

数据治理视角下的数据中心算力-电力耦合分析研究*

孙 钢¹, 杜阳阳²

(1. 国网浙江省电力有限公司营销服务中心, 浙江 杭州 311121;

2. 浙江省轨道交通运营管理集团有限公司, 浙江 杭州 311121)

摘要: 在数据中心能源消耗快速增长与算力需求结构趋于复杂的背景下, 从数据治理视角出发, 围绕数据中心多源异构数据的治理体系构建、算力相关数据挖掘分析及算力-电力负荷协同关系展开研究。基于数据治理理念, 构建多源异构数据的标准化预处理体系, 通过数据清洗、特征提取、模式识别等数据挖掘手段, 提炼算力强度与动态核心特征, 从而构建基于治理后数据的算力-电力映射关系模型, 揭示不同任务类型对负荷变化的影响规律。在模型层面, 引入 LSTM 与注意力机制融合的预测结构, 依托高质量电力数据实现对算力驱动负荷变化的高精度建模。研究表明, 完善的数据治理体系有效提升了数据质量, 基于治理数据构建的模型显著增强了负荷预测对任务行为变化的敏感性与稳定性, 为数据中心能效优化、算力调度策略改进及数据治理体系完善提供了可靠依据。

关键词: 数据中心; 电力负荷; 算力行为; 数据治理

中图分类号: TP311

文献标志码: A

DOI:10.19358/j.issn.2097-1788.2026.07.006

中文引用格式: 孙钢, 杜阳阳. 数据治理视角下的数据中心算力-电力耦合分析研究[J]. 网络安全与数据治理, 2026, 45(7): 39-46.

英文引用格式: Sun Gang, Du Yangyang. Research on the coupling analysis method of computing power behavior and power load in data centers from the perspective of data governance[J]. Cyber Security and Data Governance, 2026, 45(7): 39-46.

Research on the coupling analysis method of computing power behavior and power load in data centers from the perspective of data governance

Sun Gang¹, Du Yangyang²

(1. State Grid Zhejiang Marketing Service Center, Hangzhou 311121, China;

2. Zhejiang Rail Transit Operation Management Group Co., Ltd., Hangzhou 311121, China)

Abstract: Against the backdrop of the rapid growth of energy consumption in data centers and the increasingly complex structure of computing power demand, this paper conducts research on the construction of a governance system for multi-source heterogeneous data in data centers, data mining and analysis related to computing power, and the collaborative relationship between computing power and power load from the perspective of data governance. Based on the concept of data governance, a standardized preprocessing system for multi-source heterogeneous data is constructed. Through data mining methods such as data cleaning, feature extraction, and pattern recognition, the computing power intensity and dynamic core characteristics are extracted. A computing power-power mapping relationship model based on governed data is further constructed to reveal the influence law of different task types on load changes. At the model level, a prediction structure integrating LSTM and attention mechanism is introduced to achieve high-precision modeling of load changes driven by computing power based on high-quality governed data. The research results show that the improved data governance system effectively improves data quality, and the model built based on governed data significantly enhances the sensitivity and stability of load forecasting to changes in task behavior, providing a reliable basis for energy efficiency optimization of data centers, improvement of computing power scheduling strategies, and improvement of data governance systems.

Key words: data center; power load; computational behavior; data governance

* 基金项目: 国网浙江省电力有限公司科技项目 (5211YF230004)

0 引言

在生成式人工智能高速演进和数字经济全面深化的背景下,全球算力规模呈指数级扩张,大模型参数量从百亿级迈向万亿级,引发数据中心算力需求与能耗同步飙升^[1]。据中国信通院权威统计,2019~2030年全球算力规模年均增速高达47%,我国数据中心用电量预计在2030年逼近3 000~7 000亿千瓦时,届时社会用电量占比将突破5%,成为能耗增长的核心源头^[2]。同时,新一代AI芯片推动算力密度突破,带来前所未有的瞬时功率冲击,使数据中心呈现强耦合的“算力突发-负荷跃增”特性^[3],而针对这一特性的精准刻画,离不开高质量的数据支撑与科学的数据治理体系。

数据治理作为数字基础设施建设的核心环节,是实现数据中心算力与电力负荷协同优化的基础前提,数据中心的算力运行、电力能耗、环境保障等多源数据存在异构性、碎片化、质量参差不齐等问题,若缺乏系统的数据治理,将导致数据价值难以挖掘,无法精准捕捉算力与负荷的内在关联。当前,国内外研究主要集中于数据中心整体能效指标PUE(Power Usage Effectiveness,电源使用效率)优化^[4],或单一维度的负荷预测方法改进,对数据治理的重视不足,未形成“数据治理-数据挖掘-协同分析-预测优化”的完整体系:既有研究多从基础设施节能、制冷优化角度切入,对算力任务数据的挖掘分析不够深入;传统负荷预测模型依赖低质量、碎片化数据,难以应对算力波动带来的复杂场景^[5]。

基于上述研究现状与挑战,本文从数据中心算力行为的时空特征出发,构建覆盖“数据治理-数据挖掘-模式识别-耦合建模-预测优化”的系统化分析框架,并着力凸显数据治理的核心支撑作用:首先,面向数据中心多源异构数据,构建标准化的数据治理体系,涵盖数据采集、清洗、质量控制、时空对齐等全流程,夯实数据基础设施,为后续分析提供高质量数据支撑;其次,基于治理后的高质量数据,通过数据挖掘方法提取算力核心特征、识别典型算力模式,构建算力与电力负荷的协同映射关系;最后,基于治理数据与挖掘成果,构建高精度负荷预测模型,实现算力驱动下负荷变化的精准预测。通过上述研究,完善数据中心数据治理体系,挖掘算力与负荷数据的核心价值,为数据中心能效优化与算力调度提供技术支撑。

1 数据基础设施构建与数据资产治理

数据基础设施构建与数据资产治理是实现算力与

电力负荷精准协同分析的双重基础,二者协同联动、缺一不可。本节围绕“设施完备性、资产高质量、价值可挖掘性”原则,同步推进数据基础设施布局与数据资产全流程治理,构建“基础设施搭建-数据采集-数据清洗-质量控制-时空对齐-标准化”的完整体系,实现多源异构数据的规范化管控、高质量沉淀与核心价值挖掘,为后续算力特征提取、耦合建模提供可靠的数据基础设施支撑与高质量数据资产输入。

1.1 多源异构数据采集

数据治理以多源数据采集为起点,并需同步建立统一的数据标准体系。针对算力运行、电力能耗、环境保障及调度策略等数据,制定统一的数据编码规范、指标口径、采样周期和数据交换格式,确保不同系统间数据语义一致、结构统一、来源可追溯。在此基础上,构建“算力运行、电力能耗、环境保障、调度策略”四维数据采集体系,实现数据资源规范接入与统一管理,为后续数据质量治理与价值挖掘奠定基础。

1.1.1 算力运行类数据

算力运行类数据涵盖与计算资源使用直接相关的核心指标^[6],如CPU利用率、GPU占用率、内存读写速度、存储IO吞吐率及网络流量等关键算力行为数据。这类数据通常来源于数据中心内部的监控系统、虚拟化平台以及作业调度系统,能够刻画不同业务负载在微观运行层面的资源使用特征。此外,数据中心任务类型多样^[7],包括AI训练任务、推理任务、数据分析作业、视频渲染及传统IT业务等,它们在计算密度、运行周期和资源占用模式上存在显著差异,因此本研究在采集过程中同步记录任务类别、运行阶段、优先级与资源申请策略等信息,用于后续构建算力模式的识别基础。

1.1.2 电力能耗类数据

电力能耗类数据是构建算力-负荷协同关系的关键数据,其采集范围覆盖设备级、机架级、机房级、站地级,采集参数包括服务器功耗、机房UPS输入输出电量、冷却系统耗电量及整体电力负荷曲线等,数据来源于智能PDU、电表、高压配电系统等数据基础设施。同时,引入PUE、CUE等能效指标及区域供电负荷曲线、峰谷电价数据,为数据挖掘与能效分析提供多维度支撑^[8-9],确保数据治理后的数据能够满足协同分析需求。

1.1.3 环境与机房保障类数据

环境数据对电力负荷具有显著调节效应,是数据治理中不可或缺的组成部分,其采集范畴涵盖机房温

湿度、冷冻水温度、设备散热状态及室外气象数据等，数据来源于分布式传感器、机房保障系统监控及气象信息。此类数据的采集需与算力、能耗数据同步，确保数据的时空一致性，为后续挖掘环境因素对负荷的调节规律提供支撑。

1.1.4 任务调度与业务策略类数据

调度策略数据决定算力任务的空间落点与资源使用模式，间接影响电力负荷分布，其采集内容包括作业调度算法、资源分配策略、负载均衡策略及任务调

度轨迹，数据来源于作业调度系统日志、集群管理平台。此类数据采用事件触发式采集，确保能够完整捕捉算力任务的调度过程，为挖掘空间调度对负荷的影响规律提供数据支撑。

为明确数据治理各环节的核心对象，本文在数据采集的基础上建立多源异构数据汇总表，如表 1 所示，清晰呈现数据类别、核心指标、采集来源、采样频率及治理价值，为后续数据清洗、质量控制提供结构化依据，完善数据治理的基础流程。

表 1 多源异构数据汇总表

数据类别	核心指标	采集来源	采样频率	治理价值
算力运行类	CPU 利用率、GPU 占用率、内存读写速度、存储 IO 吞吐率、网络流量	Zabbix/Nagios 监控系统、虚拟化平台	1 次/(30~60 s)	建立统一算力资源画像
	任务类别、运行阶段、优先级、资源申请策略	Slurm/Torque 作业调度系统日志	任务生命周期内实时记录	
电力能耗类	服务器/机架功耗、UPS 电量、冷却系统能耗、整体负荷曲线	智能 PDU、电表、高压配电系统	1 次/min	支撑能耗资产管理与协同分析
	PUE、CUE、区域供电负荷曲线、峰谷电价	能耗监控系统、电网运营平台	PUE 实时计算，其余 1 次/h	
环境与机房保障类	机房温湿度、冷冻水参数、室外气象数据	分布式传感器、保障系统监控、气象接口	1 次/5 min	提升环境数据可信度
任务调度与业务策略类	调度算法、资源分配策略、负载均衡策略、任务调度轨迹	作业调度系统日志、集群管理平台	事件触发式记录	支撑数据责任追踪与行为审计

1.2 数据质量控制与治理规则设计

为保障数据资产的可信性、完整性与可用性，本文建立覆盖数据采集、存储、共享和应用全过程的数据质量治理机制，形成统一的数据质量规则体系，并通过自动化校验实现质量持续监测。

一是建立完整性规则，对关键字段缺失率、采集到位率等指标进行监测，针对缺失数据采用插值修复、历史映射等方式补全；二是建立准确性规则，采用 3 σ 准则和箱线图方法识别异常数据，并结合业务逻辑进行修正；三是建立一致性规则，对不同系统间同源数据进行交叉校验，确保算力、能耗和调度数据在统计口径和时间维度上的一致性；四是建立可追溯规则，为每条数据记录来源系统、采集时间和责任主体，实现数据全生命周期质量追踪。通过上述治理规则，形成持续改进的数据质量管理机制。

1.3 元数据管理与时空统一建模

为提升多源数据的共享利用能力，本文构建元数据管理机制，对数据来源、采集时间、设备位置、业

务类型及数据责任主体等信息进行统一描述与登记，形成覆盖数据全生命周期的元数据目录体系。在此基础上，开展时空统一建模与标准化处理，实现跨系统数据的关联融合与规范共享。

时空对齐遵循“时间统一、空间关联”的核心理念。在时间维度上将多源数据统一至 1 min 采样周期，对高频算力数据采用降采样，对低频环境数据通过线性插值升维，同时以算力任务时间戳为基准校准能耗、环境数据时间偏差。采用 Z-score 标准化方法处理算力利用率、负荷等连续数据，消除量纲差异；对任务类型、调度策略等离散数据，采用独热编码进行数值化重构。最终形成具备统一标准、统一语义、统一时空坐标的数据资产，为后续算力特征挖掘、协同建模及数据共享应用提供可信的数据底座。

2 基于数据挖掘的算力特征提取与模式识别

基于前文构建的数据治理体系，依托治理后的高质量数据，本节进一步开展算力数据挖掘分析，核心实现算力特征提取与典型算力模式识别，通过主成分

分析 (PCA)、时序聚类等数据挖掘方法, 提炼低冗余、高区分度的算力特征, 识别典型算力模式, 为后续算力-电力负荷协同建模提供数据挖掘支撑, 彰显数据治理的价值。

2.1 算力行为特征提取

算力特征提取是数据挖掘的核心步骤, 其核心目标是从治理后的标准化数据中提炼兼具区分度与低冗余性的特征指标, 为算力模式识别与协同建模提供支撑^[10]。本环节基于 500 条算力运行样本数据, 构建“强度-动态”二维特征体系, 结合主成分分析实现特征降维与核心信息提取, 具体流程如下。

2.1.1 初始特征集构建

结合算力运行的核心属性, 选取 8 项关键指标构建初始特征集, 涵盖硬件资源占用与算力变化特性。为明确特征间的线性关联程度, 进一步开展相关性分析, 结果显示多项指标存在强相关性, 具体关联性如表 2 所示。其中 CPU 利用率与内存占用率的皮尔逊相关系数达 0.82, GPU 利用率与网络流量相关系数为 0.76, 直接用于建模易引发多重共线性问题, 因此需通过 PCA 进行维度压缩。

表 2 初始特征关联性分析表

特征名称	CPU 利用率	GPU 利用率	内存 占用率	存储 IO	网络 流量	波动 系数	峰值 持续时间	任务 并行数
CPU 利用率	1.00	0.68	0.82	0.71	0.65	0.23	0.19	0.73
GPU 利用率		1.00	0.63	0.59	0.76	0.31	0.25	0.61
内存占用率			1.00	0.74	0.69	0.28	0.22	0.78
存储 IO				1.00	0.72	0.35	0.18	0.67
网络流量					1.00	0.29	0.21	0.64
波动系数						1.00	0.15	0.24
峰值持续时间							1.00	0.19
任务并行数								1.00

2.1.2 降维实现与结果解读

采用 PCA 对初始特征集进行降维^[11]。首先, 构建计算标准化特征的协方差矩阵, 通过特征分解得到 8 个特征值及对应特征向量; 其次, 进行主成分筛选, 以“累计方差贡献率 $\geq 85\%$ ”为准则, 确定主成分数量。结果如表 3 所示, 前 2 个主成分的累计方差贡献率达 89.3%, 可替代原始特征实现维度压缩。

通过主成分载荷系数分析, 对核心主成分进行物理意义解读: 第一主成分与 CPU 利用率、GPU 利用率等负载指标的载荷系数均超 0.85, 定义为“算力强度

表 3 PCA 主成分方差贡献率与载荷系数表

主成分	方差 贡献率/%	累计方差 贡献率/%	核心特征及载荷系数
F1 (算力强度主成分)	62.1	62.1	CPU 利用率 (0.89)、GPU 利用率 (0.86)、内存占用率 (0.91)、任务并行数 (0.83)
F2 (算力动态主成分)	27.2	89.3	波动系数 (0.85)、峰值持续时间 (0.82)、存储 IO (0.61)、网络流量 (0.58)
F3	5.6	94.9	网络流量 (0.42)、存储 IO (0.39)
F4~F8	0.1~4.9	100.0	特征载荷系数均 <0.3 , 信息承载量低

主成分”, 集中反映算力资源的整体负载水平; 第二主成分与波动系数、峰值持续时间的载荷系数超 0.8, 定义为“算力动态主成分”, 重点刻画算力负载的时间变化特性。

2.1.3 特征有效性验证

基于治理后的高质量数据, 采用随机森林模型验证提取特征的区分能力, 在 5 类算力任务的分类实验中, 基于 2 个主成分的识别准确率达 82.4%, 与原始 8 维特征 (83.1%) 的精度接近, 但维度降低 75%, 有效提升后续建模效率。进一步通过 t 检验验证, 提取的主成分在突发算力与平稳算力样本中差异显著, 证明其可精准捕捉不同算力行为的核心差异, 为后续耦合关系建模与模式划分奠定坚实基础。

2.2 典型算力模式识别与时空特征划分

基于前文提取的算力强度主成分 (F1)、动态主成分 (F2) 及任务类型信息, 采用“时序聚类+场景匹配”二级划分方法, 以 DBSCAN 时序聚类算法 (时间窗口设为 15 min) 提取算力行为共性特征, 结合业务场景属性完成模式归类, 最终划分出 3 类典型算力行为模式, 其时空特征如下, 为后续算力-负荷协同建模提供针对性的数据支撑。

第一类为高密突发模式, 核心载体为 AI 训练任务。时间维度呈“长周期高基荷+毫秒级脉冲峰”特征, 日均高算力 ($F1>0.7$) 持续时长超 8 min, GPU 利用率峰值达 98%, 脉冲间隔与数据迭代周期 (10~30 s) 强关联; 空间维度表现为 AI 服务器集群集中负载, 单机架算力密度超 500 TFLOPS, 形成局部高负荷区域, 是电网峰荷冲击的主要来源。

第二类为平稳持续模式, 覆盖传统 IT 业务与常态化 AI 推理。时间上算力负载波动系数 (F2) 低于

0.1, CPU 利用率稳定在 40%~60% 区间, 24 h 负载变异系数仅 0.05; 空间分布均匀, 通过虚拟机动态调度实现跨机架算力均衡, 单机架负荷偏差控制在 10% 以内, 对应电力负荷呈“低波动平稳曲线”, 可作为电网基础负荷调节锚点。

第三类为周期波动模式, 典型场景为定时数据分析与批量视频渲染。时间维度呈现与业务周期匹配的规律性波动, 如金融数据分析任务每日 9 时、15 时形成双峰值, 波动周期与数据批处理窗口 (1~2 h) 一致; 空间上随任务调度在计算节点间迁移, 负荷热点区域每 4 h 完成一次动态切换, 具备可预测的调节潜力。

2.3 基于数据挖掘的算力-负荷协同关系建模

基于以上划分的 3 类算力模式, 针对性构建“模式-算力-负荷”的量化映射关系, 核心是结合不同模式的时空特征差异, 优化耦合模型参数, 提升算力到电力负荷的映射精度。

首先归纳各模式的电力负荷基础特征, 明确模式差异对负荷响应的影响: 高密突发模式因算力冲击显著, 单机平均功耗达 420 W, 功耗波动系数为 0.58; 平稳持续模式负荷稳定, 单机功耗集中在 180~220 W, 波动系数仅 0.08; 周期波动模式则介于两者之间, 平均功耗为 280 W, 波动系数为 0.25。具体特征如表 4 所示。

表 4 不同类型算力任务电力负荷特征表

算力模式	核心任务	负荷形态特征	单机平均功耗/W	功耗波动系数	核心能耗驱动因素
高密突发模式	AI 训练	高基荷+脉冲峰	420	0.58	GPU 满负荷、数据迭代
平稳持续模式	传统 IT 业务、AI 推理	低基荷+平稳运行	200	0.08	连接数、推理请求量
周期波动模式	数据分析、视频渲染	中基荷+周期性波动	280	0.25	数据吞吐量、渲染帧率

基于上述特征分析, 为量化算力行为与电力负荷的映射关系, 引入前文提取的算力强度主成分 ($F1$)、算力动态主成分 ($F2$) 及模式编码 (M) 作为核心输入变量, 构建多元线性回归耦合方程, 实现算力特征到电力负荷的精准映射, 方程形式如下:

$$P=\alpha\times F1+\beta\times F2+\gamma\times M+\varepsilon \tag{1}$$

其中, P 为服务器实时功耗, 作为模型输出变量表征电力负荷水平; $F1$ 为算力强度主成分, 反映算力资源整体负载状态; $F2$ 为算力动态主成分, 刻画算力负载

的时间变化特性; M 为模式编码, 采用独热编码将 3 类任务转换为数值特征 (如 AI 训练编码为 [1,0,0]); α 、 β 、 γ 分别为 $F1$ 、 $F2$ 、 M 的任务相关系数, 用于量化不同输入变量对负荷的驱动权重; ε 为环境修正项, 用于补偿环境因素对负荷的影响。

该协同方程基于治理后的高质量数据与数据挖掘成果构建, 通过整合算力核心特征、任务类型差异及环境影响, 实现“算力输入-负荷输出”的量化关联, 为后续负荷预测建模提供核心支撑。后续可通过样本训练确定 α 、 β 、 γ 的具体数值, 进一步提升模型的拟合精度, 以更好地捕捉不同算力场景下的负荷响应规律。

3 基于治理数据的负荷预测模型构建与仿真

基于数据治理体系输出的高质量数据、数据挖掘得到的算力特征与模式成果, 本节构建面向数据治理视角的算力-电力负荷预测模型, 通过仿真实验验证模型有效性, 凸显数据治理对预测精度的提升作用。

3.1 电算耦合驱动的预测模型框架

传统依赖历史负荷序列的建模方式, 因缺乏高质量数据支撑, 难以应对算力波动带来的强非线性、电算交互性和多时延影响。基于数据治理视角, 依托治理后的高质量数据及数据挖掘成果, 本文提出一套面向算力-负荷协同特性的预测模型框架, 以治理后的算力数据为核心驱动, 以深度时序模型捕获复杂协同关系, 实现对数据中心负荷的高精度预测。该框架包括输入特征体系构建、模型结构设计、协同机制集成三个核心部分, 全程依托数据治理成果展开。

3.1.1 输入特征体系构建

为反映算力行为与电力负荷之间的内在关联, 本研究基于前文的特征提取与模式识别结果, 构建“基础特征-耦合特征-外生修正特征”的三级输入体系: 一是基础算力特征, 包括算力强度主成分 $F1$ 与算力动态主成分 $F2$, 分别表征整体资源负载水平与瞬态波动特性, 是负荷变化的直接驱动量; 二是模式结构特征, 即模式编码向量 M , 用于表达任务类型、运行机制与调度方式引起的结构性差异, 使模型能够区分三类典型算力行为模式 (高密突发、平稳持续、周期波动); 三是外生修正特征, 包括环境温度 T 、机架分布指标 D 等, 用于补偿冷却能耗与机房布局对电力负荷的影响。

最终, 模型输入序列可表示为: $X_t=\{F_{1,t}, F_{2,t}, M_t, T_t, D_t\}$, 具有维度低、物理意义明确、可扩展性强等特点。

3.1.2 模型建构思想

传统多元回归方法难以处理算力行为引起的非平稳性、突发性及长短期依赖,因此本研究采用“深度时序网络+选择性注意机制”的结构来捕获电算耦合关系^[12]。其设计思想包括:

(1) 利用 LSTM 捕获负荷随算力变化的长短期依赖关系。算力行为中的突发峰值、周期波动等均体现明显的时序相关性, LSTM 可通过输入门、遗忘门与输出门结构对相关信息进行选择保留,使预测模型能提取基于算力驱动的负荷响应规律。

(2) 引入 Attention 机制增强模型对关键时段与关键特征的关注度。高密突发模式中短周期强冲击行为对负荷影响远大于平稳期,通过注意力权重 α_t 可放大关键时刻对预测结果的贡献,使模型具备“选重点”的能力。

(3) 构建融合机制实现算力特征与外生特征的协同作用。考虑模型在不同算力模式下的响应差异,通过模式编码向量控制网络中若干参数的选择,使模型具备“模式感知”能力,更精准地捕获模式差异导致的负荷变化规律。

3.2 基于注意力机制的预测模型构建

基于上述建模思想,本研究构建了“LSTM 时序特征提取层+Attention 权重分配层+负荷回归输出层”的预测架构,其流程如下:

(1) 时序特征编码:将输入序列 $X_{t-\omega:t}$ 输入至多层 LSTM 网络,得到隐藏状态序列

$$\mathbf{h}_t = \text{LSTM}(\mathbf{X}_t, \mathbf{h}_{t-1}) \quad (2)$$

其中, $\mathbf{h}_t$ 为 t 时刻 LSTM 隐藏状态向量; $\mathbf{X}_t$ 为 t 时刻的输入特征向量; LSTM($\cdot$) 为长短期记忆网络单元,用于建模时间序列中的长期依赖关系。

(2) 注意力权重计算:基于隐藏状态,对每一时刻计算注意力权重

$$\alpha_t = \frac{\exp(e_t)}{\sum_{k=1}^{\omega} \exp(e_k)}, e_t = \text{score}(\mathbf{h}_t) \quad (3)$$

其中, α_t 为 t 时刻的注意力权重; e_t 为注意力打分值; $\text{score}(\cdot)$ 为注意力评分函数,可由单层前馈神经网络或点积函数实现; ω 为时间窗口长度; k 为时间索引变量。

(3) 时序动态融合:利用注意力权重对隐藏状态加权求和,得到全局时序特征

$$\mathbf{H} = \sum_{t=1}^{\omega} \alpha_t \mathbf{h}_t \quad (4)$$

其中, $\mathbf{H}$ 为全局时序特征向量,表示加权融合后的算

力-负荷综合时序信息; α_t 为注意力权重; $\mathbf{h}_t$ 为 t 时刻的隐藏状态向量。

(4) 负荷预测输出:最终通过全连接层预测电力负荷

$$\hat{P}_{t+1} = \mathbf{W} \cdot \mathbf{H} + b \quad (5)$$

其中, $\mathbf{W}$ 为权重矩阵,用于将高维特征映射到负荷空间; b 为偏置项,用于修正系统性偏差。

3.3 仿真实验与验证

为验证“LSTM+Attention”电算耦合预测模型的有效性,基于多源数据特征与算力模式划分结果,构建模拟数据集开展对比实验,验证模型性能,明确其相较于传统方法的优势。

3.3.1 实验数据与评价指标

实验数据采用“真实数据映射+场景扩充”的方式生成:以某中型数据中心 15 天真实运行数据为基础,按本文第 2 节算力模式特征扩充至 10 000 条样本,涵盖高密突发(25%)、平稳持续(40%)、周期波动(35%) 3 类场景。数据按 7:2:1 划分为训练集、验证集与测试集,时间步长设为 10 (对应 10 min 历史数据预测未来 1 min 负荷)。

选取三类评价指标量化模型性能:(1) 平均绝对误差(MAE),反映预测值与真实值的绝对偏差;(2) 均方根误差(RMSE),放大极端误差的影响,体现模型对突发场景的把控能力;(3) 平均绝对百分比误差(MAPE),消除量纲影响,便于不同模型间横向对比。

3.3.2 实验设计

设计三组对比实验,以凸显“算力特征引入”“Attention 机制”的核心价值^[13]:

对照组 1:传统 LSTM 模型,仅输入历史负荷与环境温度特征,不引入算力相关特征与 Attention 机制;

对照组 2:LSTM+算力特征模型,输入 3.1 节三级特征体系,但不加入 Attention 权重分配层;

实验组:LSTM+Attention+算力特征模型(本文所提模型),完整包含 3.2 节架构的所有模块。

所有模型基于 TensorFlow 框架实现,设置相同超参数:LSTM 网络为 2 层,隐藏单元数为 64,优化器采用 Adam,学习率为 0.001,训练轮次为 50,防止过拟合采用 Dropout=0.2 策略。

3.3.3 实验结果与分析

(1) 整体预测性能对比

三组模型在测试集上的整体性能指标如表 5 所示。由表 5 可知,实验组模型在全场景下的 MAE、RMSE、

MAPE 均最优，其中 MAPE 较对照组 1 降低 53.9%，较对照组 2 降低 29.3%，验证了算力特征与 Attention 机制的协同增效作用。

表 5 各模型整体预测性能对比

模型类型	MAE	RMSE	MAPE/%
对照组 1（传统 LSTM）	18.6	25.3	8.9
对照组 2（LSTM+算力特征）	12.3	16.7	5.8
实验组（本文模型）	9.5	12.4	4.1

(2) 典型场景预测结果对比

为进一步分析模型在不同算力模式下的适应性，选取高密突发（AI 训练）、平稳持续（传统 IT 业务）两个代表性场景，抽取 10 个连续时间步的预测数据进行对比，结果如图 1 所示。




图 1 典型场景下各模型预测结果对比

图 1 中结果显示，高密突发场景中，“LSTM+Attention+算力特征模型”预测值与真实负荷偏差最小，峰值 428 kW 时仅差 3 kW，传统 LSTM 模型与“LSTM+算力特征模型”预测偏差达 37 kW、13 kW；平稳持续场景下，“LSTM+Attention+算力特征模型”预测值基本贴合真实负荷，多数时间步完全一致。

综上，基于数据治理后的高质量数据构建的预测模型，通过数据挖掘与 Attention 机制的融合，有效解决了传统模型因数据质量不足、算力特征挖掘不深入导致的预测精度低、突发场景响应差等问题，凸显了数据治理在数据中心算力-负荷协同分析中的核心支撑作用，为数据中心负荷精准预测提供了可靠技术支撑。

4 结论

本文从数据治理视角出发，围绕数据中心多源异构数据治理、算力数据挖掘、算力-电力负荷协同分析与预测展开研究，构建了“数据治理-数据挖掘-协同建模-预测优化”的完整体系，核心结论如下：

一是构建了多源异构数据治理体系，涵盖数据采集、清洗、质量控制、时空对齐与标准化全流程，完善了数据基础设施，有效解决了数据异构性、碎片化、质量差等问题，输出的高质量数据为后续数据挖掘与建模提供了坚实支撑，彰显了数据治理的基础价值。

二是基于治理后的高质量数据，通过 PCA、时序聚类数据挖掘方法，成功提取算力强度与动态核心特征，识别出 3 类典型算力模式，明确了不同模式的时空特征与负荷响应规律，实现了算力数据的价值挖掘，为算力-负荷协同建模提供了针对性支撑。

三是基于治理数据与挖掘成果构建的“LSTM+Attention”预测模型，预测精度显著优于传统模型，MAPE 降至 4.1%，能够精准捕捉算力驱动下的负荷变化，验证了数据治理、数据挖掘与预测模型的协同增效作用，为数据中心能效优化与算力调度提供了可靠技术路径。

本文构建了较为完整的数据治理视角下算力-负荷协同分析体系，但仍存在若干不足：一是受限于现有数据基础设施，部分环境数据、调度策略数据的时空颗粒度仍不足，可能影响细粒度数据挖掘与协同关系的刻画；二是数据治理流程仍可优化，未实现实时治理与动态更新，难以适应算力任务的快速变化；三是模型仍主要基于历史治理数据构建，未充分融合任务调度策略的动态预测能力。

在未来研究中，将进一步完善数据基础设施，提升多源数据的采集精度与时空颗粒度；优化数据治理流程，构建实时动态数据治理体系，实现数据质量的动态管控；引入更高频的算力运行与能耗监控数据，结合因果推断方法，构建面向调度优化的预测模型，并进一步探索数据中心与新能源出力的联合调控策略，为算力基础设施的低碳化运行及数据治理体系的持续完善提供更加全面的技术支撑。

参考文献

[1] 郭明军,陈东,王建冬,等. 数字化转型背景下数字政府的建设模式与实践探索——基于琼黔鲁粤等地的调研思考[J]. 电子政务,2023(1):2-11.

[2] 王永真,唐豪,魏一鸣,等. 中国数据中心综合能耗及其灵活性预测[J]. 北京理工大学学报(社会科学版),2025,27(2):12-18.

[3] 陈瑞,曹军. 基于卷积神经网络-长短期记忆-注意力机制模型的数据中心冷负荷预测研究[J]. 制冷技术,2025,45(3): 62-68,81.

[4] Rose T J, Wissuwa M. Rethinking internal phosphorus utilization efficiency: a new approach is needed to improve PUE in grain crops[J]. Advances in Agronomy, 2012, 116: 185-217.

[5] 张晨晨. 混合优化的长短期记忆神经网络短期空调冷负荷预测及其应用研究[D]. 青岛:青岛大学,2022.

[6] 黄国瑞,刘宏伟,赵耀,等. 基于 TRNSYS 的数据中心制冷系统能耗分析[J]. 制冷技术,2024,44(3):36-43.

[7] 高富贵,周文勤,张宝林. 云数据中心任务调度算法建模与仿真[J]. 电脑知识与技术,2025,21(4):88-91.

[8] 罗亮,吴文峻,张飞. 面向云计算数据中心的能耗建模方法[J]. 软件学报,2014,25(7):1371-1387.

[9] 丁肇豪,曹雨洁,张素芳,等. 能源互联网背景下数据中心与电力系统协同优化(一):数据中心能耗模型[J]. 中国电机工程学报,2022,42(9):3161-3177.

[10] 陈晓红,曹廖滢,陈蛟龙,等. 我国算力发展的需求、电力能耗及绿色低碳转型对策[J]. 中国科学院院刊,2024,39(3): 528-539.

[11] 戴坤成,王贵评,赵超. 基于 PCA 与 RBF 的建筑能耗预测建模[J]. 福州大学学报(自然科学版),2015,43(4):512-516.

[12] 章挺飞,罗恒,刘杭. 基于 LSTM 网络的建筑能耗预测方法[J]. 苏州科技大学学报(自然科学版),2020,37(4):78-84.

[13] 邵必林,史洋博,赵煜. 融合注意力机制与 LSTM 的建筑能耗预测模型研究[J]. 软件导刊,2021,20(10):61-67.

(收稿日期:2026-02-27)

作者简介:

孙钢(1987-),男,硕士,正高级工程师,主要研究方向:电力能源、电力市场管理等。

杜旻旻(1987-),女,本科,高级经济师,主要研究方向:轨道建设、交通能源管理等。

版权声明

凡《网络安全与数据治理》录用的文章，如作者没有关于汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权等版权的特殊声明，即视该文章署名作者同意将该文章的汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权授予本刊，本刊有权授权本刊合作数据库、合作媒体等合作伙伴使用。同时，本刊支付稿酬已包含上述使用的费用，特此声明。

《网络安全与数据治理》编辑部