



AI驱动的网管支撑系统性能优化算法研究

任高强, 崔云龙, 陈昶旭, 郭昱炜, 赵军生

(中国移动通信集团设计院有限公司河南分公司, 河南 郑州 450003)

摘要: 当前网管支撑系统面临着业务规模扩大与服务需求多样化的挑战, 传统的人工经验与固定规则已难以实现系统性能的精准优化。提出一种AI驱动的网管系统性能优化算法。首先通过分析网管系统特征构建了性能优化问题模型, 形式化定义了优化目标与约束条件; 其次设计了基于AI的优化算法框架, 实现了从系统状态感知与优化决策到资源调度的智能化闭环; 最后在真实网管环境下进行了对比实验。结果表明, 该算法在系统吞吐量与资源利用率以及任务响应时间等关键指标上均有一定幅度的提升, 验证了AI驱动优化方案的可行性与有效性。

关键词: AI驱动; 网管支撑系统; 性能优化算法; 智能调度; 模型构建

中图分类号: TN919

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025280

0 引言

网管支撑系统是通信网络的运维管理中枢, 其性能水平直接影响网络服务质量, 随着5G网络规模部署与云网融合的深入推进, 传统优化方法在面对动态复杂的性能需求时显现出明显不足, 人工智能技术的发展为网管系统性能优化提供了新思路, 但如何构建有效的AI驱动优化算法仍是一个关键科学问题。针对这一问题, 本文首先建立了网管系统模型, 形式化定义了性能优化问题, 在此基础上设计了智能化的优化算法, 通过感知与决策以及调度3个关键环节, 实现了系统性能的动态优化, 为网管支撑系统的智能化演进提供了新的技术路径。

1 系统模型与问题建立

1.1 网管支撑系统模型构建

基于网管支撑系统的核心架构, 本节构建了一个包含业务支撑与运营支撑以及网管支撑功能的多维系统模型, 架构图如图1所示。该模型通过定义系统状态空间 $S=\{s_1, s_2, \dots, s_n\}$ 来表征系统特征, 其中每个状态向量 s_i 包含业务开通效率与故障处理时延以及资源调度成功率等支撑网管的关键指标, 以及CPU利用率与内存占用等基础资源指标, 全面反映支撑系统在不同时刻的运行特征, 为准确描述网管支撑业务处理流程, 引入任务请求集合 Q 并定义资源分配映射函数:

$$f: S \times Q \rightarrow A \quad (1)$$

其中, A 表示网管支撑系统的可行资源分配方案集合^[1]。考虑支撑系统的动态特性, 模型引入了

时间维度 t ，通过状态转移函数 $P(s_{t+1}|s_t, a_t)$ 描述在不同资源分配策略下系统的演化过程，此外，模型还考虑了网管支撑系统特有的B/O/M/S域业务协同与资源调度策略，以及性能瓶颈传递机制，通过资源分配矩阵 R 展现各类资源与支撑任务间的映射关系。

1.1.1 性能优化问题形式化

立足网管支撑系统的特点，本节对其性能优化问题进行形式化描述，首先定义支撑系统在 t 时刻的综合性能指标 $P(t)$ ，该指标包含了业务支撑效率与运营支撑质量以及网管支撑能力等多个维度，为实现网管支撑系统性能的动态优化，定义综合性能评估函数：

$$P(t) = \alpha \times B(t) + \beta \times O(t) + \gamma \times M(t) \quad (2)$$

其中， $B(t)$ 表示业务支撑效率， $O(t)$ 表示运营支撑质量， $M(t)$ 表示网管支撑能力， α 、 β 、 γ 为相应权重系数。通过这种形式化描述，将网管支撑系统的性能优化转化为可求解的优化问题，同时构

建了支撑指标间的关联关系模型，分析了各项支撑能力对系统整体性能的影响，针对网管支撑系统的特点，引入了基于BOMS域的自适应权重调整机制，使优化目标能够根据不同支撑域的业务需求动态调整，提高了模型对网管支撑场景的适应性^[2]。

1.1.2 优化目标与约束定义

立足网管支撑系统的核心架构特征，需要构建面向BOMS域的性能优化目标体系。在保障网络运维效率的基础上，优化目标主要聚焦于网管系统3个关键功能模块：网络监控子系统的告警处理能力与数据采集效率，配置管理子系统的业务开通时延与资源调度效率，以及性能管理子系统的性能管理效率与存储利用率。针对网管系统的分层分域特点，约束条件被划分为不同层级：网元层面关注设备数据采集周期与网元并发数等底层约束，网管服务层面包括数据库访问频率与消息队列容量以及缓存命中率等中间件约束，应




图1 网管支撑系统多维模型架构图



用层面则涉及业务处理超时与系统响应时间以及界面操作流畅度等上层约束，同时考虑网管系统特有的南北向接口约束，包括北向对接OSS/BSS系统时的并发处理能力与协议转换效率，以及南向管理网元时的命令下发成功率与状态同步及时性等。

1.2 AI驱动的性能优化算法

1.2.1 智能感知机制设计

针对网管支撑系统复杂多变的性能特征，设计了基于AI技术的智能感知机制，该机制首先利用预训练的深度网络对BOMS各域数据进行特征提取，通过自编码器以及迁移学习的组合实现对系统性能数据的高效编码，在处理来自业务支撑与运营支撑以及管理支撑与服务支撑各域的多源异构数据时，采用多头注意力机制：

$$A(t) = \text{MultiHead}(Q_t, K_t, V_t) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^O \quad (3)$$

其中， Q_t 、 K_t 、 V_t 分别表示性能数据的查询矩阵、键矩阵、值矩阵，通过多头结构捕获不同域间的性能关联。为提升泛化能力，引入迁移学习模块快速适应新出现的性能模式，同时设计长短时记忆网络预测单元进行性能预警^[3]。系统还集成了基于对比学习的异常检测机制，通过分析性能指标的时空关联特征识别潜在风险，在数据预处理环节，采用动态时间窗口技术对原始性能数据进行降噪与标准化，并根据不同性能指标的重要程度设计自适应采样策略，此外，针对网管支撑系统特有的分域特点，设计了层次化的特征融合网络，在保证感知精度的同时降低了计算复杂度。

1.2.2 优化决策算法构建

基于智能感知的结果，构建了面向网管支撑系统的AI优化决策算法，创新性地将性能优化问题建模为多智能体协同学习任务，每个智能体负责优化BOMS中一个特定域的性能指标，智能体

通过深度强化学习框架不断优化决策策略，其值函数更新计算式为：

$$Q(s_t, a_t) = Q(s_t, a_t) + \alpha[R_t + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a_t)] \quad (4)$$

其中， $Q(s_t, a_t)$ 表示在状态 s_t 下采取动作 a_t 的价值函数， α 为学习率($0 < \alpha < 1$)， R_t 为即时奖励值， γ 为折扣因子($0 < \gamma < 1$)。状态空间包含了系统各项性能指标以及资源使用情况，动作空间涵盖了资源分配与任务调度等优化操作，为提升学习效率，引入了分层强化学习架构，将复杂的优化决策分解为多个子任务；同时，通过设计基于图神经网络的状态表征模块，有效捕获了系统各组件间的依赖关系，针对网管支撑系统的实时性要求，采用优先级经验回放机制加速策略收敛，并引入双网络结构提升训练稳定性；在奖励函数设计上，综合考虑了业务响应时间与资源利用率以及系统吞吐量等多个性能指标，通过自适应权重调整机制平衡各项优化目标。

1.2.3 资源调度策略实现

在AI决策模型的指导下，构建了智能化的资源调度执行策略，AI驱动的资源调度架构如图2所示，设计分层调度架构，将资源管理分为全局策略规划与局部动作执行两个层次。全局层采用改进的深度强化学习模型，学习业务模式与资源需求的长期依赖关系，局部层则通过即时优化算法处理突发的资源竞争。在具体实现中，引入多任务学习机制同时优化计算资源与存储资源以及网络资源的分配策略，并通过注意力机制动态调整不同资源类型的优化权重，针对网管支撑系统的特点，设计了基于预测的资源预留机制，通过机器学习模型预测业务高峰期的资源需求，提前做好资源储备^[4]。同时，实现了跨域资源的协同调度，通过强化学习探索最优的资源共享策略，为保证调度的实时性，采用分布式执行框架，将全局优化策略分解为多个并行执行的局部调度任

务,系统还集成了自适应反馈控制机制,通过实时监控调度效果动态调整策略参数,确保在波动场景下维持较高的调度性能^[5]。

1.3 优化算法验证分析

1.3.1 实验环境与方案设计

为全面验证所提出的AI驱动优化算法的性能,搭建了一套完整的网管支撑系统测试环境,实验平台采用分布式架构,包含16台高性能服务器,配置双路Intel Xeon处理器与256 GB内存以及10 Gbit/s网络互联,在软件环境上,部署了完整的BOMS域系统组件,涵盖业务受理与资源调度以及性能管理等核心功能模块,为模拟真实业务场景,基于实际网管数据构建了多组测试用例,包括日常业务流程与突发性能事件以及资源竞争场景等,测试数据集包含6个月的历史运行数据,其中70%用于算法训练,20%用于验证,10%用于测试,同时设计了多组对照实验,分别与传统规则调度与启发式算法以及基准AI模型进

行对比,重点考查算法在任务响应时间与资源利用率以及系统吞吐量等方面的优化效果,为确保实验的准确性,每组测试重复执行5次,取平均值作为最终结果。

1.3.2 性能指标测试评估

针对网管支撑系统的关键性能指标,开展了全面的对比测试实验,在评估过程中,重点关注系统响应时间与资源利用率以及业务处理效率等核心指标,不同算法在关键性能指标上的对比结果见表1。

表1 不同算法在关键性能指标上的对比结果

性能指标	规则调度	启发式算法	AI驱动算法
平均响应时间/ms	245	187	142
CPU利用率	45.2%	62.8%	78.5%
内存利用率	52.6%	65.3%	82.1%
任务处理量/(件·s ⁻¹)	856	1024	1386
告警处理效率	72.5%	83.6%	91.8%
配置下发成功率	94.2%	96.5%	98.7%




图2 AI驱动的资源调度架构



从表1可以看出,本文所提AI驱动算法在各项关键指标上均表现显著优势,在系统响应性能方面,平均响应时间较规则调度方法减少了42.0%;在资源利用效率上,CPU与内存利用率分别提升了33.3与29.5个百分点;在业务处理能力方面,任务处理量提升了61.9%,告警处理效率以及配置下发成功率也均达到了较高水平。这些数据充分验证了AI驱动算法在提升网管支撑系统整体性能方面的有效性。

1.3.3 优化效果对比验证

为进一步验证算法在不同场景下的优化效果,设计了多组特定场景的对比实验,重点关注算法在高负载与突发业务等典型场景下的表现,不同场景下的算法性能对比见表2。

表2 不同场景下的算法性能对比

测试场景	指标类型	规则调度	启发式算法	AI驱动算法
高负载	吞吐量/(Mbit·s ⁻¹)	845	1123	1465
	任务完成率	82.3%	88.5%	95.2%
突发业务	响应时延/ms	386	294	215
	资源调度时间/s	4.2	3.1	1.8
故障恢复	检测时间/s	5.6	4.2	2.5
	恢复成功率	91.4%	94.8%	98.3%

实验结果显示,在高负载场景下,AI驱动算法的系统吞吐量比传统方法提升了73.4%,任务完成率提高了12.9个百分点;在突发业务处理上,平均响应延迟降低了44.3%,资源调度时间减少了57.1%;在故障恢复场景中,检测时间缩短了55.4%,恢复成功率提升了6.9个百分点。这些数据充分证明了算法在复杂场景下的优越性与稳定性。

2 结束语

本文面向网管支撑系统性能优化的关键需求,提出了一种AI驱动的创新算法,该算法基于

系统模型以及问题形式化,设计了包含智能感知与优化决策以及资源调度的完整技术方案。通过在实际网管环境的对比实验验证了算法在提升系统性能方面的显著效果,实验数据表明,该算法能够准确把握系统动态特征,实现资源的智能化调度,显著提升系统整体性能,在资源利用率以及业务处理效率等关键指标上取得了明显提升。未来研究将重点关注算法在大规模异构网管系统中的适应性优化,进一步提升其实用价值以及推广应用潜力。

参考文献:

- [1] 刘宝丽. 采控中心支撑网管解耦演进为能力调度子系统的研究[J]. 电子元器件与信息技术, 2024, 8(2): 198-201.
- [2] 周玮, 李瑛琦, 陈立伟, 等. 内蒙古移动新网管体系微服务支撑平台设计[J]. 信息技术与信息化, 2022(6): 142-145.
- [3] 任红. 电力通信数据网网管系统设计与数据采集功能实现[J]. 信息记录材料, 2021, 22(7): 226-227.
- [4] 王家成. 移动业务支撑网网管系统探究[J]. 信息通信, 2020, 33(6): 277-278.
- [5] 王亮, 陈强, 张敏. 一种池化的通信网络网管系统采集机网络架构研究[J]. 通信管理与技术, 2020(1): 47-51.

[作者简介]

任高强 (1989-), 男, 中国移动通信集团设计院有限公司河南分公司工程师, 主要研究方向为网管支撑网、人工智能、云计算、数据网。

崔云龙 (1989-), 男, 中国移动通信集团设计院有限公司河南分公司工程师, 主要研究方向为IT系统设计与工程应用。

陈昶旭 (1993-), 男, 中国移动通信集团设计院有限公司河南分公司工程师, 主要研究方向为核心网、电力电源。

郭昱炜 (1987-), 男, 中国移动通信集团设计院有限公司河南分公司工程师, 主要研究方向为通信工程、软件开发。

赵军生 (1987-), 男, 中国移动通信集团设计院有限公司河南分公司高级工程师, 主要研究方向为智算、算力基础设施。