

智能算法在风力发电远程控制中的应用与优化

吴晓丹

内蒙古华电新能源分公司 内蒙古 呼和浩特 010010

摘要：智能算法在风力发电远程控制中的应用为提升发电效率、降低运维成本提供了新路径。通过深度学习、强化学习等技术，智能算法可实现多源数据融合处理、风速与功率精准预测、设备状态实时监测与故障诊断，并优化控制策略以适应动态环境。实际应用仍面临数据质量、算法适应性、实时性及系统稳定性等挑战。本文从数据质量提升、算法融合、实时性优化及鲁棒性增强四个维度提出优化策略，旨在构建高效、可靠的风力发电远程控制系统，推动清洁能源的智能化发展。

关键词：智能算法；风力发电远程控制；优化策略

1 智能算法基础与选型

1.1 常见智能算法介绍

智能算法作为人工智能领域的核心技术，旨在通过模拟生物智能或物理规律解决现实中的复杂问题。常见的智能算法可分为多个类别：机器学习算法是其中的重要分支，包含监督学习（如支持向量机、决策树、神经网络等），通过标注数据训练模型以实现分类或回归任务；无监督学习（如K-Means聚类、PCA降维）则从无标签数据中挖掘潜在结构或模式；强化学习（如Q-Learning、深度强化学习）通过与环境交互学习最优策略，适用于动态决策场景。进化算法（如遗传算法、粒子群优化）模拟自然选择或群体协作机制，通过迭代优化求解复杂问题。神经网络与深度学习进一步拓展了智能算法的能力，卷积神经网络（CNN）在图像识别领域表现卓越，循环神经网络（RNN）及其变体（如LSTM、GRU）则擅长处理序列数据（如自然语言处理）。概率图模型（如贝叶斯网络、马尔可夫随机场）通过条件概率建模变量间的依赖关系，为不确定性推理提供了理论基础。这些算法各具特色，共同构成了智能算法的丰富生态。

1.2 智能算法的特点

智能算法的核心特征体现在其自适应性、非线性建模能力、全局与局部优化结合、并行计算支持、鲁棒性及领域通用性等多个维度。第一，智能算法能够根据数据特征或环境变化动态调整参数或策略，例如神经网络通过反向传播算法优化权重，遗传算法通过交叉与变异操作适应问题需求^[1]。第二，神经网络、决策树等算法具备强大的非线性建模能力，可拟合现实世界中复杂的高维数据关系，突破了传统线性模型的局限。第三，智能算法融合了全局搜索与局部优化的优势，例如遗传算

法通过种群进化避免陷入局部最优，而梯度下降法等局部优化方法则能快速收敛至近似解。第四，深度学习框架（如TensorFlow、PyTorch）通过GPU加速和分布式计算，显著提升了大规模数据的处理效率，进化算法也常通过多线程并行优化求解速度。第五，智能算法对噪声数据或部分失效的输入具有较高的容忍度，例如集成学习通过组合多个模型降低过拟合风险，增强系统的稳定性。第六，智能算法既具备领域通用性（如支持向量机可应用于多种分类任务），也支持领域定制化（如医疗影像分析需结合解剖学知识设计专用模型）。

2 风力发电远程控制的必要性

2.1 提高发电效率与稳定性

风力发电受自然环境（如风速、风向、温度等）的动态变化影响显著，传统人工监控方式难以实时响应环境波动，导致发电效率波动较大。通过远程控制系统，可实现风电机组的实时状态监测与参数自适应调整，例如根据风速变化动态优化叶片角度、转速或功率输出，确保设备始终运行在最佳效率区间。远程控制可结合气象预测数据，提前调整机组运行策略以应对极端天气（如强风、雷暴），避免因突发性环境变化导致的发电中断或设备损坏。通过集中监控平台对多台机组进行协同调度，可平衡区域电网的供需波动，提高整体发电稳定性，减少因局部故障引发的连锁反应。

2.2 降低运维成本与风险

风力发电场通常分布于偏远地区（如山区、海域），传统人工巡检方式需投入大量人力、物力，且受限于地理条件与气候因素，运维效率低下且成本高昂。远程控制系统通过集成传感器网络、无人机巡检与智能诊断算法，可实现对设备状态的实时监测与故障预警。远程运维支持远程软件升级、参数调优等操作，减少现

场作业需求,降低人员暴露于恶劣环境(如高空、强风)的风险。基于大数据分析的运维决策可优化备件库存管理,减少因备件短缺导致的维修延误,进一步压缩运维成本。

3 智能算法在风力发电远程控制中的应用

随着风力发电技术的快速发展,风电机组逐渐向大型化、复杂化方向发展,传统控制方法已难以满足高效、稳定、低成本的运维需求。智能算法凭借其强大的数据处理能力、非线性建模能力和自适应优化特性,在风力发电远程控制中展现出显著优势。

3.1 数据处理与特征提取

风力发电系统的运行数据具有高维度、强噪声、非线性等特点,传统方法难以直接挖掘数据中的有效信息。智能算法通过深度学习、特征工程等技术,可实现多源数据的融合处理与关键特征提取,为后续分析提供高质量数据基础。多源数据融合:风力发电系统涉及气象数据(风速、风向、温度)、机组运行数据(转速、功率、振动)、电网数据(电压、频率)等多源异构数据。智能算法(如深度信念网络、自编码器)可通过无监督学习提取数据间的潜在关联,构建统一的数据表示框架^[2]。特征降维与选择:高维数据易导致“维度灾难”,降低模型训练效率。智能算法(如主成分分析PCA、t-SNE降维)可提取数据的主导特征,去除冗余信息;基于随机森林、Lasso回归的特征选择方法可识别对发电效率或设备状态影响最大的变量,降低模型复杂度。实时数据处理:风力发电需实时响应环境变化,智能算法(如流式计算框架Apache Flink、边缘计算)可实现毫秒级数据采集与处理,确保控制指令的及时性。

3.2 风速与功率预测

风速的随机性和波动性是风力发电面临的主要挑战之一。准确预测风速与功率输出,可优化机组运行策略,提高发电效率与稳定性。短期预测(0-4小时):基于LSTM、GRU等循环神经网络,可结合历史气象数据、实时风速监测数据和地形信息,构建高精度短期预测模型。例如,通过引入注意力机制,模型可聚焦于影响风速的关键因素(如气压梯度、地形起伏),提升预测准确性。中长期预测(1天-1周):中长期预测需结合气象预报数据和历史统计规律。智能算法(如XGBoost、LightGBM)可通过集成学习融合多源数据,降低单一模型的不确定性。功率优化调度:基于风速预测结果,智能算法可动态调整机组运行参数(如叶片角度、转速),实现功率输出的最大化。

3.3 设备状态监测与故障诊断

风电机组长期运行于恶劣环境,易发生机械故障(如齿轮箱磨损、叶片裂纹)和电气故障(如变频器故障、传感器失效)。智能算法可通过数据驱动的方式实现设备状态的实时监测与故障诊断。振动信号是反映设备健康状态的重要指标。智能算法(如卷积神经网络CNN)可自动提取振动信号的时频特征,识别异常振动模式。基于支持向量机(SVM)等分类算法,可分析油液样本的理化指标(如粘度、酸值),预测齿轮箱、轴承等部件的润滑状态,提前预警潜在故障。结合振动、油液、温度等多源数据,智能算法(如随机森林)可综合评估设备状态,提升故障诊断的准确率。

3.4 控制策略优化与自适应控制

风力发电场受风速、风向等环境因素影响显著,传统固定控制策略难以适应动态变化。智能算法可通过强化学习、自适应控制等技术,实现控制策略的动态优化。基于Q-Learning等强化学习算法,机组可在不同风速区间学习最优控制策略(如叶片角度、转速等参数),通过与环境交互不断优化控制策略,提升发电效率。结合气象预测数据与实时环境监测,智能算法可动态调整控制策略,确保机组在复杂环境中的稳定运行。为满足实时性要求,需对深度学习模型进行压缩(如知识蒸馏、量化训练),在边缘设备上实现轻量化部署。例如,通过训练轻量级卷积神经网络(如MobileNet),可在保证精度的同时降低计算复杂度,满足远程控制的实时性需求^[3]。

4 智能算法在风力发电远程控制中的优化策略

随着风力发电技术的智能化升级,智能算法在远程控制中的应用日益广泛。实际应用中仍面临数据质量、算法适应性、实时性及系统稳定性等挑战。为进一步提升智能算法在风力发电远程控制中的效能,需从数据质量、算法选择、实时性优化及系统稳定性四个维度制定针对性策略。

4.1 数据质量与多样性提升

数据是智能算法的核心驱动力,数据质量与多样性直接影响模型的预测精度与泛化能力。在风力发电场景中,需从以下三方面优化数据:(1)数据清洗与预处理。风力发电数据常受传感器噪声、通信干扰等因素影响,存在缺失值、异常值等问题。需采用插值法、均值滤波等技术填补缺失数据,利用孤立森林、Z-score等方法识别并剔除异常值。可通过标准化、归一化处理消除数据量纲差异,提升模型训练效率;(2)多源数据融合。风力发电系统涉及气象数据(风速、风向)、机组运行数据(转速、功率、振动)、电网数据(电压、频

率)等多源异构数据。需构建统一的数据表示框架,通过特征工程或深度学习模型(如自编码器)提取数据间的潜在关联;(3)数据增强与生成。针对历史数据不足或样本不均衡问题,可采用数据增强技术(如时间序列平移、噪声叠加)扩充数据集,或利用生成对抗网络(GAN)生成合成数据,提升模型对极端工况的适应性。

4.2 算法选择与模型融合

智能算法的多样性为风力发电远程控制提供了丰富的解决方案,但单一算法难以应对复杂场景。需通过算法选择与模型融合提升系统性能:算法适配性分析:根据任务需求(如预测、诊断、控制)选择合适算法。例如,时间序列预测任务适合LSTM、GRU等循环神经网络;故障诊断任务则需CNN、随机森林等具备特征提取能力的模型。模型融合与集成学习:通过集成学习(如Bagging、Boosting)融合多个基础模型,可降低单一模型的过拟合风险,提升预测精度。迁移学习与知识蒸馏:利用迁移学习将相似领域(如风电场B)的预训练模型迁移至目标风电场(如风电场A),减少数据依赖;通过知识蒸馏将复杂模型(如深度神经网络)的知识压缩至轻量级模型(如决策树),提升实时性。

4.3 实时性与动态性优化

风力发电需实时响应环境变化,对智能算法的实时性与动态性提出高要求。在风电场边缘设备部署轻量级模型(如MobileNet、TinyYOLO),减少数据传输延迟;通过模型压缩(如量化训练、剪枝)降低计算复杂度,确保实时性。例如,在振动信号分析中,采用一维卷积神经网络(1D-CNN)替代传统傅里叶变换,可实现毫秒级异常检测^[4]。结合气象预测数据与实时环境监测,动态调整控制策略。例如,基于强化学习算法(如DQN),机组可在不同风速区间自动切换最优控制参数(如叶片角度、转速),通过与环境交互不断优化策略,提升发电效率。采用ApacheFlink、Kafka等流式计算框架,实现毫秒级数据采集与处理,确保控制指令的及时性。

4.4 系统稳定性与鲁棒性分析

风力发电场运行于恶劣环境,需确保智能算法在噪声干扰、设备故障等异常情况下的稳定性。需从以下三方面提升系统鲁棒性:(1)噪声与异常处理:在模型训练中引入噪声数据(如高斯噪声、椒盐噪声),提升模型对噪声的容忍度;通过对抗训练(AdversarialTraining)增强模型对恶意攻击的防御能力。(2)容错机制与冗余设计:构建多级容错机制,如主备模型切换、数据回滚等,确保系统在部分组件失效时仍能正常运行;采用冗余设计(如双机热备、多传感器融合)提升系统可靠性。(3)鲁棒性评估与测试:通过蒙特卡洛模拟、压力测试等方法评估模型在不同工况下的稳定性;结合实际风电场数据验证模型在极端环境(如强风、雷暴)下的性能,针对性优化模型参数。

结束语

智能算法在风力发电远程控制中的应用与优化,是清洁能源技术发展的重要方向。通过提升数据质量、选择适配算法、优化实时性与增强系统鲁棒性,智能算法可显著提升风力发电的效率与稳定性,降低运维成本。未来,随着算法创新与硬件技术的突破,智能算法将在风力发电领域发挥更关键作用,助力实现能源结构的绿色转型。需持续探索跨学科融合,推动智能算法与风力发电技术的深度协同,为全球可持续发展贡献力量。

参考文献

- [1]张涛,李江楠,文浚.分析风力发电机电动叶轮锁[J].电气技术与经济,2024(3):196-198.DOI:10.3969/j.issn.1673-8845.2024.03.065.
- [2]刘启栋,芦彪,宋首先,等.风力发电叶片裂缝监测技术原理和应用[J].电力设备管理,2024(4):89-91.
- [3]景小楠.风电场电气设备中风力发电机的运行与维护[J].数码设计,2023(18):109-111.DOI:10.3969/j.issn.1672-9129.smsj-shang202318033.
- [4]秦洪亮.人工智能算法文学的"文学性"平议[J].内蒙古社会科学,2025,46(1):140-148.DOI:10.14137/j.cnki.issn1003-5281.2025.01.018.