

基于机器学习的电力拖动系统负载预测控制研究

宋双双

河南中柱建设集团有限公司 河南 郑州 450000

【摘要】：电力拖动系统是现代工业自动化的核心驱动单元，其负载状态的时变性与不确定性对系统的控制精度、能效优化及运行可靠性提出了严峻挑战。传统控制策略在面对复杂多变的负载工况时存在参数自适应性差、响应滞后等局限。本文系统梳理了机器学习方法在电力拖动系统负载预测与控制领域的研究进展，重点分析了基于深度学习的时序预测模型、强化学习自适应控制策略以及模型预测控制与神经网络融合技术的研究现状与适用场景。研究表明：长短期记忆网络（LSTM）及其变体在负载时序预测中表现出良好的非线性拟合能力；深度强化学习可动态调整电机控制参数，实现负载突变工况下的自适应优化；模型预测控制与深度学习结合可有效提升系统在多变量约束条件下的动态响应性能。当前该领域的研究正向模型轻量化、在线学习和多模态感知融合等方向深入发展。

【关键词】：电力拖动系统；负载预测；机器学习；深度学习；预测控制

DOI:10.12417/2811-0528.26.17.007

1 引言

电力拖动系统作为一种将电能转换为机械能的关键装置，主要由电动机（包括交流电动机、直流电动机及特种电机）、传动机构（如齿轮箱、皮带传动等）、控制装置（如变频器、伺服驱动器）及负载设备（如风机、泵机、机床主轴）组成。该系统广泛应用于工业生产（如智能制造流水线、重型机械加工）、交通运输（如电动汽车、轨道交通牵引）、航空航天（如飞控作动系统）及新能源发电（如风力发电机桨距控制）等领域，成为现代工业自动化的核心动力来源。随着工业场景对系统动态响应速度、能效水平及智能化程度要求的不断提高，传统的PID控制、矢量控制等方法在面对负载突变、非线性干扰及工况漂移等挑战时，其参数固定的控制架构难以维持最优性能，常出现超调、振荡或响应滞后等问题，导致能效下降和设备损耗。因此，引入机器学习方法（如监督学习、强化学习）实现负载状态的精准预测与自适应控制，通过在线学习与参数调整来应对复杂工况，已成为电力拖动系统智能化升级的重要研究方向。

近年来，深度学习技术在时序预测、模式识别及决策优化等领域取得了突破性进展，例如长短期记忆网络（LSTM）和卷积神经网络（CNN）在时间序列分析中的成功应用，为电力拖动系统的负载预测与控制提供了新的技术路径。基于运行数据驱动的建模范式，可在不依赖精确物理模型的前提下，从系统运行数据（如电流、电压、转速、转矩信号）中提取负载变化的隐含规律，结合大数据平台与边缘计算实现实时特征学习，从而实现超前预测与主动调控，提升系统鲁棒性和能效。本文旨在系统梳理已有研究成果，归纳主要的技术路线（如基于深度学习的预测模型、融合物理信息的混合建模方法）与关

键方法（如迁移学习、元学习在跨工况适配中的应用），分析现存问题（如数据稀缺性、模型可解释性不足、实时部署挑战），并前瞻未来发展方向（如数字孪生集成、联邦学习保障数据安全、自适应优化算法创新），以期后续深入研究提供参考。

2 电力拖动系统负载特性与预测问题描述

2.1 系统结构与负载分类

电力拖动系统的负载根据其机械特性可分为恒转矩负载、恒功率负载和通风机型负载三类。恒转矩负载如起重机、传送带，其阻转矩与转速基本无关，在低速和高速运行时均保持相对稳定的转矩值，适用于需要恒定输出力的场合，这类负载在启动和调速过程中要求电机提供均匀的力矩。恒功率负载如机床主轴，其功率在调速范围内近似恒定，通常表现为在高速时转矩减小、低速时转矩增大，以满足加工过程中的功率需求，常见于金属切削、卷绕设备等需要宽调速的领域。通风机型负载如离心式风机，其转矩与转速的平方成正比，因此随着转速升高，转矩迅速增加，常见于泵类、风扇等流体输送设备，这种负载的机械特性对电机的加速和减速过程有较大影响。不同类型的负载对电机控制策略的适应性要求存在显著差异，例如恒转矩负载适合采用直接转矩控制或矢量控制以保持转矩平稳，恒功率负载可能需要弱磁调速技术来扩展速度范围，而通风机型负载则需考虑转矩的平方律特性以避免过载。这为负载预测与自适应控制提出了多样化需求，要求系统能够实时识别负载类型、监测工况变化，并动态调整控制参数，以实现高效、稳定的运行，从而提升整个电力拖动系统的智能化水平和能效。

2.2 负载预测的关键科学问题

负载预测的核心问题在于：如何在有限历史数据的基础上，利用时序建模方法准确预测未来负载的演变趋势，进而为控制策略的提前调整提供可靠依据。这一过程在能源管理、云计算资源调度等实际应用中至关重要，但面临多重挑战。第一，负载信号往往呈现强非平稳性与多时间尺度特征，例如由于季节变化、工作日与节假日差异等因素，负载波动表现出长期趋势、周期性和随机性交织的复杂模式，这要求模型能够同时捕捉短期波动和长期演化规律。第二，实际运行数据存在噪声扰动与缺失值，这些噪声可能源于测量误差或外部干扰，而数据缺失则因设备故障或传输问题导致，这显著增加了数据清洗与预处理的工作量，并影响建模的准确性与鲁棒性。第三，系统在负载突变的非稳态阶段，例如突发高峰或骤降场景，需要模型具备快速响应能力，以实时适应变化并避免控制滞后，这对预测模型的计算效率与实时性提出了紧迫要求，往往需要在精度与速度之间取得平衡。此外，负载预测还涉及模型泛化能力、可解释性以及与其他系统模块的协同集成等潜在难点，进一步凸显了该领域研究的复杂性与重要性。

3 机器学习驱动的负载预测方法

3.1 基于深度学习的时序预测模型

在负载时序预测任务中，深度学习模型凭借其强大的特征自动提取能力，逐渐替代了传统的自回归滑动平均模型（ARIMA）与支持向量回归（SVR）方法。这主要得益于深度学习模型能够自动从原始时序数据中学习复杂的非线性关系和动态模式，而无需依赖人工特征工程，从而在预测精度和适应性上取得显著提升。其中，长短期记忆网络（LSTM）通过引入门控机制，如输入门、遗忘门和输出门，有效解决了循环神经网络（RNN）在处理长序列时的梯度消失问题，使得模型能够更好地捕捉长期依赖关系，在电力负荷预测领域展现出良好性能。研究表明，基于LSTM的区域微网短期负荷预测模型能够较传统BP神经网络显著降低预测误差，这主要归因于LSTM对时序依赖关系的长程记忆能力，例如它可以有效识别负荷数据中的日周期波动、周循环趋势以及季节性变化，从而在多变环境下保持稳定的预测表现。

同时，基于生成对抗网络（GAN）的预测框架为解决负载数据小样本问题提供了新思路。通过生成器与判别器的对抗训练机制，GAN模型能够从有限的真实样本中学习数据分布特征，生成高质量合成数据以扩充训练集，有效提升预测模型在小样本条件下的泛化能力。具体而言，生成器通过噪声输入生成模拟数据，而判别器则致力于区分真实样本与生成样本，两者在博弈过程中不断优化，最终使生成数据逼近真实分布。这种数据增强策略对于电力拖动系统中负载工况频繁切换、长

时序数据获取成本高的场景具有重要应用价值，它不仅缓解了数据稀缺带来的过拟合风险，还为模型训练提供了更丰富的多样性。此外，GAN的扩展模型如条件生成对抗网络（cGAN）可以整合外部因素如温度、时间信息，进一步生成针对性强的合成数据，从而优化预测模型在特定工况下的性能。

总体而言，深度学习模型在负载时序预测中的应用正不断深化，LSTM和GAN等技术的结合不仅推动了预测方法的创新，还为实际工业场景中的能效管理和系统优化提供了可靠工具，未来随着模型架构和训练策略的改进，其应用潜力将进一步释放。

3.2 多任务与多模态预测架构

实际电力拖动系统的负荷特性往往呈现多任务耦合的复杂特点，具体表现为电负荷、机械负荷与热负荷之间存在着动态的、非线性的关联关系，这种耦合效应在工业运行场景中尤为显著，使得单一负荷的独立预测难以准确反映系统整体行为。多任务学习模型通过设计共享隐藏层的网络结构，能够同时处理并预测多种类型的负荷，有效利用任务间知识的互补性与协同性，从而在训练过程中增强模型的泛化能力，显著提升各个子任务的预测精度。实验研究表明，相较于传统的单任务学习模型，多任务学习模型在电负荷、冷负荷和热负荷的联合预测任务中，不仅能够更好地捕捉负荷间的交互影响，其评估指标如平均绝对百分比误差（MAPE）和均方根误差（RMSE）均有显著下降，这进一步验证了该模型在复杂电力系统负荷预测中的实用性与优越性。

4 机器学习与预测控制的融合策略

4.1 深度强化学习在自适应控制中的应用

智能决策是电力拖动系统智能化的核心环节。深度强化学习通过智能体与环境的持续交互学习最优控制策略，实现了从预设规则到动态优化的根本转变。具体而言，通过强化学习算法动态调整PID控制参数，可使电机在负载突变时仍保持高效稳定运行。有研究显示，在电动汽车驱动电机中，利用人工智能算法优化再生制动策略，可使整车续航能力提升约5%。

此外，基于聚类分析的负载模式识别技术（如K均值算法）能够自动识别电机运行工况类别，驱动控制器在不同负载模式下自动切换节能策略。例如，工业水泵电机在负荷较低时切换至节能模式，整体能耗可降低30%。这种基于数据驱动的负载自适应控制策略，有效弥补了传统控制方法在工况识别与模式匹配方面的不足。

4.2 深度学习与模型预测控制的协同优化

模型预测控制（MPC）通过在线滚动优化处理系统的多

变量、多约束问题，特别适用于电机启动过程的平滑转矩控制与发电模式的电压快速恢复场景。然而，传统 MPC 的建模精度高度依赖于系统动态模型的准确性，在未知扰动或模型失配时控制性能会显著下降。将深度学习与 MPC 结合，利用神经网络在线学习系统动态特性，是提升 MPC 对非建模不确定性鲁棒性的有效途径。深度神经网络可根据实时输入数据自适应更新预测模型，使得 MPC 控制器在负载特性变化后仍能维持较优的控制效果。

研究还表明，针对高可靠性需求的关键电机驱动系统（如航空燃油泵驱动电机），深度学习可辅助实现快速的故障诊断算法（如基于电流 Park 矢量轨迹分析方法），并在单相故障发生后通过重构剩余健康相实现“故障后降额持续运行”，从而保障拖动系统在极限工况下的生存能力。

5 现有方法的局限性与发展趋势

尽管机器学习在电力拖动系统负载预测控制中展现了显

著潜力，现有方法仍面临若干共性问题。首先，深度学习模型普遍依赖大量高质量标注数据，而在实际工业场景中获取故障工况下的负载数据难度较大，数据稀疏性问题制约了模型泛化能力。其次，许多高精度预测模型计算复杂度较高，难以在嵌入式控制器等资源受限平台上实现在线运行。第三，大部分现有研究侧重于单一预测任务或单一控制环节的优化，缺乏从负载感知到控制执行端到端的一体化方案。

面向未来，该领域的发展趋势可归纳为以下三个方面：其一，模型轻量化——通过知识蒸馏、网络剪枝及量化技术，在保证预测精度的前提下降低模型计算开销，使之适配边缘计算环境；其二，在线适应——引入在线学习与增量更新机制，使模型能够在系统运行过程中不断适应负载特性的时变漂移；其三，多模态融合——集成电流、转速、温度及振动等多源传感信息，构建高维状态空间下的负载感知与预测架构，提升系统在复杂工况下的鲁棒性与智能化水平。

参考文献：

- [1] 尹春杰,肖发达,李鹏飞,等.基于 LSTM 神经网络的区域微网短期负荷预测[J].计算机与现代化,2022(4):7-11.
- [2] 李晓静,张永华,魏小兵,等.基于深度学习的 TBM 运行参数预测及小样本扩充研究[J].应用基础与工程科学学报,2025,33(3):727-742.
- [3] 倪建辉,张菁,张昊立,等.基于时序特征灰度图与多任务学习的综合能源负荷短期预测[J].电气工程学报,2024,19(2):186-199.
- [4] 孔武斌,刘迪,范兴纲,等.航空发动机多电控制系统源-网-荷架构与关键技术[J].航空学报,2025,46(2):1-39.
- [5] 钱育树,孔钰婷,黄聪.电力负荷预测研究综述[J].四川电力技术,2023,46(4):37-43,58.