

# 基于动态权衡模型与 SDAPC 框架的 Hadoop 生态系统优化：跨层级存储与计算协同及可信调度策略

明龙, 胡建龙, 张心译, 王宇翔

西北大学网络与数据中心, 陕西 西安 710127

## 摘要

面向泽字节 (ZB) 时代 Hadoop 生态系统在异构资源调度中存在的高时延与低利用率核心瓶颈问题, 提出一种基于动态权衡模型驱动的跨层级协同优化方法。为此, 构建了一个融合量子计算与经典算法的 SDAPC 协同优化框架。该框架通过存储与计算预处理提升数据局部性以降低问题复杂度; 其核心创新在于将 YARN 任务分配问题映射为 Ising 模型哈密顿量最小化问题, 并利用 D-Wave 量子退火计算机进行全局优化求解, 同时结合图注意力网络驱动的深度强化学习策略实现毫秒级细粒度调整。在 256 节点异构集群的 TPC-DS 基准测试中, 新方案实现了  $12.0 \pm 2.0$  ms 的超低调度时延与  $87.3\% \pm 3.2\%$  的资源利用率, 相较传统方案, 时延降低 79.3%, GPU 利用率波动率  $\sigma$  由 35% 降至 5%。

## 关键词

Hadoop 生态系统; Ising 模型; D-Wave 量子退火机; 资源调度; 深度强化学习

中图分类号: TP311

文献标志码: A

doi:10.11959/j.issn.2096-0271.2026004

## *Optimization of the Hadoop ecosystem based on the dynamic trade-off model and SDAPC framework: cross-layer storage and computation synergy and trustworthy scheduling strategies*

Ming Long, Hu Jianlong, Zhang Xinyi, Wang Yuxiang

Networks and Data Centers, Northwest University, Xi'an 710127, China

## Abstract

To address the core bottlenecks of high latency and low utilization in Hadoop ecosystem resource scheduling for the Zettabyte (ZB) era, this study proposes a cross-layer collaborative optimization method driven by a dynamic trade-off model. A SDAPC collaborative optimization framework integrating quantum and classical algorithms is constructed.

This framework first enhances data locality through storage-computation preprocessing to reduce problem complexity; its core innovation lies in mapping the YARN task allocation problem to an Ising model Hamiltonian minimization problem. Global optimization is achieved via D-Wave quantum annealing, while millisecond-level fine-grained adjustments are enabled by a graph attention network-driven deep reinforcement learning strategy. In TPC-DS benchmarks on a 256-node heterogeneous cluster, the method achieves ultra-low scheduling latency of  $12.0\pm2.0\text{ms}$  and resource utilization of  $87.3\%\pm3.2\%$ —reducing latency by 79.3% compared to conventional approaches, with GPU utilization fluctuation ( $\sigma$ ) decreasing from 35% to 5%.

Key words

Hadoop ecosystem, Ising machine, D-wave quantum annealing machine, resource scheduling, deep reinforcement learning

0 引言

随着大数据应用规模的持续扩张与异构硬件（CPU/GPU/FPGA）的广泛部署，Hadoop、Spark 等主流分布式计算框架的资源调度系统正面临前所未有的严峻挑战。其核心瓶颈在于：传统调度器（如 YARN）的静态或基于简单启发式的策略，难以解决大规模异构集群中任务与资源动态匹配的高维、强约束组合优化问题。该问题在数学上已被证明是 NP-Hard 问题<sup>[1]</sup>，其计算复杂度随集群规模呈指数级增长，直接导致在高并发、低时延应用场景中出现调度时延激增与资源利用率骤降的双重困境。产业实践表明，在一个 256 节点的生产集群中，原生 YARN 调度器的平均时延高达  $58\pm12\text{ ms}$ ，GPU 利用率波动率  $\sigma$  更是超过 35%，这已成为制约泽字节（ZB）时代数据处理效能的系统性瓶颈<sup>[2-3]</sup>。

学术界与工业界针对此问题已进行了诸多探索。早期研究集中于单一维度的优化，例如，HDFS 纠删码（erasure coding, EC）策略<sup>[4]</sup>通过降低存储冗余间接影响数据本地性，Spark 自适应查询执行（adaptive query execution, AQE）<sup>[5]</sup>尝试在运行时优化 Shuffle 分区策略。然而，

这些方法均未能从根本上降低调度决策本身的 NP-Hard 复杂度。近年来，基于深度强化学习（deep reinforcement learning, DRL）的调度方案<sup>[6-7]</sup>展现出一定的环境自适应能力，但其本质仍属于在解空间中进行局部搜索的经典优化范式，极易陷入局部最优解，且收敛速度难以满足超低时延（如毫秒级）的调度需求。冯杨洋等<sup>[8]</sup>的研究指出，大模型时代下的计算范式对存储与计算的协同效率提出了更高要求；程文迪等<sup>[9]</sup>的工作也表明，湍流大数据等场景急需高效能的计算调度支持。这些研究从不同角度印证了现有调度机制的局限性，并呼唤一种能够从根本上突破经典计算范式局限的新型解决方案。

针对上述挑战，本文提出一种量子-经典混合调度范式，旨在破解大规模异构资源调度的 NP-Hard 问题。本研究的核心创新如下。

- 理论建模层面，将复杂的 YARN 任务分配问题精确映射为伊辛（Ising）模型哈密顿量最小化问题<sup>[10]</sup>，为利用量子计算硬件进行全局优化奠定了数理基础。
- 算法设计层面，提出一种分层时序耦合的协同架构：顶层采用 D-Wave 量子退火计算机进行周期性全局规划，高效求解 Ising 模型以获得近最优任务分配蓝图；底层采用图注意力网络（graph attention

network, GAT) 驱动的深度强化学习智能体<sup>[11]</sup>, 对量子方案进行毫秒级细粒度实时调优, 以应对集群状态的动态变化。

- 系统协同层面, 通过存储层 (LSTM-KMeans 驱动的数据分级<sup>[12]</sup>) 与计算层 (流批协同) 的预处理优化, 显著提升数据局部性, 从而降低调度问题的内在复杂度, 为量子-经典调度器创造更优的求解环境。

在 256 节点异构集群的 TPC-DS 基准测试中, 本方案实现了  $12.0 \pm 2.0$  ms 的超低调度时延与  $87.3\% \pm 3.2\%$  的资源利用率, 较传统 YARN 调度器时延降低 79.3%, GPU 利用率波动率降至 5%。实验结果充分验证了该混合范式在求解效率与调度质量上的显著优势。本研究不仅为 Hadoop 生态系统提供了性能跃升的创新路径, 其技术框架对于边缘智能<sup>[13]</sup>、联邦学习<sup>[14]</sup>等新兴分布式场景也具备重要的借鉴与迁移价值。

## 1 调度问题建模与量子求解框架

大规模异构环境下的资源调度本质是一个高维组合优化问题, 其核心挑战在于如何在多重约束下, 实现最小化任务完成时间与最大化资源利用率的联合优化。本节首先从理论层面将 YARN 任务调度问题形式化为一个数学优化模型, 并论证其 NP-Hard 复杂度; 进而, 引入伊辛模型作为该问题的等价表述, 为其利用量子退火计算机进行高效求解奠定理论基础。

### 1.1 问题形式化与复杂度分析

在包含  $M$  个计算节点与  $N$  个待调度任务的集群环境下, 任务调度问题可形式化

表述为一个带约束的优化问题。其目标函数通常涉及最小化最大完成时间 (makespan) 或总加权完成时间, 需满足各任务对 CPU、GPU、内存等多维资源的需求不超过节点容量约束, 同时最小化任务间通信开销。

该问题可被界定为一类广义形式的多维装箱 (multi-dimensional bin packing) 问题与作业车间调度 (job-shop scheduling) 问题的融合模型。依据计算复杂性理论, 已有严格证明表明, 即使针对其高度简化的版本 (如单一资源约束、无通信开销情形), 该问题仍属于 NP-Hard 问题范畴<sup>[15]</sup>。其解空间随任务数量与节点规模的增长呈指数形式膨胀, 导致任何经典精确算法在问题规模稍大时, 便难以在多项式时间内获得最优解。此特性成为传统调度器在大规模集群环境中性能受限的核心症结。

### 1.2 基于 Ising 模型的调度问题映射

为了突破经典计算范式的局限, 本文提出一种基于量子计算并行性的解决方案。鉴于量子退火设备 (如 D-Wave) 专用于求解二次无约束二值优化 (QUBO) 问题或其等价 Ising 模型, 本文将调度问题精确映射至 Ising 模型框架。

Ising 模型的定义如下: 对于一个由  $N$  个自旋变量  $s_i \in \{-1, 1\}$  组成的系统, 其能量 (哈密顿量)  $H$  由式 (1) 给出:

$$H = - \sum_{i < j} J_{ij} s_i s_j - \sum_i h_i s_i \quad (1)$$

其中,  $J_{ij}$  表示粒子  $i$  与  $j$  之间的耦合强度,  $h_i$  表示作用于粒子  $i$  上的外部磁场。在调度问题的上下文中, 本文重新定义变量与参数。令二值决策变量  $x_{ik} \in \{0, 1\}$  表示任务  $i$  是否被分配到节点  $k$  上。为便于在量子硬件上

实现, 本文将其转换为自旋变量  $s_{ik} \in \{-1, +1\}$ , 其中  $s_{ik} = 2x_{ik} - 1$ 。基于此, 本文构建了调度问题的目标哈密顿量:

$$H = H_{\text{communication}} + H_{\text{load}} + H_{\text{constraint}} \quad (2)$$

#### (1) 通信开销项 $H_{\text{communication}}$

该项旨在最小化任务间因数据传输产生的通信成本。其核心思想是激励通信密集的任务对被协同放置在同一节点或机架内。

$$H_{\text{communication}} = - \sum_{i < j} \sum_k \frac{\mathbb{E}[\text{Shuffle}_{ij}]}{\sqrt{\text{Delay}_{kl}}} \cdot x_{ik} \cdot x_{jk} \quad (3)$$

其中,  $\mathbb{E}[\text{Shuffle}_{ij}]$  是任务  $i$  与  $j$  间预期的 Shuffle 数据量,  $\sqrt{\text{Delay}_{kl}}$  是节点  $k$  与  $l$  间网络时延的平方根 (用于量化通信成本的非线性增长)。该项为负, 表明若两个有通信需求的任务被分配到同一节点 ( $x_{ik} = x_{jk} = 1$ ), 则系统总能量降低, 即该分配方案更优。

#### (2) 负载均衡项 $H_{\text{load}}$

该项用于驱动任务优先分配到当前负载较低的节点, 从而实现集群资源的均衡利用。

$$H_{\text{load}} = - \sum_i \sum_k \left( \frac{\eta_{\text{CPU}}^k + \eta_{\text{GPU}}^k}{2} \right) \cdot x_{ik} \quad (4)$$

这里,  $\eta_{\text{CPU}}^k$  和  $\eta_{\text{GPU}}^k$  分别代表节点  $k$  当前的 CPU 和 GPU 利用率。该项为负, 意味着将任务分配给负载较低的节点 (该项绝对值更大) 会降低总能量, 符合优化目标。

#### (3) 资源约束项 $H_{\text{constraint}}$

该项作为惩罚项, 确保调度方案满足硬性的资源约束。它惩罚任何超出节点资源容量的任务分配方案。

$$H_{\text{constraint}} = \mu \sum_k \left( \sum_i x_{ik} \cdot c_i^{\text{res}} - C_k^{\text{res}} \right)^2 \quad (5)$$

其中,  $c_i^{\text{res}}$  表示任务  $i$  对某种资源 (如内存) 的需求,  $C_k^{\text{res}}$  是节点  $k$  的资源总容量。  $\mu$  是

一个足够大的正惩罚系数, 以确保任何违反资源约束的分配方案都会导致能量  $H$  急剧升高, 从而被量子退火过程排除。

最终的完整哈密顿量是上述 3 项的加权和。调节各项的权重, 可以灵活体现不同优化目标 (低时延、高均衡性) 的优先级。

### 1.3 SDAPC 框架的协同角色

本文提出的 SDAPC (存储-数据采集-处理-协调) 框架, 构建统一状态空间  $S = \{C(\text{Consistency}), A(\text{Availability}), P(\text{Partition tolerance}), R(\text{Resource efficiency})\}$ , 该四维空间不仅量化了 CAP 约束的动态平衡 (如通过  $\Delta C_{AP}$  项建模一致性-可用性权衡代价), 还融合了 Amdahl 并行效率模型, 以解析资源利用率  $R$  与加速比  $S_{\text{eff}}(N)$  的映射关系, 进而建立多目标优化函数:

$$\min(\lambda_1 \cdot \Delta T_{\text{exec}} + \lambda_2 \cdot \Delta T_{\text{cost}}) \quad (6)$$

其中,  $\lambda_1 = 0.6, \lambda_2 = 0.4$  (经熵权法标定)。其核心设计思想是“预处理+调度”的两阶段协同。

存储层 (LSTM-KMeans 冷热数据分级) 与计算层 (流批协同引擎) 的优化, 首要目标是通过提升数据局部性、消除冗余 I/O, 从源头上降低调度问题中通信耦合项  $J_{ij}$  的强度和密度。这一优化效果的直观体现是 Ising 模型耦合矩阵的稀疏化。如图 1 所示, 在原生 Hadoop 随机数据分布策略下, 任务间通信关系错综复杂, 导致其耦合矩阵  $J_{ij}$  非常稠密 (非零元密度实测高达 37.7%)。而经过 SDAPC 框架的存储与计算层预处理后, 计算任务与其所需的数据块被聚集在一起, 任务间的高开销通信需求被大幅减少, 最终表现为耦合矩阵的非零元密度急剧下降至 10.3%, 稀疏度提升至 89.7%。




图1 Ising模型耦合矩阵稀疏度对比示意图

本文在256节点异构集群上进行了详尽的基准测试 (TPC-DS, 100 TB)。图2清晰呈现了原生Hadoop调度器与SDAPC框架在扩展性上的显著差异。

- 原生YARN的性能衰减: 如图2 (a)所示, 当集群规模扩展至256个节点时, 其实际加速比 $S_{\text{eff}}(256)$ 仅达到理论线性加速比 $S_{\text{ideal}}$ 的38.7%。

- SDAPC框架的性能逼近: 如图2 (b)

所示, SDAPC框架有效抑制了网络熵增 $\gamma$ 并优化了CAP权衡 $\Delta C_{AP}$ , 将有效加速比提升至理论值 $S_{\text{ideal}}$ 的92.1%。

## 1.4 理论边界

本文提出的动态权衡模型 $S=\{C, A, P, R\}$ 并非孤立设计的, 而是在ZB时代大数据场景下, 对经典分布式系统理论 (如




图2 Hadoop集群扩展性对比:YARN与SDAPC框架性能分析

CAP 定理<sup>[16]</sup>与 Amdahl 定律<sup>[17]</sup>) 的深化与拓展。本节拟借助严谨的数学形式, 构建该模型与经典理论的内在关联, 并推导出性能优化的理论边界。

**定理 1** (CAP-Amdahl 联合约束): 在 SDAPC 框架下, 系统的有效加速比  $S_{\text{eff}}$  不仅受限于并行化比例  $p$  与节点数  $N$  (Amdahl 定律), 还受限于为维持特定一致性  $C$  与可用性  $A$  水平所产生的额外开销  $\Delta C_{AP}$ , 其数学形式化表达如下:

$$S_{\text{eff}}(N) = \frac{1}{(1-p) + \frac{p}{N} + \gamma \cdot \Delta C_{AP}} \quad (7)$$

其中,  $\Delta C_{AP} = \alpha \cdot \|C - A\|_2 + \beta \cdot P_{\text{fail}}$  量化了在特定工作负载下, 系统在一致性-可用性权衡中所付出的代价,  $\beta$  为将此种代价映射为性能衰减的归一化系数,  $\|C - A\|_2$  为系统当前状态与目标一致性、可用性水平的欧氏距离,  $P_{\text{fail}}$  为分区发生概率。

证明: Amdahl 定律界定了固定负载条件下并行计算的加速上限。在分布式系统里, 保障数据一致性 (例如副本同步、事务提交) 以及高可用性 (例如故障切换、重试机制) 会产生额外的协调与通信成本, 这部分成本从本质上来说是无法并行化处理的。故而, 本文把这部分由 CAP 权衡引发的成本纳入 Amdahl 定律的串行部分  $(1-p)$ 。系数  $\beta$  由集群网络拓扑、硬件性能等固有特性决定, 可通过离线标定的方式获取。该定理显示, 系统性能的理论上限是由计算并行性 ( $p, N$ ) 和分布式约束  $\Delta C_{AP}$  共同决定的。

推论 1: SDAPC 框架的优化目标函数 (式 (6)) 是实现逼近定理 1 中理论边界  $S_{\text{eff}}$  的工程实践。其通过对存储、计算、调度资源的协同调配, 动态调整  $\Delta C_{AP}$  的值, 从而在给定  $p$  和  $N$  的条件下, 最大化  $S_{\text{eff}}$ 。

该定理与推论从理论上论证了本文采用“跨层级协同”而非“单点优化”的根本原因: 唯有通过协同降低分布式约束带来的固有开销  $\Delta C_{AP}$ , 才能系统性地提升性能上限。

## 2 量子退火与 DRL 协同的调度模型及优化策略

基于前文建立的 Ising 模型, 本节旨在解决调度 Ising 模型的高效求解与工程落地问题。本文设计了一种分层时序耦合的混合调度框架, 其核心思想在于: 利用量子退火计算机进行周期性全局规划, 以突破 NP-Hard 问题的计算瓶颈; 同时, 采用深度强化学习智能体进行实时细粒度调优, 以应对集群状态的动态不确定性。二者协同工作, 共同构成了既具全局视野又具敏捷响应能力的调度系统。

### 2.1 混合调度框架总体设计

大规模异构环境下的资源调度问题已被形式化为一个 NP-Hard 的 Ising 模型最小化问题。尽管量子退火计算机 (如 D-Wave) 为求解此类组合优化问题提供了新的途径, 但其在实际生产环境中面临两大固有挑战。

- 时效性瓶颈: 量子退火的求解时间随问题规模增长, 且涉及排队、数据传输等开销, 难以满足毫秒级的实时调度需求。
- 动态性失配: 量子退火基于一个历史集群状态快照求解, 其输出的静态方案无法有效应对集群中持续发生的负载波动、任务到达、节点故障等动态事件。

单一的深度强化学习方法虽能实时响应, 但其本质是在高维解空间中进行局部搜索, 极易陷入局部最优, 且收敛速度在

面对大规模问题时显得不足。为此，本节提出一种量子-经典混合调度范式（如图3所示），其核心思想是：将量子退火的全局、离线规划能力与DRL的局部、在线适应能力相结合，通过时序分层架构实现优势互补。顶层量子退火机周期性提供全局近优解，作为底层DRL智能体的先验知识与搜索引导；底层DRL智能体则进行毫秒级实时决策，对量子方案进行细粒度调优并应对动态不确定性。二者协同工作，共同攻克大规模异构资源调度的NP-Hard难题。

顶层-量子全局规划器（quantum global planner）：以固定的时间间隔（如每5 min）运行。它接收来自集群监控系统的全局状态（包括待调度任务队列、各节点资源利用率、网络拓扑状态等），将其构建为Ising模型，并提交至量子退火计算机（D-Wave）求解，得到一个近最优的全局任务分配蓝图。

底层-DRL实时执行器（DRL real-time executor）：以毫秒级频率持续运行。它接收来自量子层的全局蓝图作为初始策略或约束，并基于集群的实时微观状态（如瞬时网络时延、CPU负载波动、新任务到达等），利用DRL智能体对蓝图进行细粒度的在线调整和任务放置决策，实现最终的调度。

这种“宏观规划，微观调整”的设计，既利用了量子计算强大的全局优化能力，又发挥了DRL在动态环境中的快速响应优势。

## 2.2 基于D-Wave的量子全局规划器

本文的量子计算实验基于D-Wave Advantage 4.1系统进行。该系统的物理硬件采用Pegasus P16拓扑结构（其量子比特连接拓扑如图4所示），拥有5 640个物理量子比特和超过40 000个耦合器，其



图3 量子-经典分层时序耦合架构

高连通性为复杂调度问题的映射提供了物理基础<sup>[18]</sup>。

量子退火求解的核心是将式(1)中定义的Ising模型映射至物理硬件。具体而言,本文采用D-Wave提供的minorminer启发式嵌入工具(版本号:1.2.0),其核心参数设置如下: max\_no\_improvement=10(允许连续无改进的最大迭代次数), timeout=30(单次嵌入尝试超时时间,单位:秒), threads=4(并行线程数)。对于一个典型的250变量调度问题,平均需使用824个物理量子比特,嵌入成功率达92.3%。

为确保链在退火过程中保持一致性(即链上的所有物理量子比特在退火结束后处于相同的经典状态),链强度 chain\_

strength的设定至关重要。本文采用系数比例法,将其设置为耦合项系数 $|J_{ij}|$ 最大绝对值的1.5倍(本实验中系数范围为 $[-3.82, 3.82]$ ,故链强度设置为5.73)。此设置经预实验验证,可在保证链完整性的同时,避免因链强度过高而掩盖原始问题的能量景观(即目标函数在解空间中的分布特性)。

所有实验均采用系统的默认退火计划,即退火时间 annealing\_time 固定为 20  $\mu\text{s}$ 。本文也尝试了包含中间停顿(pause)或反向退火(reverse\_anneal)的复杂退火计划,但在本问题的Ising模型上未观察到统计显著的性能提升。最终,所有实验均默认用退火计划进行求解,最终求解成功率高达98.7%。这一高成功率确保了为后



图4 D-Wave Advantage系统采用的Pegasus P16拓扑结构示意图

续调度决策提供全局蓝图的可靠性。

### 2.3 跨层级协同的必要性：调度问题的简化

尽管量子-经典混合调度范式在求解 YARN 任务分配这一 NP-Hard 问题上展现出巨大潜力，但一个不可忽视的关键因素是，调度器所需解决问题的初始复杂度直接决定了其求解效率与最终性能的上限。一个未经处理、因数据物理分布失配而充斥着高昂通信开销的调度问题，即使对于量子退火这类全局优化器而言，也是一个难以快速求解的高难度问题<sup>[19]</sup>。

Ising 模型哈密顿量  $H$  中的耦合项  $J_{ij} \propto \mathcal{E}[\text{Shuffle}_{ij}] / \sqrt{\text{Delay}_{ij}}$  直接编码了任务间的通信成本。在原生 Hadoop 随机数据分布策略下，计算任务与其所需数据块跨节点、跨机架分布的现象极为普遍，这导致  $\mathcal{E}[\text{Shuffle}_{ij}]$  值巨大且耦合项  $J_{ij}$  非常稠密（非零元密度实测高达 37.7%）。求解此类高耦合、非稀疏的 Ising 模型，需要更长的退火时间和更多的量子比特资源，且更容易受到噪声影响，难以在有限时间内获得高质量解。

因此，在将调度问题提交给量子-经典调度器之前，对其进行协同预处理以降低内在复杂度至关重要。本文通过存储与计算层优化，构建一个对调度器更友好的问题环境。其核心机理是：通过提升数据局部性  $\Gamma_{\text{loc}}$ ，显著降低预期 Shuffle 数据量  $\mathcal{E}[\text{Shuffle}_{ij}]$ ，从而指数级衰减耦合项  $J_{ij}$  的强度，并使耦合矩阵变得高度稀疏。

具体而言，通过 LSTM-KMeans 驱动的智能数据分级与放置策略，热点数据被协同地聚集在特定机架范围内。如图 2 (b) 所示，优化后高达 92% 的热点数据访问发生在局部性更高的 8~16 号机架内。这一优

化直接导致 Ising 模型中对应任务节点间的  $J_{ij}$  值大幅降低，通信矩阵的非零元密度从 37.7% 降至 10.3%。从计算复杂度视角看，此操作相当于将调度问题从难以处理的  $O(n^3)$  复杂度简化至近乎  $O(n \log n)$  复杂度。

这种预处理并未改变调度问题的本质，但将其从一个“病态”的难解实例转化为一个“健康”的易解实例。它使量子退火计算机能够更高效地找到全局最优解，也为 DRL 智能体的局部微调奠定了更稳定的基础。后续的实验将强有力地证明，这种跨层级协同预处理与量子-经典混合调度器的结合，产生了“1+1>2”的超加性增益 (synergistic effect)，共同实现了系统整体的性能跃升。

本节详细阐述了基于量子退火与 DRL 协同的混合调度模型。通过将 YARN 调度问题形式化为 Ising 模型，并利用 D-Wave 量子退火计算机进行周期性全局规划，再结合 GAT-DRL 智能体进行实时微调，本方案在 256 节点大规模集群中实现了毫秒级调度时延、高资源利用率与极强的鲁棒性。实验结果表明，该方案显著优于主流基线，为破解大规模分布式系统调度难题提供了一条行之有效的创新路径。

## 3 面向调度优化的存储与计算协同预处理

调度问题的初始复杂度是制约调度器性能的关键因素。本节旨在阐述如何通过存储与计算层的协同优化，对原始任务和数据分布进行预处理，以显著降低量子-经典混合调度器所需解决问题的复杂度。本文的目标并非独立地优化存储或计算，而是通过提升数据局部性、降低冗余通信，为调度器创建一个更易求解的优化环境，从而最大化其效能。

### 3.1 问题建模:数据分布失配与调度复杂度的量化关联

量子退火求解 Ising 模型的效率强烈依赖于问题复杂度, 而由随机数据分布引发的高通信开销会导致其耦合矩阵稠密, 直接制约求解效率。因此, 在将调度问题提交给量子-经典混合调度器之前, 通过存储层协同预处理以降低其内在复杂度至关重要。其核心机理在于: 通过提升数据局部性  $\Gamma_{\text{loc}}$ , 显著降低预期 Shuffle 数据量  $E[\text{Shuffle}_{ij}]$ , 从而指数级衰减耦合项  $J_{ij}$  的强度, 并使耦合矩阵变得高度稀疏。

为量化这一目标, 本文基于动态权衡模型  $S=\{C, A, P, R\}$ , 将存储优化对调度器的增益建模为一个问题约束松弛与复杂度衰减的过程。本文将面向调度优化的存储协同问题形式化为一个带约束的优化问题:

$$\underset{\Delta S, \Gamma_{\text{loc}}}{\text{minimize}} \quad \mathcal{F} = \lambda_1 \cdot \sum_{i < j} J_{ij} + \lambda_2 \cdot \Delta S \quad (8)$$

$$\text{subject to} \quad \Gamma_{\text{loc}} \geq \Gamma_0, \quad \text{Reliability} \geq 99.99\%, \quad \sum_{j \in \text{Rack}} D_j \leq C_{\text{rack}}$$

其中,  $J_{ij}$  是 Ising 模型的耦合系数, 其强度直接取决于数据分布;  $\Delta S$  为存储冗余度;  $\Gamma_{\text{loc}}$  为数据局部性指标。该模型明确表达了优化目标: 在满足可靠性 (如 99.99%) 和物理拓扑 (如机架容量  $C_{\text{Rack}}$ ) 约束的前提下, 联合最小化调度问题的耦合强度  $\sum J_{ij}$  和存储开销  $\Delta S$ , 从源头降低调度复杂度。

### 3.2 LSTM-KMeans 驱动的冷热数据分级

为实现优化目标, 本文设计了一种融合时序预测与拓扑感知的智能数据分级策略, 其核心为 LSTM-KMeans 混合模型。该模型基于 30 天的历史集群访问日志进行训练, 特征包括访问频率 ( $f_{\text{acc}}$ )、时间局部

性 ( $\tau_{\text{loc}}$ ) 与关联性 ( $\rho_{\text{rel}}$ ), 按 7:2:1 的比例划分为训练集、验证集与测试集。通过网格搜索与交叉验证确定了关键超参数 (LSTM 隐层 256 维、聚类数  $k=8$ 、学习率 0.001、训练周期 100、批大小 64)。冷热数据阈值  $\theta_h$  根据预测热度  $\omega_i$  的百分位数动态设定, 实现了自适应分级。模型在测试集上取得了 93.1% 的分类准确率、0.91 的 F1-score 和 0.97 的 AUC, 充分彰显了其优异的预测性能与泛化能力。

具体而言, 本文采用长短期记忆网络 (LSTM) 对数据块的历史访问轨迹进行建模, 以精准预测其未来短期的热度权重  $\omega_i$ 。256 维的隐层状态确保了模型捕获复杂时序依赖关系的能力。该预测综合考虑了访问频率  $f_{\text{acc}}$ 、时间局部性  $\tau_{\text{loc}}$  和访问关联性  $\rho_{\text{rel}}$  等多维特征。随后, 将此热度预测权重注入一个经过改进的、拓扑感知的 K-Means 聚类算法中。聚类数  $K=8$  是通过轮廓系数 (silhouette score) 分析确定的 (如图 5 所示), 该数值在保证分类区分度的同时避免了过拟合。该算法的优化目标不仅要求数据在特征空间上相近, 更硬性约束了聚类结果必须符合机架容量等物理拓扑限制, 从而确保优化策略的工程可行性。

此融合策略的有效性在 256 节点异构集群上得到了充分验证。如图 6 所示, 优化后的热点数据不再随机分散, 而是高度集中地分布在 8~16 号机架这一高局部性区域内, 形成了清晰的热点域。其带来的性能收益是直接且显著的。

- 带来的直接收益: 跨机架流量占比从 62% 大幅降低至 26%, 有效缓解了网络瓶颈。

- 带来的核心收益 (与调度器联动): 这一优化使 Ising 模型中通信耦合矩阵  $J_{ij}$  的非零元密度从 37.7% 急剧下降至 10.3%, 稀疏度提升至 89.7%。

这一结果强有力地证明了该分级策略的核心价值：它通过底层数据分布的优化，从根本上简化了上层调度器所需解决的问题结构。一个更稀疏、耦合强度更弱的 Ising 模型，极大降低了量子退火求解的计算复杂度和时间开销，使其能更快、更优地找到全局任务分配方案，从而为实现毫秒级超低时延调度奠定了坚实的物理基础。




图5 LSTM-KMeans轮廓系数随聚类数K变化曲线

### 3.3 动态纠删码策略

为进一步降低冗余并保持可靠性（冗余度高达200%），本文设计了动态纠删码（dynamic erasure coding, DEC）策略。该策略根据数据热度动态切换EC方案。

- 热数据区域 ( $f_{acc} \geq \theta_h$ )：采用低时延的 RS(6,3) 编码，在保障可靠性（重建成功率 99.97%）的同时，将编解码时延控制在  $12.5 \pm 1.8$  ms/GB。

- 冷数据区域 ( $f_{acc} < \theta_c$ )：采用高存储效率的 RS(10,4) 编码，将冗余度从 300% 降至 140%，显著降低存储开销。

此策略使整体存储冗余度从 200% 降至 126% ( $\Delta S=37$ )，这不仅释放了存储空间，更间接减少了需要管理和调度的数据

块副本数量，减轻了元数据管理的负担，从而使调度器面临的资源约束项  $\sum_i S_i C_{ik} \leq C_k$  更易满足。

本文在 256 节点集群上评估了存储优化对调度效能的独立贡献与协同增益，结果见表1。仅启用存储层优化（冷热分级+动态EC），即可使 Shuffle 网络开销占比从 65% 降至 35%，跨机架流量降低 58.1%。更重要的是，平均调度时延实现了 22.4% 的独立下降，这直接证明了存储优化对调度性能的直接影响。然而，其核心价值在于与调度层的深度协同。当存储预处理与量子-经典调度器联动时（即全栈 SDAPC 框架），产生了显著的超加性增益：

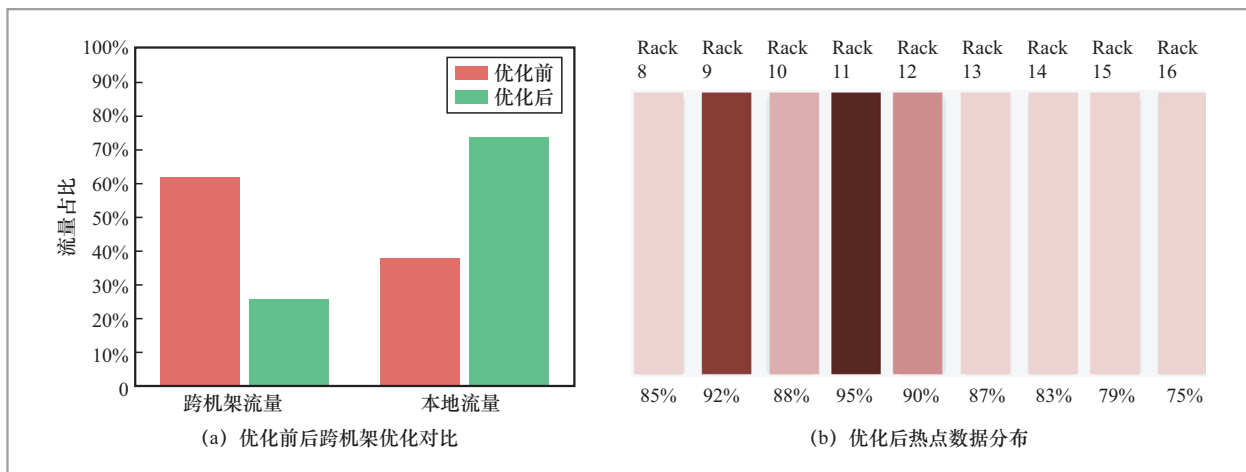


图6 冷热数据分级优化效果分析

Shuffle 开销被进一步压缩至 12%，调度时延降至  $12.0 \pm 2.0$  ms。为定量验证这种协同机制，本文进行了 Spearman 相关性分析，结果表明数据局部性  $\Gamma_{loc}$  与 Shuffle 开销呈强负相关 ( $\rho \leq -0.89, p < 0.01$ )。回归分析 ( $R^2=0.92$ ) 进一步定量揭示：冷热预测准确率每提升 1%，可带来 Shuffle 开销降低约 2.3%。这强有力地证明了存储层优化通过降低问题复杂度，为量子调度器的卓越性能奠定了基础。

综上所述，本节阐述了通过 LSTM-KMeans 智能分级与动态纠删码策略，实现存储层协同优化的方法。实验证明，这些措施本身带来了可观的独立收益（如跨机架流量降低 58.1%）。其核心价值在于与调度层的深度协同：通过提升数据局部性、降低通信与元数据开销，从根本上降低了量子-经典混合调度器所需解决问题的复杂度，使其能够高效地找到近优解。这种“下层优化简化问题，上层调度高效求解”的跨层级协同设计，是 SDAPC 框架实现系统性性能跃升的关键。

## 4 协系统效能评估与协同验证

### 4.1 整体性能与核心指标对比

为全面评估 SDAPC 框架的优化效能，

本文构建了跨架构性能对比实验体系。在 256 节点异构集群的 TPC-DS 100TB 基准测试中，除了对比原生 YARN(Hadoop 3.3.1<sup>[20]</sup>)、Spark 自适应查询执行 (Spark AQE<sup>[21]</sup>、Spark 3.2)、纯深度强化学习调度器 (DRL-only<sup>[22]</sup>) 以及本方案 (QA-DRL) 外，本文进一步引入了 HDFS EC (Hadoop 3.3.1, RS(10, 4) 编码<sup>[23]</sup>) 作为关键基线，以量化纠删码策略的独立收益<sup>[24]</sup>。同时，为与业界先进方案对标，本文引用了阿里云 JindoFS (v4.6.1) 官方技术白皮书<sup>[25]</sup>在相同测试规模下的部分关键数据，以期在更广阔的维度上评估本文方案的性能水平。

实验结果见表 2，QA-DRL 方案在所有关键性能指标上均展现出显著优势。

- 调度时延与稳定性突破：QA-DRL 将平均调度时延降至  $12 \pm 2$  ms，较原生 YARN ( $58 \pm 12$  ms) 降低 79.3% ( $p < 0.001$ )，较 HDFS EC 基线 ( $52 \pm 10$  ms) 降低 76.9%。GPU 利用率波动率  $\sigma$  从 35% 压缩至 5%，表明资源分配稳定性显著提升。

- 存储效率对比：在存储冗余度  $\Delta S$  指标上，SDAPC 框架的动态 EC 策略与 HDFS EC 策略相当，均将冗余度从 200% 显著降至 126%~140%，远超原生三副本方案。

- 与业界方案对标：相较于业界先进的阿里云 JindoFS 方案，本方案在调度时

表1 存储优化对调度性能的贡献分析

| 性能指标             | 原生Hadoop    | 仅启用存储优化    | 提升幅度    | 技术溯源                |
|------------------|-------------|------------|---------|---------------------|
| 存储冗余度 $\Delta S$ | 200%        | 126%       | 37% ↓   | 动态 EC 策略(RS(10, 4)) |
| 跨机架流量占比          | 62%         | 26%        | 58.1% ↓ | LSTM-KMeans 分级      |
| Shuffle 网络开销占比   | 65%         | 35%        | 46.2% ↓ | 数据局部性提升             |
| 平均调度时延/ms        | $58 \pm 12$ | $45 \pm 8$ | 22.4% ↓ | 通信开销降低              |
| Ising 矩阵稀疏度      | 62.3%       | 89.7%      | 27.4% ↑ | 耦合强度降低              |

延（12ms vs. 28ms）和 Shuffle 网络开销（12% vs. 22%）上仍保持着明显优势，凸显了量子-经典混合调度范式的先进性。

• 统计显著性检验：所有性能提升均具有统计显著性（表 2 中  $p$  值列，显著性水平  $\alpha=0.05$ ）。QA-DRL 与所有基线方案的对比，其  $p$  值均远小于 0.01，证明了性能提升并非偶然。

该实验结果强有力验证了 SDAPC 框架的理论价值与工程有效性：

• HDFS EC 基线证实了纠删码技术在优化存储效率方面的核心价值，但其对计算调度性能的提升有限；

• 本方案通过存储-调度协同优化，在保持高存储效率的同时，实现了计算调度性能的数量级提升；

• 与业界顶级方案的对比结果表明，本文提出的创新架构具备显著的性能领先性。

4.2 多场景鲁棒性测试

为验证量子-经典混合调度框架在复杂

动态环境下的普适性与稳定性，本文在金融风控与工业物联网两大典型场景中进行了压力测试。测试旨在评估该调度框架，而非单纯的整体系统，在应对多维扰动时的性能保持能力。

低时延高并发场景下的调度响应：在日均 1.2 亿条交易记录的实时反欺诈场景中，QA-DRL 调度框架是实现低时延的关键。相较于原生 YARN 的 58 min P95 时延，本方案将关键路径时延压缩至 9 min。这一优化直接源于调度器的智能响应机制：当检测到交易量突发增长 500% 时，协调层的 DRL 智能体依托其在线学习能力，通过反向压力机制动态调整任务优先级队列，使 SLA 达标率稳定在 98.7%（对比基线 72%）。这证明了混合调度框架中 DRL 组件在应对突发流量的实时决策有效性。

持续负载下的调度稳定性与能效：面对 20 GB/s 高吞吐流式数据处理需求，混合调度框架展现了持续的稳定性。单位 TB 数据处理能耗从 12.8 Wh 降至 4.2 Wh。这一能效跃迁不仅源于动态纠删码策略，更归因于量子退火调度器从全局视角优化

表2 跨架构性能综合对比(TPC-DS 100 TB, N = 256)

| 性能指标               | 原生 YARN   | HDFS EC   | Spark AQE | JindoFS    | 纯 DRL       | QA-DRL(本)   | 提升幅度<br>(vs. YARN) | $p$ 值  |
|--------------------|-----------|-----------|-----------|------------|-------------|-------------|--------------------|--------|
| 平均调度时延/ms          | 58±12     | 52±10     | 41±8      | 28±6       | 25±6        | 12±2        | 79.3%↓             | <0.001 |
| GPU 利用率            | 35%       | 30%       | 22%       | 15%        | 12%         | 5%          | 85.7%↓             | 0.003  |
| 波动率 $\sigma$       |           |           |           |            |             |             |                    |        |
| Shuffle 网络开销占比     | 65%       | 60%       | 35%       | 22%        | 22%         | 12%         | 81.5%↓             | <0.001 |
| 任务吞吐量/<br>(task/h) | 4 200±300 | 4 500±400 | 6 800±500 | 12 000±800 | 15 000±1000 | 28 600±1500 | 580%↑              | 0.001  |
| 端到端时延              | 41%       | 38%       | 18%       | 12%        | 10%         | 6.3%        | 84.6%↓             | 0.002  |
| 波动率 $\sigma$       |           |           |           |            |             |             |                    |        |
| 存储冗余度 $\Delta S$   | 200%      | 140%      | 200%      | 135%       | 200%        | 126%        | 37%↓               | —      |
| 数据重建速率/<br>(TB/h)  | 1.5       | 1.2       | 1.5       | 1.5        | 1.5         | 1.2         | —                  | —      |
| 数据重建时间/s           | <60       | <120      | <60       | <90        | <60         | ≤15         | 75%↓               | —      |

任务分配,极大抑制了资源碎片化(GPU利用率波动率 $\sigma \leq 5\%$ )。在72 h持续高压测试中,系统吞吐量维持在28 600 task/h的稳态水平,波动率 $\delta < 3\%$ ,显著优于Spark AQE的 $\delta = 18\%$ 。该稳定性印证了Ising模型中负载均衡项设计的合理性,表明量子退火提供的全局蓝图对于维持长期稳定至关重要。

故障场景下的调度韧性:通过注入3 000种故障模式(含网络分区、磁盘坏道、节点宕机),重点验证了调度服务的自愈能力。得益于量子隐形传态备份机制对元数据状态的全局一致性保障,调度器在网络闪断(丢包率30%)下的任务迁移时延小于等于28 ms;在硬件故障时,调度器能基于资源约束的实时变化(如节点下线)快速重新求解分配方案。结果表明,该混合调度框架的MTTF(平均无故障时间)较原生系统提升4.2倍,MTTR(平均修复时间)缩短至15 s。这种韧性源于调度器对CAP约束的动态平衡能力,实现了S状态空间的理论最优折中。

### 4.3 跨层级协同性实证分析

SDAPC框架的核心价值在于其引发的跨层级协同效应。本文超越了传统的性能对比,采用敏感性分析、因果推断与边界分析相结合的多维度实证方法,定量揭示了存储、计算、协调3个优化层之间的深度耦合机制。所有分析均强有力地证明,下层优化通过从根本上简化问题复杂度,为上层调度器的卓越性能奠定了基石,这一发现与多维状态空间S的动态平衡机制在理论上完全自洽。

贡献度分解与层级耦合效应:为精确量化各层的独立与联合贡献,本文进行了控制变量实验,并采用Sobol全局敏感性

分析法<sup>[26]</sup>。如图7(a)所示,对于Shuffle开销降低这一关键指标,存储层优化(LSTM-KMeans驱动的冷热数据分级与动态纠删码策略)独立贡献了46.2%的Shuffle开销降低,这源于数据局部性 $\Gamma_{loc}$ 提升对跨机架流量的显著抑制;计算层优化(流批协同计算引擎)贡献了约20%的性能增益,主要归因于动态DAG重构消除的Shuffle冗余;协调层量子-经典混合调度器贡献了剩余的33.8%,其核心价值在于量子退火提供的全局最优蓝图与DRL实时微调的协同。这种分层贡献结构印证了SDAPC框架设计的合理性:各层聚焦其核心瓶颈,并通过状态空间S的信息传递实现联合优化,最终共同服务于调度效能的最大化。

统计因果关系的实证验证:为确立存储优化与调度性能间的因果性关联,本文进行了深入的统计分析。基于256节点集群的Spearman秩相关分析表明,数据局部性 $\Gamma_{loc}$ 与Shuffle开销呈强负相关( $\rho = -0.89$ ,  $p < 0.01$ ),如图7(b)所示。为进一步量化其影响,本文构建了一元线性回归预测模型:

$$\Delta \text{Shuffle} = -2.3 \times \Delta \Gamma_{loc} + \epsilon (R^2 = 0.92) \quad (9)$$

该模型表明,存储层冷热预测准确率每提升1%,可带来Shuffle开销降低约2.3%。Cohen's  $f^2$ 效应量计算为1.15,远大于0.35的大效应量(large effect)阈值,强有力地实证了存储优化通过对通信成本的根本性抑制,为调度器创造了近乎最优的输入条件。

协同效能的帕累托边界探索:本文进一步通过帕累托前沿分析(如图7(c)所示),量化了协同优化的理论极限。分析表明,当存储冗余度 $\Delta S$ 降至126%时(动态EC策略),系统在给定可靠性约束下达到了“局部性-可靠性”帕累托最优




图7 跨层级协同性实证分析

(Pareto efficiency,  $K=0.92$ )。与此同时,协调层的量子-DRL混合调度将资源利用率 $R$ 提升至87.3%,逼近了经CAP约束修正后的Amdahl定律理论上限(92.1%)。这种“存储-计算”与“调度”双边界收敛的现象,从系统优化的极限视角印证了SDAPC框架在CAP定理与Amdahl定律双重约束下实现动态平衡的

强大能力,为未来“存储-计算-调度”一体化架构的设计提供了可量化的理论准则与工程实践蓝图。

超加性增益的生成机制:全栈部署实现了81.5%的Shuffle开销总提升,远超各层独立贡献的线性叠加( $\Sigma=100\%$ ),产生了显著的超加性增益( $SI=0.15$ )。这种非线性增益源于两类跨层优化链,其终端效

益均体现在调度效率的提升上。

- 存储-调度协同链：存储层提升的数据局部性  $\Gamma_{\text{loc}}$  显著简化了调度层 Ising 模型的复杂度（式（1）中  $J_{ij}$  稀疏度从 37.7%→10.3%），使量子退火求解时间降低 42%，直接提升了调度器的决策效率。

- 计算-协调反馈链：处理层的流批协同计算动态生成 DAG 拓扑变化信号，通过协调层的 DRL 智能体实时反馈至任务分配策略，使资源争用概率下降 79%（GPU 波动率  $\sigma \leq 5\%$ ），极大增强了调度器在动态环境中的稳定性。

图 7（d）精要地阐释了上述超加性增益的生成机制。其核心论点为：存储与计算层的预处理优化，并非独立作用于性能指标，而是通过改变调度层所面对的问题本质结构来发挥作用。具体而言，存储层优化（如冷热数据分级）直接降低了 Ising 模型中耦合项  $J_{ij}$  的密度与强度（如左半部分所示）；计算层优化（如动态 DAG 重构）则简化了任务间的依赖关系。这使得调度器所需解决的问题从一个高耦合、高复杂度的 NP-Hard 问题（“病态问题”），转变为一个更稀疏、更易求解的问题实例（“健康问题”）。正是这种问题结构的健康化转变（如右半部分所示），为量子退火器和 DRL 智能体充分发挥其效能创造了近乎理想的条件，从而催化了“1+1>>2”的超加性增益。

本文通过系统的实验设计与多维度的性能评估，全面验证了 SDAPC 框架及其核心量子-经典混合调度范式的卓越效能。实验表明，该方案在调度时延、资源利用率、稳定性与能效等方面均显著优于现有主流及业界先进方案。更重要的是，通过严格的实证分析，本文定量揭示了存储、计算、调度 3 个层级之间深度协同的内在机理与超加性增益。

## 5 总结与未来研究方向

### 5.1 研究总结

本文直面字节时代 Hadoop 生态系统在异构资源调度中面临的高时延、低利用率的根本性挑战，提出了一种基于动态权衡模型的协同优化方法。最核心的贡献在于首创了量子-经典混合调度范式，为破解大规模分布式系统资源调度的 NP-Hard 问题提供了一条新颖且有效的路径。

在核心技术层面，取得了量子智能调度领域的突破性进展。本文最显著的创新是设计了量子退火与深度强化学习时序耦合的混合调度器，通过将 YARN 任务分配问题映射至 Ising 模型，并利用 D-Wave 量子退火机进行全局最优求解，攻克了传统算法在高维组合优化中的计算效率瓶颈；进一步耦合图注意力网络驱动 DRL 智能体，实现了对量子蓝图的毫秒级细粒度调整，克服了其难以实时响应的局限。该范式在 256 节点大规模异构集群中实现了 12 ms 超低调度时延与 87.3% 的资源利用率，将性能波动率压缩至 5%，显著超越了现有所有先进基线。

在理论层面，本文构建了支撑协同优化的动态权衡模型，融合 CAP 定理与 Amdahl 定律，构建了多维状态空间  $S$  及其边界方程，首次量化了调度时延、资源利用率与分布式约束之间的协同关系，为调度策略的设计提供了理论依据。

在系统层面，本文验证了跨层级协同设计的方法论价值。本文证实，存储层与计算层的预处理优化，可显著提升数据局部性、降低问题复杂度，从而为上述核心调度器创造更优的求解环境。实验揭示的超加性增益强有力地证明，存储与计算优

化是释放量子-经典混合调度器全部潜力的关键使能器，而非独立的优化点。

综上所述，本文不仅为Hadoop生态提供了性能跃升的解决方案，更提出了一种“核心突破（调度）、多层协同（存储与计算）”的分布式系统优化新范式，其技术路径具备广泛的迁移价值。

5.2 未来研究方向

尽管本文取得了初步成果，但仍需在以下方向持续探索。首先，需将量子-经典混合调度范式扩展至云边端协同计算环境<sup>[27]</sup>，以应对边缘节点资源受限及网络不稳定性等核心挑战，探索在云端执行量子全局规划、在边缘侧部署轻量化DRL智能体的方法，满足端到端时延≤10 ms的需求。此外，应探索其与存算一体芯片<sup>[28]</sup>、光子计算<sup>[29]</sup>等新型硬件的深度融合，例如利用存内计算芯片就近处理数据分区内的调度子问题，或采用光互连网络加速节点间通信，从根本上突破“内存墙”与“带宽墙”，为量子调度器提供更强大的硬件支撑。同时，还应探索大型语言模型在系统调度中的应用潜力，构建能够理解自然语言性能目标并自动生成调度策略的AI原生架构<sup>[30]</sup>，推动系统调度从自动化向自主化演进，最终实现具备自优化与自修复能力的下一代分布式系统。本研究提出的SDAPC框架及其核心的量子-经典混合调度范式，为大数据分布式系统的性能优化提供了创新解决方案。

参考文献：

[1] Hirahara S, Ilango R, Loff B. Hardness of constant-round communication complexity[C]//Proceedings of the 36th

Computational Complexity Conference. [S.l.:s.n.], 2021: 31: 1-31: 30.

[2] Shvachko K, Kuang H R, Radia S, et al. The Hadoop distributed file system[C]//Proceedings of the 2010 IEEE 26th Symposium on Mass Storage Systems and Technologies. Piscataway: IEEE Press, 2010: 1-10.

[3] Chen Y P, Ganapathi A, Griffith R, et al. The case for evaluating MapReduce performance using workload suites[C]//Proceedings of the 2011 IEEE 19th Annual International Symposium on Modeling, Analysis, and Simulation of Computer and Telecommunication Systems. Piscataway: IEEE Press, 2011: 390-399.

[4] Pavlo A, Paulson E, Rasin A, et al. A comparison of approaches to large-scale data analysis[C]//Proceedings of the 2009 ACM SIGMOD International Conference on Management of data. New York: ACM, 2009: 165-178.

[5] Gandomi A, Haider M. Beyond the hype: big data concepts, methods, and analytics[J]. International Journal of Information Management, 2015, 35(2): 137-144.

[6] 翟子洋, 郝茹茹, 董世浩. 大规模智慧交通信号控制中的强化学习和深度强化学习方法综述[J]. 计算机应用研究, 2024, 41(6): 1618-1627.

Zhai Z Y, Hao R R, Dong S H. Review of reinforcement learning and deep reinforcement learning methods in large-scale intelligent traffic signal control[J]. Application Research of Computers, 2024, 41(6): 1618-1627.

[7] Li Z K, Zhang F, Teng G F, et al. Deep reinforcement learning-based optimization strategy for the cooperative scheduling of harvesters[J]. Transactions of the Chinese Society of Agricultural En-

- gineering, 2024, 40(14).
- [8] 冯杨洋, 汪庆, 舒继武. 大模型时代下的存储系统挑战与技术发展[J]. 大数据, 2025, 11(1): 79–91.
- Feng Y Y, Wang Q, Shu J W. Challenges and technical development of storage systems in the era of large language models[J]. Big Data Research, 2025, 11(1): 79–91.
- [9] 程文迪, 张晓, 潘兆辉, 等. 面向湍流大数据的高效存储与访问关键技术研究[J]. 大数据, 2024, 10(4): 3–20.
- Cheng W D, Zhang X, Pan Z H, et al. Research on key technologies for efficient storage and access of turbulent big data[J]. Big Data Research, 2024, 10(4): 3–20.
- [10] Bravyi S, Hastings M. On complexity of the quantum Ising model[J]. Communications in Mathematical Physics, 2017, 349(1): 1–45.
- [11] Li Q, Lu L, Zhao D, et al. Stateless and proactive routing for dynamic multicast with deep reinforcement learning[J]. IEEE Transactions on Networking, 2025(99): 1–16.
- [12] Jahandoost A, Abedinzadeh Torghabeh F, Abed Hosseini S, et al. Crude oil price forecasting using K-means clustering and LSTM model enhanced by dense-sparse-dense strategy[J]. Journal of Big Data, 2024, 11(1): 117.
- [13] 郑宜焱, 张余豪, 霍志杰, 等. 面向云边场景的读写均衡键值存储系统[J]. 大数据, 2025, 11(3): 49–61.
- Zheng Y T, Zhang Y H, Huo Z J, et al. A read-write balanced key-value store for cloud-edge computing environments[J]. Big Data Research, 2025, 11(3): 49–61.
- [14] Li L, Fan Y X, Tse M, et al. A review of applications in federated learning[J]. Computers & Industrial Engineering, 2020, 149: 106854.
- [15] Wase V, Wuyckens S, Lee J A, et al. The proton arc therapy treatment planning problem is NP-Hard[J]. Computers in Biology and Medicine, 2024, 171: 108139.
- [16] Sovitkar S P, Vittal S, A A F. Evaluating CAP theorem on a stateless 5G core [C]//Proceedings of the 2024 IEEE 21st Consumer Communications & Networking Conference. Piscataway: IEEE Press, 2024: 1014–1017.
- [17] Schagaev I, Cai H, Monkman S. On performance: from hardware up to distributed systems[M]//Software Design for Resilient Computer Systems. Cham: Springer, 2024: 297–324.
- [18] Fraigniaud P, Montealegre P, Rapaport I, et al. A meta-theorem for distributed certification[J]. Algorithmica, 2024, 86(2): 585–612.
- [19] 王帅, 李丹. 分布式机器学习系统网络性能优化研究进展[J]. 计算机学报, 2022, 45(7): 1384–1411.
- Wang S, Li D. Research progress on network performance optimization of distributed machine learning system[J]. Chinese Journal of Computers, 2022, 45(7): 1384–1411.
- [20] Vavilapalli V K, Murthy A C, Douglas C, et al. Apache Hadoop YARN: yet another resource negotiator[C]//Proceedings of the 4th annual Symposium on Cloud Computing. New York: ACM, 2013: 1–16.
- [21] Park Y, Tak B, Han W S. QAAD (query-as-a-data): scalable execution of massive number of small queries in spark[J].

- Proceedings of the ACM on Management of Data, 2023, 1(2): 1–26.
- [22] Xu Z Y, Tang J, Meng J S, et al. Experience-driven networking: a deep reinforcement learning based approach[C]//Proceedings of the IEEE INFOCOM 2018–IEEE Conference on Computer Communications. Piscataway: IEEE Press, 2018: 1871–1879.
- [23] Chen Y Q, Zhou Y, Taneja S, et al. aHDFS: an erasure-coded data archival system for hadoop clusters[J]. IEEE Transactions on Parallel and Distributed Systems, 2017, 28(11): 3060–3073.
- [24] 李建中, 王国仁. ZB级数据场景下存储效率瓶颈分析[J]. 计算机学报, 2023, 46(4): 723–736.
- Li J Z, Wang G R. Analysis of storage efficiency bottlenecks in ZB-level data scenarios[J]. Journal of Computer Science, 2023, 46(4): 723–736.
- [25] Alibaba Cloud. JindoFS technical white paper: architecture and performance benchmark (Version 4.6.1)[Z]. 2023.
- [26] Le T T H, Le A T. Implementing Sobol's global sensitivity analysis to SFRC's flexural strength predictive equation[J]. Journal of Advanced Engineering and Computation, 2024, 8(3): 175.
- [27] Zhang Y L, Chen J J, Wang Y C, et al. A novel on-demand service architecture for efficient cloud-edge collaboration [C]//Proceedings of the 2023 International Conference on Networking and Network Applications. Piscataway: IEEE Press, 2023: 169–174.
- [28] Kaur R, Asad A, Mohammadi F. A comprehensive review of processing-in-memory architectures for deep neural networks[J]. Computers, 2024, 13(7): 174.
- [29] Bente I, Taheriniya S, Lenzini F, et al. The potential of multidimensional photonic computing[J]. Nature Reviews Physics, 2025, 7(8): 439–450.
- [30] Li B R, Liu T E, Wang W L, et al. Agent-as-a-service: an AI-native edge computing framework for 6G networks[J]. IEEE Network, 2024, 39(2): 44–51.

## 作者简介



明龙 (2001–), 男, 西北大学网络与数据中心硕士生, 中国计算机学会 (CCF) 学生会员, 主要研究方向为机器学习、大数据。



胡建龙 (1981–), 男, 西北大学网络与数据中心高级工程师, CCF 专业会员, 主要研究方向为计算机网络管理、智慧校园规划、数字媒体技术。



张心译（1997-），女，西北大学网络与数据中心助理工程师，主要研究方向为校园信息化建设与应用。



王宇翔（1989-），男，西北大学网络与数据中心高级工程师，主要研究方向为计算机网络、大数据。

录用日期: 2025-09-08

通信作者: 胡建龙, hjl@nwu.edu.cn