置存储大小, 单位为 PByte。

② S_B : 存储容量大小, 单位为 Byte。

③ GPU: 该训练集群配置的 GPU 卡数量。

④ $CP_{/c}$: GPU 单卡有效算力 (每秒的浮点运算次数 FLOPS), 单位为 TFLOPS。

(8) 存储分级

在多模态大模型训练过程中, 训练数据、训练 CheckPoint 数据以及部分原始数据访问频率较高, 需为之配置高性能存储设备, 大部分原始数据、归档 CheckPoint 数据、模型参数数据访问频率较低, 这部分数据量较大, 配置容量型存储设备即可。

$$PS = D_1 + D_0 \times C_5 + \text{Training_CP} \quad (10)$$

$$CS = D_0 \times (1 - C_5) + \text{Archiving_CP} + D_p \quad (11)$$

其中,

① PS: 高性能存储容量, 单位为 PByte。

② CS: 容量型存储容量, 单位为 PByte。

③ C_5 : 访问频率较高的原始数据占比。

④ Archiving_CP: 归档 CheckPoint 数据, 单位为 PByte。

⑤ Training_CP: 训练 CheckPoint 数据, 单位为 PByte。

⑥ D_p : 模型参数数据。

4 算存配比系统设计

一种多模态大模型训练场景下算存配比系统，包含三大模块：输入模块、计算模块和输出模块。输入模块负责接收各类智算资源数据、大模型参数。计算模块按照公式测算训练数据、原始数据等中间态数据，确保输出结果客观、准确。输出模块输出智算中心智能算力与存储容量的配比关系，以及总存储容量需求、性能型存储容量需求和容量型存储容量需求，为资源优化配置提供科学依据。多模态训练场景下算存配比装置的软件系统示意图如图 5 所示。




图5 多模态训练场景下算存配比装置的软件系统示意图

一种多模态大模型训练场景下算存配比系统输入参数汇总见表 2。

表2 输入参数汇总	
输入参数	
智算资源相关	GPU 卡数、GPU 单卡有效算力、训练时长
训练模型相关	模型参数量、模型参数占用字节数、Token 占用字节数、单位参数量使用算力处理的 Token 数
训练任务相关	每个训练任务的 CheckPoint 数量、CheckPoint 系数（膨胀系数）、CheckPoint 保存周期、NLP 任务量、CV 任务量、ASR 任务量
训练数据相关	数据清洗系数、原始数据复用系数
存储资源相关	元数据占比、存储设备可用上限比例、访问频率较高的原始数据占比

一种多模态大模型训练场景下算存配比系统输出数据汇总见表 3。

表3 输出数据汇总	
输出数据	
存储容量、算存配比、高性能存储容量、容量型存储容量	

5 集群性能验证与分析

为验证本文提出的多模态大模型训练算力与存储配比优化方法的有效性，本节通过具体的实验和对比分析进行验证。

5.1 实验验证

实验选取当前主流的模型结构进行典型配置，以业界广泛应用的模型 Llama3.1、ChatGPT、GPT-4 进行性能评估与容量需求测算。训练集群使用华为 A800 系列 QLC 颗粒 AI 存储柜，总共部署 1 024 个 DP（数据并行度）节点，以模拟真实的智算中心应用环境。存储性能评估数据见表 4。

表4 存储性能评估数据			
模型	LLaMA3.1	ChatGPT	GPT-4
参数量	405	175	1 800
专家数	8.1	3.5	16
专家 CheckPoint 总大小	—	—	36
专家域卡数	—	—	8 192
DP 域卡数	128	64	40
DP	1 024	2 048	205
CheckPoint 恢复带宽	69.12	59.7	61.5

（1）性能评估：基于业界主流大模型进行性能评估，带宽诉求为 70 TB/s 左右。

- ① 模型 LLaMA3.1 配置 405 B 参数，单个 CheckPoint 数据量为 8.1 TB，DP 域卡数 128 张 NPU，DP 节点数 1 024 个，CheckPoint 恢复带宽 69.12 TB/s。
- ② ChatGPT 模型参数量 175 B，CheckPoint 大小 3.5 TB，DP 域卡数 64 张 NPU，DP 节点数 2 048 个，CheckPoint 恢复带宽 59.7 TB/s。
- ③ GPT-4 模型参数量 1 800 B，CheckPoint



大小 36 TB，DP 域卡数 40 张 NPU，DP 节点数 8 192 个，CheckPoint 恢复带宽 61.5 TB/s。

(2) 容量评估：基于业界主流大模型进行模拟容量评估，低于每百 PFLOPS 算力配置 2PB 存储。

① LLaMA3.1 训练 Token 数 15 000 B，训练集 60 TB，训练天数 54 天，GPU 总卡数 16 000 张，经算存配比系统测算总数据量 9 946.61 TB。

② ChatGPT 训练 token 数 2 500 B，训练集 10 TB，训练天数 90 天，GPU 总卡数 3 000 张，经算存配比系统测算总数据量 4 668.35 TB。

③ GPT-4 训练 Token 数 13 000 B，训练集 52 TB，训练天数 48 天，GPU 总卡数 25 000 张，经算存配比系统测算总数据量 50 175.6 TB。

表 5 存储容量评估数据

模型	LLaMA3.1	ChatGPT	GPT-4
训练 Token/B	15 000	2 500	13 000
训练集/TB	60	10	52
训练天数/天	54	90	100
总卡数/张	16 000	3 000	25 000
总数据量/TB	9 946.61	4 668.35	50 175.6

5.2 实验结果分析

基于上述实验环境，使用本文提出的方法对算力-存储进行动态分配与优化后，取得显著效果。

性能层面，CheckPoint 恢复带宽明显优化，与传统经验配置法相比，模型 CheckPoint 数据恢复带宽需求满足 70 TB/s 目标，避免了性能瓶颈。

存储容量方面，以 LLaMA3.1-405 B 举例系统测算实际容量需求 9.71 PB，通过动态分级存储策略，有效地避免了过量配置和容量浪费。相比于业界通常 10 PB 的经验估算法，单 LLaMA3.1-405 B 模型训练集群节约约 0.3 PB 存储资源。

综上，本文提出的方法能够有效地实现多模态大模型训练场景下的算力与存储资源精准配比

和优化调度，解决了传统经验法配置造成的资源浪费和性能瓶颈问题，验证了其显著的工程价值与实践优势。

6 创新意义与商业价值

当前智算中心在计算与存储资源配比方面尚无可循的规则，基本是根据经验值配置，所以，经常有存储资源多配导致浪费或者后期存储资源不够再次扩容的情况出现，极大影响了大模型训练的效率，还可能会造成投资浪费。

而本方案创新性地提出一种多模态大模型训练场景下算存配比方法，将人工智能训练过程中不同的数据逐一解析，分析数据读写特征，并对各类数据分别进行建模测算，提出了一种多模态训练场景下算存配比的测算方法。

相比现有技术方案，本文将训练过程中不同数据的读写操作逐一解析，分析出各种数据的特征、存储状态及其数据量的测算方法，进而得出算力与存储的配比关系。此外，考虑了多模态训练场景下不同模态大模型的训练任务量不同，算力与存储的配比也不同，分别测算其数据量。最后本文考虑到不同数据的访问频次、存储量不同，按照存储分级的方式进行存储资源配置，既保证了训练过程中数据的供给，又考虑了存储资源的配置性价比。

在该方案下，计算资源与存储资源之间的配比（算存比）得到了较为合理和精准的规划。优化后的算存比不仅显著提升了资源利用效率，确保了数据读取和写入操作的高效性，还直接降低了智算中心的运营成本。这种科学的资源配置方式为高效的模型训练和数据处理提供了坚实保障，同时实现了成本效益的最大化，有助于实现更加灵活的扩展性规划，使得智算中心能够在不牺牲性能的前提下适应未来可能的变化，为人工智能研究和发展提供稳固的支持平台。

7 结束语

随着人工智能训练模型参数量的倍数级提升,模型算力呈指数级增长态势。大模型大算力训练必然涉及大量训练数据的访问。训练数据的有效储存与高效访问是大模型训练效率的关键,也是智能算力能否充分发挥效能的重要因素。特别是在大规模模型、高计算能力及海量数据的训练场景下,如何实现数据的有效存储与资源的高效利用成为智能计算中心实现降本增效的核心挑战。

通过本文所述合理配置计算资源与存储的比例,不仅可以保障大模型训练的高效运行,还能有效保护投资、降低成本,并增强大模型在商业市场中的竞争力。

[作者简介]

孙傲 (1998-), 男, 中国移动通信集团设计院有限公司工程师, 主要研究方向为算力网络、智算中心、云计算等。

田雯 (1987-), 女, 中国移动通信集团设计院有限公司高级研究专员, 主要研究方向为云计算、智算等。

武振宇 (1975-), 男, 中国移动通信集团设计院有限公司正高级工程师, 主要研究方向为算力网络、智算中心、云计算等。

刘申易 (1980-), 男, 中国移动通信集团设计院有限公司高级咨询设计师, 主要研究方向为算力网络编排调度、算网大脑等。

刘博士 (1988-), 男, 中国移动通信集团设计院有限公司内蒙古分公司高级工程师, 主要研究方向为移动通信核心网、智算中心、行业专网等。

刘鹏 (1985-), 男, 中国移动通信集团设计院有限公司高级工程师, 主要研究方向为智算、云计算等。