

山东电力技术

SHANDONG ELECTRIC POWER



能源动力技术实验室



国网山东省电力公司主办

ISSN 1007-9904



2025.12 第52卷
2025年12月

收录情况

中国科技核心期刊
中国核心期刊（遴选）数据库收录期刊
中国期刊全文数据库（CJFD）收录期刊
中文科技期刊数据库收录期刊
波兰 ICI World of Journals 数据库收录期刊
美国《乌利希期刊指南》收录期刊
瑞典开放获取期刊目录（DOAJ）收录期刊
美国 EBSCO 学术数据库收录期刊

山东电力技术 SHANDONG DIANLI JISHU (月刊)

1974 年创刊 2025 年第 12 期
第 52 卷（总第 337 期）
2025 年 12 月 25 日出版

主管单位：国网山东省电力公司
主办单位：国网山东省电力公司
编辑出版：《山东电力技术》编辑部
地址：济南市市中区望岳路 2000 号
邮政编码：250003
电话：(0531) 67982997
电子信箱：sddljs@sina.com
网址：sddljs.cbpt.cnki.net
印刷：济南浪宇印刷有限公司
发行：公开发行 自办征订
定价：18.00 元/册

《山东电力技术》编辑委员会

顾问：陈维江 郑建华 侯保荣 雷清泉 王成山
主任：孙岗

副主任：王伟胜 吴文传 刘玉田 陈志勇 梁作宾
田健

委员：（按姓氏笔画为序）

丁磊 丁勇 王波 王建东 孙波
孙树敏 严志国 苏洲 吴秋伟 赵艳雷
姜雨泽 郭锐 彭道刚 董泽 程新功

青年编委主任委员：姚伟 李正烁

青年委员：（按姓氏笔画为序）

丁涛 王士柏 王中冠 王彬 巨云涛
牛涛 刘晓明 许寅 李志刚 李知艺
杨越 沈欣炜 陈思捷 郑伟业 钟海旺
高嵩 常馨月 薛屹洵

主编：吴文传 孟瑜

执行主编：马艳

责任编辑：郑天茹 姜婷婷 张丹丹 车永强

中国标准连续出版物号：

ISSN 1007-9904

CN 37-1258/TM

期刊基本参数：

CN 37-1258/TM*1974*m*A4*128*zh*P* ¥18.00*8000*11*2025-12*n

《山东电力技术》连续入选 中国科技核心期刊



“基于人工智能的车桩网协同最优规划 调度关键技术”专栏

征稿启事

全球“双碳”目标的推进与可再生能源技术的迅猛发展，推动了电动汽车的广泛应用。与此同时，人工智能技术的突破性进展为电动汽车、充电基础设施与电网的协同优化开辟了全新路径。电动汽车充电基础设施是配电网与路网的重要组成部分。对电网而言，充电桩的规划与运行必须考虑大规模电动汽车充电负荷带来的安全、可靠性和经济性挑战。同时，充电桩的建设和运营也受到电网容量和运行可靠性的制约。对路网而言，电动汽车的出行行为以及充电桩的选址与容量规划显著改变了电动汽车在路网上的时空分布，进而影响充电基础设施的规划与运营。在此背景下，利用人工智能技术对车桩网协同交互策略进行深入研究，实施充电桩的合理选址与容量规划，并确保大规模电动汽车接入下电网的安全稳定运行，对于推动新能源汽车技术的发展以及提升电网的安全性、稳定性和经济性具有重要意义。同时，如何制定合适的调度策略使得车主 - 运营商 - 电网三方利益最大化，电网运营压力最小也是亟待解决的重要问题。

为展示车桩网一体协同规划关键技术的最新研究进展和发展趋势，解决技术研究和应用中的难题和热点问题，推动技术创新和交流，**诚邀昆明理工大学教授杨博、英国利物浦大学教授蒋林、东北大学副教授张孝顺和新西兰奥克兰理工大学讲师周率担任特约主编**，拟针对“基于人工智能的车桩网协同最优规划调度关键技术”开设专栏，欢迎国内外相关领域的专家学者踊跃投稿！

一、征稿方向（包括但不限于）

- 1、基于人工智能的电动汽车充电负荷预测技术；
- 2、基于人工智能的车桩网耦合的规划与调度技术；
- 3、基于人工智能的充电基础设施选址与容量规划技术；
- 4、基于人工智能的车桩网一体化系统调度技术；
- 5、基于人工智能的车桩网深度耦合的电网协同规划与运行技术；
- 6、含大规模电动汽车与充电基础设施的电网安全稳定运行技术；
- 7、考虑电动汽车运行的综合能源系统规划与调度技术；
- 8、基于人工智能车桩网协同互动（V2G）策略优化；
- 9、基于人工智能的电动汽车 - 充电桩 - 电网系统故障诊断与预测性技术；
- 10、基于人工智能的车桩网协同互动（V2G）参与多元市场调度策略优化。

二、投稿要求

- 1、请从山东电力技术网站投稿，请在题名后标注“基于人工智能的车桩网协同最优规划调度关键技术”，
网址：<http://sddljs.cbpt.cnki.net>
- 2、稿件详细要求请参照《山东电力技术》投稿须知及论文写作模版，投稿须知及论文写作模版请在山东电力技术网站下载。
- 3、稿件一经采用，本刊将按照《山东电力技术》期刊稿费发放标准向作者发放稿费，稿酬优厚。
- 4、征文截止时间 2026 年 3 月 31 日，其他不明事宜，请联系《山东电力技术》编辑部。电话：0531-67982997。

目次

新能源

- 基于偏最小二乘和改进时间卷积网络的风电场超短期发电功率预测
 郑广宇, 辛 征, 迟蔚然, 陈立征, 王士柏(1)
- 基于地基云图与卫星云图相结合的光伏功率预测方法 马文文, 胡思雨, 杨 凡, 李登宣, 卜强生(17)
- 基于储能惯量支撑的高比例新能源基地效益提升优化方法 李红刚, 李 勇, 李晓宁, 穆明亮(27)
- 融合多元时间序列与TCN-BiLSTM的分布式光伏功率超短期预测研究
 高任龙, 李 峰, 马天东, 吴 骥(38)

电力市场运营

- 面向光储集群接入的有源配电网两阶段交易机制设计 徐嘉豪, 徐俊俊, 王福晶(50)
- 适应新增电器的非侵入式负荷监测增量学习方法 杨国朝, 贾明辉, 李子墨, 白辛雨, 于普瑶, 刘 尧(61)

电网运行与控制

- 基于动态电压反馈的变流器锁相同步稳定控制方法 武乃虎, 苗伟威, 刘 露, 周海全, 孙伶雁(70)
- 基于扰动观测器的并网逆变器鲁棒模型预测控制 滕 飞, 吴俊俊, 姜 辰, 黄昊怡, 黄 堃(81)

输变电

- 考虑城轨杂散电流的主变压器隔直装置最优配置 宋景博, 陈 晨, 齐桓若, 张金凤, 薛文杰, 刘铜锤(92)
- 基于电场等效的 ± 800 kV直流输电线路直线塔无人机灭火安全距离研究
 过 羿, 胡圣涛, 刘宇舜, 赵玉顺, 张佳庆(102)
- 基于数据质量提升的变压器顶层油温预测模型 张若愚, 石 峥, 郭 建, 宫 鑫, 雷 敏(113)

CONTENTS

• New Energy •

- Ultra-short Term Power Generation Prediction of Wind Farm Based on Partial Least Squares and Improved Time Convolutional Network ZHENG Guangyu, XIN Zheng, CHI Weiran, CHEN Lizheng, WANG Shibo(1)
- Photovoltaic Power Prediction Method Based on Combination of Ground-based and Satellite Cloud Maps MA Wenwen, HU Siyu, YANG Fan, LI Dengxuan, BU Qiangsheng(17)
- A Method for Optimizing the Allocation of Comprehensive Benefits of a High Proportion of New Energy Bases Based on Energy Storage Inertia LI Honggang, LI Yong, LI Xiaoning, MU Mingliang(27)
- The Research on Ultra-short-term Prediction of Distributed Photovoltaic Power Based on Multivariate Time Series Fusion With TCN-BiLSTM Network GAO Renlong, LI Feng, MA Tiandong, WU Ji(38)

• Electricity Market Operation •

- Design of Two-stage Trading Mechanism for Active Distribution Network Integrating Photovoltaic and Storage Clusters XU Jiahao, XU Junjun, WANG Fujing(50)
- Non-intrusive Load Monitoring Incremental Learning Method for New Appliances YANG Guochao, JIA Minghui, LI Zimo, BAI Xinyu, YU Puyao, LIU Yao(61)

• Power Grid Operation and Control •

- PLL Synchronization Stability Control Scheme for Converters Based on Dynamic Voltage Feedback WU Naihu, MIAO Weiwei, LIU Lu, ZHOU Haiquan, SUN Lingyan(70)
- Robust Model Predictive Control for Grid-connected Inverters Based on Disturbance Observer TENG Fei, WU Junjun, JIANG Chen, HUANG Haoyi, HUANG Kun(81)

• Power Transmission and Transformation •

- Optimal Configuration of DC Blocking Devices for Main Transformers Considering Stray Currents in Urban Rail SONG Jingbo, CHEN Chen, QI Huanruo, ZHANG Jinfeng, XUE Wenjie, LIU Tongchui(92)
- Research on the Safety Distance for UAV Fire Extinguishing on ± 800 kV DC Transmission Line Linear Tower Based on Electric Field Equivalence GUO Yi, HU Shengtao, LIU Yushun, ZHAO Yushun, ZHANG Jiaqing(102)
- Transformer Top Oil Temperature Prediction Model Based on Data Quality Improvements ZHANG Ruoyu, SHI Zheng, GUO Jian, GONG Xin, LEI Min(113)

SHANDONG ELECTRIC POWER

(Monthly, Started in 1974)

Administration State Grid Shandong Electric Power Company**Sponsor** State Grid Shandong Electric Power Company**Edited by** Editorial Department of Shandong Electric Power**Chief Editor** WU Wenchuan MENG Yu**Address** No.2000, Wangyue Road, Jinan, China 250003

基于偏最小二乘和改进时间卷积网络的风电场超短期发电功率预测

郑广宇¹, 辛 征^{1*}, 迟蔚然¹, 陈立征¹, 王士柏²

(1. 山东建筑大学信息与电气工程学院, 山东 济南 250101; 2. 国网山东省电力公司电力科学研究院, 山东 济南 250003)

摘要:为提高超短期风电功率预测的精度,提出结合偏最小二乘法(partial least squares, PLS)与改进时间卷积网络(improved temporal convolutional network, ITCN)的预测方法。首先,利用PLS提取与风电功率高度相关的气象特征;随后,在时间卷积网络(temporal convolutional network, TCN)中引入空间卷积层,增强时间和空间特征的提取能力。为避免局部最优,采用黏菌算法优化超参数。通过对我国东部与西部实际数据集的实验验证,结果显示所提方法在捕捉输入变量与风电功率的时空特性上表现优越,预测精度较常用方法卷积神经网络(convolutional neural network, CNN)、长短期记忆网络(long short-term memory, LSTM)、双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)和TCN分别提高12.61%、4.45%、3.65%和2.18%。该方法为提升风电场运行效率和稳定性提供了新思路。

关键词:风电功率预测;偏最小二乘法;改进的时间卷积网络;空间卷积层;黏菌算法优化

中图分类号:TK8

文献标志码:A

文章编号:1007-9904(2025)12-0001-16

Ultra-short Term Power Generation Prediction of Wind Farm Based on Partial Least Squares and Improved Time Convolutional Network

ZHENG Guangyu¹, XIN Zheng^{1*}, CHI Weiran¹, CHEN Lizheng¹, WANG Shibo²

(1. School of Information and Electrical Engineering, Shandong Jianzhu University, Jinan 250101, China;

2. State Grid Shandong Electric Power Research Institute, Jinan 250003, China)

Abstract: To enhance the accuracy of ultra-short-term wind power prediction, a method combines the partial least squares (PLS) technique with an improved temporal convolutional network (ITCN) is proposed. First, PLS is employed to extract meteorological features that are closely related to wind power. Next, a spatial convolution layer is integrated into the temporal convolutional network (TCN) to improve its ability to extract both temporal and spatial features. To prevent local optimization, the slime mold algorithm is utilized for hyperparameter optimization. Experimental results from actual datasets in eastern and western China demonstrate that the proposed method effectively captures input variables and spatiotemporal characteristics of wind power, improving prediction accuracy by 12.61%, 4.45%, 3.65%, and 2.18% compared to common methods (CNN, LSTM, BiLSTM, and TCN). This method offers a novel approach to enhancing the efficiency and stability of wind farm operations.

Keywords: wind power prediction; partial least square method; improved time convolutional network; spatial convolution layer; slime mold algorithm optimization

0 引言

近年来,随着全球能源转型的推进,可再生能源

的应用成为重要的研究热点^[1]。风能作为清洁、可持续的能源,在发电领域的应用已成为实现碳中和的重要途径之一^[2]。伴随风电场装机容量的不断增长,风力发电在全球总发电量中的占比逐年上升。然而,由于风力发电的随机性和不稳定性,其输出功率的波动给电力系统的安全运行和调度带来重大挑战^[3]。因此,风电功率预测,尤其是超短期预测,在保障风电场并网运行、电网调度和维护中起到至关

基金项目:山东省自然科学基金青年科学基金项目“考虑极端气象的智能建筑微电网与电力系统动态交互特性研究”(ZR2021QF066)。
Shandong Provincial Natural Science Fund Youth Science Fund Project “Research on Dynamic Interaction Characteristics between Intelligent Building Microgrids and Power Systems Considering Extreme Weather” (ZR2021QF066).

重要的作用^[4]。

风电功率预测的研究方法主要分为基于物理模型和基于数据驱动的深度学习两种。物理模型方法通过建立数学表达式,结合风速、风向等气象变量,研究它们与风电功率之间的关系。该方法依赖于物理规律,能够逐步解析各变量对功率输出的影响,具有计算过程透明、易于解释的优点。然而,物理模型对气象数据的高精度要求较高,且在复杂非线性条件下的适应性较差,限制了其应用范围。与物理模型方法不同,数据驱动的深度学习方法通过深度挖掘历史数据,自动学习气象条件与风电功率之间的隐含关系。该方法不依赖于明确的物理机制,而是通过模型训练优化结构和输入特征,提升预测精度,其关键在于如何从大规模、高维数据中提取有效特征,并设计高效的模型框架,以适应复杂的实际场景。

沿用数据驱动的研究思路,专注于风电功率的超短期预测。研究的创新点包括:优化输入特征的选择,充分考虑气象变量的时序关联性和预测价值;设计改进的深度学习网络结构,提升特征提取能力和非线性拟合性能;针对超短期预测的特点,通过实验验证模型的鲁棒性和实际应用效果。研究避免引入风电机组的物理参数,进一步突出数据驱动方法的灵活性和广泛适用性,为风电功率预测提供一种有效的技术方案。

相关领域的研究中,单风机功率预测已取得了一定进展。文献[5]提出了一种基于长短期记忆网络(long short-term memory, LSTM)和遗传算法的预测方法,用于提高功率预测的精度。该方法通过遗传算法优化 LSTM 的超参数,自动学习数据特征,但在超短期预测中可能受限于时间分辨率。文献[6]基于自适应噪声的完全系综经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)技术,结合改进的 LSTM 提出了一种新模型,用于预测超短期风电功率。然而,其分解过程可能导致原始数据信息丢失,尤其是面对快速变化的风速情况,模型难以准确反映风电功率的动态变化。此外,文献[7]探讨了如何通过多重插补技术处理风电数据中的缺失值,填补数据样本,但在超短期预测中可能面临时

效性问题。文献[8]提出了通过 CEEMDAN 结合时间卷积网络(temporal convolutional network, TCN)预测风电功率的模型,但该方法在处理复杂时空数据时可能受到计算复杂度的限制,尤其是在超短期预测中,无法保证预测的实时性和准确性。为应对这些挑战,深度学习方法近年来在超短期风电功率预测中得到了广泛应用。文献[9]提出一种基于自注意力机制的 LSTM,通过捕捉关键时序特征,有效提高预测的精度。文献[10]则通过结合变分自编码器和 LSTM,在压缩输入数据的同时提高预测性能。文献[11]通过结合卷积神经网络(convolutional neural network, CNN)和门控循环单元,增强了对风电数据空间和时间特征的捕捉能力,在大规模数据的实时预测中表现突出。此外,文献[12]通过组合预测模型,结合时空特征提取与注意力机制,成功降低了超短期预测的误差。随着物联网和边缘计算技术的发展,文献[13]提出一种基于物联网监控系统 and 边缘计算的风电功率预测方法,实现了实时数据处理和快速预测。

上述方法多数集中于单风机的时间序列预测,未充分考虑风电场整体气象数据的复杂性和空间关联性。事实上,风电场中采集到的气象数据常常具有显著的内在关联性。这些气象数据不仅相互交织,还呈现出高度的多重相关性和复杂的高维特征^[14]。风电机组所在的地理位置、设备安装的高度、传感器安装的角度等因素使得所采集的风电数据天然具备了空间属性,如果单纯依赖气象数据进行预测,往往无法全面准确地反映风电功率的真实变化。文献[9]指出,直接使用未经处理的原始气象数据进行预测,可能会因为数据之间的冗余性和相关性过高,从而降低预测模型的精度。显然,除了气象数据,还应当将风电机组的运行参数纳入考量,以更准确地捕捉功率输出的规律。因此,在数据预处理和特征提取时,除了利用偏最小二乘法(partial least squares, PLS)来消除数据的多重共线性,保留关键特征外,还应将更多与机组运行状态相关的变量纳入其中。通过这样的多维度特征提取,既能剖析气象因素与风电功率之间的复杂关系,也能确保风电机组的运行特性不被忽视,从而进一步提升预测模型的准确性和鲁棒性。

在上述研究的基础上,提出一种结合 PLS 和改进时间卷积网络(improved temporal convolutional network,ITCN)的超短期风电功率预测方法。通过在 TCN 中引入空间卷积层,模型不仅能够提取时间特征,还能捕捉空间特征,从而提高风电功率预测的精度。此外,为提升模型的泛化能力并避免陷入局部最优解,采用黏菌算法对模型的超参数进行优化^[14]。以我国东部某风电场和西部某风电场的真实风电出力数据为例,搭建基于 PLS 和 ITCN 的预测模型。结果表明所提方案相比于传统方法训练速度快、预测误差降低、预测精度有所提高。

1 PLS 气象数据特征提取

数据预处理是模型构建的关键步骤之一^[15]。首先,对数据进行了异常值的检测与删除处理^[16]。异常值的检测采用 z-score 方法,剔除超出设定阈值($m=3$)的异常数据。删除异常数据后,针对数据集中存在的缺失值,采用线性插值法进行填补,确保数据的完整性和连续性^[17]。然后对所有气象特征数据以及历史风电功率数据都进行标准化处理。采用 Min-Max 标准化方法,将所有特征值缩放到区间 $[0, 1]$,通过此标准化过程,不同特征的数据分布保持一致,避免训练过程中因不同尺度的数据导致的梯度问题。通过对输入数据的标准化、异常值处理及缺失值填补,有效提升了模型的预测精度和稳定性。

风电功率的变化不仅受风速和风向的影响,还与风电场的其他气象因素密切相关,如湿度、温度和气压等^[18]。由于这些气象因素之间存在较强的关联性,每一个气象条件的变化都有可能对风电功率输出产生影响。如果只考虑一个气象因素对风电功率的影响,则无法真正体现气象数据与风电功率之间的关联。使用所有气象因素作为输入会使模型复杂化,并降低其泛化能力。因此,保留气象因素中的重要信息,同时消除数据间的多重共线性和冗余信息显得至关重要^[19]。

PLS 在风电功率预测中的优势在于其能够在降维的同时保留数据中与目标变量(风电功率)最密切相关的信息。PLS 通过将高维的原始气象数据映射到低维空间,生成线性无关的综合特征,从而有效降

低多重共线性带来的干扰。这一过程不仅简化模型结构,还显著提升了模型的泛化能力。与其他特征提取方法相比,PLS 直接利用因变量信息来指导特征提取,使得提取的特征更具针对性和解释性。因此使用 PLS 进行特征提取,可以挑选出与风电功率高度相关的数据,同时消除气象数据中的多重共线性和冗余信息。

通过 PLS 对气象数据进行特征提取,其实现原理如下:

假设原始气象数据为 $\mathbf{X}_{\text{ntp}} = (x_{\text{ntp}}^1, x_{\text{ntp}}^2, \dots, x_{\text{ntp}}^n)$, 其中, n 表示气象数据个数;原始风电功率矩阵为 \mathbf{x}_{wp} 。经过标准化处理后的气象数据为 $\mathbf{E} = (e^1, e^2, \dots, e^n)$, 风电功率矩阵为 \mathbf{P}_f 。

设 \mathbf{t}_1 是 \mathbf{E} 的第一个重要特征, $\mathbf{t}_1 = \mathbf{E} \times \mathbf{w}_1$, 其中 \mathbf{w}_1 是 \mathbf{E} 的第一个特征向量,并且是单位向量,即 $\|\mathbf{w}_1\| = 1$ 。为满足 \mathbf{t}_1 尽可能携带气象数据中的信息,则有

$$\max f_{\text{var}}(\mathbf{E} \times \mathbf{w}_1) \quad (1)$$

式中: f_{var} 为方差,用于衡量数据的离散程度。

式(1)使得 $\mathbf{E} \times \mathbf{w}_1$ 的方差最大化,同时还要使主成分 \mathbf{t}_1 和 \mathbf{P}_f 之间的相关程度最高,则有式(2)。

$$\max f_{\text{corr}}(\mathbf{E} \times \mathbf{w}_1, \mathbf{P}_f) \quad (2)$$

式中: f_{corr} 为相关系数,用于衡量两个变量之间的线性相关性。式(2)使得 $\mathbf{E} \times \mathbf{w}_1$ 与 \mathbf{P}_f 之间的相关系数最大化。

结合式(1)和式(2),PLS 提取第一重要特征时应满足式(3)。

$$\max f_{\text{cov}}(\mathbf{E}\mathbf{w}_1, \mathbf{P}_f), \text{ s.t. } \{\mathbf{w}_1^T \mathbf{w}_1 = 1\} \quad (3)$$

式中: f_{cov} 为协方差,用于衡量两个变量的总体误差。

以上 3 个为优化问题的目标函数值。采用拉格朗日乘子法,可得 \mathbf{w}_1 是对应于 $\mathbf{E}^T \mathbf{P}_f \mathbf{P}_f^T \mathbf{E}$ 矩阵最大特征值的单位特征向量。求得 \mathbf{w}_1 后可得到 \mathbf{t}_1 。

然后,根据式(4)求出残差 \mathbf{E}^* 和 \mathbf{P}_f^* , 即 \mathbf{t}_1 未能表示的部分。

$$\begin{cases} \mathbf{E}^* = \mathbf{E} - \mathbf{t}_1 \mathbf{P}_f^T \\ \mathbf{P}_f^* = \mathbf{P}_f - \mathbf{t}_1 \mathbf{r}_1^T \end{cases} \quad (4)$$

式中: \mathbf{p}_f 和 \mathbf{r}_1 为 \mathbf{t}_1 关于 \mathbf{E} 和 \mathbf{P}_f 的回归系数矩阵。

其他全部特征使用以上步骤全部求出。通过交叉验证反复迭代求出合适的新特征个数,整个过程如图 1 所示。

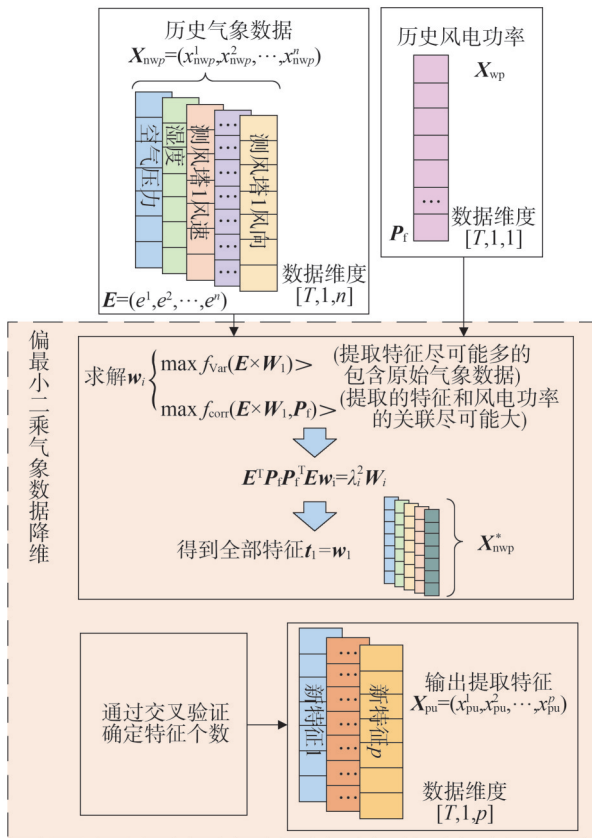


图1 PLS实现原理图

Fig.1 Implementation principle of partial least squares method

经过 PLS 处理后,一组低维解释变量被提取出来,既保留了大部分气象相关信息,又消除了气象数据之间的多重相关性,降低数据维度,并使特征提取后数据与风电功率保持一定相关性。它将成为后续风力发电预测模型的输入,提取的新特征如图 2 所示。

2 基于改进 TCN 的风电功率预测

受大气物理运动的影响,气象数据和实测风电功率在时间和空间维度上表现出复杂的关联特征^[20]。TCN 能够有效地提取时间序列之间的关联性,并展现出优异的预测性能^[21]。尽管 TCN 在时间维度上具有良好的预测性能,并且其卷积结构能够并行处理数据,从而大大提高运算效率,但 TCN 在空间特征提取方面仍存在不足。为准确描绘不同时间断面及不同地理位置下气象数据与风电功率之间的耦合关系,有必要从大量数据中深入挖掘其时间

和空间特征。因此,需要改进 TCN 以增强其在空间特征提取方面的能力,解决风电数据中空间关联的复杂性问题。

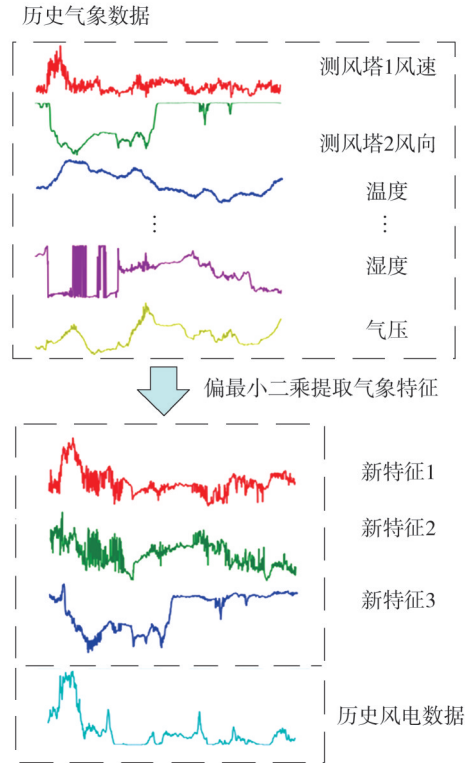


图2 提取之后的新特征

Fig.2 New features after extraction

2.1 改进的 TCN 预测模型结构

为捕捉数据之间的长期时间特征,在因果卷积的基础上引入了扩张卷积。扩张卷积原理如图 3 所示,输入为 $X = [X_1, X_2, \dots, X_h]$, 输出为 $Y = [Y_1, Y_2, \dots, Y_h]$, h 为样本维度,膨胀卷积在不使用池化操作且不添加参数的情况下增加了网络的感受野,因此没有分辨率损失也没有添加参数。随着更大的扩展,引入扩张的因果卷积顶层的输出可以代表更大范围的输入,从而有效地扩展了 TCN 的感受野。形式上,对于一维时间序列和滤波器,时间序列元素上的扩张卷积的运算定义如式(5)所示。

$$F(s) = (f_1 * f_2)(s) = \sum_{x=0}^{k-1} f(x) \cdot f_{s-d \cdot x} \quad (5)$$

式中: f_1, f_2 分别为卷积的两个函数; $*$ 为卷积运算; k

为滤波器尺寸; d 为膨胀因子; $s - d \cdot x$ 解释了过去的方向。当 $d=1$ 时,扩展卷积被简化为常规的卷积。




图3 膨胀因果卷积原理图

Fig.3 Schematic diagram of inflated causal convolution

另一种进一步增加网络感受野的常用方法是因果卷积堆叠^[22]。然而,当网络很深时,除了增加计算资源消耗,还会出现梯度消失或梯度爆炸^[23]。TCN中引入了残差连接,以避免层数过多出现梯度问题^[24]。

残差连接结构如图4所示,输入 X 为经过PLS特征提取之后的特征矩阵,残差网络由一系列残差块构成。每个残差块包含直接映射 X 和残差部分 $f(X)$ 。残差块的输出 $h(X)$ 包含非线性变换后的新信息 $f(X)$ 以及输入信息 X 。因此,即使残差部分学习效果不佳,输出与输入之间的差异也不会太大。这种设计有助于更深的网络避免梯度消失和梯度爆炸问题。

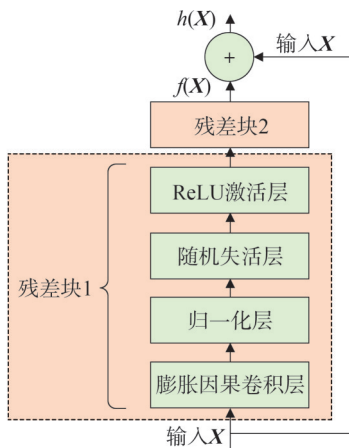


图4 残差连接结构图

Fig.4 Residual connection structure diagram

由于各测风塔的气象条件和地理位置接近,其数据之间存在时间和空间上的联系。以气象因素和风电功率为联合输入的预测模型也具有这种时空相关性^[25]。因此,在进行风电功率预测时,需要同时考虑风电功率的时间序列关联和不同位置的气象因素与风电功率输出的空间关联^[26]。为了体现不同位置的气象数据与风电功率及气象因素之间的空间关联,在TCN的基础上加入空间卷积层,以提取不同序列之间的空间特征。时空特征提取示意如图5所示。

将原始的一维时间序列数据转化为二维数据表示,其中每一列代表一个时间序列(即气象数据),每一行代表一个采样时间点。然后,应用TCN来提取每一列数据的时间特征。同时,为了充分考虑数据之间的空间关联,引入了列与列之间的空间卷积层,以提取不同光伏数据之间的空间特征。因此,将这一改进后的模型命名为ITCN。

TCN的时间特征提取能力主要体现在膨胀因果卷积过程中的因果性和对足够大视野范围内信息的完整考虑。在将一维时间序列合并为二维数据后,膨胀因果卷积实际上是在二维数据的每一列上以滑动窗口的形式进行卷积操作。卷积核的大小可以表示为 $(q, 1)$ (其中 q 表示在列方向上每 q 个元素进行一次卷积运算),这并不涉及二维数据中不同列之间的运算。为了确保空间特征的提取,应该使用卷积核的大小为 (q, m) ,其中 m 应该大于等于2,这样才能在不同列之间进行卷积运算,从而考虑不同特征之间的空间特性。

通常情况下,卷积核的长和宽应该相等(即 $q = m$),但考虑到通过滑动窗口截取的光伏相关数据在时间尺度上比空间尺度上的个数要多得多,即行数大于列数。因此,根据数据在不同方向上的维度大小,可以分别选择合适的卷积核大小。

另外,考虑到在提取时间特征时必须保证卷积过程中的因果关系,而在提取空间特征时则不必考虑时间因果关系。因此,针对时间特征和空间特征,可以选择不同的卷积结构来进行提取。非对称卷积指将标准的大小为 $(d * d)$ 卷积核分解为 $(d * 1)$ 卷积核和 $(1 * d)$ 卷积核串行,这种分解方法可以保证模型的表征能力和性能的前提下,有效地减少卷积操作中

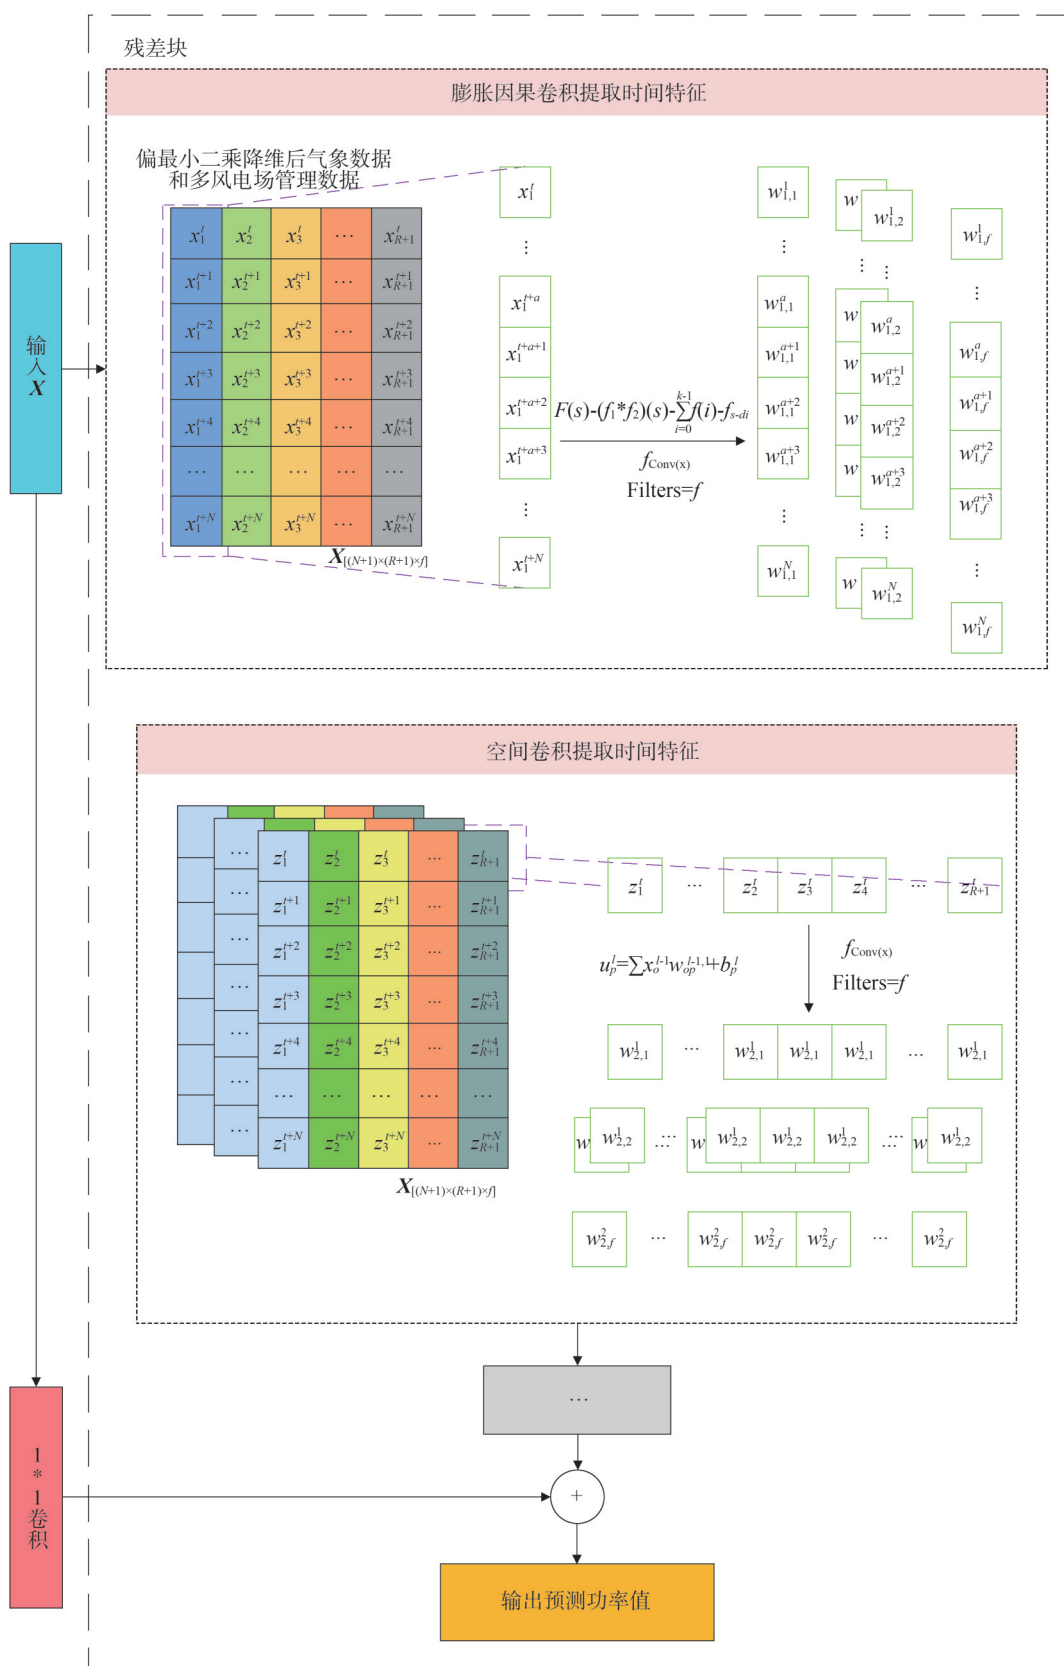


图5 时间特征和空间特征提取结构示意图

Fig.5 Schematic diagram of temporal and spatial feature extraction structure

的参数量。更重要的是可以根据数据在时间和空间维度上的不同,利用不同的卷积结构分别提取时间和空间特征。针对非对称卷积,将大小为 (q, m) 的卷积核分解成 $(q, 1)$ 和 $(1, m)$ 串行,分别提取时间和空间特征。二维数据不同列之间的空间卷积可以用式(6)表示。

$$u_k^l = \sum_o x_o^{l-1} w_{ok}^{l-1,l} + b_k^l \quad (6)$$

式中: u_k^l 为第 K 列第 l 层网络的卷积结果; x_o^{l-1} 为第 o 列第 $l-1$ 层网络通过膨胀因果卷积得到的时间特征; $w_{ok}^{l-1,l}$ 为第 K 列和第 o 列的第 l 层和第 $l-1$ 层卷积过程的权重; b_k^l 为第 K 列第 l 层网络的偏置。

在TCN内部,膨胀因果卷积之后添加列之间的卷积层,实现空间特征的提取。通过膨胀因果卷积,可以捕捉到不同风电数据随时间的变化规律,帮助模型更好地理解历史数据中的趋势和周期性。通过空间卷积可以考虑不同数据之间的位置关系、地形等因素,从而更全面地分析发电的影响因素。

2.2 黏菌算法优化改进TCN超参数

超参数选择对深度学习网络的性能和训练过程至关重要^[27]。例如,卷积核大小和数量直接影响特征提取能力,学习率和优化器影响训练的收敛速度和性能,正则化参数影响模型的泛化能力^[28]。此外,网络结构的选择也显著影响模型的性能。因此,合理调整 and 选择超参数对于提高深度学习网络的性能、泛化能力和训练效率至关重要^[29]。为最好地体现改进TCN模型的预测能力,采用黏菌算法寻找模型的最优超参数,提升模型的泛化能力,避免陷入局部最优。与传统的网格搜索方法相比,黏菌算法在同样的条件下显著缩短了参数调整的时间。黏菌算法的优势在于其全局搜索能力和较快的收敛速度。它通过模拟黏菌在环境中寻找食物的行为,能够有效避免陷入局部最优,并通过随机探索扩大搜索范围,提高了在复杂优化问题中的性能。相比于其他优化算法,如遗传算法或粒子群算法,黏菌算法在超参数调整过程中具有更高的效率,尤其是在多维度优化问题上,表现出较强的稳定性和鲁棒性^[30]。因此,黏菌算法不仅在计算时间上具备优势,还能够较短时间内找到较优的超参数组合,提升模型的泛化能力和预测精度。

黏菌算法灵感来源于黏菌寻找食物过程中的行为,是一种元启发算法^[31]。为探索更多食物源,黏菌种群有一定概率进行未知领域的探索。黏菌算法的实现流程如图6所示。

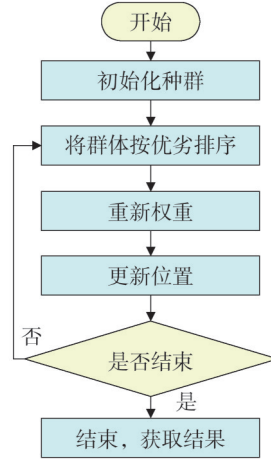


图6 黏菌算法实现流程图

Fig.6 Implementation flowchart of slime mold algorithm

在第一阶段,黏菌依靠空气中的气味寻找食物来源,其位置更新如式(7)所示。

$$M(v+1) = \begin{cases} M_b(v) + b_1(W \times M_A(v) - M_B(v)), r < p \\ c_1 \times M(v), r \geq p \end{cases} \quad (7)$$

式中: $M_b(v)$ 为当前适应度最优的个体位置; b_1 为 $[-a, a]$ 内的随机数; c_1 为在 $[-1, 1]$ 内振荡并最终趋于零的参数; $M(v)$ 为当前黏菌个体的位置; $M_A(v)$ 和 $M_B(v)$ 分别为两个随机个体 A 和 B 的位置; v 为当前迭代次数; W 为黏菌的权重系数; r 为 $[0, 1]$ 之间的随机数; p 为控制参数。

控制参数 p 、参数 a 和权重系数 W 的更新公式分别如式(8)一式(11)所示。

$$p = \tanh(S(i) - D_F), i = 1, 2, \dots, N \quad (8)$$

$$a = \operatorname{arctanh}\left(-\left(\frac{v}{v_{\max}}\right) + 1\right) \quad (9)$$

$$W(S_{\text{SmellIndex}}) = \begin{cases} 1 + r \lg\left(\frac{b_F - S(i)}{b_F - w_F}\right), i \leq \frac{N}{2} \\ 1 - r \lg\left(\frac{b_F - S(i)}{b_F - w_F}\right), i > \frac{N}{2} \end{cases} \quad (10)$$

$$S_{\text{SmellIndex}} = S_{\text{sort}}(N) \quad (11)$$

式中: N 为种群规模; $S(i)$ 为第 i 个黏菌个体的适应度; D_F 为当前取得的最优适应度; v_{\max} 为最大迭代次

数; $r \lg(\cdot)$ 为对分母部分值的非线性缩放; b_F 为当前迭代获得的最佳适应度; w_F 为当前迭代获得的最差适应度; $i < \frac{N}{2}$ 表示 $S(i)$ 排名前一半的黏菌个体; $S_{\text{SmellIndex}}$ 为适应度序列; $S_{\text{sort}}(N)$ 为排序后的适应度值。

包围食物模拟了黏菌静脉结构在搜索过程中的收缩模式,在该步骤中,将黏菌的位置更新如式(12)所示。

$$M(v+1) = \begin{cases} r_{\text{and}}(U_B - L_B) + L_B, r < z \\ M_b(v) + b_1[W \times M_A(v) - M_B(v)], r < p \\ c_1 \times M(v), r \geq p \end{cases} \quad (12)$$

式中: U_B 、 L_B 分别为搜索范围的上边界与下边界; $r_{\text{and}}(\cdot)$ 为随机函数,取值范围为 $[0, 1]$; z 为包裹食物时全局搜索的概率因子,一般设置为0.03。

在将黏菌算法应用于改进TCN模型的超参数选择时,可以按照以下步骤进行^[31]。

1)确定需要优化的超参数。首先,确定需要优化的TCN模型的超参数,包括:初始学习率、卷积核大小、残差块个数、滤波器数量和膨胀因果卷积的膨胀率。

2)定义适应度函数。为了使用黏菌算法进行超参数优化,需要定义一个适应度函数来评估每组超参数的性能。选择预测值与实际值之间的均方误差指标作为适应度函数来衡量模型性能,如式(13)所示。

$$F_{\text{Fitness}(w)} = \frac{1}{J} \sum_{j=1}^J (y_j - \hat{y}_j(w))^2 \quad (13)$$

式中: w 为候选的超参数向量; J 为样本数量; y_j 为第 j 个样本的真实值; $\hat{y}_j(w)$ 为在超参数 w 下模型的第 j 个预测值。

3)模拟黏菌行为。将超参数空间视为一片区域,黏菌算法可以模拟黏菌在这个区域内寻找最优路径的过程。初始化一群黏菌,每个黏菌代表一个超参数组合。

4)计算黏菌的运动。根据黏菌当前位置和周围环境的信息,计算黏菌下一步的移动方向和距离。

5)更新黏菌位。根据计算得到的移动方向和距离,更新黏菌的位置以尝试寻找更优的超参数

组合。

6)迭代优化。通过迭代优化,黏菌算法可以逐步调整超参数的取值,以寻找模型性能的最优组合。

7)评估结果。最终,根据黏菌算法的迭代结果,评估得到的最优超参数组合在验证集或测试集上的性能表现。

2.3 预测模型整体结构

提出一种基于偏最小二乘和改进TCN的风电功率预测方法,旨在实现更高效的预测。该模型的整体流程如图7所示。本文提出的方法主要包括以下4个步骤:第1步,对原始数据进行预处理,包括删除异常数据、填补缺失数据,以及标准化处理,以统一数据量纲;第2步,使用偏最小二乘方法对气象数据进行特征提取,提取重要信息,降低数据维度,并确保提取的特征与风电功率高度相关;第3步,在TCN的基础上添加空间卷积,对偏最小二乘提取的特征和历史风电功率数据进行处理,提取输入数据中的时间特征和空间特征;第4步,通过黏菌算法寻找模型的最优超参数,提升预测模型的泛化能力。

3 实验结果与分析

在本研究中,一次预测的最大提前时间是指模型能够预测未来的最长时间范围。在风电场的超短期预测中,通常要求模型能够准确预测未来4h内的功率输出。对于未来出力的多点预测,本文采用的是迭代式预测。因此在本文中最大提前时间设定为4h,意味着模型在一次预测过程中可以预测从当前时刻起至未来4h内的风电功率变化。数据使用滑动窗口提取,每15min采样一次。

此外,模型的训练依赖于大量的历史样本数据。训练模型的历史样本包括风电场过去的气象数据(如风速、风向、温度、湿度等)和对应时间段的风电功率输出。通过对这些历史数据的学习,模型能够识别出气象条件与风电功率输出之间的复杂关联性,并应用这些学习到的模式来预测未来的风电功率。为了确保模型的泛化能力和预测准确性,历史样本的数据覆盖了不同的天气模式和风电场运行状态,帮助模型更全面地适应多样化的输入

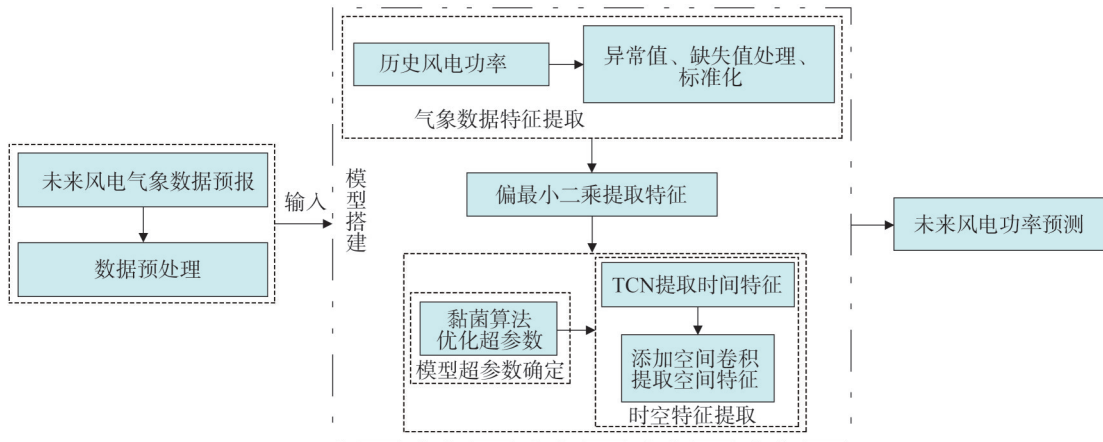


图7 预测模型整体流程图

Fig.7 Overall flowchart of prediction model

数据。

3.1 黏菌算法性能测试

在算例分析中,所有实验均使用 Python 3.8.8 和 PyTorch 进行。软件测试是在一台具有 i7-6700 CPU @ 3.40 GHz, 16 GB RAM 的计算机上进行的。

选取灰狼优化算法 (grey wolf optimization, GWO), 樽海鞘群优化算法 (salp swarm algorithm, SSA), 黏菌优化算法 (slime mold optimization algorithm, SMA) 3 种算法进行对比, 算法参数如表 1 所示, 种群规模设为 20, 既能确保初始解的多样性, 又优化了计算效率。解空间的维度限制为 20, 最大迭代次数为 200, 各算法分别运行 40 次, 通过结果的平均值和标准差 2 个指标来反映算法的寻优能力, 如表 2 所示。

表 1 各算法参数设置

Table 1 Sets the parameters of each algorithm

算法	超参数设置
GWO	$A=[2,0]$
SSA	$C_1, C_2 \in [0,1]$
SMA	$Z = 0.03$

从表 2 的数据可以看出, SMA、GWO 和 SSA 在不同测试函数 (F_1-F_4) 上的表现差异显著。这些差异反映了各算法在优化能力和稳定性上的特点和局限性。

在 F_1 测试中, SSA 的平均值为 0.86, 标准差仅为 0.29, 表现出极高的稳定性和优异的优化能力。相比之下, SMA 的平均值为 7.68, 标准差为 3.27, 虽然稳定, 但优化结果稍逊一筹。而 GWO 的平均值为 236.86, 标准差高达 316.99, 波动性大, 性能较差。总体来看, SSA 在 F_1 测试中表现最佳。

表 2 函数测试结果

Table 2 Function test results

函数	算法	平均值	标准差
F_1	SMA	7.68	3.27
	GWO	236.86	316.99
	SSA	0.86	0.29
F_2	SMA	3.88	42.46
	GWO	8.94	22.40
	SSA	1.88	0.36
F_3	SMA	42.76	293.83
	GWO	58.53	66 245.00
	SSA	539.57	368.96
F_4	SMA	22.39	5.02
	GWO	26.15	16.26
	SSA	36.99	17.38

在 F_2 测试中, SSA 再次展现优势, 其平均值为 1.88, 标准差为 0.36, 表现稳定且优化效果显著。相

比之下, SMA 的平均值为 3.88, 标准差高达 42.46, 结果离散性较大, 稳定性不足。GWO 的平均值为 8.94, 标准差为 22.40, 虽然优于 SMA, 但依然不如 SSA 稳定。

F_3 测试结果显示, 各算法在此函数上的表现差异更加明显。SMA 的平均值为 42.76, 标准差高达 293.83, 结果波动显著。GWO 的平均值为 58.53, 但标准差高达 66 245.00, 显示出极大的不稳定性。SSA 的平均值为 539.57, 标准差为 368.96, 尽管均值较高, 但结果分布较集中, 表现出较强的局部搜索能力。然而, SSA 在全局优化上的表现可能不如其在其他测试中的出色。

在 F_4 测试中, SMA 以平均值 22.39 和标准差 5.02 的表现展现出较好的稳定性, 而 GWO 的平均值为 26.15, 标准差为 16.26, 稳定性略差。SSA 的平均值最高, 为 36.99, 但其标准差为 17.38, 波动较大。综合来看, SMA 在 F_4 测试中表现最优, SSA 的高均值虽然说明了其潜在的优化能力, 但稳定性不足。

总体而言, SSA 在 F_1 和 F_2 测试中表现最佳, 稳定性和优化结果均优于其他算法, 但在 F_3 和 F_4 中波动较大, 适用性相对有限。GWO 的表现则在所有测试中均显得不稳定, 尤其在 F_4 测试中波动最大, 优化性能较差。SMA 在大多数测试中表现出较高的稳定性, 尤其在 F_4 测试中表现突出, 显示出其适合处理结果分布较均匀的优化问题。这种稳定性和可靠性使其在光伏功率预测问题中的应用具有重要价值。

基准函数收敛曲线如图 8 所示。SMA 在与 GWO 和 SSA 的比较中表现出更快的收敛速度和更低的最终适应度值, 尤其是在迭代的前期展现了较快的收敛趋势, 并最终达到了较优的水平。这些结果显示了 SMA 在全局优化能力和收敛效率方面的潜力。然而, 值得注意的是, 不同优化算法在不同问题和应用场景中可能具有各自的优势。尽管 SMA 在本文实验中的表现较为突出, 但这并不否定 GWO 和 SSA 在特定优化问题中可能展现的独特能力和优势。因此, 具体算法的选择仍需根据实际应用需求和特性进行综合评估。




图8 基准函数收敛曲线图

Fig.8 Convergence diagram of the benchmark function

3.2 我国东部实际数据集实验结果与分析

为验证所提出预测模型的有效性和实用性, 本节通过我国东部某风电场实际数据集进行实验。该风电场建成于 2010 年, 总装机容量为 60 MW, 由 12

台风机组成。使用了两种主要型号的风机:AREVA M5000-116 和 REpower 5M,每种型号各 6 台。数据集收集于 2019 年 10 月 1 日至 2020 年 10 月 1 日,数据点间隔为 5 min。

数据集包括 4 个位置(高度分别为 10 m、30 m、50 m 和 70 m 的测风数据)的风速、风向和轮毂处的风向和风速以及环境的气温、湿度和气压共 13 个气象因素。选取前 80% 数据作为训练集,剩余 20% 作为测试集。为更好展示所提预测方法在风电预测中的性能,选择 CNN、LSTM、双向 LSTM (BiLSTM)和 TCN 作为比较模型进行对比实验。所有实验均在 Python 3.8 下用 Tensorflow 深度学习框架实现。

使用平均绝对误差(mean absolute error, MAE) E_{MAE} 、均方根误差(root mean square error, RMSE) E_{RMSE} 均方误差(mean square error, MSE) E_{MSE} 、决定系数 E_{R^2} 来评估所提出的模型与本文中其他模型之间的性能。 E_{MAE} 、 E_{RMSE} 、 E_{MSE} 表示预测值和真实值之间的误差大小, E_{R^2} 表示预测值和真实值的相似程度。这些评估指标如式(14)一式(17)所示。

$$E_{MAE} = \frac{\sum_{g=1}^G |y_g^{tr} - y_g^{pr}|}{G} \quad (14)$$

$$E_{MSE} = \frac{\sum_{g=1}^G (y_g^{tr} - y_g^{pr})^2}{G} \quad (15)$$

$$E_{RMSE} = \sqrt{\frac{\sum_{g=1}^G (y_g^{tr} - y_g^{pr})^2}{G}} \quad (16)$$

$$E_{R^2} = 1 - \frac{\sum_{g=1}^G (y_g^{pr} - y_g^{tr})^2}{\sum_{g=1}^G (y_g^{tr} - \bar{y})^2} \quad (17)$$

式中: y_g^{tr} 为第 g 次真实值; y_g^{pr} 为第 g 次预测值; \bar{y} 为真实值的平均值。 E_{MAE} 、 E_{MSE} 和 E_{RMSE} 值越小,预测效果越好。 E_{R^2} 的值越大,模型拟合效果越好。

将数据输入模型前,有必要进行数据预处理。数据预处理主要包括两步,首先,删除异常数据并填补缺失数据,然后进行标准化处理,消除不同量纲之间的影响。预处理后的数据使用 PLS 提取气象特征,气象数据由 13 个减至 3 个。将 PLS 提取的气象特征和风电功率输入改进的 TCN 进行模型训练。使用黏菌算法确定改进 TCN 的最优超参数。

卷积核大小范围为[2,6],残差块个数为[1,5],滤波器数量取值范围为[16,128],膨胀因果卷积的膨胀率范围为[2,6]。优化后确定的改进 TCN 超参数为:初始学习率 0.005,卷积核大小 2,残差块个数 2,滤波器数量 52,膨胀因果卷积膨胀率 2。其他对比模型的超参数通过网格搜索算法确定,不同模型的超参数如表 3 所示。

4 种方法的预测曲线如图 9 和图 10 所示。与 CNN、LSTM、BiLSTM 和 TCN 相比,改进 TCN 在 4 个评价指标下均取得最佳成绩。证明改进模型的性能优于单个预测模型。CNN 由于视野域有限,虽然能拟合风电功率的运行趋势,但具有明显的滞后性。BiLSTM 通过在序列前后两个方向进行运算,相比 LSTM 预测性能有所提升。所提方法与 CNN、LSTM、BiLSTM、TCN 和改进 TCN 之间的对比结果如表 4 所示,其中每个指标的最佳值用粗体字标注。

在算法的时间消耗方面,实验环境为使用 NVIDIA GeForce RTX 4060 GPU 的计算平台。实验结果表明,所提基于特征提取的 TCN 方法相较于其他传统模型,训练时间和收敛速度表现出了明显的

表 3 网格搜索算法确定对比模型的超参数

Table 3 Grid search algorithm determines yperparameters of comparative models

模型	超参数设置
CNN	卷积核大小:2,滤波器个数:30,卷积层数:3,初始学习率:0.001
LSTM	隐藏单元个数:50,层数:3,初始学习率:0.001
BiLSTM	隐藏单元个数:50,层数:2 初始学习率:0.001
TCN	卷积核大小:3,滤波器个数:30,残差块个数:3,膨胀率:3,初始学习率:0.001

优势。具体而言,所提方法的训练时间为 150 s,而 CNN、LSTM、BiLSTM 和 TCN 分别需要 200 s、300 s、320 s 和 250 s,表明基于特征提取的 TCN 方法在时间消耗上有显著减少。尤其在模型的效率方面,通过优化网络结构与训练策略,能够在更短的时间内完成更高质量的训练。

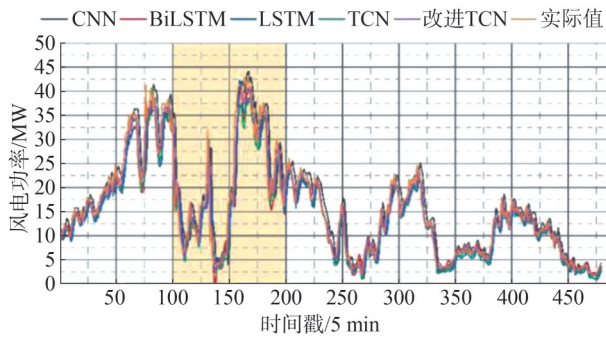


图9 不同预测模型曲线图
Fig.9 Graphs of different prediction models

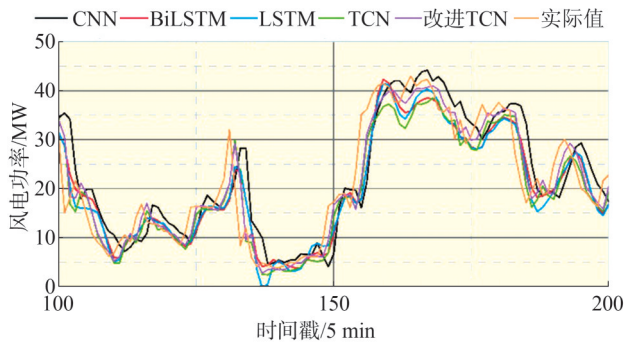


图10 预测曲线局部放大图
Fig.10 Partial enlarged prediction curve

进一步来看,关于算法的收敛情况,所提方法在 40 个迭代次数即可达到收敛,且损失函数的下降趋势较为平稳。相比之下, CNN、LSTM、BiLSTM 和

TCN 分别需要 50、60、65 和 55 个迭代次数才能收敛,所提方法不仅收敛速度较快,而且训练过程中的稳定性也表现更优。

与 CNN、LSTM、BiLSTM 和 TCN 相比,提出的基于特征提取的 TCN 预测方法能够提高预测性能。根据预测结果, CNN、LSTM、BiLSTM 和 TCN 的指标 R^2 值分别为 0.833、0.898、0.905 和 0.918。所提方法的指标 R^2 值为 0.938,分别提高了 12.61%、4.45%、3.65% 和 2.18%。CNN、LSTM、BiLSTM 和 TCN 的指标 RMSE 值分别为 4.156、3.240、3.139 和 2.905。所提方法的指标 RMSE 值为 2.533,分别降低了 39.05%、21.82%、19.31% 和 12.81%。CNN、LSTM、BiLSTM 和 TCN 的指标 MAE 值分别为 2.768、2.243、2.119 和 1.972。所提方法的指标 MAE 值最小,为 1.671。

此外,在时间消耗上,所提方法的训练时间为 250 s,显著低于其他模型,并且收敛速度较快,展示了其在实际应用中的潜力。特别是在长时间训练任务中,训练时间的减少将极大提升模型的应用效率和实用性。

改进后的 TCN 由于加入了空间卷积,更好地处理序列之间的空间关联,充分考虑风电数据中的时空特征,有效提升预测精度。通过黏菌算法确定改进 TCN 的超参数,可有效避免预测模型参数陷入局部最优。相比网格搜索确定的超参数,黏菌算法更能体现预测模型的性能。

从图 9 和图 10 中的预测结果可以看出,所提方法的预测曲线更加接近实际值曲线,特别是在风电功率波动较大的时间段(如图 9 中的第 150~200 个时间戳),所提方法能够更好地捕捉到功率变化的细节。具体而言,在这些时间段内,所提方法不仅在峰值预测上表现更为准确,而且在谷值

表4 不同模型评价指标

Table 4 Different model evaluation indicators

不同模型	MAE	MSE	RMSE	R^2	训练时间/s	收敛次数
CNN	2.768	17.278	4.156	0.833	200	50
LSTM	2.243	10.496	3.240	0.898	300	60
BiLSTM	2.119	9.854	3.139	0.905	320	65
TCN	1.972	8.441	2.905	0.918	250	55
ITCN	1.671	6.415	2.533	0.938	150	40

预测上也展现出较强的鲁棒性。这表明,改进的TCN方法在处理复杂风电功率变化时,能够提供更加稳定和精确的预测结果。此外,所提方法在降低预测误差方面表现突出。从上述RMSE和MAE指标可以看出,所提方法在不同预测时间段内均保持了较低的误差水平,进一步验证了其在风电功率预测中的有效性。这不仅提升了预测模型的实用价值,也为未来风电场的运行调度提供了更加可靠的数据支持。

3.3 我国西部实际数据集实验结果与分析

本节通过我国西部某实际数据集进行实验。风电场位于我国西部青藏高原边缘,自2018年全面运营,总装机容量为120 MW,覆盖约25平方公里,并部署了20台风机。风电场采用了Sinovel SL1500/82型和Goldwind GW140-3000型两种风机。风电场设计充分考虑当地特有的地形和气候特点,采用高度定制化的方案,包括安装智能监控系统的风机,这些系统能实时调节运行模式以适应不同的天气变化,最大化发电效率。数据集收集于2020年6月6日至2021年6月6日,数据点间隔为5 min。

数据集包括3个位置(高度为50 m、70 m和100 m的测风数据)的风速、风向和轮毂处的风向和风速以及环境气温、湿度和气压共11个气象因素,其余设置与3.2节一致。4种方法的预测曲线如图11和图12所示。与CNN、LSTM、BiLSTM和TCN相比,所提出的改进TCN在4个评价指标下均取得最好成绩。证明所提出的改进模型的性能优于单个预测模型。CNN由于其视野域有限,虽然能够拟合风电功率的

运行趋势,但是具有明显的滞后性。BiLSTM通过在序列的前后两个方向进行运算,相比于LSTM预测性能有一定程度的提升。

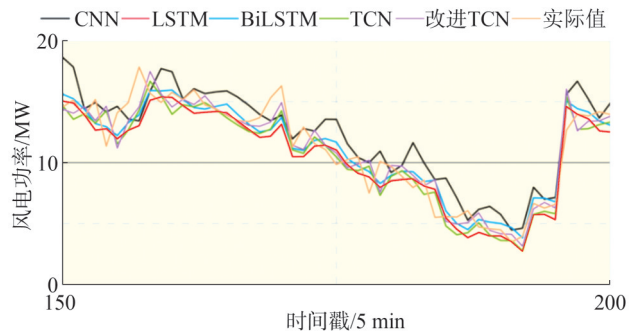


图12 预测曲线局部放大图

Fig.12 Localized enlargement of the prediction curve

所提方法与CNN、LSTM、BiLSTM、TCN和改进TCN之间对比结果如表5所示。

与CNN、LSTM、BiLSTM和TCN相比,本文提出的基于特征提取的TCN预测方法能够提高预测性能。根据预测结果,CNN、LSTM、BiLSTM和TCN的指标 R^2 值分别为0.794、0.881、0.896和0.916。所提方法的指标 R^2 值为0.931,分别提高了17.25%、5.68%、3.91%和1.64%。这表明所提方法能够更好地拟合实际数据,解释了更多的风电功率变化。CNN、LSTM、BiLSTM和TCN的指标RMSE值分别为3.129、2.380、2.219和1.997。所提方法的指标RMSE值为1.802,分别降低了42.4%、24.33%、18.79%和9.77%。这表明所提方法在预测风电功率时误差更小,预测结果更接近实际值。CNN、LSTM、BiLSTM和TCN的指标MAE值分别为2.212、1.731、1.575和1.467。所提方法的指标MAE值最小,为1.280。这进一步证明了所提方法在风电功率预测中的优越性。

从训练时间和收敛速度来看,改进TCN在计算效率上表现良好。尽管其在性能上有显著提升,但训练时间仅为160 s,相较于LSTM和BiLSTM(分别为220 s和240 s),改进TCN具有更高的计算效率。收敛速度方面,改进TCN在130次迭代后便已稳定收敛,相比之下,LSTM和BiLSTM的收敛周期分别为180和200次迭代,表明改进TCN不仅在预测精




图11 不同预测模型曲线图

Fig.11 Graphs of different prediction models

表5 不同模型评价指标
Table 5 Different model evaluation indicators

不同模型	MAE	MSE	RMSE	R^2	训练时间/s	收敛次数
CNN	2.212	9.790	3.129	0.794	125	120
LSTM	1.731	5.664	2.380	0.881	220	180
BiLSTM	1.575	4.922	2.219	0.896	240	200
TCN	1.467	3.986	1.997	0.916	180	150
ITCN	1.280	3.248	1.802	0.931	160	130

度上优于其他方法,还具有较好的训练效率,能够在较短时间内获得较为精确的预测结果。

综上所述,使用改进的 TCN 方法在风电功率预测中表现最佳。该模型预测风电功率与真实值之间的误差最小,相似度最大。

4 结论

由于风电功率具有间歇性、波动性和不确定性,本研究提出了一种基于 PLS 和 ITCN 的风电场超短期发电功率预测方法。得到以下结论:

1)通过 PLS 对风电数据特征提取可以有效提取关键气象特征,消除气象数据之间的多重共线性。简化模型训练,提升预测精度和鲁棒性。

2)提出一种基于 TCN 的改进预测方法,即 ITCN 模型。通过在 TCN 中引入空间卷积层,ITCN 能够更全面地挖掘气象因素和风电数据的时空特征,从而兼顾时间和空间特征的提取。实验结果表明,ITCN 模型在风电功率预测中较传统方法(如 CNN、LSTM、BiLSTM 和标准 TCN)显著提升了预测精度和泛化能力。例如,在 RMSE 方面,ITCN 模型相较于 CNN、LSTM、BiLSTM 和 TCN 分别降低了 39.05%、21.82%、19.31% 和 12.81%。此外,在决定系数 R^2 方面,ITCN 模型达到 0.938,比传统方法分别提升了 12.61%、4.45%、3.65% 和 2.18%。这些结果充分证明了 ITCN 模型在捕捉风电功率的复杂变化特征上的优越性,有效提高了预测精度和可靠性。该模型为提升风电场运行效率和稳定性提供了一种创新的技术路径。

3)为更好地体现 ITCN 的性能,采用黏菌算法寻找最优超参数,提升预测模型的泛化能力,避免陷入局部最优,从而使得风电功率预测模型的精度进一

步提高。

参考文献

- [1] 刘洋,伍双喜,朱誉,等.基于 CEEMDAN 和 DBO-GRNN 的风电功率超短期预测[J].电力建设,2024,45(8):97-105.
LIU Yang, WU Shuangxi, ZHU Yu, et al. Ultra-short-term prediction of wind power based on CEEMDAN and DBO-GRNN [J].Electric Power Construction,2024,45(8):97-105.
- [2] 张弘喆,丛伟,王瑞梅,等.基于 Bhattacharyya 系数和 Pearson 相关系数的交直流混联电网电压波形相似度纵联保护方法[J].山东电力技术,2024,51(12):19-26.
ZHANG Hongzhe, CONG Wei, WANG Ruimei, et al. Longitudinal protection method of AC/DC hybrid power grid for voltage wave similarity using bhattacharyya coefficient and pearson correlation coefficient[J].Shandong Electric Power,2024,51(12):19-26.
- [3] 韩明冲,韩杰,姜超,等.基于 WOA-AM-GRU 的短期电力负荷预测方法的研究[J].山东电力技术,2024,51(12):27-33.
HAN Mingchong, HAN Jie, JIANG Chao, et al. Research on short-term electric load forecasting method based on WOA-AM-GRU [J].Shandong Electric Power,2024,51(12):27-33.
- [4] 杨国华,祁鑫,贾睿,等.基于 CEEMD-SE 的 CNN&LSTM-GRU 短期风电功率预测[J].中国电力,2024,57(2):55-61.
YANG Guohua, QI Xin, JIA Rui, et al. Short-term wind power forecast based on CNN & LSTM-GRU model integrated with CEEMD-SE algorithm[J].Electric Power,2024,57(2):55-61.
- [5] 李振华,崔九喜,杨信强,等.基于融合 K-近邻算法的电压互感器在线监测方法[J/OL].电网技术,1-12[2024-07-15].https://kns.cnki.net/kcms2/article/abstract?v=hmawDzFpZzQin00ho-m8r-Y9PdrTfdrAlvtvVVarhQ6k0JI_FJtMh43XXBkTzdyfMFJ3NunuAQuSTL64SIXNqo_ywIcFsulfgont_umcmF4-ZND10M_ie9WTwRUffxhpbjvboaH4PxVHeCrLD4tN0dhB9cydtkKXOyBYcvuNwODNHwDl7yje5zCPyZtVxayK7&uniplatform=NZKPT&language=CHS.
LI Zhenhua, CUI Jiuxi, YANG Xinqiang, et al. Online monitoring method of voltage transformer based on fusion K-nearest neighbor algorithm [J/OL].Power System Technology, 1-12[2024-07-15].https://kns.cnki.net/kcms2/article/abstract?v=hmawDzFp

- ZzQin00ho-m8r-Y9PdrTfdrAlvtvVVarhQ6k0Jl_FJtMh43XXBkTz
dyIMFJ3NunuAQuSTL64SIXNqo_yw1cFsulfgont_umcmF4 - ZND
10M_iE9WTwRUffxhpbjvoaH4PxVHcCrLD4tNOdhB9cydtkKXOy
BYcvuNwODNHwdl7yje5zCPyZtVxayK7&uniplatform=NZKPT&
language=CHS.
- [6] 卢冠华,余涛,吴毓峰,等.基于MAGAT的风电场功率缺失数据填充方法[J].电网技术,2024,48(8):3391-3400.
LU Guanhua, YU Tao, WU Yufeng, et al. MAGAT-based method for imputing power loss data in wind farms [J]. Power System Technology, 2024, 48(8): 3391-3400.
- [7] 师洪涛,李希彬,丁茂生,等.基于自适应时距的K-ADBiGRU-AM短期风电功率预测方法[J/OL].电气工程学报,2024:1-11 [2024-07-15]. <http://kns.cnki.net/KCMS/detail/detail.aspx?filename=DQZH20240607003&dbname=CJFD&dbcode=CJFQ>.
SHI Hongtao, LI Xibin, DING Maosheng, et al. K-ADBiGRU-AM short-term wind power forecasting method based on adaptive time interval [J/OL]. Journal of Electrical Engineering, 2024: 1-11 [2024-07-15]. <http://kns.cnki.net/KCMS/detail/detail.aspx?filename=DQZH20240607003&dbname=CJFD&dbcode=CJFQ>.
- [8] 张强,刘红军,尚力,等.山东新能源调度运行模式及技术支持系统设计[J].山东电力技术,2012,39(6):1-6.
ZHANG Qiang, LIU Hongjun, SHANG Li, et al. Analysis of dispatching mode and design of technical supporting system for Shandong new energy operation [J]. Shandong Electric Power, 2012, 39(6): 1-6.
- [9] YANG S M, YUAN A J, YU Z Q. A novel model based on CEEMDAN, IWOA, and LSTM for ultra-short-term wind power forecasting [J]. Environmental Science and Pollution Research, 2023, 30(5): 11689-11705.
- [10] WANG J, LI X, NIU Z. A CNN-GRU hybrid model for short-term wind power forecasting [J]. Renewable Energy, 2021, 178: 753-764.
- [11] ZHAN J, WU C K, YANG C Q, et al. Condition monitoring of wind turbines based on spatial-temporal feature aggregation networks [J]. Renewable Energy, 2022, 200: 751-766.
- [12] LU G, CHEN, L, WANG F. Edge computing enabled real-time wind power prediction for smart grid systems [J]. IEEE Transactions on Industrial Informatics, 2023, 19(4): 2256-2265.
- [13] NIU Z W, YU Z Y, TANG W H, et al. Wind power forecasting using attention-based gated recurrent unit network [J]. Energy, 2020, 196: 117081.
- [14] 欧旭鹏,任涛,王玉鹏,等.基于改进麻雀搜索算法优化深度学习网络超参数的短期风电功率预测[J].智慧电力,2023,51(3):31-38,52.
OU Xupeng, REN Tao, WANG Yupeng, et al. Short-term wind power prediction by optimizing deep learning network hyper-parameters based on ISSA [J]. Smart Power, 2023, 51(3): 31-38, 52.
- [15] 赵龙,孟祥飞,田鑫,等.基于模型-数据混合驱动的风电场暂态过程等值方法[J].电力建设,2023,44(10):22-32.
ZHAO Long, MENG Xiangfei, TIAN Xin, et al. Equivalence method for wind farm transient process based on model-data hybrid drive [J]. Electric Power Construction, 2023, 44(10): 22-32.
- [16] 翟保豫,张龙,徐志,等.基于WRF模式和风速误差修正的中期风电功率预测方法[J].智慧电力,2023,51(7):31-38.
ZHAI Baoyu, ZHANG Long, XU Zhi, et al. Mid-term wind power forecasting based on WRF mode and wind speed error correction [J]. Smart Power, 2023, 51(7): 31-38.
- [17] XIN Z, LIU X R, ZHANG H Y, et al. An enhanced feature extraction based long short-term memory neural network for wind power forecasting via considering the missing data reconstruction [J]. Energy Reports, 2024, 11: 97-114.
- [18] 施进伟,张程,原冬芸.基于数据修正的概率稀疏自注意短期风电功率预测[J].智慧电力,2023,51(10):54-61.
SHI Jinwei, ZHANG Cheng, YUAN Dongyun. Short-term wind power prediction based on data correction with probabilistic sparse self-attention [J]. Smart Power, 2023, 51(10): 54-61.
- [19] 刘金朋,邓嘉明,高鹏宇,等.基于VMD-IMPA-SVM的超短期风电功率预测[J].智慧电力,2024,52(07):24-31,79.
LIU Jinpeng, DENG Jiaming, GAO Pengyu, et al. Ultra short term wind power prediction based on VMD-IMPA-SVM [J]. Smart Power, 2024, 52(07): 24-31, 79.
- [20] CAO Y D, DING Y F, JIA M P, et al. A novel temporal convolutional network with residual self-attention mechanism for remaining useful life prediction of rolling bearings [J]. Reliability Engineering & System Safety, 2021, 215: 107813.
- [21] LI Y Y, SONG L D, ZHANG S, et al. A TCN-based hybrid forecasting framework for hours-ahead utility-scale PV forecasting [J]. IEEE Transactions on Smart Grid, 2023, 14(5): 4073-4085.
- [22] GONG R, LI J X, WANG C L. Remaining useful life prediction based on multisensor fusion and attention TCN-BiGRU model [J]. IEEE Sensors Journal, 2022, 22(21): 21101-21110.
- [23] FOROUGH B, NHAN P V, IRANMANESH M, et al. Determinants of intention to use autonomous vehicles: findings from PLS-SEM and ANFIS [J]. Journal of Retailing and Consumer Services, 2023, 70: 103158.
- [24] MANSURI S M, CHAKRABORTY S K, MAHANTI N K, et al. Effect of germ orientation during Vis-NIR hyperspectral imaging for the detection of fungal contamination in maize kernel using PLS-DA, ANN and 1D-CNN modelling [J]. Food Control, 2022, 139: 109077.
- [25] NAIK M K, PANDA R, ABRAHAM A. Adaptive opposition slime mould algorithm [J]. Soft Computing, 2021, 25(22): 14297-14313.

- [26] YU T Y, PAN J W, QIAN N A, et al. Improved slime mould algorithm by perfecting bionic-based mechanisms[J]. International Journal of Bio-Inspired Computation, 2023, 22(1): 1-15.
- [27] LIU X G, WANG J W, LIANG T, et al. SE-TCN network for continuous estimation of upper limb joint angles[J]. Mathematical Biosciences and Engineering, 2022, 20(2): 3237-3260.
- [28] SHI T, LI P Y, YANG W, et al. Application of TCN-biGRU neural network in PM2.5 concentration prediction [J]. Environmental Science and Pollution Research, 2023, 30(56): 119506-119517.
- [29] 杨至元, 陈晖, 李沛. 基于生成对抗网络和迁移学习的电力碳流耦合特征数据生成与评估[J]. 电力建设, 2024, 45(3): 126-136.
YANG Zhiyuan, CHEN Hui, LI Pei. Acquisition and evaluation of the coupled featuring data of power system and carbon emissions flows using generative adversarial networks and transfer learning method[J]. Electric Power Construction, 2024, 45(3): 126-136.
- [30] 韩小地, 郭家兴, 钱康, 等. 基于双分支特征集成LSTM的非侵入式负荷分解研究[J]. 山东电力技术, 2024, 51(10): 31-43.
HAN Xiaodi, GUO Jiaying, QIAN Kang, et al. Research on non-intrusive load disaggregation with dual-branch feature integration LSTM[J]. Shandong Electric Power, 2024, 51(10): 31-43.
- [31] 高帅, 杨战海. 多策略改进的黏菌算法[J]. 延安大学学报(自然科学版), 2024, 43(3): 102-108.
GAO Shuai, YANG Zhanhai. Multi-strategy improved slime mold algorithm [J]. Journal of Yan'an University (Natural Science Edition), 2024, 43(3): 102-108.

收稿日期: 2024-10-22

修回日期: 2025-02-19

作者简介:

郑广宇(1999), 男, 硕士在读, 主要研究方向为深度学习;

辛征(1978), 通信作者(xinzheng9309@sdjzu.edu.cn), 男, 博士, 副教授, 主要研究方向为深度学习;

迟蔚然(1998), 女, 硕士, 主要研究方向为深度学习;

陈立征(1989), 男, 博士, 讲师, 主要研究方向为电力系统及其自动化;

王士柏(1987), 男, 博士, 高级工程师, 主要研究方向为电力系统继电保护与控制。

(责任编辑 姜婷婷)

DOI: 10.20097/j.cnki.issn1007-9904.240618

基于地基云图与卫星云图相结合的光伏功率预测方法

马文文^{1,2*}, 胡思雨¹, 杨凡^{1,2}, 李登宣¹, 卜强生³

(1. 中国电力科学研究院有限公司, 江苏 南京 210037; 2. 可再生能源并网全国重点实验室, 北京 100192;
3. 国网江苏省电力有限公司电力科学研究院, 江苏 南京 210000)

摘要: 太阳能作为可再生能源中最丰富的资源之一, 具有巨大的发展潜力, 尤其是在当前我国能源结构调整的背景下, 其开发与利用显得尤为重要。光伏(photovoltaics, PV)发电是目前应用最为广泛的太阳能利用方式之一。然而, 光伏发电的效率和稳定性受到自然因素的显著影响, 例如辐照度的高低和云层的变化等因素都会导致光伏功率的昼夜波动。为提高光伏功率预测的精度, 本文提出了一种基于地基云图与卫星云图相结合的光伏功率预测方法。该方法通过卷积神经网络(convolutional neural network, CNN)提取卫星云图和地基云图的特征, 实现光伏功率的超短期预测。通过对云层动态变化的准确捕捉, 该方法能够有效缓解由自然因素引起的光伏功率波动给电网带来的压力, 为推动光伏发电技术的广泛应用和电网的智能化管理提供坚实的技术支持。

关键词: 卫星云图; 地基云图; 卷积神经网络; 光伏功率

中图分类号: TM615

文献标志码: A

文章编号: 1007-9904(2025)12-0017-10

Photovoltaic Power Prediction Method Based on Combination of Ground-based and Satellite Cloud Maps

MA Wenwen^{1,2*}, HU Siyu¹, YANG Fan^{1,2}, LI Dengxuan¹, BU Qiangsheng³

(1. China Electric Power Research Institute Co., Ltd., Nanjing 210037, China;

2. National Key Laboratory of Renewable Energy Grid Connection, Beijing 100192, China;

3. State Grid Jiangsu Electric Power Co., Ltd. Electric Power Research Institute, Nanjing 210000, China)

Abstract: As one of the richest sources of renewable energy, solar energy holds significant development potential, especially in the current context of China's energy structure adjustment. Its development and utilization is particularly important. Photovoltaic (PV) power generation is one of the most widely employed methods for harnessing solar energy. However, the efficiency and stability of PV power generation are significantly affected by natural factors, such as irradiance levels and variations in cloud cover, which can lead to diurnal fluctuations in PV power. In order to improve the accuracy of PV power prediction, this paper proposes a novel PV power prediction method that combines satellite cloud maps and ground-based cloud maps. The method utilizes a convolutional neural network to extract features from both satellite and ground-based cloud maps, enabling ultra-short-term predictions of PV power output. By accurately capturing the dynamic changes in cloud cover, the method can effectively alleviate the pressure on the power grid caused by PV power fluctuations due to natural factors. Furthermore, it provides robust technical support for the widespread adoption of PV power generation technology and the intelligent management of the power grid.

Keywords: satellite cloud map; ground-based maps; convolutional neural network; photovoltaic power

基金项目: 国家电网公司总部管理科技项目“基于分布式光伏多层次预测的配电网运行风险预控关键技术研究及应用”(5400-20235555A-3-2-ZN)。

Science and Technology Project of State Grid Corporation of China "Research and Application of Key Technologies for Operation Risk Pre-control of Distribution Network Based on Distributed Photovoltaic Multilayer Prediction" (5400-20235555A-3-2-ZN).

0 引言

太阳能作为可再生能源中最丰富的资源之一, 具有巨大的发展潜力, 尤其是在当前我国能源结构调整的背景下, 其开发与利用显得尤为重要^[1]。光伏(photovoltaics, PV)发电是目前应用最为广泛的太

太阳能利用方式之一^[2]。2023年,我国光伏新增装机容量达到了216.88 GW,显示出光伏行业持续增长的强劲势头和广阔的市场前景。然而,光伏发电的效率和稳定性受到自然因素的显著影响,例如辐照度的高低和云层的变化等因素都会导致光伏功率的昼夜波动。这种功率的不稳定性在某种程度上制约了光伏发电场站的大规模部署^[3]。因此,精准的光伏发电功率预测显得尤为关键,它不仅有助于光伏电站的优化运行和电力系统的合理调度,还能确保电网的安全、稳定和经济运行。实现对光伏电站的超短期光伏功率预测,其重要性不言而喻^[4]。通过提高预测精度,可以有效缓解由于自然因素引起的光伏功率波动给电网带来的压力,为推动光伏发电技术的广泛应用和电网的智能化管理提供坚实的技术支持^[5]。

光伏发电系统受阴影影响大,任何形式的遮挡,如云层遮蔽太阳光,都会导致光伏组件接收到的辐照度迅速下降,进而引发光伏功率的急剧波动。为实现更精确的光伏发电功率预测,必须关注云层的动态变化,因为云观测数据能够实时反映云团在短时间对光伏发电系统的影响。基于云观测数据的预测方法是一种前瞻性的光伏发电功率预测技术,它主要依赖于地基云图或卫星云图^[6]。

基于地基云图预测法是通过全天空成像仪得到的云图数据进行的功率预测法。首先要实现地基云图中目标云团的识别,目前采用的方法有比阈值分割法^[7]和卷积神经网络(convolutional neural network, CNN)^[8]。天空成像仪的成像特性会导致地基云图出现一定的切向和径向畸变。在基于地基云图进行功率预测时,必须对这些畸变进行矫正,否则将对预测精度产生不利影响^[9]。文献[10]提出了一种镜像渐变算法,该算法能够有效矫正地基云图的切向畸变和径向畸变,并大致恢复图中缺失的信息,为功率预测提供了基础。采用改进的Criminisi算法来修复原始云图中的数据缺失区域,结合梯度决策树算法构建预测模型,实现了2 h内的滚动功率预测^[11]。考虑到云量、云厚度和云高度等因素对光伏输出功率的影响,有研究进一步提出了云图特征联想功率预测模型。该模型通过对连续多幅图像进行动态特征提取,并基于传统的长短期记忆网络进行建模,在多

种天气条件下表现出更优的预测性能^[12]。天空图像与光伏输出直接相关,通过深度学习探索两者之间的关系可以更充分地表征云层状态对光伏功率的影响。深度学习技术如卷积神经网络已被广泛用于天气和环境数据的分析,通过学习大量数据样本中的模式和关联性,能够建立起天空图像与PV输出之间复杂的非线性关系^[13]。基于地基云图数据的预测方法具有采集频率高和图像分辨率高的优势,能够较为准确地评估短时间内云团轨迹对功率波动的影响,尤其适用于小规模光伏场站的分钟级功率预测^[14]。然而,由于天空成像仪的拍摄范围有限,且高空云运动速度较快,若要覆盖大面积的光伏场站,则需要安装多个成像仪,这会增加整体的发电成本。因此,基于地基云图的预测法在大规模应用中存在一定的局限性,而基于卫星云图的预测法则能较好地克服这些问题。

与地基云图相比,卫星云图的获取更为便捷快速,并且其图像覆盖范围更广,能够捕捉光伏场站周围的云状态。通过深入分析卫星云图的特征,验证了卫星云图在功率预测应用中的可行性^[15]。以卫星云图为基础的光伏功率预测方法依赖于对云图的跟踪预测。通过尺度不变特征变换算法^[16]来实现云团轨迹的跟踪。此外,另一种基于云团在短时间内运动中灰度值不变原理的变分光流算法,能够实现超前15 min的云图位置信息预测^[17]。通过改进的粒子图像测速算法对局部图像进行信息匹配,通过位移矢量变换和线性外推法,追踪云团的移动轨迹^[18]。基于未来卫星云图的信息,建立了深度学习模型和光电转换模型来实现功率预测^[19]。在预测模型中结合云量信息并使用人工神经网络,将云量纳入模型,从而实现对水平辐照度的准确预测^[20]。卫星可见光图像的像素值直接反映了云层的厚度,将卫星图像中提取的云与辐照度联系起来,以深入探索它们之间的关系。通过分析云层的厚度和分布,可以更准确地预测太阳辐照度的变化^[21]。卫星云图记录了特定时刻天空中的云况,虽然信息丰富,但其中也夹杂着无效信息。文献[22]提出云图区域定位算法,来确定卫星云图对光伏场站有影响的区域。然而,卫星云图的空间分辨率相对地基云图较低,难以捕捉到小尺度的云层变化,这对于需要高精度局部预测

的光伏电站来说是一个限制因素。

为解决上述问题,本文提出了一种综合地基云图和卫星云图信息的模型(以下简称综合模型)。该方法创新性地结合了地基云图和卫星云图的优势,利用卫星云图具有大范围覆盖能力的特点,可获取区域尺度的云层分布信息;同时结合地基云图具有高空间分辨率(通常可达百米级)和低延迟(实时性可达分钟级)的优势,可精确捕捉局部云团的运动细节。通过构建卷积神经网络模型,分别提取两类云图的深层特征,并建立特征融合机制,从而更全面地反映云层对光伏功率波动的影响规律。这种多源数据融合方法不仅克服了单一数据源在覆盖范围或分辨率上的局限性,而且通过优势互补显著提升了预测模型的准确性和可靠性,为实现精细化光伏功率预测提供了新的技术途径。

1 卫星云图与地基云图数据处理

1.1 卫星云图处理

卫星云图能够全面展示云层分布状况,揭示云层对太阳辐射(包括直射与散射)的重要影响机制。具体来说,较薄或稀疏的云层虽能减弱太阳直射强度,但仍允许部分直射光透过,同时对太阳散射的影响相对较小。反之,厚密云层则能够完全遮蔽太阳直射,并显著增强太阳光的散射效应。

太阳辐射是决定光伏功率的关键因素,其强弱直接关系到光伏电池板接收的能量多寡,进而影响光伏系统的发电效率。较高的太阳辐射水平意味着更多的光能被有效转化为电能,从而提升光伏系统的功率输出。由此可得,光伏系统的性能与功率输出深受云层特性的影响。

然而,卫星云图中云与地面的界限并不十分清晰,这给云层的精确识别带来了挑战。为提高卫星云图的视觉效果和信息可读性,可以采用以下综合处理方法。首先,读取卫星云图的原始图像数据。其次,调整图像的对比度和亮度,使用直方图均衡化方法增强图像的整体对比度,同时通过加法或乘法运算调整图像的亮度值,以使图像更加明亮或暗淡。然后,根据亮度和对比度的不同来检测图像中的云边界,生成边缘图像。下一步,对图像进行锐化处理,来增强图像的细节,使云的结构更加清晰。最

后,应用滤波技术减少图像中的噪声,可以使用高斯滤波去除图像中的噪声,从而提高图像的质量。通过这一系列处理步骤,可以显著提升卫星云图的视觉效果。这一改进措施旨在更为精确地捕捉云层分布及其对太阳辐射的动态影响,从而进一步提升光伏功率预测的准确性与可靠性。

$$I'(x_w, y_w) = \sum_{i=-k}^k \sum_{j=-k}^k I(x_w + i, y_w + j) \cdot G(i, j) \quad (1)$$

$$G(i, j) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{i^2 + j^2}{2\sigma^2}\right) \quad (2)$$

式中: x_w 为原始图像所在位置的横坐标; y_w 为原始图像所在位置的纵坐标; $I'(x_w, y_w)$ 为经过处理后图像在 (x_w, y_w) 位置的像素值; $I(x_w, y_w)$ 为原始图像在 (x_w, y_w) 位置的像素值; σ 为高斯函数的标准差; k 为高斯核函数的半径; i, j 为高斯核的坐标值; $G(i, j)$ 为高斯核 (i, j) 对应的权重值。

在现阶段基于卫星云图的光伏预测研究中,普遍采用的卫星云图空间分辨率介于几百米至几千米之间,这意味着卫星云图上光伏电站仅由一个像素点来表示。多数方法依赖于该像素点的数值来直接反映云层对太阳辐射的遮挡效果,这实际上等同于默认太阳光总是以垂直角度照射光伏电站。然而,考虑到太阳高度角与方位角会随时间动态变化,这一假设明显与实际状况不符。为此,本文选择以光伏电站为核心,选取一定范围内的卫星云图区域作为影响光伏功率的关键区域。这一改进旨在更准确地捕捉太阳光在不同时间与空间条件下对光伏电站输出功率的影响,从而提升光伏预测的精度和可靠性。

1.2 地基云图处理

地基云图是通过地面观测设备获取的云层分布图像,利用光、电波等物理信号对大气中的云层进行垂直和水平方向的扫描与成像,从而生成具有高时空分辨率的云层分布图。与卫星云图相比,地基云图具有显著优势:其近距离观测特性能提供更高分辨率的云层信息,使得云层的细节特征得以更准确把握;地基观测不受卫星轨道和天气条件限制,可实现持续不间断的实时监测;此外,地基设备能够通过多角度扫描和数据融合技术,提高云层识别和分类的准确性。因此,地基云图为光伏功率预测等应用提供了更为精确和实时的云层数据支持,显著提升

了相关领域的研究与应用效果。

地基云图采用全天空成像仪拍摄,由于相机成像原理的限制,图像边缘区域存在一定的畸变现象。为解决此边缘畸变问题以及因缺乏遮阳板而引起的太阳直射过曝问题,本文提出了一套综合处理方法。

首先,基于相机的具体参数,通过相机标定获取内参矩阵和畸变系数,利用径向畸变和切向畸变的校正公式对图像进行畸变校正。

$$x_d = x_a(1 + k_1r^2 + k_2r^4 + k_3r^6) + [2p_1x_a y_a + p_2(r^2 + 2x_a^2)] \quad (3)$$

$$y_d = y_a(1 + k_1r^2 + k_2r^4 + k_3r^6) + [p_1(r^2 + 2y_a^2) + 2p_2x_a y_a] \quad (4)$$

式中: x_a 为校正前图像所在位置的横坐标; y_a 为校正前图像所在位置纵坐标; x_d 为校正后图像所在位置的横坐标; y_d 为校正后图像所在位置的纵坐标; r 为半径; k_1 、 k_2 、 k_3 为径向畸变系数; p_1 、 p_2 为切向畸变系数。

其次,通过插值方法填充校正后的空缺区域,从而消除图像边缘的畸变。针对过曝问题,通过亮度

阈值分割检测过曝区域,采用非线性亮度压缩、局部直方图均衡化和对比度拉伸等方法调整过曝区域的亮度,恢复细节并使其表现更加自然。通过这些技术手段的应用,最大限度地消除因太阳光直射导致的图像干扰,从而提升云层识别的准确性,最终增强光伏功率预测的精确度与可靠性。

2 超短期光伏功率预测模型

本文提出了一种基于地基云图与卫星云图相结合的超短期光伏功率预测方法。方法的整体架构如图1所示。首先,采用图像处理技术对地基云图及卫星云图进行预处理,以提高云层识别的准确性,这有助于增强模型的训练效能。在处理后的地基云图和卫星云图的基础上,首先确保两者的尺寸一致,必要时进行缩放,然后将两张图像在通道维度上进行拼接,形成一个多通道张量作为卷积神经网络的输入。其次,定义卷积神经网络模型,确保输入层的形

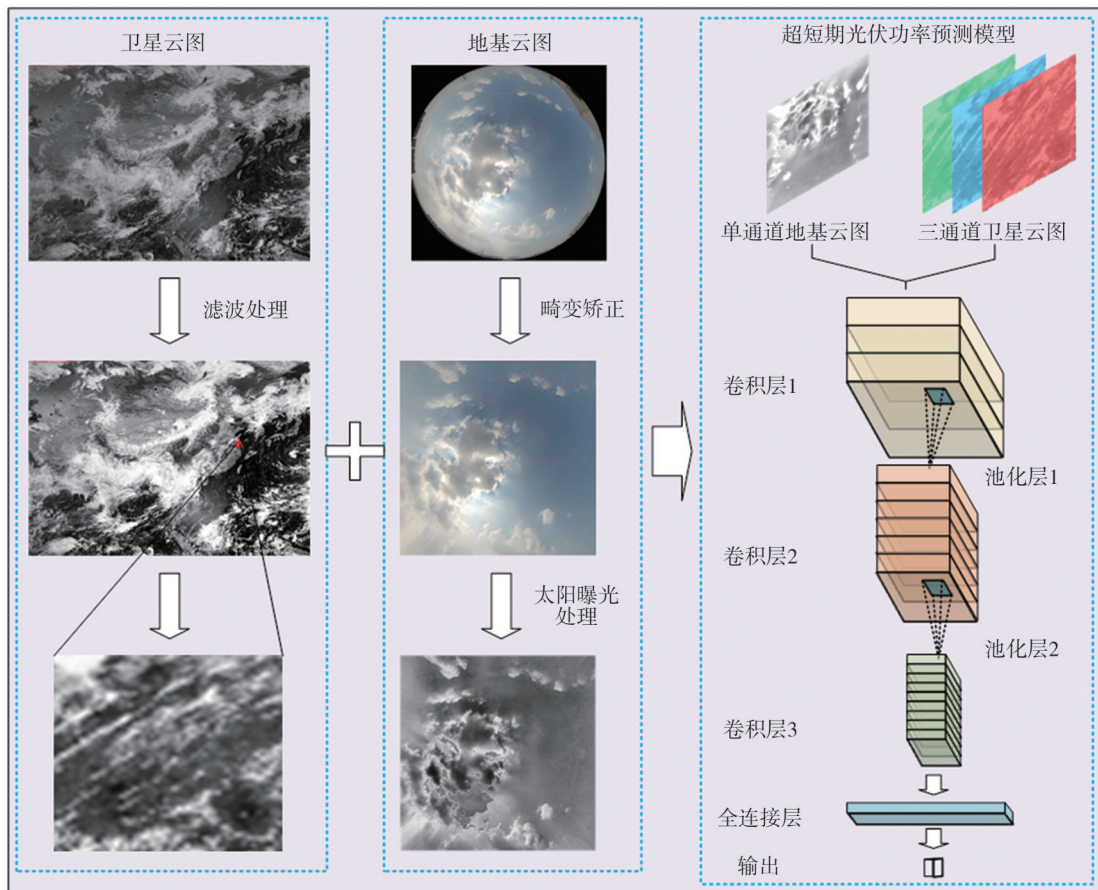


图1 超短期光伏功率预测模型框架图

Fig.1 Framework of the ultra-short-term PV power prediction model

状与拼接后的图像维度匹配。网络结构包括卷积层、池化层、激活函数和全连接层等,设计了一个三层卷积神经网络,具体架构如下。第一层卷积层:卷积核大小为 3×3 ,滤波器数量为 32。之后接一个 2×2 的最大池化层。第二层卷积层:卷积核大小为 3×3 ,滤波器数量为 64。之后接一个 2×2 的最大池化层。第三层卷积层:卷积核大小为 3×3 ,滤波器数量为 128。全连接层:神经元数量为 128,激活函数为 ReLU。输出层:神经元数量为类别数,激活函数为 Softmax。为防止过拟合,在卷积层和全连接层之间加入了批量归一化。将拼接后的图像张量输入到网络中,并根据任务需求设置训练目标和损失函数,使用标注数据集对网络进行训练,优化模型参数,从而完成对拼接图像的特征提取和任务处理。最后,通过全连接层完成从这些特征到超短期光伏功率的精确预测。

3 算例分析

3.1 数据来源

本文选取了中国南京地区某光伏场站的实测数据进行验证,该数据集详细记录了光伏场站的功率输出情况,时间分辨率达 5 min。用于辅助分析的数据源包括中国气象数据网提供的 FY-2G 卫星可见光云图,其原始更新频率为每小时一次。为确保卫星云图与光伏功率数据的时间分辨率匹配,本文采用插值技术对卫星云图进行处理,使之具备 5 min 的时间分辨率。另外,本文采用的地基云图数据每分钟更新一次,为与光伏数据保持时间分辨率的统一,每 5 min 选取一张地基云图进行分析。鉴于夜间光伏功率数据为零,本文的研究仅限于光伏功率数据不为零的有效时间段,以集中分析光伏系统在日照条件下的性能表现,并使用该时刻的数据来预测 5 min 后的光伏功率。通过这种数据处理与时间序列匹配的方法,确保了研究结果的精确性和一致性,进而提升了光伏功率预测模型的可靠性。

3.2 模型评价指标

为验证模型的性能,本文采用了 6 种有效的误差评价指标:平均绝对误差 A_{ME} 、平均绝对百分比误差 P_{MAE} 、均方根误差 R_{MSE} 、标准化均方根误差 N_{RMSE} 、相关系数 R 和决定系数 R_c ,上述 6 个误差评价指标

的数学表达式分别如式(5)一式(10)所示。

$$A_{ME} = \frac{1}{n} \sum_1^n |x - y| \quad (5)$$

$$P_{MAE} = \frac{1}{n} \sum_1^n \left| \frac{x - y}{x} \right| \quad (6)$$

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_1^n (x - y)^2} \quad (7)$$

$$N_{RMSE} = \frac{\sqrt{\frac{1}{n} \sum_1^n (x - y)^2}}{x_{\max}} \quad (8)$$

$$R = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}} \quad (9)$$

$$R_c = 1 - \frac{\sum (x - y)^2}{\sum (x - \bar{x})^2} \quad (10)$$

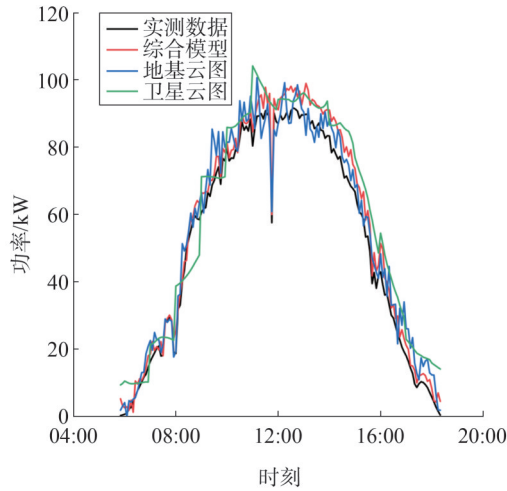
式中: x 为测量值; \bar{x} 为测量值的平均值; y 为预测值; \bar{y} 为预测值的平均值; n 为样本数量; x_{\max} 为测量值的最大值。

3.3 结果分析


为验证模型的有效性,本文设计了对比实验,分别采用同时考虑地基云图和卫星云图的综合模型,以及仅考虑卫星云图、仅考虑地基云图的单一数据模型。图 2(a)展示了在晴朗天气条件下,三种模型的光伏功率预测结果,图 2(b)则呈现了对应预测结果的绝对误差比较。从图 2(a)和图 2(b)中可以看出,仅依赖地基云图或卫星云图进行预测的模型,其结果显示出较大的波动性,尤以仅使用卫星云图的模型的预测波动最大。相比之下,综合模型其预测结果的波动显著减小,显示出更高的稳定性。进一步分析图 2(b)中的绝对误差数据,可以发现,综合模型的预测结果的绝对误差均低于 10 kW,为三种模型中误差最小的情况。

为深入对比三种模型预测结果的优劣,本文选取了 6 项误差评价指标,以此对各模型进行量化评估。详细评估结果如表 1 所示。从这 6 项误差指标的综合表现来看,综合模型在所有评价维度上均显示出最小的误差值。在晴朗条件下,该模型的预测精度明显优于其他两个单一数据源的模型。具体而言,相较于仅考虑地基云图的模型,综合模型在 P_{MAE}

指标上降低了 42.52%, 在 R_{MSE} 指标上降低了 44.87%; 而相较于仅考虑卫星云图的模型, 综合模型在 P_{MAE} 指标上降低了 52.32%, 在 R_{MSE} 指标上降低了 37.97%。这些数据表明, 综合模型显著提升了晴朗条件下光伏功率预测的准确性, 大幅降低了预测误差。



(a) 晴天下不同模型的预测结果



(b) 晴天下不同模型预测结果的误差

图2 晴天条件下不同模型的预测结果及其误差

Fig.2 Prediction results of different models and their errors under sunny conditions


图 3(a)展示了在多云天气条件下, 三种模型的光伏功率预测结果, 图 3(b)则呈现了对应预测结果的绝对误差比较。从图 3 中可以得到, 仅依赖地基云图进行预测的模型, 其结果显示出较大的波动性; 仅依赖卫星云图进行预测的模型曲线较为平缓, 捕捉不到功率突变的信息。相比之下, 综合模型

预测结果的波动显著减小, 显示出更高的稳定性。进一步分析图 3(b)中的绝对误差数据, 可以发现, 综合模型预测结果的绝对误差均低于 10 kW, 为三种模型中误差最小的, 另外两种模型的误差可以达到 20 kW。


表 1 晴天下不同模型预测结果误差

Table 1 Errors in the prediction results of different models under sunny days

参数	综合模型	地基云图	卫星云图
A_{ME}/kW	3.514	5.912	5.244
$P_{MAE}/\%$	44.754	77.861	93.865
R_{MSE}/kW	4.228	7.670	6.816
N_{RMSE}	0.066	0.120	0.107
R	0.975 7	0.930 1	0.913 2
R_c	0.928 1	0.763 4	0.813 1



(a) 多云条件下不同模型的预测结果



(b) 多云条件下不同模型预测结果的误差

图3 多云条件下不同模型的预测结果

Fig.3 Predictions of different models under cloudy conditions


多云天气下不同模型预测结果误差如表 2 所示,从这 6 项误差指标的综合表现来看,综合模型在所有评价维度上均显示出最小的误差值。在多云条件下,该模型的预测精度明显优于其他两个单一数据源的模型。具体而言,相较于仅考虑地基云图的模型,综合模型在 R_{MSE} 指标上降低了 9.52%;而相较于仅考虑卫星云图的模型,综合模型在 R_{MSE} 指标上降低了 46.99%。这些数据表明,综合模型显著提升了多云条件下光伏功率预测的准确性,大幅降低了预测误差。

表 2 多云天气下不同模型预测结果误差


Table 2 Errors of prediction results of different models under cloudy weather

参数	综合模型	地基云图	卫星云图
A_{ME}/kW	4.163	4.351	7.996
$P_{MAE}/\%$	45.705	54.103	125.815
R_{MSE}/kW	4.914	5.431	9.271
N_{RMSE}	0.054	0.059	0.101
R	0.997 2	0.991 3	0.977 2
R_c	0.975 7	0.970 3	0.913 4


为验证不同模型的适用范围,本文采用了一个月的实测数据对各模型进行了对比分析,图 4 展示了三种模型预测值与实测值的散点图分布情况。通过观察颜色标识的散点分布,可以发现大部分散点集中于低功率区域,这与辐照度较低时的实际运行情况相吻合。从图 4 中各散点图的分布情况来看,仅依赖卫星云图的模型在预测值与实测值对比时表现出较大差异。这一现象主要是由于卫星云图时间与空间分辨率不足,难以充分捕捉光伏组件上空云图在不同时间和空间尺度上的细微变化。相比之下,综合模型的预测值与实测值在高功率区域内的散点分布更为集中。这一观察结果进一步验证了综合模型在预测精度方面的优势,特别是在高功率输出条件下,该模型的预测值与实际测量值之间的吻合度显著提高。因此,综合利用地基云图和卫星云图信息,能够显著提升光伏功率预测的准确性,扩大模型的适用范围,特别适用于需要高精度预测的应用场景。



(a)综合模型的预测值与实测值对比



(b)仅考虑地基云图的模型预测值与实测值对比



(c)仅考虑卫星云图的模型预测值与实测值对比

图 4 不同模型预测值与实测值对比

Fig.4 Comparison of predicted and measured values of different models

太阳辐射是决定光伏系统功率输出的关键因素,其强度直接影响光伏电池板接收的能量,进而影响系统的发电效率。较高的太阳辐射水平意味着更多的光能被转化为电能,显著提升光伏系统的输出功率。鉴于此,本文对综合模型在不同辐照度区间下的光伏功率预测精度进行了深入研究,结果如图5所示。观察图5可以发现,在各个辐照度预测区间内,超过一半的预测值高于实际测量值;并且随着辐照度的增加,光伏功率的预测误差也随之增大;然而,尽管误差随辐照度增加而扩大,但超过一半的预测数据点的误差仍保持在10 kW以内。这一现象表明,即便在高辐照度条件下,模型的预测偏差仍得到有效的控制。




图5 综合模型预测误差随辐照度分布图

Fig.5 Distribution map of comprehensive model prediction error with irradiance

综合误差数值分析,无论在低辐照度还是高辐照度环境中,综合模型均表现出色,显示出优越的预测性能。这种跨辐照度区间的预测能力,显示出该模型在不同光照条件下的适应性与稳定性。

为全面评估三种模型的预测准确性,本文计算了不同模型的不同误差指标,结果如图6所示。通过对比不同模型曲线的分布情况,可以清晰地观察到,综合模型在各项误差指标上均表现最佳,显示出最小的误差值,如表3中加粗的数据。具体来看,相较于仅依赖地基云图的模型,综合模型在 A_{ME} 指标上降低了25.51%,在 R_{MSE} 指标上降低了29.17%。相较于仅考虑卫星云图的模型,综合模型在 A_{ME} 指标

上进一步降低了62.86%,并在 R_{MSE} 指标上降低了68.60%。这些数据的差异性表明,通过利用地基云图和卫星云图的双重数据源,显著提升了超短期光伏功率预测的准确性,有效地减少了预测误差。




图6 不同模型预测结果误差雷达图

Fig.6 Radar plot of the error in the prediction results of different models

表3 基于CNN的不同模型预测结果误差

Table 3 Prediction errors of different models based on CNN

参数	综合模型	地基云图	卫星云图
A_{ME}/kW	4.684	6.287	12.610
$P_{MAE}/\%$	89.807	151.026	171.567
R_{MSE}/kW	6.068	8.567	19.322
N_{RMSE}	0.024	0.034	0.076
$1 - R$	0.002 5	0.006 6	0.049 6
$1 - R_c$	0.010 2	0.020 3	0.103 2

为系统评估不同数据类型对光伏功率预测精度的影响,本文增加了基于CNN-LSTM(long short-term memory)和Transformer的预测模型,通过多维度对比分析单一数据源与多源数据融合的预测性能,深入探究卫星云图、地基云图及其组合对预测准确性的贡献度。

基于CNN-LSTM的模型误差结果如表4所示,可以看出,相较于仅基于地基云图的模型,综合模型

的 A_{ME} 降低了 20.23%, R_{MSE} 降低了 12.71%。相较于仅考虑卫星云图的模型,综合模型的 A_{ME} 降低了 65.98%, R_{MSE} 降低了 63.12%。基于 Transformer 的模型误差结果如表 5 所示,结果表明,相较于仅依赖地基云图的模型,综合模型的 A_{ME} 降低了 21.72%, R_{MSE} 降低了 16.59%。相较于仅考虑卫星云图的模型,综合模型的 A_{ME} 降低了 75.88%, R_{MSE} 降低了 71.17%。

表 4 基于 CNN-LSTM 的不同模型预测结果误差
Table 4 Prediction error of different models based on CNN-LSTM

参数	综合模型	地基云图	卫星云图
A_{ME}/kW	5.965	7.478	17.535
$P_{MAE}/\%$	1.555	1.915	5.052
R_{MSE}/kW	9.762	11.183	26.471
N_{RMSE}	0.038	0.044	0.104
R	0.986 9	0.98 26	0.902 3
R_c	0.973 9	0.965 4	0.814 2

表 5 基于 Transformer 的不同模型预测结果误差
Table 5 Prediction errors based on different models based on Transformer

参数	综合模型	地基云图	卫星云图
A_{ME}/kW	10.103	12.907	41.894
$P_{MAE}/\%$	2.533	7.057	30.159
R_{MSE}/kW	15.740	18.872	54.591
N_{RMSE}	0.062	0.074	0.215
R	0.969 8	0.954 5	0.450 1
R_c	0.940 5	0.911 2	0.202 6

4 结束语

本文提出了一种基于地基云图和卫星云图相结合的光伏功率预测方法,通过卷积神经网络提取地基云图与卫星云图的高层特征,更准确地捕捉云层对光伏功率波动的影响。本文将提出的方法在 CNN、CNN-LSTM 和基于 Transformer 的不同算法模型进行实验,实验结果表明,该方法在多种天气条件下表现出优越的预测性能,显著提高了光伏功率预测的精度和可靠性。通过对云层分布情况的深入研究,该方法不仅有助于光伏电站的优化运行和电力

系统的合理调度,还能确保电网的安全、稳定和经济运行。未来的研究将进一步优化模型,提高预测的时间分辨率和空间分辨率,以适应更大规模光伏电站的需求。

参考文献

- [1] 史丹.中国能源安全结构研究[M].北京:社会科学文献出版社,2015.
- [2] 刘晓艳,王珏,姚铁锤,等.基于卫星遥感的超短期分布式光伏功率预测[J].电工技术学报,2022,37(7):1800-1809.
LIU Xiaoyan, WANG Jue, YAO Tiechui, et al. Ultra short-term distributed photovoltaic power prediction based on satellite remote sensing[J]. Transactions of China Electrotechnical Society, 2022, 37(7): 1800-1809.
- [3] 崔杨,张汇泉,仲悟之,等.考虑需求响应的含光热电站可再生能源高渗透率电力系统多源优化调度[J].高电压技术,2020,46(5):1499-1507.
CUI Yang, ZHANG Huiquan, ZHONG Wuzhi, et al. Multi-source optimal scheduling of renewable energy high-permeability power system with CSP plants considering demand response [J]. High Voltage Engineering, 2020, 46(5): 1499-1507.
- [4] 赖昌伟,黎静华,陈博,等.光伏发电出力预测技术研究综述[J].电工技术学报,2019,34(6):1201-1217.
LAI Changwei, LI Jinghua, CHEN Bo, et al. Review of photovoltaic power output prediction technology [J]. Transactions of China Electrotechnical Society, 2019, 34(6): 1201-1217.
- [5] 时珉,许可,王珏,等.基于灰色关联分析和 GeoMAN 模型的光伏发电功率短期预测[J].电工技术学报,2021,36(11):2298-2305.
SHI Min, XU Ke, WANG Jue, et al. Short-term photovoltaic power forecast based on grey relational analysis and GeoMAN model [J]. Transactions of China Electrotechnical Society, 2021, 36(11): 2298-2305.
- [6] 董存,王铮,白捷予,等.光伏发电功率超短期预测方法综述[J].高电压技术,2023,49(7):2938-2951.
DONG Cun, WANG Zheng, BAI Jieyu, et al. Review of ultra-short-term forecasting methods for photovoltaic power generation [J]. High Voltage Engineering, 2023, 49(7): 2938-2951.
- [7] 陈志宝,李秋水,程序,等.基于地基云图的光伏功率超短期预测模型[J].电力系统自动化,2013,37(19):20-25.
CHEN Zhibao, LI Qiushui, CHENG Xu, et al. A very short-term prediction model for photovoltaic power based on ground-based cloud images [J]. Automation of Electric Power Systems, 2013, 37(19): 20-25.
- [8] 钟振兴,马晓波,安巍,等.基于地基云图与气象数据的辐照度轻量化预测[J].东北电力大学学报,2021,41(1):24-30.
ZHONG Zhenxing, MA Xiaobo, AN Wei, et al. A lightweight solar

- irradiance prediction model based on ground-based cloud images and meteorological data [J]. *Journal of Northeast Electric Power University*, 2021, 41(1): 24-30.
- [9] 余光正, 陆柳, 汤波, 等. 基于云图特征提取的改进混合神经网络超短期光伏功率预测方法[J]. *中国电机工程学报*, 2021, 41(20): 6989-7003.
- YU Guangzheng, LU Liu, TANG Bo, et al. An improved hybrid neural network ultra-short-term photovoltaic power forecasting method based on cloud image feature extraction [J]. *Proceedings of the CSEE*, 2021, 41(20): 6989-7003.
- [10] 朱想, 周海, 朱婷婷, 等. 光伏系统中地基云图的预处理[J]. *电力系统自动化*, 2018, 42(6): 140-145.
- ZHU Xiang, ZHOU Hai, ZHU Tingting, et al. Pre-processing of ground-based cloud images in photovoltaic system [J]. *Automation of Electric Power Systems*, 2018, 42(6): 140-145.
- [11] 路志英, 周庆霞, 李鑫, 等. 基于地基云图图像特征的光伏功率预测[J]. *电力系统及其自动化学报*, 2020, 32(8): 70-76.
- LU Zhiying, ZHOU Qingxia, LI Xin, et al. Photovoltaic power prediction based on image features of ground cloud image [J]. *Proceedings of the CSU-EPSA*, 2020, 32(8): 70-76.
- [12] 柴闵康, 夏飞, 张浩, 等. 基于云图特征自识别的光伏超短期预测模型[J]. *电网技术*, 2021, 45(3): 1023-1031.
- CHAI Minkang, XIA Fei, ZHANG Hao, et al. Ultra-short-term prediction of self-identifying photovoltaic based on sky cloud chart [J]. *Power System Technology*, 2021, 45(3): 1023-1031.
- [13] SUN Y C, SZ-CS G, BRANDT A R. Solar PV output prediction from video streams using convolutional neural networks [J]. *Energy & Environmental Science*, 2018, 11(7): 1811-1818.
- [14] 蒋俊霞, 高晓清, 吕清泉, 等. 基于地基云图的云跟踪与太阳辐照度超短期预报方法研究[J]. *太阳能学报*, 2020, 41(5): 351-358.
- JIANG Junxia, GAO Xiaoqing, LYU Qingquan, et al. Study on cloud tracking and solar irradiance ultra-short-term forecasting based on tsi images [J]. *Acta Energetica Solaris Sinica*, 2020, 41(5): 351-358.
- [15] ALONSO-MONTESINOS J, BATLLES F J. Solar radiation forecasting in the short- and medium-term under all sky conditions [J]. *Energy*, 2015, 83: 387-393.
- [16] CHENG H Y. Cloud tracking using clusters of feature points for accurate solar irradiance nowcasting [J]. *Renewable Energy*, 2017, 104: 281-289.
- [17] CHOW C W, BELONGIE S, KLEISSL J. Cloud motion and stability estimation for intra-hour solar forecasting [J]. *Solar Energy*, 2015, 115: 645-655.
- [18] CHU Y H, PEDRO H T C, LI M Y, et al. Real-time forecasting of solar irradiance ramps with smart image processing [J]. *Solar Energy*, 2015, 114: 91-104.
- [19] LI M Y, CHU Y H, PEDRO H T C, et al. Quantitative evaluation of the impact of cloud transmittance and cloud velocity on the accuracy of short-term DNI forecasts [J]. *Renewable Energy*, 2016, 86: 1362-1371.
- [20] MARQUEZ R, PEDRO H T C, COIMBRA C F M. Hybrid solar forecasting method uses satellite imaging and ground telemetry as inputs to ANNs [J]. *Solar Energy*, 2013, 92: 176-188.
- [21] KATO T, MANABE Y, FUNABASHI T, et al. A study on several hours ahead forecasting of spatial average irradiance using NWP model and satellite infrared image [C] // 2016 International Conference on Probabilistic Methods Applied to Power Systems (PMAPS). *IEEE*, 2016: 1-8.
- [22] 司志远, 杨明, 于一潇, 等. 基于卫星云图特征区域定位的超短期光伏功率预测方法[J]. *高压技术*, 2021, 47(4): 1214-1223.
- SI Zhiyuan, YANG Ming, YU Yixiao, et al. Ultra-short-term photovoltaic power prediction method based on satellite image feature region positioning [J]. *High Voltage Engineering*, 2021, 47(4): 1214-1223.

收稿日期: 2024-12-31

修回日期: 2025-04-10

作者简介:

马文文(1994), 通信作者(mawenwen@epri.sgcc.com.cn), 女, 硕士, 工程师, 主要研究方向为人工智能与功率预测;

胡思雨(1997), 女, 硕士, 工程师, 从事气象应用工作;

杨凡(1997), 男, 硕士, 工程师, 从事气象应用工作;

李登宣(1991), 男, 硕士, 工程师, 从事气象应用工作;

卜强生(1983), 男, 硕士, 正高级工程师, 长期从事继电保护自动化、配网运行控制、分布式新能源观测等方面工作。

(责任编辑 车永强)

DOI: 10.20097/j.cnki.issn1007-9904.240460

基于储能惯量支撑的高比例新能源基地效益提升优化方法

李红刚^{1*}, 李勇¹, 李晓宁¹, 穆明亮^{1,2}

(1. 国网山东省电力公司滨州供电公司, 山东 滨州 256603; 2. 中国石油大学(华东), 山东 青岛 266580)

摘要:随着新能源渗透率的不断提高和大量电力电子设备的接入,电力系统逐渐出现惯性减小、系统强度变弱的趋势,使得跟网型风机等设备在一些情况下难以维持并网状态。储能系统拥有建立和支撑电压的能力,能够有效解决新能源难以并入弱电网的问题。本文分析了高比例新能源基地中风光储各部分的惯量响应特性,在此基础上,结合电力系统的传统惯量对新能源场站惯量建模,并进一步形成新能源基地最小惯量需求。从成本与收益角度出发,建立了计及频率安全稳定约束的储能对高比例新能源基地并网系统综合效益提升优化配置模型,采用粒子群算法对储能优化配置模型进行求解,以日为单位采用 kmeans 聚类方法构建季节典型场景。最后对典型场景系统进行算例分析,验证所提优化方法的有效性。

关键词:储能系统;惯量支撑;综合效益;优化方法

中图分类号:TM732

文献标志码:A

文章编号:1007-9904(2025)12-0027-11

A Method for Optimizing the Allocation of Comprehensive Benefits of a High Proportion of New Energy Bases Based on Energy Storage Inertia

LI Honggang^{1*}, LI Yong¹, LI Xiaoning¹, MU Mingliang^{1,2}

(1.State Grid Binzhou Power Supply Company, Binzhou 256603, China;

2.China University of Petroleum (East China), Qingdao 266580, China)

Abstract: With the continuous improvement of the penetration rate of new energy and the access of a large number of power electronic equipment, the power system gradually shows a trend of decreasing inertia and weakening system strength, which makes it difficult for equipment such as grid-based fans to maintain grid-connected status in some cases. The energy storage system has the ability to establish and support voltage, which can effectively solve the problem that new energy is difficult to integrate into the weak power grid. In this paper, the inertia response characteristics of each part of the wind-solar-storage in the high-proportion new energy base are analyzed, and on this basis, the inertia of the new energy station is modeled, and the minimum inertia demand of the new energy base is formed. From the perspective of cost and benefit, an optimal configuration model of energy storage for the comprehensive benefit improvement of the grid-connected system with a high proportion of new energy bases, considering the constraints of frequency safety and stability, is established. The particle swarm optimization configuration model is used to solve the energy storage optimal configuration model, and the kmeans clustering method is used to construct the typical seasonal scenarios on a daily basis. Finally, a typical scenario system analysis is carried out to verify the effectiveness of the proposed configuration method.

Keywords: energy storage systems; inertia support; comprehensive benefits; optimization method

0 引言

随着社会经济的蓬勃发展,人们对电力的需求

持续攀升,同时对电能供应的质量也提出了更为严苛和多样化的要求。2021年中国的总用电量达83128亿kWh,比2012年增长了近1.7倍。然而,传统能源如煤炭、石油等已呈枯竭态势,环境问题也愈发严重。为了改善能源与环境问题,落实可持续发展战略,我国于2020年9月明确提出碳达峰碳中和

基金项目:国网山东省电力公司科技项目(2023A-086)。
Science and Technology Project of State Grid Shandong Electric Power Company(2023A-086)。

目标。能源领域进一步聚焦可再生新能源的开发与利用。

由于风电和光伏等可再生能源在发电过程中,其出力特性显著地表现为随机性、间歇性、周期性及波动性,这些特点对电力系统的稳定运行和调度管理带来了独特的挑战。随着新能源的大规模接入,发电侧的电能产量无法按需控制,使得用电侧负荷预测准确性也大幅下降,这就意味着发电侧和用户侧均不可控,难以实现生产量和需求量的严格匹配,对电力系统的稳定性构成严重威胁。因此,要建设以新能源为主体的新型电力系统,就要对传统电力系统进行改革,提升电力系统对新能源的消纳能力,保障电力系统的稳定运行,而储能是支撑高比例新能源接入和消纳的关键技术手段。

储能系统同时具有电源和负荷的双重属性,在高占比新能源接入的电力系统中,储能系统可以快速响应发电端和负荷端的功率的迅速变化,稳定电网电压和频率,保障电网稳定运行。稳定电能输出的同时,储能系统还可以通过对储能变流器(power conversion system, PCS)的控制,提供有功、无功功率支撑,稳定电压波动。储能系统也能为微电网提供部分谐波治理功能,提升供电质量。储能系统作为电网一种优质的灵活性调节资源,可以解决新能源出力波动性、随机性强等问题,为系统提供必要的惯量支撑,以提高电力系统的稳定性和可靠性。在新型电力系统下,储能是支撑高比例新能源接入和消纳的关键技术手段,在提升电力系统灵活性和保障电网安全稳定等方面具有独特优势。

国内外学者已经针对含储能的高比例新能源电力系统控制问题开展了一系列研究,并提出了多种解决方案^[1-4]。文献[5-6]介绍了一种控制策略,该策略借助电池储能系统来匹配并调节可再生能源的输出,以达到稳定其功率输出的目的。尽管储能具备可靠的能量储备和快速功率响应能力,但目前仍沿用风电频率控制方法,采用微分控制和下垂控制,通过模拟同步机的调频方式主动参与系统的调频过程。文献[7]提出了一种基于虚拟惯性和虚拟下垂动态结合的电池储能电源参与电网一次调频的自适应控制策略。文献[8-9]参考风电机组的虚拟惯量定义,推导出储能的静止能量和风电机组转动动能

之间的关系表达式,定义储能的虚拟惯量。文献[10-11]为储能附加微分控制和下垂控制,模拟同步机的惯量响应和一次调频过程。文献[12-13]设计了采用虚拟同步机技术的储能运行方案,使系统拥有惯性和阻尼特性。

本文在考虑新能源基地惯量需求的前提下,结合频率安全稳定约束得出了高比例新能源基地并网系统综合效益提升优化配置模型。首先,分析了风、光、储的惯性响应特性;其次,结合电力系统的传统惯量得出新能源机组虚拟惯量的公式,并进一步得出新能源基地最小惯量需求;然后,建立高比例新能源基地并网系统综合效益提升的优化配置模型;最后,基于算例系统,验证了所提方法的有效性。

1 高比例新能源基地惯量特性分析

高比例新能源发电基地中存在系统惯量不足的问题,因此,构建新能源场站的虚拟惯量对维持电网频率的稳定性极为关键。虚拟惯量具有可调性和动态变化的特点,其调节参数依赖于能源类型和控制策略。然而,该参数的设定必须考虑调频能量来源的物理限制,若忽视这些物理约束来讨论控制,将毫无实际意义^[14]。

1.1 风电机组的惯量特性

对于风电机组,其虚拟惯量控制方法有无功率备用控制的虚拟惯量控制(virtual inertia control, VIC)、有功功率备用控制的功率减载控制和风储协同配合调频控制等。

1.1.1 虚拟惯量控制

风机在正常工作时,叶片会储存一定的旋转动能,与其转动惯量有关。当负荷突变时,通过调节叶片转速释放或吸收有功功率,对电网进行惯量支撑。由于风机本身具备一定的储能手段,风机无须准备调频备用功率。但是,受到叶片转动惯量的限制,这种方法储存的能量有限,只能应对微小的电网频率波动或者剧烈波动的初期阶段,能够迅速提供调频所需有功功率,有效降低系统的频率变化率(rate of change of the frequency, RoCoF),并减轻频率最低点的波动^[15],支撑电网。由于风力发电机的转动惯量与传统火力、水力发电机相当,因此它们的惯量时间

常数、所储存的能量大致相同。通过相应控制手段,可以使风力发电机模拟传统发电机的频率特性,实现对电网的稳定支撑。

基于此,有学者提出了虚拟惯量控制策略,其主要控制方法为在风机侧最大功率点跟踪(maximum power point tracking, MPPT)控制回路中加入一个比例控制器,根据电网频率偏差生成辅助功率,对输出功率进行主动调整,以满足电网的调频要求。图1为风机虚拟惯量控制图。当系统频率波动时,风机释放其转子中的旋转惯量,主动参与系统的频率调节过程,从而增强电力系统的频率稳定性。




图1 风机虚拟惯量控制图

Fig.1 Turbine virtual inertia control chart

在频率控制环节下,有功功率附加量为

$$\Delta P_1 = -(K_D \frac{df_{mea}}{dt} + K_P (f_{mea} - f_{ref})) \quad (1)$$

式中: ΔP_1 为有功功率附加量; K_D 为微分控制系数; K_P 为比例控制系数; f_{mea} 为系统测量频率值; f_{ref} 为系统参考频率值。

风机实际输出的有功功率为

$$P_s = P_{ref} + \Delta P_1 \quad (2)$$

式中: P_s 为风机实际输出有功功率; P_{ref} 为系统参考功率。

虚拟惯量控制在现有系统中应用广泛,其控制结构设计简单,对原有控制方法改动小。但其效果受频率死区和控制延迟的影响,特别是在电网不稳定的情况下,锁相环的动态性能会显著下降。但是,风力发电机组在主动参与频率控制时,其附加惯量控制可能会与MPPT控制发生冲突,降低控制稳定性,影响其经济效益。同时,由于风机转子在进行频率支撑后,其转速会恢复至最大功率时的设定值,此过程也可能导致频率波动。

1.1.2 功率备用控制

桨距角调整和减载运行是功率备用控制策略的

常用手段,其特点是对风机进行主动调节,使其脱离最大功率点运行,预留一部分功率用于频率调节。风机功率备用控制图如图2所示。




图2 风机功率备用控制图

Fig.2 Turbine power backup control diagram

这种控制方法能够显著提高电网的稳定性,但其以牺牲风能捕获效率为代价,损失了大量的能量,降低了发电效率。同时,预留功率大小的选择也是一个需要考虑的问题。桨距角调整是主动通过变桨距角控制来降低风力发电机的输出功率。当电网频率波动时,可以通过调节桨距角来增加或者减少输出功率,达到支撑频率的目的。而减载运行则是让风力发电机的运行速度超过MPPT的运行速度,从而实现减载。图2中, P_{MPPT} 和 ω_{opt} 分别为最大功率点下的系统功率和风机角速度。

1.1.3 构网型风机控制

风电机组的网侧控制可采用基于虚拟同步机技术(virtual synchronous generator, VSG)的构网型风机控制。

VSG的有功-频率控制模拟了同步发电机的转子运动和一次调频过程,用于表征有功-频率下垂特性。有功-频率控制如图3(a)所示,其中 θ 为VSG输出电动势角度,频率动态调节过程为

$$J\dot{\omega} = (P^* - P)/\omega - D(\omega_{ref} - \omega) \quad (3)$$

式中: J 为虚拟转动惯量; D 为阻尼系数; P 为网侧有功功率; P^* 为网侧有功功率参考值; ω 为网侧角频率; ω_{ref} 为网侧角频率参考值。 J 的存在使VSG在频率动态响应过程中具有了虚拟惯性, D 的存在使VSG对振荡具有了阻尼作用。

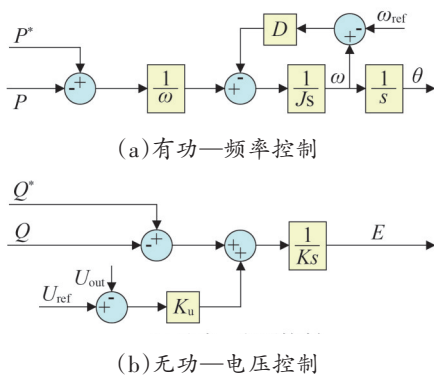


图3 VSG控制框图

Fig.3 VSG control block diagram

VSG的无功-电压控制模拟了同步发电机的励磁调节过程,用于表征无功-电压下垂特性。VSG的无功-电压控制框图如图3(b)所示,其中 U_{out} 和 U_{ref} 分别为输出电压的实际值和参考值; Q 为网侧无功功率; Q^* 为网侧无功功率参考值; K_u 为单位电压变化时对应的无功功率调整值; K 为积分系数; E 为VSG输出电动势幅值。控制框图中的积分控制器用以实现输出电压的无静差调节。采用基于VSG的构网型风机控制可进一步为系统提供惯量储备,进而提升新能源基地系统的安全性与经济性。

1.1.4 风电场虚拟惯量表示

本文利用等值模型对风电机组进行聚合^[16],风电场虚拟惯量为

$$H_{w,t} = \sum_{k \in N} H_{k,t} \cdot P_N / P_{w_n} \quad (4)$$

式中: $H_{w,t}$ 为 t 时刻风电场虚拟惯性时间常数; $H_{k,t}$ 为 t 时刻第 k 台风力机组的虚拟惯性时间常数; P_N 为风力机的额定容量; P_{w_n} 为风电场的装机容量; N 为任意常数。

1.2 光伏的惯量特性

不同于风力发电机,光伏组件是静态、非旋转的,因此光伏不具备旋转惯量,无法为系统提供惯性响应。与风力虚拟惯量支撑相比,关于利用光伏进行快速惯量或频率支撑的研究相对较少。光照的随机性、不稳定性要求光伏系统必须能够快速且准确地执行MPPT控制,因此不能预留额外的容量用于频率响应。对于大型的光伏电厂而言,比MPPT控制更重要的是能够保持场站功率的稳定。

许多电网要求在中高电压等级下的光伏电厂应具备快速频率响应能力。然而,对没有这项要求、处于低电压等级下的光伏阵列在系统频率突变时可能会脱网离网,极大增加系统的不稳定性。此外,使光伏系统具备快速频率响应特性的一个可能措施是减载运行。然而,在持续的减载运行模式下,光伏系统的经济性并不理想。因此,为了增强光伏自身的惯性支撑能力,可通过光储系统联合来实现。

2 储能的惯量响应特性和控制

2.1 储能的惯量响应特性

储能系统响应迅速,能快速充放电,并有效地削峰填谷,可以满足各种场景下的频率调制需求,有广阔的应用场景。电化学储能具有高能量密度、快速响应时间、较高成本效益等特点,是当前大规模储能技术领域的重要发展方向,其代表包括锂离子电池、钠硫电池等。根据容量大小、功率输出规模与响应速度的不同,可分为功率型储能和能量型储能两大类,以满足不同应用场景下对储能性能与效率的具体需求。

储能系统采用两级式PCS,包含双向DC/DC变换器、双向脉冲宽度调制(pulse width modulation, PWM)变流器和电感-电容-电感(inductor capacitor inductor, LCL)滤波电路。其中,双向DC/DC变换器可对直流电压进行灵活升、降压变换。在能量传输方面,以风储系统为例,当风力输出功率不足时,双向变换器通过控制蓄电池放电,来维持功率的平衡;当风力发电单元输出功率超出负荷所需功率时,DC/DC电路控制蓄电池处于充电模式,吸收差额功率,保证系统的可靠运行。

两级式PCS主要包括直-直环节和直-交环节两部分。其中,直-直环节采用电压电流双闭环控制直流母线电压恒定,直-交环节负责控制系统的有功功率和无功功率,其内环控制系统电流。储能系统的矢量控制核心聚焦于实现精确的设定输出功率,可以实时响应功率指令以确保功率的连续调节,有效提升了能源管理的灵活性和精确性。鉴于上述优势,在电网负荷高峰时段,PCS能迅速响应,增加或减少输出功率,以平衡供需;而在紧急情况

下,如电网故障导致的功率短缺,PCS可提供必要的功率支撑,确保电网稳定运行。在电网电压波动或频率偏移时,PCS能够自动调整其输出,维持电网电压和频率的稳定,显著提升电网的整体运行质量和可靠性。

当系统频率偏移的绝对值超过 0.05 Hz 且满足 $\Delta f \frac{df}{dt} > 0$ 时,需要为系统提供必要的惯量支撑来维持系统稳定。通过对储能控制器的设计,能够为系统提供惯量支撑。惯量支撑时, ΔP_1 最大值应大于 $10\%P_N$, 响应时间应小于 0.5 s。

$$\Delta P_1 \approx -\frac{T_J}{f_N} \frac{df}{dt} P_{NESS} \quad (5)$$

式中: T_J 为储能惯性时间常数; P_{NESS} 为储能的额定功率; f_N 为额定频率; f 为系统频率。

2.2 储能的虚拟惯量控制

本文通过引入频率追踪负反馈以实现恒频控制,进一步达到为系统提供惯量支撑的目的^[17-18]。图4为储能虚拟惯量控制流程图。储能虚拟惯量控制器采用PI控制器,通过对系统频率偏差的实时追踪,动态调整储能出力,确保储能系统能够快速响应系统频率的变化,有效完成惯量支撑以及后续的调频任务。考虑到混合储能的功率分配以及电池储能与超级电容协同配合以平抑功率波动的相关问题,保留了中间功率环,以此来保障系统运行的稳定性与高效性。因此,储能DC/DC变换器不再采用传统的电压电流双闭环控制,而采用频率外环、功率电流内环控制。

在变频极端条件下,恒频追踪技术确保了储能装置能够稳定地跟踪并维持目标频率,最大限度地发挥了储能的功率调节能力,并有效地填补了系统功率的瞬时缺口,实现了高效的惯性支撑作用,保障了电力系统的稳定运行。恒频控制策略能够使储能系统保持自身较高的功率输出水平,无须从系统中吸收能量进行充电,进一步优化了系统的频率调节性能。恒频控制不仅完善了储能的调频能力,还实现了调频控制方法的简化。通过将虚拟惯性控制、一次调频以及二次调频三者有机集成,构建了一个高效、集成的控制体系,极大地提升了储能系统应对电网频率波动挑战的灵活性和响应速度。




图4 储能虚拟惯量控制流程

Fig.4 Energy storage virtual inertia control diagram process

图4中, f_m 为频率测量值; $P_{ess,ref}$ 为储能功率参考值; $P_{ess,m}$ 为储能测量值; I_{ref} 为储能电流参考值; I_m 为储能电流测量值。

此外,调频完成后,尽管储能系统在恒定频率控制下能够维持功率输出,并承担新能源机组所需的一次、二次调频职责,但持续的充放电操作会逐步消耗其能量储备,最终导致储能能力下降。因此,如何使其在无须工作时在安全范围内平稳地退出系统也十分重要。

对于储能网侧控制器可采用 1.1.3 节所述的基于 VSG 的构网型控制,为系统增加惯量储备,有效增强新能源基地系统的稳定性,降低运营成本,实现安全与经济的双重提升。

2.3 储能虚拟惯量表示

根据 DL/T 2246.7—2021《电化学储能电站并网运行与控制技术规范》,储能惯性时间常数为 4~12 s^[19]。新能源在实际运行过程中,由于其出力具有极大的不确定性,系统的频率稳定安全具有很大的挑战。在这种情况下,为保证系统的稳定性,应选择一个更大的储能惯性时间常数。根据鲁北某区域新能源历史发电量数据记录,利用一次函数模型来近似模拟和表示不同时间段内的惯性时间常数,如式(6)所示。

$$H_{e,t} = \frac{P_{new,t} - P_{new,min}}{P_{new,max} - P_{new,min}} (H_{max} - H_{min}) + H_{min} \quad (6)$$

式中: $H_{e,t}$ 为 t 时刻的储能惯性时间常数; $P_{new,t}$ 为 t 时刻新能源系统整体出力; $P_{new,max}$ 为新能源系统历史出力最大值; $P_{new,min}$ 为新能源系统历史出力最小值; H_{max} 为储能惯性时间常数最大值; H_{min} 为储能惯性时间常数最小值。

2.4 新能源基地惯量需求

为防止变化率超限而引发继电保护机制,进而造成更广泛的系统故障,基地的惯量需求需要满足对最大频率变化率的考核标准。系统最小惯量需求应满足

$$H_{\text{sys}}^{\min} \geq \frac{|\Delta P_{\text{dis}}| f_0}{2F_{\text{RoCo,max}}} \quad (7)$$

式中: H_{sys}^{\min} 为系统最小惯量需求; ΔP_{dis} 为扰动功率; f_0 为系统频率基准值; $F_{\text{RoCo,max}}$ 为系统允许的最大频率变化率。

3 高比例新能源基地并网系统综合效益提升的量化评估

3.1 综合效益评估

对于系统的成本估算, 主要包括储能(energy storage system, ESS)成本、风力机(wind turbine, WT)成本和光伏(photovoltaic, PV)成本, 建立储能系统总成本最小函数模型, 寻求 ESS 最优配置。基地 ESS 成本包括 ESS 投资成本、ESS 维护成本、新能源基地总运行成本。

$$\min C_{\text{total}} = C_{\text{inv}} + C_{\text{mc}} + C_{\text{op}} \quad (8)$$

式中: C_{total} 为 ESS 总成本; C_{inv} 为 ESS 投资成本; C_{mc} 为 ESS 维护成本; C_{op} 为基地总运行成本。

$$\begin{cases} C_{\text{inv}} = \frac{1}{365} [(C_p P_n + C_{\text{cap}} E_n)] \frac{i(1+i)^{T_{\text{cy}}}}{(1+i)^{T_{\text{cy}}} - 1} \\ C_{\text{mc}} = C_{\text{om}} P_n \\ C_{\text{op}} = C_{\text{pun}} + C_{\text{res}} + C_{\text{tra}} \end{cases} \quad (9)$$

式中: C_p 为 ESS 单位功率; C_{cap} 为容量投资成本; P_n 为 ESS 额定功率; E_n 为 ESS 额定容量; T_{cy} 为 ESS 的运行年限; i 为按年利率计算的投资折现系数; C_{om} 为单位平均维护成本; C_{pun} 为基地弃风、弃光惩罚成本; C_{res} 为降载荷备用成本; C_{tra} 为支撑功率成本。

新能源基地总运行成本可细分为

$$\begin{cases} C_{\text{pun}} = \sum_t c_a (P_{\text{w},t}^f - P_{\text{w},t}^{\text{av}}) + \sum_t c_b (P_{\text{v},t}^f - P_{\text{v},t}^{\text{av}}) \\ C_{\text{res}} = \sum_t c_d R_{\text{w},t} \\ C_{\text{tra}} = \sum_t c_e P_{\text{tra},t} \end{cases} \quad (10)$$

式中: c_a 为单位风电成本; c_b 为弃光惩罚系数; c_d 为单位备用成本; c_e 为西北地区单位度电成本; $P_{\text{w},t}^f$ 为 t 时刻风电场预测出力; $P_{\text{w},t}^{\text{av}}$ 为 t 时刻风电场可用最大出力; $P_{\text{v},t}^f$ 为 t 时刻光伏电站预测出力; $P_{\text{v},t}^{\text{av}}$ 为 t 时刻光伏电站可用最大出力; $R_{\text{w},t}$ 为 t 时刻风电场的备用功率; $P_{\text{tra},t}$ 为 t 时刻弱交流系统提供的支撑功率。

WT 成本函数为

$$C_{\text{WT}} = [\lambda_{\text{WT}} \frac{r_0(1+r_0)^{d_{\text{WT}}}}{(1+r_0)^{d_{\text{WT}}-1} + \mu_{\text{WT}}}] N_{\text{WT}} \quad (11)$$

式中: C_{WT} 为 WT 总成本; λ_{WT} 为 WT 造价成本; r_0 为贴现率; d_{WT} 为 WT 运行年限; μ_{WT} 为 WT 年运行维护成本; N_{WT} 为 WT 机组数量。

PV 成本函数为

$$C_{\text{PV}} = [\lambda_{\text{PV}} \frac{r_0(1+r_0)^{d_{\text{PV}}}}{(1+r_0)^{d_{\text{PV}}-1} + \mu_{\text{PV}}}] N_{\text{PV}} \quad (12)$$

式中: C_{PV} 为 PV 总成本; λ_{PV} 为 PV 造价成本; d_{PV} 为 PV 运行年限; μ_{PV} 为 PV 年运行维护成本; N_{PV} 为 PV 机组数量。

3.2 约束条件

1) 功率平衡约束。

$$P_{\text{tra},t} + P_{\text{wt},t} + P_{\text{pv},t} + P_{\text{ess},t}^{\text{dch}} - P_{\text{ess},t}^{\text{ch}} = P_t \quad (13)$$

式中: $P_{\text{wt},t}$ 为 t 时刻风电场实际出力功率; $P_{\text{pv},t}$ 为 t 时刻光伏电场实际出力功率; $P_{\text{ess},t}^{\text{dch}}$ 为 t 时刻储能实际充电功率; $P_{\text{ess},t}^{\text{ch}}$ 为 t 时刻储能实际放电功率; P_t 为 t 时刻新能源基地系统所需功率。

2) 弱交流系统支撑功率约束。

$$P_{\text{tra,min},t} \leq P_{\text{tra},t} \leq P_{\text{tra,max},t} \quad (14)$$

式中: $P_{\text{tra,min},t}$ 为 t 时刻弱交流系统能支撑的最小功率; $P_{\text{tra,max},t}$ 为 t 时刻弱交流系统能支撑的最大功率。

3) 新能源出力约束。

$$\begin{cases} P_{\text{w},t}^{\text{av}} \leq P_{\text{w},t}^f \\ P_{\text{v},t}^{\text{av}} \leq P_{\text{v},t}^f \\ P_{\text{wt},t} = (1 - \delta) P_{\text{w},t}^{\text{av}} \\ P_{\text{pv},t} = P_{\text{v},t}^{\text{av}} \end{cases} \quad (15)$$

式中: δ 为调频系数。

4) 储能运行约束。

$$\begin{cases} 0 \leq P_{\text{ess},t}^{\text{dch}} \leq U_{\text{ess}}^{\text{dch}} P_n \\ 0 \leq P_{\text{ess},t}^{\text{ch}} \leq U_{\text{ess}}^{\text{ch}} P_n \end{cases} \quad (16)$$

$$E_{\text{n,min}} \leq E_n \leq E_{\text{n,max}} \quad (17)$$

式中: $U_{\text{ess}}^{\text{dch}}$ 为储能系统充电状态变量; $U_{\text{ess}}^{\text{ch}}$ 为储能系统放电状态变量; $E_{\text{n,min}}$ 为 ESS 允许运行的最小容量; $E_{\text{n,max}}$ 为 ESS 允许运行的最大容量。

状态变量满足

$$U_{\text{ess}}^{\text{dch}} + U_{\text{ess}}^{\text{ch}} \leq 1 \quad (18)$$

频率响应功率与能量约束为

$$\Delta P_{\text{ess,a}} = \Delta P_n + 2H_e F_{\text{RoCo}} \frac{P_n}{f_0} \quad (19)$$

$$\begin{cases} 0 \leq \Delta P_{\text{ess},a} \leq C_{\text{max}} P_n - P_{\text{ess},t}^{\text{dch}} + P_{\text{ess},t}^{\text{ch}} \\ E_{n,\text{min}} \leq E_n - \sum \Delta P_{\text{ess},a} \cdot \tau \leq E_{n,\text{max}} \end{cases} \quad (20)$$

式中: $\Delta P_{\text{ess},a}$ 为 ESS 提供的总调频功率; C_{max} 为 ESS 最大充放电倍率; F_{RoCo} 为系统的频率变化率; τ 为离散处理步长; T 为调频时长。

3.3 模型求解

粒子群算法 (particle swarm optimization, PSO) 是一种基于群体智能的优化算法, 由 Eberhart 和 Kennedy 在 1995 年提出, 灵感来源于鸟群觅食的社会行为, 多用于算法优化^[20-25]。在 PSO 中, 每个潜在的解决方案都被看作搜索空间内的一个粒子。粒子们依据当前最优解在解空间中进行探索, 通过迭代更新自己的位置和速度来寻找全局最优解。

通过改进后的粒子群算法对上述模型进行计算, 以储能装置容量、风力发电机数量与光伏阵列数量作为决策变量, 在以上约束条件下, 以适应度函数最小为目标, 计算得到最佳储能配置容量。其算法流程如图 5 所示, 步骤如下。

步骤 1: 输入系统初始数据, 包括风光数据、各成本系数及设备系数等。

步骤 2: 对种群内的每一个粒子, 分别初始化其速度与位置。

步骤 3: 通过适应度函数计算得到每个粒子对应的适应度值, 比较当前适应度值与个体极值。更新个体极值, 得到全局极值。

步骤 4: 计算动态惯量权重系数, 更新当前粒子的速度与位置。其中, 动态惯量权重系数为

$$a = \begin{cases} a_{\text{min}} + \frac{(a_{\text{max}} - a_{\text{min}})(S - S_{\text{min}})}{S_{\text{av}} - S_{\text{min}}}, & S \leq S_{\text{av}} \\ a_{\text{max}}, & S > S_{\text{av}} \end{cases} \quad (21)$$

式中: a 为动态惯量权重系数; a_{max} 为最大惯量权重系数; a_{min} 为最小惯量权重系数; S 为当前粒子的适应度值; S_{min} 为当前种群中的最小适应度值; S_{av} 为当前种群的平均适应度值。

步骤 5: 判断是否满足终止条件。迭代次数为 500 次, 若满足, 则运算结束; 否则, 回到步骤 3 循环运算, 直至满足终止条件, 得到目标函数最小值, 即最优经济性下的风光设备数量及最优储能配置容量。

4 算例分析

4.1 系统惯量需求分析

为验证所提方法的有效性, 根据滨州区域规划指南进行了案例研究。新能源的惯性需求具有季节性时变特征, 如图 6 所示, 图 6(a)—图 6(d) 分别为春—

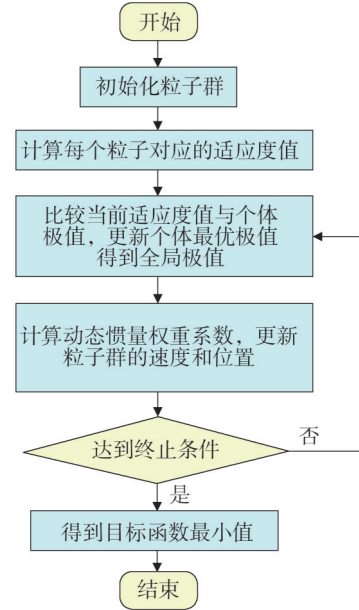




图 5 PSO 算法流程图

Fig.5 PSO algorithm flowchart



(a) 春季



(b) 夏季

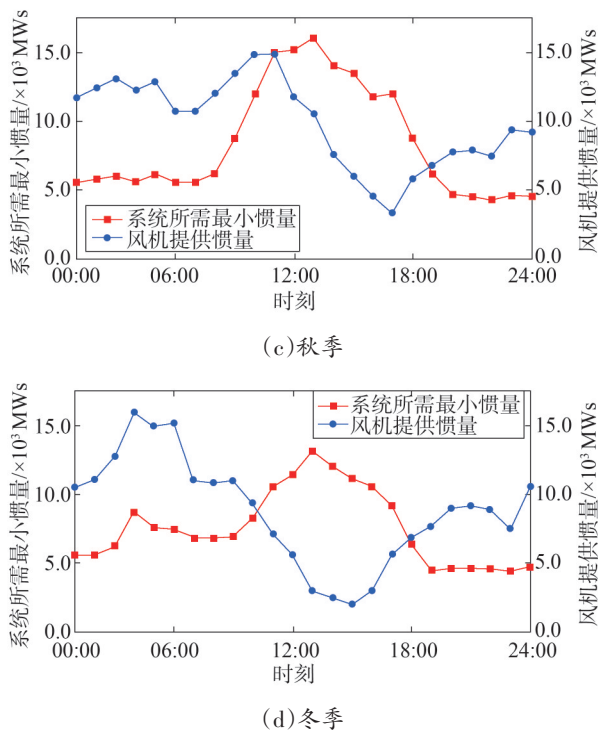


图6 系统惯量需求

Fig.6 System inertia requirements

冬四季典型场景下的基地系统所需最小惯量和风机提供惯量。从季节上看,相较于春季和冬季,夏季和秋季有更高的最低惯量需求。

由图6看出,在各种典型情景下的新能源高峰期,系统所需最大的最小惯性可达13 500 MW_s、13 809 MW_s、16 030 MW_s和13 147 MW_s,分别是低峰期的3.71倍、2.47倍、3.71倍和2.99倍。然而,此时风力发电机提供的惯量较小,仅为系统所需最小惯量的46%、23.98%、65.5%、22.31%。系统的最小惯性需求和风电场提供的虚拟惯性表现出“反向峰值”特征。此外,中午高峰时刻系统频率失稳的风险更高。

4.2 储能配置与优化分析

结合系统经济参数,如表1所示,根据所提优化模型求解算法,得出储能的配置结果,包括储能配置功率、储能规划容量及储能系统日均总成本,并结合风电、光伏日均成本,得到基地系统日均总成本,如表2所示。其中,储能配置功率 $P_{ESS}=1\ 088.3\ \text{MW}$,储能规划容量 $E_{ESS}=1\ 491.2\ \text{MWh}$ 。从储能配置的结果来看,所提方法能够达到工程项目中对新能源基地中储能配置比例为10%~20%以及持续运行1~2 h

的需求,配置结果具备合理性。

表3是四种典型场景下的各成本分析,包括新能源备用成本、弃风/弃光成本和系统支撑功率成本,三者构成总运行成本。其中,系统的支撑功率运行成本占总运行成本的50%~80%,其功率释放主要集中在集中在01:00—09:00与18:00—24:00,此时光伏出力基本为0,利用系统功率支撑能力以维持系统的功率平衡。此外,为基地系统预留了7%的备用功率以应对其他可能存在的系统频率问题,会产生一部分新能源备用成本。构成系统总运行成本中的弃风/弃光成本占比最小,其与源荷不平衡有关。

表1 系统经济参数

Table 1 System economic parameters

参数	数值	参数	数值
C_p /(元/MW)	2 175 420	C_{cap} (元/MW)	1 087 710
C_{om} (元/MW)	145.03	C_{pun} (元/MW)	725.14
C_{tra} (元/MW)	326.31	λ_{WT} (万元/MW)	77 600
r_0	0.06	μ_{WT} (万元/MW)	1 029
λ_{PV} (万元/MW)	49 610	μ_{PV} (万元/MW)	833

表2 储能配置与系统成本

Table 2 ESS configuration and system cost

参数	数值	参数	数值
储能配置功率/MW	1 088.3	储能规划容量/MWh	1 491.2
储能系统日均总成本/万元	495.4	风电、光伏日均成本/万元	5 966.4
基地系统总成本/万元	6 461.8		

表3 系统典型场景运行成本分析

Table 3 Analysis of the running cost of the system in typical scenarios

参数	单位:万元			
	春季	夏季	秋季	冬季
新能源备用成本	77.461	101.317	82.218	75.544
弃风/弃光成本	0	8.449	10.017	27.400
系统支撑功率成本	279.740	58.930	372.963	214.136

图7为典型场景下各时段的储能系统充放电情

况。由图7可看出,在某时段储能的实际出力功率远小于其配置功率,四种场景下储能的最大出力功率为538.7 MW,也仅占配置功率的48.2%。这是因为储能系统的配置功率主要是受频率限制,以最大频率约束下的储能额定功率为配置功率,从而实现

为系统提供惯量支撑的目标,维持系统稳定。即当整个系统处于缺乏惯量支撑的环境中时,储能系统起到了提供稳定惯量的关键作用,储能配置应确保系统频率在最大限度波动下仍在稳定边界以内的区域。

4.3 频率指标有效性分析

图8反映了在考虑频率约束下的系统频率偏差及最大频率变化率指标。整个运行周期内,系统在四个典型场景下的最大准稳态偏差分别为0.116 Hz、0.103 Hz、0.115 Hz、0.11 Hz,最大频率变化率分别为0.995 Hz/s、0.795 Hz/s、0.9 Hz/s、1.1 Hz/s,均满足系统频率考核要求。

此外,若不考虑系统频率约束,频率偏差会在某些时段存在失稳风险,安全稳定裕度显著降低,且在多种场景下最大频率变化率会超出其限制标准。由此也可看出本文所提储能优化配置方法的必要性与有效性。

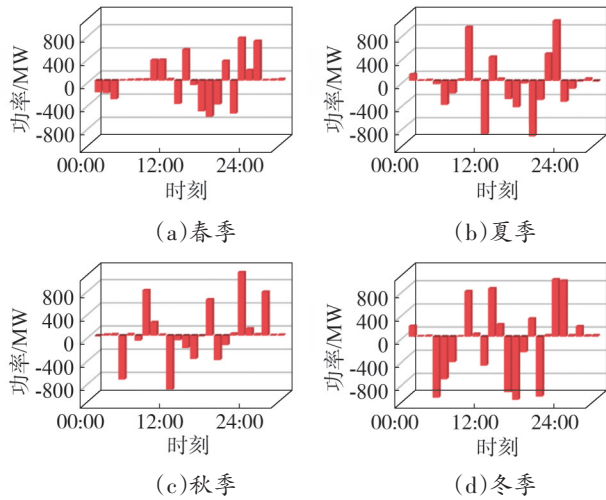


图7 储能系统充放电情况

Fig.7 Charging and discharging of the energy storage system

5 结论

高比例新能源并网会降低电力系统惯量支撑能

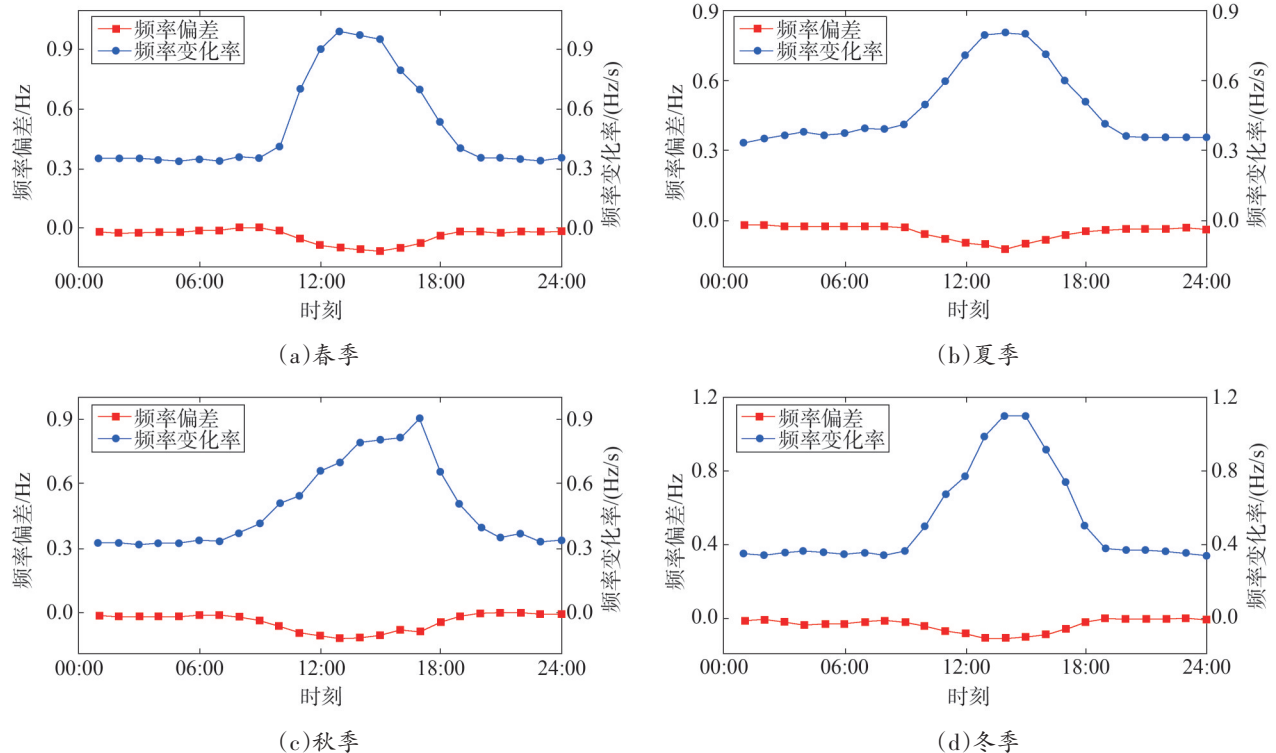


图8 系统频率指标

Fig.8 System frequency metrics

力,增加事故风险。在负荷需求大、新能源占比高的电网中,低惯量问题尤为显著,严重削弱了系统抗干扰能力。针对此问题,本文分析了风光储的惯性响应特征,得出风电场虚拟惯量表示公式、储能电站的惯量表示公式以及新能源基地最小惯量需求。风电机组释放其转子动能为系统提供所需的惯量支撑;储能适应新能源的运行工况,为系统提供惯量支撑。

此外,本文结合经济性与频率安全稳定性,建立了高比例新能源基地并网系统综合效益提升优化配置模型,采用粒子群优化算法对系统进行了储能的配置优化,对配置结果进行了有效性分析。同时对系统的惯量需求指标进行分析,并得到了最优配置下储能系统日均总成本与系统总成本,对于实际工程具有参考意义。

参考文献

- [1] 颜湘武,崔森,常文斐.考虑储能自适应调节的双馈感应发电机一次调频控制策略[J].电工技术学报,2021,36(5):1027-1039.
YAN Xiangwu, CUI Sen, CHANG Wenfei. Primary frequency regulation control strategy of doubly-fed induction generator considering supercapacitor SOC feedback adaptive adjustment[J]. Transactions of China Electrotechnical Society, 2021, 36(5): 1027-1039.
- [2] 付媛,万怿,张祥宇,等.储能虚拟惯量主动支撑与调频状态转移控制[J].中国电机工程学报,2024,44(7):2628-2641.
FU Yuan, WAN Yi, ZHANG Xiangyu, et al. Energy storage virtual inertia active support and frequency modulation state transfer control[J]. Proceedings of the CSEE, 2024, 44(7): 2628-2641.
- [3] 禹海峰,马俊杰,周年光,等.面向储能惯量支撑能力评估的新型电力系统惯性系数辨识方法[J].智慧电力,2023,51(5):1-7,72.
YU Haifeng, MA Junjie, ZHOU Nianguang, et al. New Power System Inertia Coefficient Identification Method for Energy Storage Inertia Support Capability Evaluation[J]. Smart Power, 2023, 51(5): 1-7, 72.
- [4] 毛志宇,李培强,肖家杰,等.面向风功率波动平抑的电池储能双层协调控制策略[J].中国电机工程学报,2024,44(16):6494-6507.
MAO Zhiyu, LI Peiqiang, XIAO Jiajie, et al. Coordinated two-layer control strategy of battery energy storage for wind power fluctuate mitigation[J]. Proceedings of the CSEE, 2024, 44(16): 6494-6507.
- [5] DOS SANTOS NETO P J, DOS SANTOS BARROS T A, SILVEIRA J P C, et al. Power management strategy based on virtual inertia for DC microgrids[J]. IEEE Transactions on Power Electronics, 2020, 35(11): 12472-12485.
- [6] KARIMI-GHARTEMANI M, ALI KHAJEHODDIN S, PIYA P, et al. Universal controller for three-phase inverters in a microgrid[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2016, 4(4): 1342-1353.
- [7] 李欣然,崔曦文,黄际元,等.电池储能电源参与电网一次调频的自适应控制策略[J].电工技术学报,2019,34(18):3897-3908.
LI Xinran, CUI Xiwen, HUANG Jiyuan, et al. The self-adaption control strategy of energy storage batteries participating in the primary frequency regulation [J]. Transactions of China Electrotechnical Society, 2019, 34(18): 3897-3908.
- [8] 张昭遂,孙元章,李国杰,等.超速与变桨协调的双馈风电机组频率控制[J].电力系统自动化,2011,35(17):20-25.
ZHANG Zhaosui, SUN Yuanzhang, LI Guojie, et al. Frequency regulation by doubly fed induction generator wind turbines based on coordinated overspeed control and pitch control [J]. Automation of Electric Power Systems, 2011, 35(17): 20-25.
- [9] 张祥宇,沈文奇,林毅,等.同步耦合双馈风机的虚拟惯量优化控制技术[J].电网与清洁能源,2022,38(9):126-133.
ZHANG Xiangyu, SHEN Wenqi, LIN Yi, et al. Virtual inertia control optimization of synchronous coupled doubly-fed induction wind generator[J]. Power System and Clean Energy, 2022, 38(9): 126-133.
- [10] 黄银华,李常春,罗方旋,等.大规模风电接入对福建电网调峰的影响[J].电网与清洁能源,2015,31(12):96-100.
HUANG Yinhua, LI Changchun, LUO Fangxuan, et al. Impact of large-scale wind farm connected with Fujian power grid on peak load regulation[J]. Power System and Clean Energy, 2015, 31(12): 96-100.
- [11] 邓霞,孙威,肖海伟.储能电池参与一次调频的综合控制方法[J].高电压技术,2018,44(4):1157-1165.
DENG Xia, SUN Wei, XIAO Haiwei. Integrated control strategy of battery energy storage system in primary frequency regulation [J]. High Voltage Engineering, 2018, 44(4): 1157-1165.
- [12] 李欣然,邓涛,黄际元,等.储能电池参与电网快速调频的自适应控制策略[J].高电压技术,2017,43(7):2362-2369.
LI Xinran, DENG Tao, HUANG Jiyuan, et al. Battery energy storage systems self-adaptation control strategy in fast frequency regulation [J]. High Voltage Engineering, 2017, 43(7): 2362-2369.
- [13] 吴启帆,宋新立,张静冉,等.电池储能参与电网一次调频的自适应综合控制策略研究[J].电网技术,2020,44(10):3829-3836.
WU Qifan, SONG Xinli, ZHANG Jingran, et al. Study on self-adaptation comprehensive strategy of battery energy storage in primary frequency regulation of power grid [J]. Power System Technology, 2020, 44(10): 3829-3836.

- [14] 赵冬梅,徐辰宇,杜泽航.就地无常规电源支撑下考虑新能源基地频率稳定的储能优化配置方法[J/OL].中国电机工程学报:1-14 [2024-11-16].<https://doi.org/10.13334/j.0258-8013.pcsee.230919>.
ZHAO Dongmei, XU Chenyu, DU Zehang. Optimization configuration method for energy storage considering frequency stability of new energy bases without conventional power supply support on site [J/OL].Proceedings of the CSEE:1-14[2024-11-16].<https://doi.org/10.13334/j.0258-8013.pcsee.230919>.
- [15] 刘鸿清,张秀琦,王立强,等.新能源场站惯量支撑与频率响应特性研究[J].内蒙古电力技术,2024,42(4):14-22.
LIU Hongqing, ZHANG Xiuqi, WANG Liqiang, et al. Research on inertia support and frequency response characteristics in new energy stations [J]. Inner Mongolia Electric Power, 2024, 42(4): 14-22.
- [16] NAKIGANDA A M, DEGHAN S, MARKOVIC U, et al. A stochastic-robust approach for resilient microgrid investment planning under static and transient islanding security constraints [J].IEEE Transactions on Smart Grid, 2022, 13(3):1774-1788.
- [17] 张祥宇,胡剑峰,付媛,等.风储联合系统的虚拟惯量需求与协同支撑[J].电工技术学报,2024,39(3):672-685.
ZHANG Xiangyu, HU Jianfeng, FU Yuan, et al. Virtual inertia demand and collaborative support of wind power and energy storage system [J].Transactions of China Electrotechnical Society, 2024, 39(3):672-685.
- [18] 张祥宇,朱永健,付媛.基于系统惯量需求的风储协同快速频率响应技术[J].中国电机工程学报,2023,43(14):5415-5429.
ZHANG Xiangyu, ZHU Yongjian, FU Yuan. Wind - storage cooperative fast frequency response technology based on system inertia demand [J].Proceedings of the CSEE, 2023, 43(14):5415-5429.
- [19] 全国电网运行与控制标准化技术委员会.电化学储能电站并网运行与控制技术规范 第7部分:惯量支撑与阻尼控制:DL/T 2246.7—2021[S].北京:中国电力出版社,2021.
- [20] 鞠浩,王旭东,陆佳红.基于混合参数化与粒子群算法的风力机翼型气动优化设计[J].太阳能学报,2023,44(5):473-479.
JU Hao, WANG Xudong, LU Jiahong. Aerodynamic optimization design of wind turbine airfoil based on hybrid parameterization and particle swarm algorithm [J].Acta Energetica Solaris Sinica, 2023, 44(5):473-479.
- [21] 余建树,李朝霞,龚雪娇,等.基于并行粒子群算法的电力系统分区抗差状态估计[J].电网技术,2022,46(8):3139-3149.
YU Jianshu, LI Zhaoxia, GONG Xuejiao, et al. Robust state estimation of power system based on parallel particle swarm optimization and partition calculation [J]. Power System Technology, 2022, 46(8):3139-3149.
- [22] 郭建伟,樊友平.基于改进粒子群算法的VSG参数自适应控制策略[J].电机与控制学报,2022,26(6):72-82.
GUO Jianwei, FAN Youping. Adaptive VSG parameter control strategy based on improved particle swarm optimization [J]. Electric Machines and Control, 2022, 26(6):72-82.
- [23] 徐岩,靳伟佳,朱晓荣.基于遗传粒子群算法的光伏并网逆变器参数辨识[J].太阳能学报,2021,42(7):103-109.
XU Yan, JIN Weijia, ZHU Xiaorong. Parameter identification of photovoltaic grid - connected inverter based on gapso [J]. Acta Energetica Solaris Sinica, 2021, 42(7):103-109.
- [24] 李欣煜,周建萍,李泓青,等.基于粒子群算法的微电网实时功率均分的改进下垂控制策略[J].高电压技术,2018,44(10):3425-3432.
LI Xinyu, ZHOU Jianping, LI Hongqing, et al. Improved droop control strategy for real-time power sharing of microgrid based on particle swarm optimization [J].High Voltage Engineering, 2018, 44(10):3425-3432.
- [25] 苏海滨,高孟泽,常海松.基于粒子群算法的微电网有功无功下垂控制[J].电工技术学报,2015,30(增刊1):365-369.
SU Haibin, GAO Mengze, CHANG Haisong. Microgrid droop control of active and reactive power based on PSO [J].Transactions of China Electrotechnical Society, 2015, 30(S1):365-369.

收稿日期:2024-11-17

修回日期:2025-07-14

作者简介:

李红刚(1987),通信作者(707131700@qq.com),男,高级工程师,主要研究方向为电网调度、电力系统运行;

李勇(1978),男,高级工程师,主要从事电网调度管理工作;

李晓宁(1984),男,高级工程师,主要从事电网调度管理工作;

穆明亮(1989),男,硕士,高级工程师,主要研究方向为电网规划。

(责任编辑 车永强)

DOI: 10.20097/j.cnki.issn1007-9904.240428

融合多元时间序列与TCN-BiLSTM的分布式光伏功率超短期预测研究

高任龙¹, 李峰¹, 马天东¹, 吴骥^{2*}

(1. 国网宁夏电力有限公司, 宁夏 银川 750000; 2. 中国电力科学研究院有限公司, 江苏 南京 100192)

摘要: 气候条件对分布式光伏发电功率的影响显著, 导致功率输出呈现波动性、间歇性和周期性等特性。同时, 不同的气象因素对光伏发电输出的影响程度存在差异。提出了一种融合多元时间序列和时序卷积神经网络-双向长短期记忆神经网络(temporal convolutional neural network-Bi-directional long short-term memory, TCN-BiLSTM)的分布式光伏功率超短期预测方法。基于分布式光伏功率与多元气象要素的相关性分析, 构建光伏功率输出强相关的多元时间序列数据集, 利用提出的TCN-BiLSTM模型获取多元时间序列输入数据与输出功率的映射关系, 实现分布式光伏功率超短期预测。利用实际运行数据对提出的TCN-BiLSTM模型进行单步和多步时间序列功率预测, 并将其预测结果与多种预测模型结果进行对比, 结果验证了提出模型的准确性和有效性。

关键词: 分布式光伏功率预测; 多元时间序列; TCN-BiLSTM; 多步预测

中图分类号: TM615

文献标志码: A

文章编号: 1007-9904(2025)12-0038-12

The Research on Ultra-short-term Prediction of Distributed Photovoltaic Power Based on Multivariate Time Series Fusion With TCN-BiLSTM Network

GAO Renlong¹, LI Feng¹, MA Tiandong¹, WU Ji^{2*}

(1. State Grid Ningxia Electric Power Co., Ltd., Yinchuan 750000, China;

2. China Electric Power Research Institute, Nanjing 100192, China)

Abstract: The performance of distributed photovoltaic power generation systems is significantly influenced by climatic conditions, resulting in output characteristics such as volatility, intermittency, and periodicity. Furthermore, the impact of various meteorological factors on photovoltaic power generation output differs in magnitude. An ultra-short-term forecasting method for distributed photovoltaic power based on a hybrid model that integrates multivariate time series and a temporal convolutional neural network (TCN) with a Bi-directional long short-term memory (BiLSTM) network is proposed. Based on the correlation analysis between distributed PV power and multivariate meteorological factors, a multivariate time series dataset strongly related to PV power output is constructed. Utilizing the proposed TCN-BiLSTM model, the mapping relationship between multivariate time series input data and output power is obtained, thereby enabling ultra-short-term forecasting of distributed photovoltaic power. Additionally, the actual operational dataset is applied to both single-step and multi-step time series forecasting tasks of the proposed TCN-BiLSTM model, and the prediction results are compared with those of traditional forecasting models, verifying the proposed model's accuracy and effectiveness.

Keywords: distributed photovoltaic power prediction; multiple time series; TCN-BiLSTM; multi-step forecasting

基金项目: 国家电网有限公司科技项目“面向日前调度的分布式光伏精细化功率预测技术研究项目”(5229NX230007)。

Science and Technology Project of State Grid Corporation of China “Research on Fine-Grained Power Forecasting Technology for Distributed Photovoltaic Systems in Day-Ahead Scheduling” (5229NX230007).

0 引言

光伏发电作为一种重要的可再生能源形式, 已经得到了广泛的推广与应用^[1-3]。气候条件对分布式光伏发电功率的影响显著, 导致功率输出呈现波

动性、间歇性和周期性的特征^[4-5]。这些特点使得分布式光伏功率预测变得复杂,尤其是受短临气象影响的超短期功率预测难度大,对分布式光伏大规模并网的安全性构成挑战^[6-7]。因此,迫切需要提高超短期光伏功率预测的精度,为电网稳定运行提供可靠支撑。

目前,光伏发电功率预测的研究方法可分为三类:物理方法、统计方法和机器学习方法^[8-9]。物理方法受限于气象预测精度与模型复杂度,限制了物理方法的光伏发电功率预测精度^[10-12]。同时,统计方法难以处理非线性关系、非平稳时间序列以及突发事件对光伏出力的影响,限制了其在光伏发电功率预测中的应用^[13]。机器学习模型能够实现模型输入输出之间的复杂映射关系建模,基于机器学习的方法已被用于直接或间接地预测光伏功率^[14-16]。Ali Agga 等人将卷积神经网络(convolutional neural networks, CNN)用于捕捉光伏输入数据中的空间特征,通过本地感应场、权重共享、池操作和多级特征表示等机制,实现了光伏输出功率的有效预测^[17]。张晋华等人首先收集辐照度建立辐照度云模型,经过变换得到云的数字特征,然后基于云数字特征选取相似日,并使用相似日数据训练长短期记忆神经网络(long short-term memory, LSTM)预测模型^[18]。李丰君等人首先对天气类型进行分类融合,并结合 LSTM 算法提出天气情况全覆盖下分布式光伏的功率预测方法^[19]。此外,黄彦国等人采用时序卷积神经网络实现了光伏发电功率的预测^[20]。在深度学习中,单一网络的深度存在无法捕获复杂特征的问题,同时单一网络的参数量无法满足处理大规模数据需求以及存在可能陷入局部最优解等问题。为了克服这些问题,一些学者使用混合深度学习网络模型对光伏发电功率进行预测。姜景芮等人通过组合深度学习网络,建立了 CNN-LSTM 光伏功率预测模型^[21],杨锡运等人则利用邻近光伏电站的水平辐照度信息,开发了一种一维卷积神经网络-长短时记忆神经网络模型(1D convolutional neural networks-long short-term memory, 1DCNN-LSTM),实现光伏功率的预测^[22]。

特征变量选择对于提高深度学习模型的预测准确性至关重要。特征变量过少会导致模型不能完全

提取输入输出之间的特征,特征变量过多会导致建模冗余^[23]。为解决这一问题,本文在对光伏发电超短期预测的输入参量进行相关性分析基础上,提出融合多元时间序列与时序卷积神经网络-双向长短期记忆神经网络(temporal convolutional neural network-Bi-directional long short-term memory, TCN-BiLSTM)的分布式光伏功率超短期功率预测模型,并利用该模型实现了单步和多步光伏超短期功率预测。该方法基于分布式光伏功率与多元气象要素的相关性分析,构建光伏功率输出强相关的多元时间序列数据集,采用 TCN-BiLSTM 网络从多元气象数据及光伏功率历史数据中获取多维数据时序特征,构建时间序列输入数据与输出功率的映射关系,实现分布式光伏超短期功率预测。

1 多元时间序列选取与网络模型构建

1.1 Spearman 相关系数

相关性分析方法通过计算相关系数来衡量两个统计变量之间的相关性。在评估不同气象因素对分布式光伏发电超短期输出功率的影响程度时,常用的相关系数有皮尔逊相关系数和 Spearman 相关系数。皮尔逊相关系数适用于连续的定量数据,一般要求数据满足线性关系和正态分布。而 Spearman 相关系数是一种用于衡量两个连续变量之间单调关系强度的统计量,又称秩相关系数,是利用两变量的秩次大小作线性相关分析。Spearman 相关系数对原始变量的分布不做要求,因此适用范围相较于皮尔逊相关系数更广,Spearman 相关系数取值范围为 $[-1, +1]$ 。设 $X = \{X_1, X_2, \dots, X_n\}$ 、 $Y = \{Y_1, Y_2, \dots, Y_n\}$ 分别为两个变量集合,分别对每个变量的值进行排序并转换为秩次 $R_X = \{R_{X_1}, R_{X_2}, \dots, R_{X_n}\}$ 和 $R_Y = \{R_{Y_1}, R_{Y_2}, \dots, R_{Y_n}\}$;然后按皮尔逊相关性分析的方法计算 R_X 和 R_Y 之间的相关性,其计算公式为

$$\rho = \frac{\sum_{j=1}^m (R_{X_j} - \bar{R}_X)(R_{Y_j} - \bar{R}_Y)}{\sqrt{\sum_{j=1}^m (R_{X_j} - \bar{R}_X)^2} \sqrt{\sum_{j=1}^m (R_{Y_j} - \bar{R}_Y)^2}} \quad (1)$$

式中: R_{X_j} 为 X_j 在变量集合 X 中的秩次; R_{Y_j} 为 Y_j 在变量集合 Y 中的秩次; \bar{R}_X 集合 X 中所有样本秩次均值; \bar{R}_Y 为集合 Y 中所有样本秩次均值; m 为总样本数。

1.2 BiLSTM网络

LSTM 是一种特殊的递归神经网络,常用于处理和预测时间序列数据。其核心原理是通过门控机制来控制信息流动。具体而言,LSTM 通过引入遗忘门、输入门和输出门,对输入信息进行选择性控制,从而实现长期记忆的保留^[24-25]。

在 LSTM 的三个门控机制中,遗忘门用于决定哪些信息应被保留或遗忘;输入门控制新信息的输入;输出门确定记忆单元中的信息如何输出到隐藏状态。LSTM 单元的结构如图 1 所示。LSTM 的更新公式如下:

$$f_t = \sigma(W_f[h_{t-1}; x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i[h_{t-1}; x_t] + b_i) \quad (3)$$

$$o_t = \sigma(W_o[h_{t-1}; x_t] + b_o) \quad (4)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}; x_t] + b_c) \quad (5)$$

$$c_t = f_t c_{t-1} + i_t \tilde{c}_t \quad (6)$$

$$h_t = o_t \tanh(c_t) \quad (7)$$

式中: W_f 、 W_i 、 W_o 分别为 LSTM 遗忘门、输入门、输出门的权重矩阵; W_c 为候选细胞状态的权重矩阵; b_f 、 b_i 、 b_o 分别为 LSTM 遗忘门、输入门、输出门的偏置向量; b_c 为候选细胞状态的偏置向量; c_{t-1} 为 $t-1$ 时刻的细胞状态矩阵; h_{t-1} 为 $t-1$ 时刻的隐藏状态矩阵; x_t 为 t 时刻输入特征向量矩阵; f_t 、 i_t 、 o_t 分别为 t 时刻的遗忘门、输入门、输出门输出矩阵; c_t 为 t 时刻的候选细胞状态矩阵; c_t 为 t 时刻细胞状态矩阵; h_t 为 t 时刻的隐藏状态矩阵; $\sigma(\cdot)$ 为 sigmoid 运算函数。

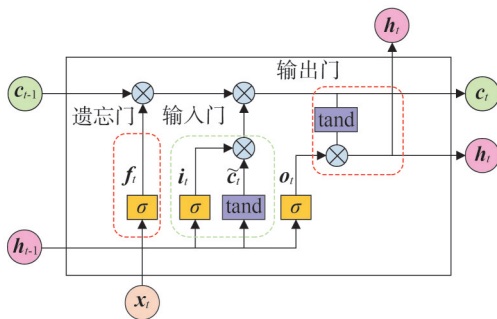


图1 LSTM单元

Fig.1 LSTM cell

传统的单向 LSTM 在序列数据处理方面存在一些局限性,主要体现在其信息传递的单向性上。具

体而言,单向 LSTM 仅能沿时间序列的一个方向传递信息,即从过去到未来。这种单向性可能导致模型无法充分利用时间序列中的未来信息,从而限制了模型在序列预测任务中的表现。为了解决这一问题,提出了 BiLSTM。BiLSTM 的结构与传统 LSTM 类似,但包含两个独立的 LSTM 层:一个 LSTM 层按时间序列的正向顺序处理输入,另一个 LSTM 层按反向顺序处理输入序列。通过连接两个方向每个时间步的隐藏状态,获得时间序列的完整双向信息。BiLSTM 的这种独特结构使得模型能够同时获取过去和未来的信息,使得每个时间步的隐藏状态由当前时刻之前和之后的信息共同决定,从而更全面地捕捉序列中的相关信息。BiLSTM 单元的结构如图 2 所示。

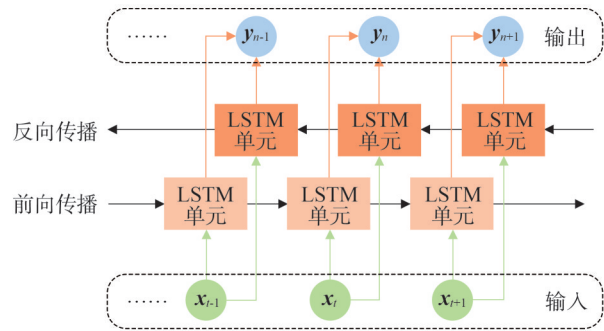


图2 BiLSTM单元

Fig.2 BiLSTM cell

1.3 TCN单元

TCN 是一种基于 CNN 的改进网络,具有独特的扩展因果卷积(dilated causal convolution, DCNN)和残差块结构,更适用于时间序列问题建模。因果卷积通过对 t 时刻及 t 时刻以前的数据进行建模来输出 t 时刻的数据。为了使输出张量与输入张量具有相同的长度,因果卷积在输入张量的左侧进行了零填充。单纯的因果卷积若要考虑更长的依赖关系,需要构建较多隐藏层。DCNN 允许输入存在间隔采样,在实现因果卷积的基础上,用较少的层获得很大的感受野。采样率由膨胀因子 d 控制。对于一个输入序列 $x=(x_1, x_2, \dots, x_t)$ 和一个卷积核 C 来说,扩展因果卷积定义为

$$F(x) = \sum_{k=1}^K C(k) x_{t-d \cdot (K-k)} \quad (8)$$

式中: K 为卷积核大小; $C(k)$ 为第 k 个卷积核。




图3 DCNN 单元
Fig.3 DCNN cell

此外,TCN 通过引入残差模块来提高网络的深度学习能力。残差模块的结构如图 4 所示。首先,输入经过一个 1×1 卷积层,并作为残差连接的一部分。同时,输入经过带有 DCNN 的卷积单元,用于扩展感受野,使网络能够捕捉更长时间跨度的历史信息。然后,对卷积结果进行权重归一化,并使用 ReLU 激活函数对输出进行非线性变换。最后,经过随机失活(Dropout)层,以减少过拟合现象并加速模型的训练过程。最终输出通过对输入进行 1×1 卷积层处理,以及输入经过两个卷积单元的输出进行逐元素相加得到。

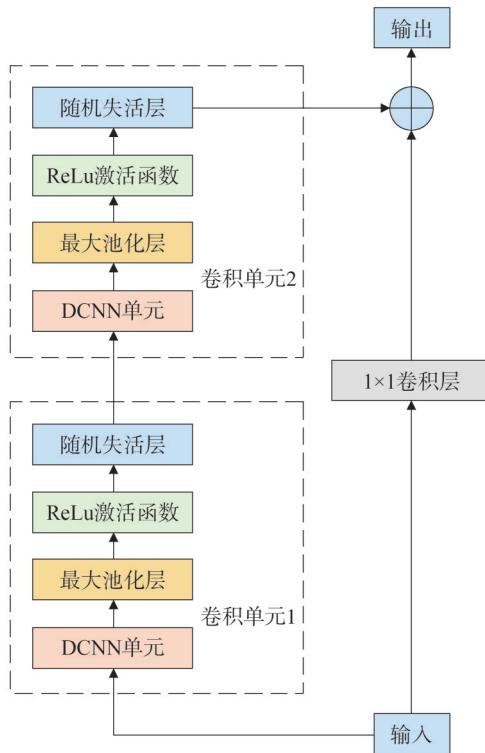


图4 TCN 网络的残差结构
Fig.4 The residual structure of TCN

1.4 总体模型构建

为了全面挖掘光伏发电历史数据中蕴含的有价值信息,并提高预测模型的准确性和计算效率,基于相关性分析技术提取了影响分布式光伏超短期功率预测的重要气象因素时间序列。随后,将这些多元时间序列与先进的神经网络模型相结合,构建了一个基于 TCN-BiLSTM 的分布式光伏发电超短期功率预测模型。模型的构建流程如图 5 所示。

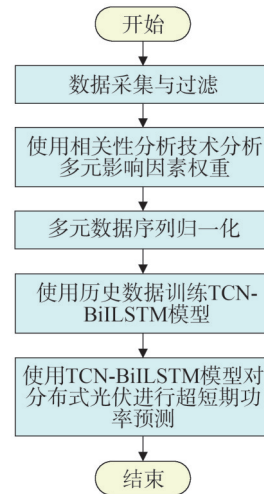


图5 本文所提方法流程
Fig.5 Flowchart of the method proposed method in this paper

2 实例验证

2.1 数据来源

本文数据来源为澳大利亚光伏功率与气象数据中心 (desert knowledge Australia solar centre, DKASC), 其中,爱丽丝泉 (Alice Springs) 拥有 38 个光伏站点,是该中心的重点区域之一。记录的数据包括历史光伏发电功率(kW)、大气温度($^{\circ}\text{C}$)、相对湿度(%)、全球水平辐射度(Wh/m^2)、散射水平辐射度(Wh/m^2)以及每日降水量(mm)等,数据记录的时间间隔为 5 min。本研究选取了 DKASC 的 No.6 Kyocera 光伏站点的数据,以验证 TCN-BiLSTM 模型的有效性和鲁棒性。

本研究进行了光伏发电输出的 1 步(5 min)、3 步(15 min)和 12 步(60 min)超短期预测。为了评估所提出模型的性能和准确性,将本文提出的模型与传统的 LSTM、BiLSTM、CNN、CNN-LSTM、TCN、

DCNN-LSTM、TCN-LSTM 以及 CNN-BiLSTM 进行了比较,分析其在单步和多步光伏功率预测中的性能表现。

2.2 仿真环境

用于实验的计算机配备了 Intel® Core™ i5-10500 CPU @ 3.10GHz 和 32 GB 内存。混合网络模型构建和学习训练使用了 PyTorch 的 v.2.0.1 版本。选择均方误差作为损失函数。使用 Adam 优化器来最小化损失函数。批次大小设置为 10。训练 epoch 数设置为 200,如果在 15 个 epoch 后损失函数没有下降,则停止模型训练过程以防止过拟合。初始学习率设置为 0.001。如果验证集损失在连续 5 个 epoch 内没有下降,则使用 PyTorch 的自适应学习率调整机制将学习率减半。

2.3 评价指标

为了验证预测效果,选择了三种广泛使用的误差指标,即均方根误差 (root mean square error, RMSE) δ_{RMSE} 、平均绝对误差 (mean absolute error, MAE) δ_{MAE} 和决定系数 (R -square, R^2)。RMSE 对异常值更为敏感,反映了预测误差的标准差,而 MAE 表示预测值与真实值之间的平均绝对误差, R^2 反映了预测值与真实值之间的拟合程度。以上指标计算公式为:

$$\delta_{\text{RMSE}} = \sqrt{\frac{1}{M} \sum_{l=1}^M (y_m(l) - y_p(l))^2} \quad (9)$$

$$\delta_{\text{MAE}} = \frac{1}{M} \sum_{l=1}^M |y_m(l) - y_p(l)| \quad (10)$$

$$R^2 = 1 - \frac{\sum_{l=1}^M (y_p(l) - y_m(l))^2}{\sum_{l=1}^M (y_p(l) - \bar{y}_m)^2} \quad (11)$$

式中: M 为样本数; $y_m(l)$ 、 $y_p(l)$ 分别为测量功率数据集与预测功率数据集第 l 个实际值和预测值; \bar{y}_m 为所有测量功率值的平均值。

2.4 结果分析

2.4.1 Spearman 相关系数分析

Spearman 相关系数的取值范围在 $[-1, 1]$ 之间。当结果为正数时,表示正相关;当结果为负数时,表示负相关。系数的绝对值越大,表明变量间的关联性越强。在实际应用中,若 Spearman 相关系数的绝对值小于 0.3,通常被认为表示变量间存在较弱或几

乎不相关的关系。图 6 展示了不同气象因素与光伏发电输出功率之间的 Spearman 相关系数热力图。从图中可以看出,全球水平辐照度、散射水平辐照度以及温度与分布式光伏发电出力呈现正相关性。特别是,全球水平辐照度与散射水平辐照度与光伏出力的正相关性较强,而温度与光伏出力之间的正相关性则相对较弱,其相关系数为 0.34。另一方面,相对湿度和每日降水量与光伏发电出力呈现负相关性,即相对湿度与降水量的增加预示着光伏出力的减少,这可能与阴雨天气条件有关。然而,相对湿度和每日降水量与光伏出力之间的负相关性较弱,相关系数分别为 -0.22 和 -0.25。




图6 不同因素与光伏输出功率之间的 Spearman 相关系数
Fig.6 The Spearman correlation coefficients between various factors and PV output power

结合 Spearman 相关系数分析结果,本文选择历史光伏发电功率、全球水平辐照度、水平散射辐照度及温度作为 TCN-BiLSTM 模型的多元时间序列融合输入数据。

2.4.2 光伏功率单步预测结果

单步光伏功率预测指的是使用滑动窗口技术,在本文中提前一步(即 5 min)进行功率预测。为了更全面地评估模型的预测性能,本文展示了不同模型在夏季和冬季条件下的预测结果。

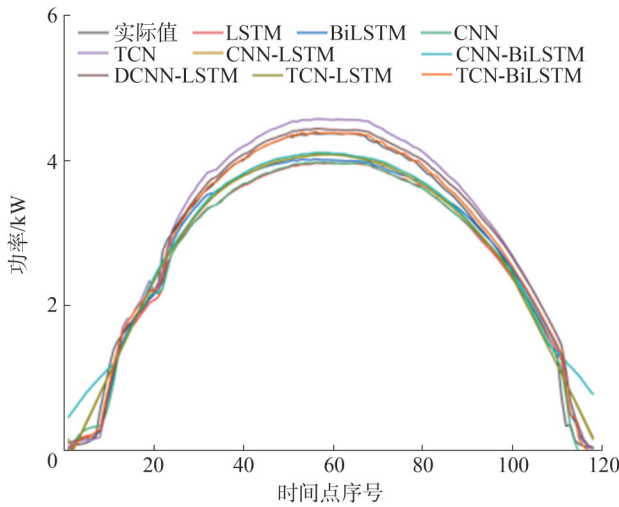
图 7 展示了夏季在晴朗和多云条件下,不同模型预测的光伏发电功率与实际测量功率的对比情况。图 8 展示了冬季在晴朗和多云条件下的相应对

比。图中横坐标时间点序号是指数据采集时间间隔,本文使用数据采集间隔为5 min。


由图7(a)可以看出,TCN和DCNN-LSTM模型的预测功率值高于实际功率,TCN-BiLSTM模型预测功率在实际功率附近上下波动,而其他模型的预测功率则普遍低于实际测量值。在所有模型中,TCN-BiLSTM模型表现出较高精度。由图7(a)可知,TCN-BiLSTM模型误差的中位值以及均值分别为0.045以及0.066,在所有模型中最小,并且,TCN-

BiLSTM模型误差的25%~75%分布更加集中,表现出较高的稳定性。在图7(b)中,所有模型均能够捕捉到功率变化的趋势,但是在功率预测值上有所不同。CNN模型的误差分布范围最广,且存在较多异常值。这表明单独使用CNN模型在应对剧烈天气变化时,其预测性能可能受限。TCN-BiLSTM模型误差的中位值是0.074,在所有模型中最小。

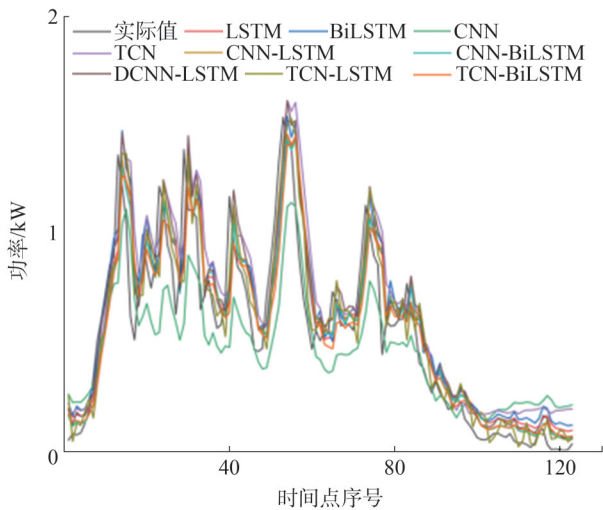
在图8(a)中,TCN与DCNN-LSTM模型的预测功率值高于实际功率;相反,LSTM与CNN模型的预测




(a)晴天光伏功率预测



(b)晴天光伏功率预测绝对误差分布



(c)阴天光伏功率预测



(d)阴天光伏功率预测绝对误差分布

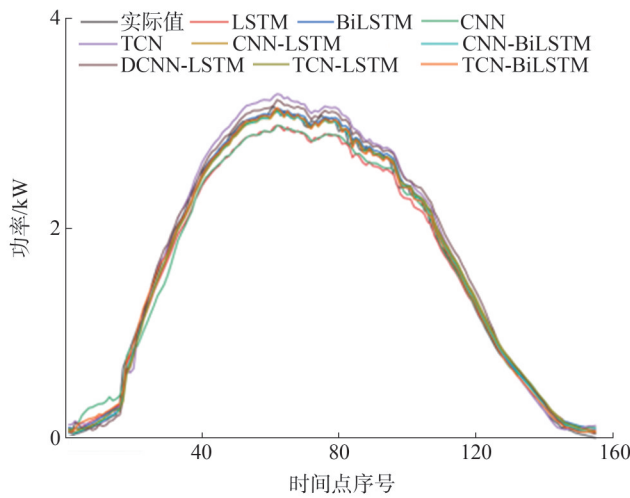
图7 夏季不同天气下所有模型光伏功率预测以及预测绝对误差分布

Fig.7 PV power prediction for all models under different summer weather conditions and the distribution of absolute prediction errors


功率值低于实际功率;其他模型的预测功率值在实际功率附近波动。在所有模型的功率误差分布图中,LSTM、CNN、TCN与DCN-LSTM模型误差的25%~75%分布更加发散,而其他模型误差的25%~75%分布则更加集中。TCN-BiLSTM模型误差的中位值以及均值分别为0.028以及0.035,在所有模型误差的中位值以及均值中最低。在图8(b)中,在多云条件下,CNN与TCN模型误差分布更为发散且误差值偏高。相较于这两种模型,其他模型的误差分

布更为集中。其中,CNN-BiLSTM模型误差的中位值为0.051,在所有模型中最小;而TCN-BiLSTM模型误差的均值为0.078,在所有模型为最小。

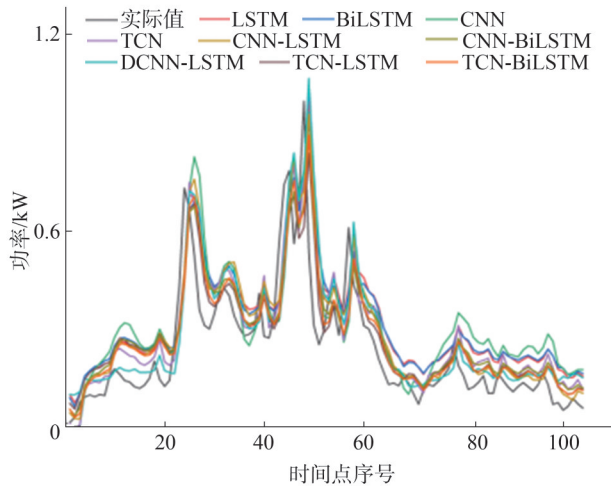
表1详细列出了所有模型在一年中各个季节的光伏功率预测性能指标。这些指标的展示旨在全面评估不同季节下,单步预测对模型性能的影响。根据表1的数据,TCN模型在春季、夏季、秋季和冬季的光伏功率预测中得到的 δ_{RMSE} 值分别为0.3269、0.4348、0.2760和0.3265。与CNN模型的相应




(a)晴天光伏功率预测



(b)晴天光伏功率预测绝对误差分布



(c)阴天光伏功率预测



(d)阴天光伏功率预测绝对误差分布

图8 冬季不同天气下所有模型光伏功率预测以及预测绝对误差分布

Fig.8 PV power prediction for all models under different winter weather conditions and the distribution of absolute prediction errors

表1 不同季节下所有模型光伏功率预测误差
Table 1 Predictive metrics of PV power for all models in different seasons

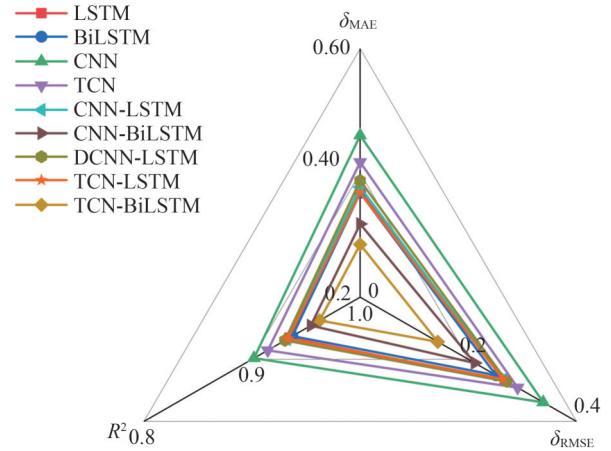
季节	指标	LSTM	BiLSTM	CNN	TCN	CNN-LSTM	CNN-BiLSTM	DCNN-LSTM	TCN-LSTM	TCN-BiLSTM
春天	δ_{RMSE}	0.322 0	0.295 9	0.344 5	0.326 9	0.297 5	0.284 2	0.305 8	0.292 1	0.266 7
	δ_{MAE}	0.221 8	0.178 6	0.239 3	0.210 8	0.182 5	0.146 3	0.188 7	0.169 4	0.121 3
	R^2	0.949 5	0.957 4	0.942 2	0.948 0	0.950 5	0.960 7	0.951 2	0.957 6	0.965 4
夏天	δ_{RMSE}	0.427 3	0.414 5	0.453 4	0.434 8	0.423 1	0.409 5	0.417 8	0.411 3	0.377 0
	δ_{MAE}	0.286 7	0.259 1	0.308 0	0.260 6	0.281 7	0.258 2	0.270 3	0.259 7	0.173 8
	R^2	0.926 7	0.931 0	0.917 5	0.924 1	0.927 5	0.932 0	0.922 8	0.930 1	0.942 9
秋天	δ_{RMSE}	0.250 1	0.245 8	0.270 3	0.276 0	0.241 7	0.237 1	0.241 3	0.240 2	0.239 3
	δ_{MAE}	0.144 6	0.123 2	0.166 8	0.153 7	0.124 1	0.103 8	0.121 9	0.117 8	0.112 3
	R^2	0.941 5	0.943 5	0.931 6	0.928 7	0.943 2	0.951 5	0.944 7	0.941 8	0.946 4
冬天	δ_{RMSE}	0.340 5	0.309 9	0.348 1	0.326 5	0.318 7	0.275 3	0.336 8	0.328 9	0.256 1
	δ_{MAE}	0.253 5	0.208 4	0.258 4	0.222 7	0.210 3	0.167 8	0.241 3	0.220 5	0.114 7
	R^2	0.948 2	0.957 1	0.945 9	0.952 4	0.953 2	0.965 4	0.949 5	0.951 4	0.970 7

δ_{RMSE} 值 0.344 5、0.453 4、0.270 3 和 0.348 1 相比,TCN 模型的预测精度分别提升了 5.4%、4.3%、2.1% 和 6.2%。这一结果表明,TCN 模型作为 CNN 模型的改进版本,展现出更强的时间序列预测能力。在所有的季节中,CNN-BiLSTM 模型在秋季的光伏功率预测中得到的 δ_{RMSE} 值为 0.237 1,在所有模型中误差最低。此外,TCN-BiLSTM 模型在春季、夏季和冬季的光伏功率预测中得到的 δ_{RMSE} 值分别为 0.266 7、0.377 0 和 0.256 1,这些值在所有比较的模型中均为最低,表明了 TCN-BiLSTM 模型优良的预测性能。

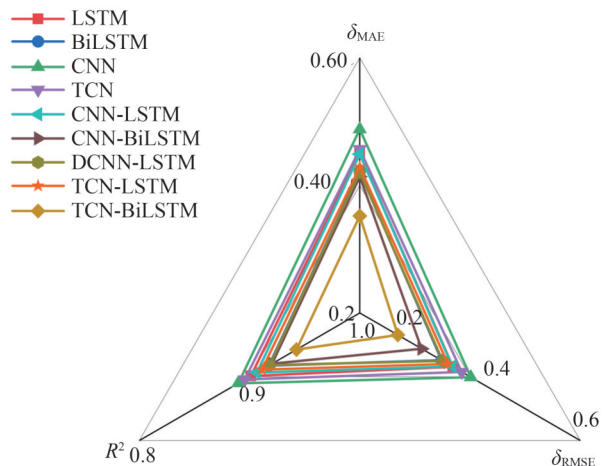
2.4.3 光伏功率多步预测结果

多步预测是指一次性预测得到一系列值,而非单个值。本节对光伏功率进行了 3 步预测和 12 步预测,即分别预测未来 15 min(5 min×3)和未来 1 h(5 min×12)的功率。

图 9 展示了在一年内所有预测值中,第 1 个、第 2 个和第 3 个时间步的预测误差对比。在所有预测时间步中,CNN 模型在雷达图中面积最大,代表该模型的功率预测误差最大,其次在雷达图中面积最大的模型为 TCN 模型。与这些模型相比,TCN-BiLSTM 模型在雷达图中面积最小,预测精度较高。另外,CNN-BiLSTM 模型在雷达图中的面积为次小,表明其在光伏发电功率 3 步预测中的良好性能。其



(a)不同模型第1个时间步预测误差



(b)不同模型第2个时间步预测误差

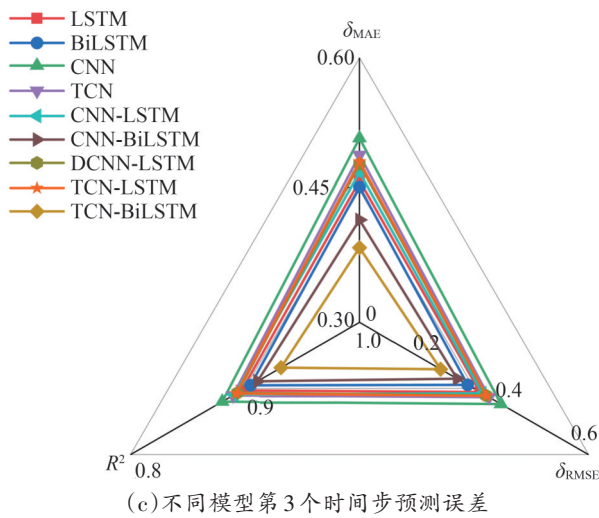


图9 不同模型不同时间步预测误差对比

Fig.9 Prediction errors for the different time step for various models

中, CNN-BiLSTM 模型在不同时间步 R^2 值分别为 0.954 3、0.920 5 与 0.910 9, TCN-BiLSTM 模型不同预测时间步的 R^2 值分别为 0.962 4、0.942 6 和 0.931 5, 与 CNN-BiLSTM 模型相应时间步的 R^2 值相比, 分别提升了 0.8%、2.3% 和 2.2%。此外, 随着预测时间步的增加, 所有功率预测模型的预测精度均不同程度下降。这些结果表明, 在多步预测中, 融合时序卷积网络和双向长短期记忆网络的 TCN-BiLSTM 模型在各个时间步均展现出较高的预测精度, 且相较于其他模

型, 其预测精度的下降幅度较小。

表 2 列出了不同时间步所有预测结果的综合误差值。CNN 模型在夏季的精度最低, 其预测功率 R^2 值为 0.8547; CNN-BiLSTM 与 TCN-BiLSTM 模型在夏季预测功率的 R^2 分别为 0.900 8 与 0.923 1, 预测精度分别为次高与最高。类似的, CNN 模型在冬季预测功率的 R^2 为 0.897 1, 精度在所有模型中最低, 而 TCN-BiLSTM 模型在冬季预测功率的 R^2 为 0.958 2, 精度在所有模型中最高。此外, 在其他季节, TCN-BiLSTM 与 CNN-BiLSTM 模型的误差值都较小。

图 10 分别展示了在光伏出力维持稳定状态和剧烈变化状态下, 未来 12 个时间步(每个时间步为 5 min)的功率预测值与实际功率值的对比分析。当光伏出力维持稳定时, CNN 模型的功率预测值下降幅度最为显著, TCN 模型的功率预测值有上升趋势, CNN-LSTM 模型的功率预测值变化呈现水平波动状, 而其他模型均以较缓和的趋势下降。所有模型的功率预测精度随着预测时间步的增加而逐渐降低, 即随着预测时间的延长, 所有模型的功率预测值与实际值的差越来越大。在第一个预测时间步中, TCN-BiLSTM 模型表现出最小的误差值, 使得其功率预测值与实际观测值的吻合度最高。

表2 预测步长为3(15 min)时,不同季节下所有模型功率预测误差

Table 2 Predictive metrics of PV power for all models in different seasons when the prediction step is 3(15 min)

季节	指标	LSTM	BiLSTM	CNN	TCN	CNN-LSTM	CNN-BiLSTM	DCNN-LSTM	TCN-LSTM	TCN-BiLSTM
春天	δ_{RMSE}	0.413 8	0.386 8	0.451 1	0.393 7	0.388 1	0.354 5	0.401 7	0.371 3	0.321 7
	δ_{MAE}	0.285 8	0.266 1	0.329 8	0.248 3	0.268 9	0.205 4	0.271 2	0.220 8	0.162 9
	R^2	0.916 7	0.927 2	0.901 0	0.924 6	0.921 2	0.940 3	0.917 5	0.938 7	0.949 7
夏天	δ_{RMSE}	0.549 8	0.509 3	0.601 6	0.518 0	0.535 5	0.493 6	0.523 1	0.505 6	0.437 5
	δ_{MAE}	0.383 4	0.344 8	0.442 3	0.334 6	0.379 3	0.311 8	0.352 3	0.328 7	0.240 3
	R^2	0.878 6	0.895 9	0.854 7	0.892 3	0.878 9	0.900 8	0.887 2	0.898 6	0.923 1
秋天	δ_{RMSE}	0.327 7	0.353 8	0.386 6	0.340 1	0.319 5	0.320 6	0.340 5	0.357 5	0.286 7
	δ_{MAE}	0.206 2	0.242 3	0.277 7	0.210 7	0.193 3	0.195 3	0.214 5	0.243 9	0.159 7
	R^2	0.899 5	0.882 9	0.860 1	0.891 7	0.903 2	0.901 5	0.891 2	0.879 8	0.923 1
冬天	δ_{RMSE}	0.441 7	0.386 9	0.480 0	0.384 3	0.415 4	0.345 9	0.368 3	0.458 5	0.305 9
	δ_{MAE}	0.340 9	0.285 2	0.364 4	0.276 6	0.313 7	0.218 1	0.252 8	0.352 5	0.160 0
	R^2	0.912 9	0.933 2	0.897 1	0.934 0	0.923 1	0.946 3	0.937 6	0.915 8	0.958 2

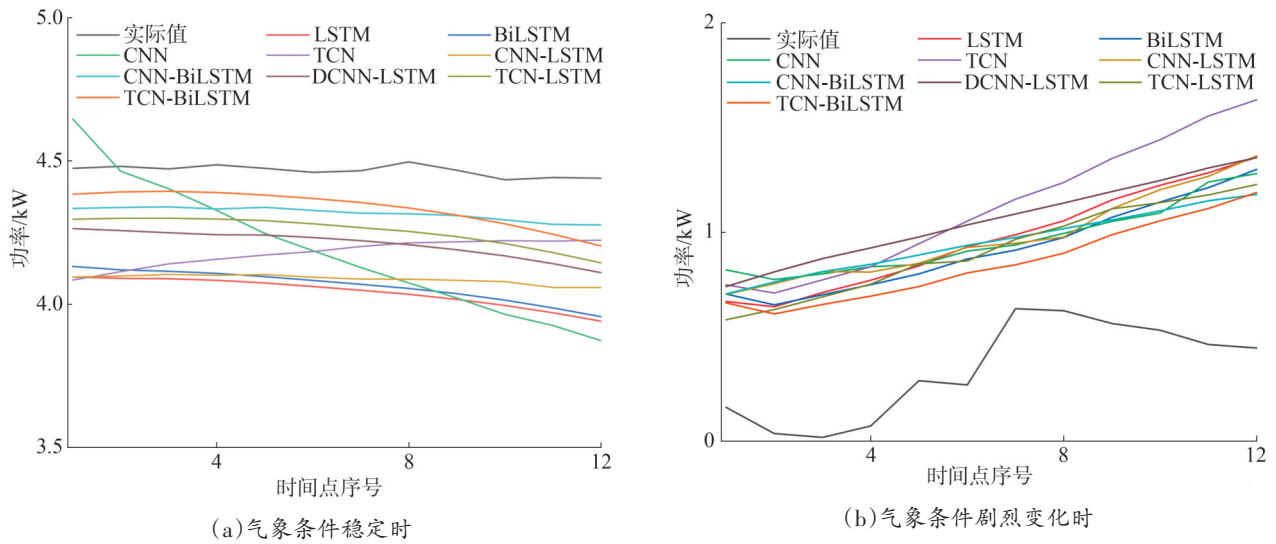


图 10 不同气象条件下未来 12 个时间步功率预测值与实际功率值

Fig.10 Predicted and actual power values under different weather conditions for the next 12 time steps

在光伏出力剧烈变化时,所有模型预测值均大于实测值,其中 TCN-BiLSTM 模型误差较小,但由于缺乏实时气象数据输入,所有模型都难以准确捕捉实际功率的变化趋势,所有模型的预测误差随预测时间步的增加而逐渐增大。这表明短期光伏出力的快速变化对模型的连续预测能力构成了挑战,尤其是在不稳定天气条件下。

表 3 汇总了所有模型在进行 12 个时间步预测时的综合误差值。与单步和三步预测相比,当预测步长增至 12 步时,模型的预测精度显著下降。这一现象可归因于预测时间跨度的延长,导致预测曲线与实际曲线之间的偏差增大。尽管如此,TCN-BiLSTM 模型在不同季节的预测误差均保持在最低水平,展现出其在多步预测任务中的优越性能。

表 3 预测步长为 12(60 min)时,不同季节下所有模型功率预测误差

Table 3 Predictive metrics of PV power for all models in different seasons when the prediction step is 12(60 min)

季节	指标	LSTM	BiLSTM	CNN	TCN	CNN-LSTM	CNN-BiLSTM	DCNN-LSTM	TCN-LSTM	TCN- BiLSTM
春天	δ_{RMSE}	0.448 4	0.449 1	0.500 7	0.496 5	0.449 7	0.422 1	0.465 3	0.437 9	0.408 6
	δ_{MAE}	0.301 1	0.295 9	0.331 1	0.335 8	0.301 8	0.267 8	0.315 4	0.271 6	0.230 4
	R^2	0.902 2	0.901 9	0.878 0	0.880 0	0.901 3	0.907 8	0.895 2	0.903 7	0.918 8
夏天	δ_{RMSE}	0.494 7	0.491 9	0.552 6	0.537 4	0.508 2	0.453 5	0.490 7	0.497 9	0.425 4
	δ_{MAE}	0.377 4	0.371 5	0.376 3	0.369 2	0.381 7	0.312 1	0.368 9	0.395 3	0.264 6
	R^2	0.890 7	0.891 9	0.863 6	0.871 0	0.896 1	0.909 3	0.892 7	0.890 2	0.919 2
秋天	δ_{RMSE}	0.409 7	0.415 5	0.437 3	0.427 1	0.421 8	0.413 2	0.439 5	0.425 7	0.375 6
	δ_{MAE}	0.271 6	0.275 8	0.304 2	0.284 4	0.285 3	0.277 9	0.302 1	0.291 6	0.240 5
	R^2	0.843 0	0.838 5	0.821 1	0.829 4	0.863 4	0.850 2	0.835 7	0.848 1	0.868 0
冬天	δ_{RMSE}	0.582 7	0.586 7	0.612 1	0.598 1	0.595 2	0.601 7	0.578 5	0.589 1	0.543 2
	δ_{MAE}	0.411 8	0.410 8	0.409 5	0.412 0	0.415 3	0.408 9	0.399 8	0.412 3	0.333 1
	R^2	0.863 6	0.861 7	0.849 5	0.856 3	0.872 1	0.857 3	0.842 7	0.835 8	0.881 5

综上所述,TCN-BiLSTM模型在短期预测中表现出较高的预测精度,但在长期预测和复杂气象条件下,TCN-BiLSTM模型与其他模型一样,预测性能有所下降。

3 结束语

为了提高分布式光伏发电功率超短期预测精度,提出了一种融合多元时间序列与TCN-BiLSTM的分布式光伏功率超短期预测方法,采用TCN-BiLSTM网络从多元气象数据及光伏功率历史数据中获取多维数据时序特征,构建多元时间序列输入数据与输出功率的映射关系,实现分布式光伏超短期功率预测。通过与其他传统预测方法的对比,验证了该方法在单步和多步预测中的准确性。在单步预测(5 min)中,TCN-BiLSTM模型展现了较高的预测精度,误差分布范围较小且稳定性较强。然而,在多步预测中,随着预测步数的增加,所有模型的预测精度均有所下降,且当预测步数达到12(60 min)时,模型对未来功率细节的预测能力明显减弱。总体而言,TCN-BiLSTM模型在不同季节下的预测误差均保持在最小值。所提方法允许每个站点根据其自身的历史数据和环境条件进行预测,更加灵活、适应性强。此外,通过进一步增加其他全局性数据输入,也可用于集中式光伏预测。

参考文献

- [1] 战文华,车建峰,王勃,等.基于网格化数值天气预报的区域光伏发电多输出功率预测方法[J].中国电力,2024,57(3):144-151.
ZHAN Wenhua, CHE Jianfeng, WANG Bo, et al. A grid-based numerical weather prediction method for multi-output prediction of regional photovoltaic power [J]. Electric Power, 2024, 57(3): 144-151.
- [2] 张松,肖小兵,何金宇,等.基于PEEC-MTL混合方法的光伏系统建模及电磁瞬态计算分析[J].电力大数据,2024,27(11):21-31.
ZHANG Song, XIAO Xiaobing, HE Jinyu, et al. Modeling and electromagnetic transient analysis of photovoltaic system based on PEEC-MTL hybrid method [J]. Power Systems and Big Data, 2024, 27(11): 21-31.
- [3] 于丹文,李山,刘航航,等.基于3DCNN与CLSTM混合模型的短期光伏功率预测[J].山东电力技术,2024,51(7):10-18.
YU Danwen, LI Shan, LIU Hanghang, et al. Short-term photovoltaic power prediction based on 3DCNN and CLSTM hybrid model [J]. Shandong Electric Power, 2024, 51(7): 10-18.
- [4] 王海燕,刘佳康,邓亚平.基于预估-校正综合BP神经网络的短期光伏功率预测[J].智慧电力,2023,51(3):46-52.
WANG Haiyan, LIU Jiakang, DENG Yaping. Short-term photovoltaic power forecasting based on predict-correct combination BP neural network [J]. Smart Power, 2023, 51(3): 46-52.
- [5] 黄莉,甘恒玉,刘兴举,等.基于Transformer编码器的超短期光伏发电功率预测[J].智慧电力,2024,52(5):16-22.
HUANG Li, GAN Hengyu, LIU Xingju, et al. Ultra-short-term photovoltaic power generation prediction based on transformer encoder [J]. Smart Power, 2024, 52(5): 16-22.
- [6] 刘建鑫.光伏发电运行失配机理及特性分析[J].山东电力技术,2022,49(1):53-59.
LIU Jianxin. Analysis on operation mismatch mechanism and characteristics of photovoltaic power generation [J]. Shandong Electric Power, 2022, 49(1): 53-59.
- [7] 李翰章,冯江涛,王鹏程,等.基于TDE-SO-AWM-GRU的光伏发电功率预测模型[J].中国电力,2024,57(12):41-49.
LI Hanzhang, FENG Jiangtao, WANG Pengcheng, et al. Photovoltaic power prediction model based on TDE-SO-AWM-GRU [J]. Electric Power, 2024, 57(12): 41-49.
- [8] 张晓英,段赛赛,吴丽珍.基于跟踪偏差角和改进迭代误差修正的光伏功率预测优化策略[J].智慧电力,2023,51(4):84-91.
ZHANG Xiaoying, DUAN Saisai, WU Lizhen. Optimization strategy of photovoltaic power prediction based on tracking deviation angle & improved iterative error correction [J]. Smart Power, 2023, 51(4): 84-91.
- [9] 史加荣,殷诏.基于GRU-BLS的超短期光伏发电功率预测[J].智慧电力,2023,51(9):38-45.
SHI Jiarong, YIN Zhao. Prediction of ultra short term photovoltaic power generation based on GRU-BLS [J]. Smart Power, 2023, 51(9): 38-45.
- [10] 陈璨,苏紫诺,马原,等.基于分层关联性建模的分布式光伏功率超短期概率预测[J].中国电力,2024,57(12):50-59.
CHEN Can, SU Zinuo, MA Yuan, et al. Ultra-short-term probabilistic forecasting of distributed photovoltaic power generation based on hierarchical correlation modeling [J]. Electric Power, 2024, 57(12): 50-59.
- [11] ZHANG Y P, SU J L, ZHANG C, et al. Performance estimation of photovoltaic module under partial shading based on explicit analytical model [J]. Solar Energy, 2021, 224: 327-340.
- [12] 杨鹏伟,赵丽萍,陈军法,等.基于相似时段匹配与Transformer网络建模的分布式光伏超短期功率预测方法[J].中国电力,2024,57(12):60-70.
YANG Pengwei, ZHAO Liping, CHEN Junfa, et al. Distributed photovoltaic ultra-short-term power forecasting method based on

- temporal analog matching approach and transformer network modeling[J].Electric Power,2024,57(12):60-70.
- [13] SOLIMAN M A, HASANIEN H M, ALKUHAAYLI A. Marine predators algorithm for parameters identification of triple-diode photovoltaic models[J].IEEE Access,2020,8:155832-155842.
- [14] 何东坡,万超,杨帆,等.基于机器学习的光伏功率预测模拟方法研究[J].中低纬山地气象,2023,47(6):66-70.
HE Dongpo, WAN Chao, YANG Fan, et al. Research on simulation method for photovoltaic power prediction based on machine learning [J]. Mid-low Latitude Mountain Meteorology, 2023, 47 (6):66-70.
- [15] 王哲,张嘉英,张彦振.基于机器学习的光伏输出功率预测方法研究[J].计算机仿真,2020,37(4):71-75.
WANG Zhe, ZHANG Jiaying, ZHANG Yanzhen. Research on photovoltaic output power prediction method based on machine learning[J].Computer Simulation,2020,37(4):71-75.
- [16] 崔杨,陈正洪,许沛华.基于机器学习的集群式风光一体短期功率预测技术[J].中国电力,2020,53(3):1-7.
CUI Yang, CHEN Zhenghong, XU Peihua. Short-term power prediction for wind farm and solar plant clusters based on machine learning method[J].Electric Power,2020,53(3):1-7.
- [17] AGGA A, ABOU A, LABBADI M, et al. Convolutional neural network (CNN) extended architectures for photovoltaic power production forecasting [C]//2021 9th International Conference on Smart Grid and Clean Energy Technologies (ICSGCE). IEEE, 2021:104-108.
- [18] 张晋华,黄远为,冯源.基于云模型-LSTM的光伏功率中期预测[J].湖北电力,2021,45(2):49-55.
ZHANG Jinhua, HUANG Yuanwei, FENG Yuan. Midterm prediction of PV power based on cloud model-LSTM [J]. Hubei Electric Power, 2021, 45(2):49-55.
- [19] 李丰君,王磊,赵健,等.基于天气融合和LSTM网络的分布式光伏短期功率预测方法[J].中国电力,2022,55(11):149-154.
LI Fengjun, WANG Lei, ZHAO Jian, et al. Research on distributed photovoltaic short-term power prediction method based on weather fusion and LSTM-net[J].Electric Power,2022,55(11):149-154.
- [20] HUANG Y G, ZHOU M G, ZHANG S S, et al. Research on PV power forecasting based on wavelet decomposition and temporal convolutional networks [C] // 2021 IEEE 4th International Electrical and Energy Conference (CIEEC).IEEE,2021:1-6.
- [21] 姜景芮,苗田,彭婧,等.基于深度学习算法的光伏发电功率预测方法研究[J].自动化应用,2023(13):102-104.
JIANG Jingrui, MIAO Tian, PENG Jing, et al. Research on photovoltaic power prediction method based on deep learning algorithm[J].Automation Application,2023(13):102-104.
- [22] 杨锡运,马文兵,彭琰,等.基于组合神经网络的分布式光伏超短期功率预测方法[J].热力发电,2023,52(8):162-171.
YANG Xiyun, MA Wenbing, PENG Yan, et al. Distributed photovoltaic ultra-short-term power prediction method based on combined neural network [J]. Thermal Power Generation, 2023, 52 (8):162-171.
- [23] 宋绍剑,李博涵.基于LSTM网络的光伏发电功率短期预测方法的研究[J].可再生能源,2021,39(5):594-602.
SONG Shaojian, LI Bohan. Short-term forecasting method of photovoltaic power based on LSTM [J]. Renewable Energy Resources, 2021, 39(5):594-602.
- [24] 李嘉宇,王东风,张妍.基于灰色关联分析的短期风速预测方法[J].山东电力技术,2020,47(3):15-19.
LI Jiayu, WANG Dongfeng, ZHANG Yan. Short-term wind speed prediction method based on grey relation analysis [J]. Shandong Electric Power, 2020, 47(3):15-19.
- [25] 韩小地,郭家兴,钱康,等.基于双分支特征集成LSTM的非侵入式负荷分解研究[J].山东电力技术,2024,51(10):31-43.
HAN Xiaodi, GUO Jiaxing, QIAN Kang, et al. Research on non-intrusive load disaggregation with dual-branch feature integration LSTM[J].Shandong Electric Power,2024,51(10):31-43.

收稿日期:2024-11-07

修回日期:2025-04-29

作者简介:

高任龙(1988),男,硕士,高级工程师,主要研究方向为新能源并网及发电运行及消纳管理研究;

李峰(1982),男,硕士,高级工程师,主要研究方向为新能源并网调度运行及新能源功率预测研究;

马天东(1987),男,高级工程师,主要研究方向为电网调度运行研究;

吴骥(1992),通信作者(wuji419520373@126.com),男,硕士,工程师,主要研究方向为新能源功率预测技术。

(责任编辑 郑天茹)

面向光储集群接入的有源配电网两阶段交易机制设计

徐嘉豪¹, 徐俊俊^{2*}, 王福晶³

(1. 国网江苏省电力有限公司泰州供电分公司, 江苏 泰州 225300;

2. 南京邮电大学自动化学院/人工智能学院, 江苏 南京 210023; 3. 华能山东发电有限公司, 山东 济南 250014)

摘要:针对分布式光伏规模化开发与集中并网场景, 提出一个面向光储集群接入的有源配电网交易机制设计。首先, 基于K-means算法综合考虑空间分布集中度、多机出力相似度等因素, 同时结合非参数化思想进行分布式光伏层次聚类分析, 实现分布式光伏资源聚合; 其次, 基于分布式光伏聚类分析的结果进行光储集群的配置; 然后, 通过分析电网和分布式光伏用户之间的交互关系, 基于两步制电价设计面向下层用户和上层电网间的配电网交易机制。最后, 通过算例进行仿真分析, 采用改进的K-means算法进行分布式光伏层次聚类分析并以此进行光储集群的配置, 结合聚类分析的结果基于两步制(两阶段)电价设计一个交易机制来开展面向分布式光伏规模化开发的层次聚类分析方法和聚合商运营模式的研究, 验证了所提方法能够最大化聚合商收益, 降低用户侧分布式光伏机会成本和支付费用, 保证用户参与调峰辅助服务积极性, 有效提升系统的整体效率和稳定性。

关键词: 分布式光伏; 有源配电网; 集群划分; 交易机制

中图分类号: TM72; TP393

文献标志码: A

文章编号: 1007-9904(2025)12-0050-11

Design of Two-stage Trading Mechanism for Active Distribution Network Integrating Photovoltaic and Storage Clusters

XU Jiahao¹, XU Junjun^{2*}, WANG Fuming³

(1.State Grid Taizhou Power Supply Company, Taizhou 225300, China; 2.College of Automation & College of Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing 210023, China;

3.Huaneng Shandong Power Generation Co., Ltd., Jinan 250014, China)

Abstract: A trading mechanism design for the integration of photovoltaic (PV) and storage clusters in active distribution network is proposed, aiming to facilitate the large-scale development of distributed PV and centralized grid-connection scenarios. The design, based on the K-means algorithm, comprehensively takes into account factors such as spatial distribution concentration and multi-machine output similarity. Additionally, hierarchical cluster analysis of distributed PV combined with non-parametric ideas is conducted to aggregate distributed PV resources. Based on the results of the distributed PV clustering analysis, the configuration of the PV-storage clusters is carried out. By analysing the interaction between the power grid and distributed PV users, a distribution network trading mechanism between lower-level users and the upper-level grid is designed based on a two-stage electricity pricing model. Through the simulation analysis of numerical examples, the enhanced K-means algorithm is employed for hierarchical clustering analysis of distributed PV, which is then applied to configure PV-storage clusters. Leveraging the outcomes of this clustering analysis, a trading mechanism based on a two-stage electricity pricing model is developed to investigate the hierarchical clustering analysis methodology and the operational models of aggregators in the context of large-scale distributed PV development. The proposed approach is validated to maximize aggregator revenues, reduce user-side distributed PV opportunity costs and payments, ensure users' active engagement in ancillary peak regulation services, and effectively enhance the overall efficiency and stability of the system.

Keywords: distributed photovoltaic; active distribution network; cluster partitioning; trading mechanism

0 引言

随着“双碳”建设任务的进一步推进,我国正加

速推进以风光为主的可再生能源并网调控与运营建设,以实现能源低碳化清洁化转型。但分布式光伏具有较强的波动性与不确定性,给电力系统带来许多问题并提高了系统的复杂性^[1-4],如何在分布式光伏发电的剧烈波动时,保持电力交易机制的稳定性、

基金项目:国家自然科学基金项目(52107101)。
National Natural Science Foundation of China(52107101)。

合理性与灵活性,是当前需要解决的关键问题之一^[5-9]。

分布式光伏电网中配有相应的储能系统来容纳多余的电能,同时在供电紧张时储能系统将重新进入电网以稳定电力供应。分布式资源应合理利用并最大化发挥其潜能,在合理预测的基础上实现分布式发电的优化,文献[10]提出一个基于改进的K-means++算法来对历史光伏数据进行聚合分析从而建立光储选址定容多目标模型,能够准确刻画光伏系统的不确定性。关于分布式发电的优化,也有如文献[11]所分析的多目标优化分布式发电规划的先进模型和优化方法及文献[12]所提出的一种考虑目标评价指标的多能源存储和风光系统容量的双层优化配置方法。传统电网是为集中式发电设计的,对集中和稳定的电源管理有较好的适应性。在电网边缘区域,分布式光伏的规模化应用增加了电网的管理难度,其中也包含储能的相关规划即单个储能装置以及集群配电网的规划。对于单个储能装置来说,文献[13]通过同时考虑用户侧储能的经济性与电网系统各部分的经济因素给出一个储能装置的充放电方案。而针对集群配电网的规划,文献[14]提出一种针对5G基站可调度潜力与配电网集群划分的储能规划方法,现有方法在描述分布式光伏的波动性与随机性时缺乏对光伏资源空间分布集中度和出力相似度的综合分析,难以准确刻画光伏系统的不确定性。

合理的交易机制设计有利于提升配电网的运行效率、市场活力以及可靠性,提高市场活力不只要保证聚合商的利益还得保证用户参与辅助服务的积极性,为此文献[15]提出了一种以激励需求响应为基础并考虑用户行为因素的调峰机制,可有效减少用电高峰期电力系统负荷,引导用户自主调整用电习惯、错峰用电,从而保证电力系统稳定性。文献[16]通过引入一个新的合同理论框架,开发了一个具有激励机制的方案,除此以外,文献[17]还比较了批发定价策略和两部关税在链对链竞争中的表现。同时由于当今社会对公民个人隐私的关注不断提高,相关机制设计也开始对其进行关注,比如文献[18]设计了一个考虑隐私保护和去中心化的分布式能源交易模式,其拥有良好的算法稳定

性和收敛性。当然随着分布式发电的快速增长,电力交易规模也在迅速增长,为此文献[19]建立了一个基于电力交易智能合约的分布式电力交易机制,既满足大规模电力交易需求,又避免电力交易过程中存在的诸多问题。除此以外,随着新能源的不断普及,电力系统也在逐渐做出交易机制的调整,比如就园区光伏储能方面,文献[20]提出共享储能充放电功率及用户与电网交互功率等日前优化策略;而火电机组优化方面,文献[21]通过构建电力系统低碳调度模型来降低系统碳排放;在如今发展迅速且对电网影响最大的电动汽车方面,文献[22]提出了EV聚合商参与多品种市场的多阶段运营策略,以实现聚合商的运营收益最大化。

基于上述研究,针对分布式电源自身光储集群划分及配电网交易机制制定难等问题,提出一种面向光储集群接入的有源配电网交易机制设计。首先,采用改进的K-means算法在综合考虑空间分布集中度和出力特性一致性的基础上,形成具备高度聚集和输出一致性的聚合商。其次,基于上述聚类分析的结果进行光储集群的配置,在确保聚合商保障电网稳定运行的同时,通过设计合理的业务交互模式和激励机制,提升用户参与辅助服务的积极性,最终实现收益最大化。

1 基于K-means算法的分布式光伏系统集群划分

由于受到各种自然因素的影响,光伏发电具有波动性与随机性,科学地描述光伏电站的出力特性,以提高线路末端储能配置的准确性与合理性^[11]。针对分布式光伏规模化开发与集中并网场景,提出分布式光伏层次聚类分析方法,实现空间区域分布集中、出力特性一致的分布式光伏资源集群划分。

首先,引入K-means算法对电网进行集群划分,通过考虑光伏系统的空间分布特点、光伏集中度和光伏系统输出等因素,实现分布式光伏系统在空间上的聚类,如图1所示,具体而言,K-means算法在基于光伏系统输出的标准差并以此方法量化了输出的波动性,从而评估系统的稳定性。

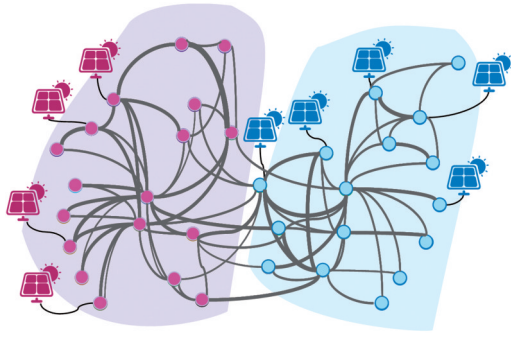


图1 分布式光伏空间聚类
Fig.1 Distributed photovoltaic spatial clustering

在聚类的过程中引入了光伏出力的相似度。通过计算不同光伏节点在不同时间点的出力特性曲线相似度,可从日平均光伏出力、日光伏出力波动率和日光伏出力分布偏度等聚合指标进行计算与归一化,从而将出力特性相近的光伏系统聚合在同一簇内。这种方式可以确保聚类内光伏系统在发电特性上的一致性,有助于简化并网后的调度管理,降低系统负担。集群划分流程如图2所示,算法中 N_c 为预期集群划分数量。

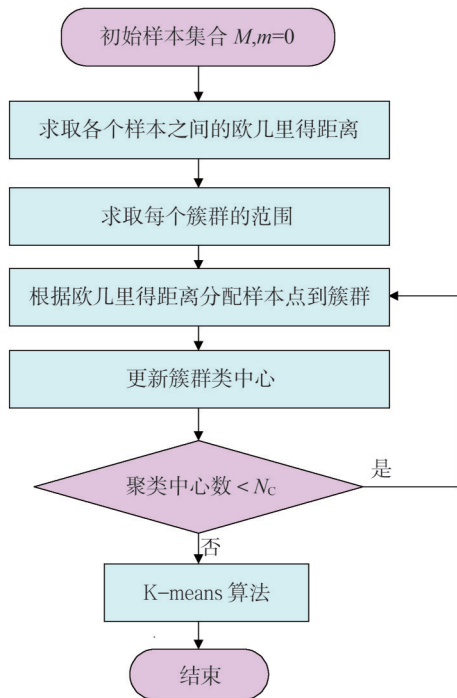


图2 算法流程
Fig.2 Algorithm flow

2 考虑运营机制的光储集群配置

2.1 光储集群系统物理建模

通过配置储能系统,可以实现对可再生能源输出功率的有效调节,减少系统对外部能源的依赖^[13]。当分布式光伏进入极高比例渗透阶段时,配电网电压越限的问题会更加突出^[23-24]。可以将储能系统直接配置在光伏发电站附近,从而实时存储多余的光伏发电,减少因光照变化带来的发电波动,确保在高峰负荷阶段提供稳定电力。

因此,在集群相关储能系统的模型中要考虑储能系统自身的参数,如式(1)所示。

$$\begin{cases} E'_{ESS,k} = E'_{ESS,k} + \frac{\Delta t \cdot P'_{ESS,k}}{\eta_{EES}}, P'_{ESS,k} < 0 \\ E'_{ESS,k} = E'_{ESS,k} + \Delta t \cdot P'_{ESS,k}, P'_{ESS,k} > 0 \\ E^{\min}_{ESS,k} \leq E'_{ESS,k} \leq E^{\max}_{ESS,k} \\ \sum_{t=1}^{t_0} E_{ESS,k}(t) = 0 \\ E^{\text{install}}_{ESS,k} \geq E^{\max}_{ESS,k} - E^{\min}_{ESS,k} \\ S'_{ESS,k} = \frac{E'_{ESS,k}}{E^{\text{install}}_{ESS,k}} \end{cases} \quad (1)$$

式中: $E'_{ESS,k}$ 为集群 k 中能量存储系统在 t 时刻的容量, $k = 1, 2, \dots, N_c$; $E'_{ESS,k}$ 为集群 k 中能量存储系统在 $t - \Delta t$ 时刻的容量, Δt 为优化的时间间隔,常取为 1 h; $P'_{ESS,k}$ 为集群 k 中能量存储系统在 t 时刻的输出功率; $E^{\min}_{ESS,k}$ 为集群 k 中能量存储系统的最小容量; $E^{\max}_{ESS,k}$ 为集群 k 中能量存储系统的最大容量; η_{EES} 为能量存储系统的充放电转换效率; t_0 为上次调度指令的时间; $S'_{ESS,k}$ 为集群 k 中能量存储系统在 t 时刻的荷电状态; $E^{\text{install}}_{ESS,k}$ 为能量存储系统的装机容量。

2.2 光储集群配置目标函数

将储能作为投资主体,通过优化调度,为用户提供电量削减、需量削减等服务,满足用户灵活。用电及经济性需求分布式光伏和储能系统还要考量建设投资成本、运维成本、峰谷套利收益以及基本电费降低收益^[11],并以此构建其经济模型。

储能系统的投资成本模型如式(2)所示。

$$\begin{aligned} C_{\text{inv},k} = & \frac{\mu_k^{\text{pv}} (1 + \mu_k^{\text{pv}})^{y^{\text{pv}}}}{(1 + \mu_k^{\text{pv}})^{y^{\text{pv}}} - 1} \eta_{\text{inv},k}^{\text{pv}} E_{\text{inv},k}^{\text{pv}} + \\ & \frac{\mu_k^{\text{ESB}} (1 + \mu_k^{\text{ESB}})^{y^{\text{ESB}}}}{(1 + \mu_k^{\text{ESB}})^{y^{\text{ESB}}} - 1} \eta_{\text{inv},k}^{\text{ESB}} E_{\text{inv},k}^{\text{ESB}} \end{aligned} \quad (2)$$

式中: $C_{inv,k}$ 为集群划分中,集群 k 分布式光伏和储能的投资成本目标函数; μ_k^{PV} 、 μ_k^{ESB} 分别为集群 k 中分布式光伏、储能的贴现率; y^{PV} 、 y^{ESB} 分别为分布式光伏、储能的使用年限; $\eta_{inv,k}^{PV}$ 、 $\eta_{inv,k}^{ESB}$ 分别为集群 k 中分布式光伏、储能的单位容量投资成本; $E_{inv,k}^{PV}$ 为集群 k 中分布式光伏规划建设容量; $E_{inv,k}^{ESB}$ 为集群 k 中储能并网容量。

分布式光伏与储能系统的运维模型如式(3)所示。

$$C_{op,k} = \delta_{ess,k} \sum_{t=1}^{t_{end}} P'_{ab,k} + \alpha C_{inv,k} + k_{re} \eta_{inv,k}^{ESB} E_{inv,k}^{ESB} \quad (3)$$

式中: $C_{op,k}$ 为集群 k 中分布式光伏与储能系统的运维成本; $\delta_{ess,k}$ 为集群 k 中分布式光伏单位弃光成本; $P'_{ab,k}$ 为集群 k 中分布式光伏在 t 时刻的预测弃光功率; t_{end} 为该分布式储能系统在一年内的的工作时间,常取8760h; α 为运维成本的折算比例,常取10%; k_{re} 为储能的更换率。

在电力市场的分时电价机制下,储能装置可以通过削峰补谷来降低电费支出^[14]。故储能系统在集群 k 中的基本电费降低收益模型为

$$I_{1,k}^A = n \sum_{t=1}^{24} \delta_{price} (P_{out,k} - P_{in,k}) \times \Delta t \quad (4)$$

式中: n 为储能系统全年的运行天数; δ_{price} 为 t 时刻的实时电价; $P_{out,k}$ 为集群 k 中储能系统的放电功率; $P_{in,k}$ 为集群 k 中储能系统的充电功率。

为实现资源的高效管理和利益的合理分配,且由于分布式光伏发电存在随机性等特点,同时考虑到聚合商作为追求利润的实体的分层电力交易框架中对各种类型的能源服务提供者进行激励,而一定的可用功率存在一个恒定的销售价格可能会降低能源服务提供者的效用,特别是储能系统以固定电价注入电网在峰值需求情景时可能会亏损。所以建立一个峰谷套利模型,如式(5)所示。

$$\begin{cases} \max \sum_m^N f_{1,k} \\ f_{1,k} = I_{1,k}^A + I_{2,k}^P + I_{3,k}^F - C_{1,k}^P - C_{2,k}^A - C_{op,k} \\ I_{2,k}^P = \mu_{trans} (S_{trans,k} - S'_{trans,k}) \\ I_{3,k}^F = \mu_r (C_{1,k}^P + C_{2,k}^A) \\ C_{1,k}^P = \mu_p P_{inv,k}^{ESS} + \mu_E E_{inv,k}^{ESB} \\ C_{2,k}^A = \mu_b C_{1,k}^P \end{cases} \quad (5)$$

式中: m 为集群 k 被划分成的子集群(或子部分)的

数量; $f_{1,k}$ 为集群 k 年度净值; $I_{2,k}^P$ 为集群 k 中降低变压器容量而减少的投资; μ_{trans} 为集群 k 中变压器的单位容量成本; $S_{trans,k}$ 为集群 k 中变压器的规划容量; $S'_{trans,k}$ 为集群 k 中具有储能功能的变压器的规划容量; $I_{3,k}^F$ 为集群 k 中残值回收收入; μ_r 为残值回收系数; $C_{1,k}^P$ 为集群 k 中储能系统成本; $C_{2,k}^A$ 为集群 k 中土建和安装成本; μ_p 为储能系统的单位功率成本; μ_E 为储能系统的单位容量成本; $P_{inv,k}^{ESS}$ 为集群 k 中储能系统的额定功率; μ_b 为土木工程和安装的成本系数,通常取3%~10%。

3 光储集群参与下计及用户收益的配电网交易机制

上文通过综合考虑空间分布集中度和出力特性一致性,实现了具有空间集中和出力特性一致的光伏资源聚合。接下来,基于合同理论为不同类别的光伏用户设计定制化的合同激励机制。光伏用户可以根据其出力特性、系统规模等因素签订差异化的服务合同,享受动态的电力交易价格。动态定价策略能够根据市场电价波动和光伏出力特性实时调整,通过提供高峰电价奖励、低谷时段折扣等措施鼓励用户参与调峰服务^[17],具体设计如图3所示。

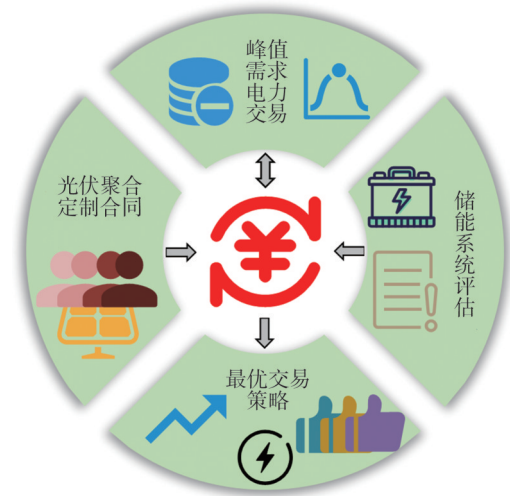


图3 运营模式设计框架

Fig.3 Operational model design framework

可再生能源输出具有间歇性和不可控性特征,在此背景下,用户侧分布式储能成为重要的调节手段。然而,目前分布式储能相关商业模式不够完善

且投资成本较高,需要探索更加高效的技术手段,促进其参与市场运营^[25]。聚合商通过设计有效的激励机制,可以鼓励用户参与调频市场,以应对电力需求的不确定性和波动。通过多阶段、多品种的市场策略,聚合商能够调整激励措施,确保需求的稳定供应,同时鼓励用户参与调频服务,从而获取调频收益。这样的策略不仅提升了电力系统的经济性,还增强了系统的灵活性和可靠性。聚合商引入了可靠性水平的概念来捕捉储能系统的电力供应不确定性。可靠性水平用随机变量 τ 表示,表示在合同期内储能系统满足合同能源的概率。为了简化,假设储能系统的可靠性水平在 $[0,1]$ 范围内,并且是独立同分布抽取的。当储能系统在合同时间结束、提供的电力为零时,可靠性水平 $\tau=0$ 。同样,当储能系统在合同时间结束,提供的电力等于或超过合同数量时,可靠性水平 $\tau=1$ 。

令 λ'_{RTP} 为峰值需求出现时从电网获取电力的价格。在本文中,假设所划分集群 k 中有 $\lambda'_{RTP} > \lambda_{RTP} > \dot{a}, \ddot{a}, \ddot{a}$,其中 $\dot{a}, \ddot{a}, \ddot{a}$ 分别为小型能源存储系统、中型能源存储系统和大型能源存储系统的销售价格, λ_{RTP} 为从电网获取电力的批发价格,同时 d, e 和 f 分别为小型能源存储系统、中型能源存储系统和大型能源存储系统出售单位电力时的效益。以小型能源系统为例,设 τ_{small} 为小型能源系统的可靠性水平并且在峰值需求场景中支付款项以获取单位的电力。如果能源服务供应商在批发价格飙升时无法提供合同规定的电量,那么用户将因供应短缺而遭受罚款。罚款被假设等于 λ'_{RTP} ,同时为了鼓励能源存储系统签订针对峰值需求情景的合同,考虑到该情景具有供应短缺时高额罚款费用的概率,故使 $\lambda'_{RTP} \gg \dot{a}$ 。在这种情况下,由于存在聚合商支付的金额高于基本负荷情景以获得相同数量的电力,因此,我们假设 $d' > d$ (d' 为传统电力市场中聚合商在峰值情况下获取 s_i 数量的电力量所需的支付)。此外,实际上, λ'_{RTP} 是公开信息,聚合商和能源存储系统都知晓。因此,能源存储系统不愿意在这两种情景下以相同的费率出售电力。

对于峰值需求场景来说,聚合商将为储能系统 i (i 为小型能源储能系统销售价格的成本等级)设计合同条款(d'_i, s_i, τ_{small}),其中 d'_i 是峰值需求发生时从

储能系统获取 s_i 数量的电力量所需的支付。供应合同约定的电量 s_i 的成本为 $s_i \varphi \dot{a} \tau_{small}$ (φ 为修正后的销售价格与储能系统单位生产成本的比率),此时储能系统 i 的电力缺口成本为 $s_i(1 - \tau_{small}) \lambda'_{RTP}$,总成本为 $s_i \varphi \dot{a} \tau_{small} + s_i(1 - \tau_{small}) \lambda'_{RTP}$ 。在这种情况下,小型能源存储系统 i 的效用函数(即效益减去成本)可以表示为

$$U'_{small}(d'_i, s_i, \tau_{small}) = d'_i - (\varphi \dot{a} s_i \tau_{small} + (1 - \tau_{small}) s_i \lambda'_{RTP}) \quad (6)$$

同样,中型能源存储系统 j 和大型能源存储系统 h 的效用函数可以通过分别将基本负荷支付(e_j, f_h)替换为峰值需求情景支付(e'_j, f'_h)来获得。

$$\begin{cases} U'_{middle}(e'_j, m_j, \tau_{middle}) = e'_j - \\ (\ddot{a}_j m_j \tau_{middle} + (1 - \tau_{middle}) m_j \lambda'_{RTP}) \\ U'_{large}(f'_h, l_h, \tau_{large}) = f'_h - \\ (\ddot{a}_h l_h \tau_{large} + (1 - \tau_{large}) l_h \lambda'_{RTP}) \end{cases} \quad (7)$$

式中: e'_j 为峰值情况下获取 m_j 数量的电力量所要的支付; f'_h 为峰值情况下获取 l_h 数量的电力量所要的支付; τ_{middle} 和 τ_{large} 分别为中型能源存储系统和大型能源存储系统的可靠性水平。

当可靠性水平为1时,第三项为零,这表明电力供应商通过提供合同规定的电力量来实现效用最大化的情况。然而,随着可靠性水平降低,由于补充电力的成本增加,能源存储系统的效用下降。因此会出现以下几种情况。

1) $\lambda'_{RTP} = \lambda_{FR}$ (λ_{FR} 为聚合商出售电力的价格)时,表示传统电力市场中聚合商的收支平衡条件。在这种情况下,聚合商与能源存储系统进行交易以盈利,而能源存储系统愿意以高于基荷情景的价格出售其过剩电力。

在这种情况下,与相同电量采购量相比,给能源存储系统的单位支付比基荷场景高0.015美元/kWh。以不同价格销售相同电量这一概念是合理的,它遵循了能源零售商向消费者提供灵活定价关税的理念。基于这一理念,在消费者相同电量消费的情况下,根据其用电时间(非高峰时段、高峰时段)采用不同的费率进行收费。

2) $\lambda'_{RTP} > \lambda_{FR}$ 时,表示聚合商通过传统交易方案遭受损失。在这种情况下,聚合商的目标是通过与能源存储系统进行交易来避免损失。此时,储能系统的效益也会增加。然而,储能系统的收入随着

λ'_{RTP} 的增加而增加,直到单位支付低于固定费率。由于固定费率构成了单位支付的饱和点,一旦实际支付超过该水平,聚合商的效用将由正转负。

基于前述两种市场情形,需要构建一个能够动态响应聚合商与储能系统间实时交易条件的定价机制。在此机制下,可进一步推导峰荷场景中聚合商的最优交易策略,从而实现对整体决策模型的优化与整合,其约束条件应包含:集群 k 中电价、成本、储能系统的供应容量以及总电力需求。其定义如式(8)所示。

$$\begin{cases} W'_k = \sum_{i=1}^S n'_{i,k} s_{i,k} + \sum_{j=1}^M n'_{j,k} m_{j,k} + \sum_{h=1}^L n'_{h,k} l_{h,k} \\ d'_i \geq \varphi \bar{a}'_1 s_1, e'_i \geq \bar{a}'_1 m_1, f'_i \geq \bar{a}'_1 l_1 \\ \bar{d}'_i \geq \varphi \bar{a}_1 s_1, \bar{e}'_i \geq \bar{a}_1 m_1, \bar{f}'_i \geq \bar{a}_1 l_1 \end{cases} \quad (8)$$

式中:在集群 k 的情况下, W'_k 为聚合商的总时峰值功率需求; $n'_{i,k}$ 、 $n'_{j,k}$ 和 $n'_{h,k}$ 分别为满足峰值负荷需求的储能系统 i 、储能系统 j 和储能系统 h 的数量; S 、 M 、 L 分别为小型能源存储系统、中型能源存储系统和大型能源存储系统的销售价格的成本等级数; \bar{a}'_1 、 \bar{a}_1 和 \bar{a}'_1 分别为聚合商从小型能源存储系统、中型能源存储系统和大型能源存储系统获得 s_1 、 m_1 和 l_1 数量的电力量时的支出; \bar{a}_1 、 \bar{a}_1 和 \bar{a}_1 分别为聚合商从能源存储系统采购 $s_{i,k}$ 、 $m_{j,k}$ 和 $l_{h,k}$ 数量的电力量时的支出。

考虑所有类型的能源存储系统与约束条件,聚合商针对集群 k 中峰值负荷场景的最优合同可由式(9)获得。

$$\begin{aligned} \max(U'_{A,k}) = & \sum_{i=1}^S n_{i,k} (R(s_i) - (d'_i)) + \\ & \sum_{j=1}^M n_{j,k} (R(m_j) - (e'_j)) + \\ & \sum_{h=1}^L n_{h,k} (R(l_h) - (f'_h)) \end{aligned} \quad (9)$$

式中: $R(s_i)$ 、 $R(m_j)$ 和 $R(l_h)$ 分别为聚合商从小型能源存储系统、中型能源存储系统和大型能源存储系统获得 s_i 、 m_j 和 l_h 数量的电力量后的收益; $n_{i,k}$ 、 $n_{j,k}$ 和 $n_{h,k}$ 分别为在集群 k 的情况下,储能系统 i 、储能系统 j 和储能系统 h 的数量; $U'_{A,k}$ 为聚合商的效益。

当储能系统的可靠性水平为 0 时,意味着储能系统无法提供任何电力来满足合同要求,聚合商需通过其他方式补充电力,以避免违约和损失。首先,聚合商面临较高的成本,包括从电网紧急采购的高价电力

和违约罚款。为减轻这些成本,合同中应明确违约补偿规则,并设置成本分担机制,确保储能系统承担部分责任。其次,聚合商应调整优化策略,通过多签合同分散风险,优先选择可靠性高的储能系统,并设计动态定价机制。若储能系统未履约,聚合商可以通过提高补偿价格来激励其他储能系统提供电力。储能系统方面, $\tau=0$ 降低其效用,因此会倾向选择高可靠性的合同,以避免罚款。聚合商需要考虑这一点,设计更具吸引力的合同条款以确保稳定供应。

4 算例测试与分析

仿真使用改进的 IEEE 33 节点案例作为配电网对分布式光伏层次聚类 and 储能优化配置、经济分析进行研究,改进的 IEEE 33 节点系统的节点数相对较小,但它包含了各种类型的负载和发电机,能够反映真实电力系统的复杂性,因此在研究电力系统的稳定性、可靠性等方面具有很好的代表性。改进的 IEEE 33 节点案例如图 4 所示,根据日平均光伏出力、日光伏出力波动率和日光伏出力分布偏度等聚合指标将其划分为 3 个集群。实际应用场景下,光储集群配装未必都能较好地考虑到网络拓扑约束并选择合适的位置。此次仿真实验主要是研究交易机制,故在此案例中选择指定位置并事先确定分布式光伏和储能的相关信息以更贴近复杂且未知的实际场景,最终将其作为本次仿真实验的集群配置。其中在集群 1 中,光伏与节点 2、节点 4、节点 19 相连接,储能系统与节点 3、节点 18 相连接;在集群 2 中,光伏与节点 9、节点 13、节点 16 相连接,储能系统与节点 6、节点 10、节点 14 相连接;在集群 3 中,光伏与节点 26、节点 28、节点 30、节点 32 相连接,储能系统与节点 27、节点 31 相连接。改进的 IEEE33 节点案例中分布式电源各节点参数如表 1 所示。在此基础上使用基于随机因素生成的光伏曲线体现光伏发电的随机性,并以此作为实验数据。

4.1 分布式光伏集群划分结果

仿真过程中聚类程序生成了大量光伏随机场景并在此基础上基于改进的 K-means 算法对大规模场景进行聚类以及优化。

通过引入随机因素生成的光伏曲线有着光伏发电总体呈现中间高左右低的情况,但受阳光照射强

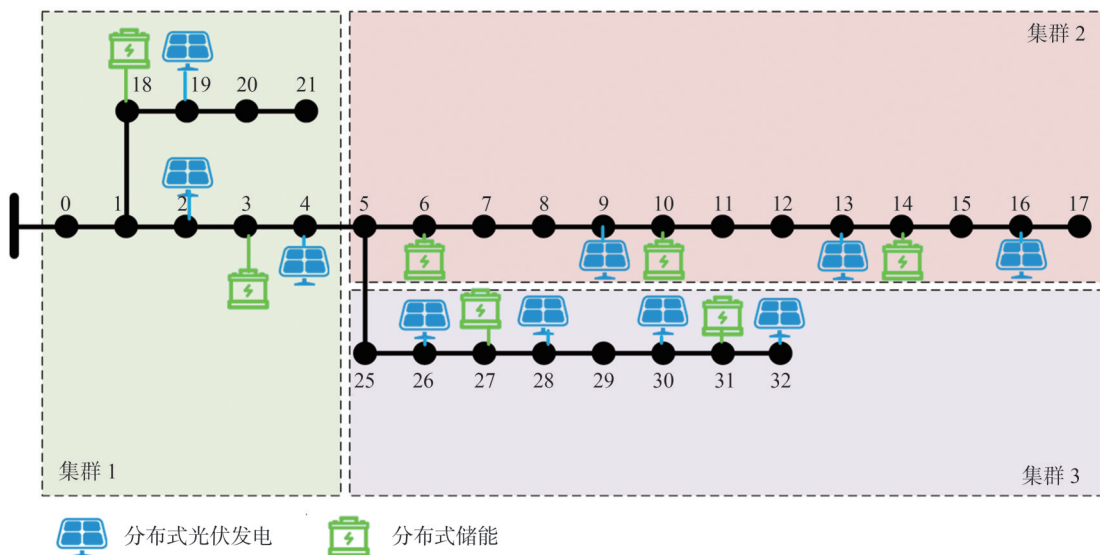


图4 改进的IEEE 33节点案例
Fig.4 Improved IEEE 33 node case

度、温度等多种因素的影响,总体下来每天的光伏输出呈现出总体趋势符合,具体数值存在较大差异,且由于各种因素的影响也不乏与大趋势所不同的光伏曲线出现,同时也有着光伏分布式发电的随机性与波动性,生成的典型光伏日出力曲线如图5所示。

通过引入随机因素生成具有随机性的光伏输出,但因为输出结果过多导致输出结果图过于杂乱,无法进行有效分析,所以使用改进的K-means算法进行聚类分析来实现大规模场景的削减,便于调度优化和性能评估。同时结合空间分布集中度、多机出力相似度等因素以实现具有空间区域分布集中、出力特性一致等特征的分布式光伏聚类分析,其结果如图6所示。




图5 典型光伏日出力曲线
Fig.5 Typical photovoltaic daily output curve

表1 分布式电源参数

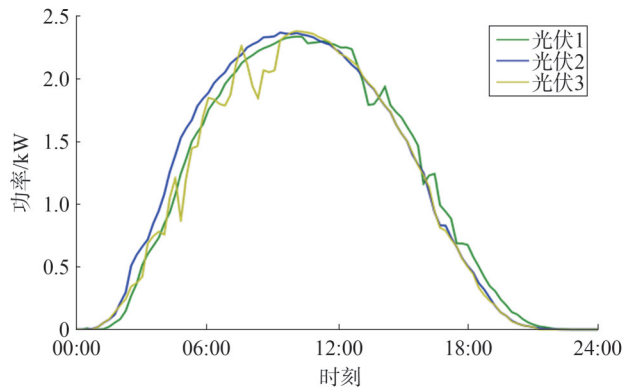
Table 1 Parameters of distributed generators

类型	所在节点编号	额定功率/kW	额定容量/kWh
分布式光伏	2,4,19	540	
	9,13,16	750	
	26,28,30,32	690	
分布式储能	3,18	650	650
	6,10,14	900	900
	27,31	850	850


4.2 考虑光储集群参与的配电网交易结果分析

基于上述分布式光伏聚类分析的结果并两步制电价为基础,考虑用户负荷特性建立起一个参与辅助服务的用户侧优化配置模型。由于光伏发电存在随机性与波动性,在引导用户用电过程中也应考虑到每时电网中储能充放电的情况以及相应储能的使用寿命、性能并结合用户每日电负荷来进行储能配置优化与经济分析。储能系统一天内充放电功率与状态如图7所示。在以此约束的前提下,基于用户一天内电负荷以及降低用户侧分布式光伏机会成本和支付费用所得出的每时分布式电价如图8所示。在本次仿真实验中从批发市场购买电力的单价在0.3~0.9元/kWh之间变化,在峰荷情景下为0.9元/kWh。

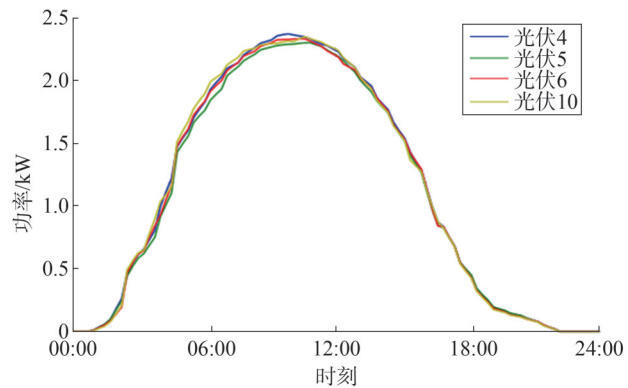
由于在实时市场中,批发电价在市场的每个时间间隔内波动,峰荷需求期间的电价可能是基荷需求期间电价的多倍。因此,在本研究中,考虑 0.3~0.9 元/kWh 的批发电价变化,以展示所提出的策略在各种条件下的有效性。同时为了最大化聚合商利益、促进用户积极性以及应对更为复杂的情况,故在峰谷电价外设置



(a) 集群 1



(b) 集群 2



(c) 集群 3

图 6 削减后光伏层次聚类划分

Fig.6 Hierarchical clustering of photovoltaics after reduction

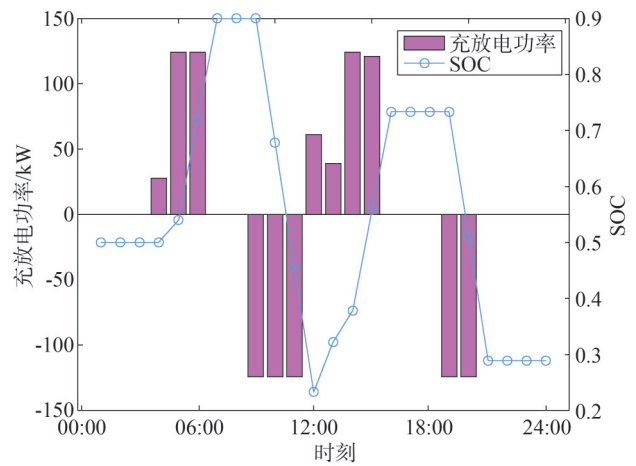


图 7 储能系统一天内充放电功率与状态

Fig.7 Charging and discharging power and status of energy storage system in one day

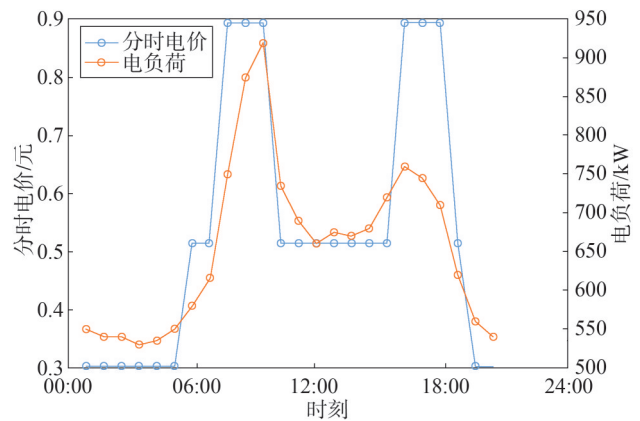


图 8 一天内分步式电价

Fig.8 Step-by-step electricity tariff throughout the day

0.51 元/kWh 作为基荷情景下的电价。除此以外,由于电力需求在每个时间间隔内存在波动,故以 1 h 为步长,对一天 24 h 全时间段进行模拟,并且充放电功率与状态每小时都会更新。此次仿真实验最后将通过优化前后负荷变化来展示方案的可行性。

优化前后电负荷曲线如图 9 所示,从中可以看出在 09:00—11:00 削减了原负荷曲线的峰值,在 19:00—20:00 也有效降低了负荷,而在 04:00—07:00 和 12:00—13:00 提高了负荷曲线,在其他时间段负荷曲线几乎无变化。此电负荷变化符合此仿真设计的目的,实现了用户侧的储能配置优化,有效降低负荷曲线的峰值,最大化利用光伏系统发电以及聚合商的收益。同时也通过电价的分时设置保证了用户

参与辅助服务的积极性。

通过一系列仿真实验,验证了所提出的基于K-means的分布式光伏聚类方法以及电价分时设置的有效性与其可行性。仿真结果表明,聚类方法可以有效进行大规模场景的削减,便于调度优化和性能评估。同时分时电价的设置可以帮助聚合商有效提高分布式光伏的电压稳定性与发电的利用率,且用户在参与调峰服务时的积极性也有所保证,用户的成本也有所降低,从而有效提升了系统的整体效率和稳定性。




图9 优化前后电负荷曲线

Fig.9 Electric load curves before and after optimization

5 结束语

提出一种面向分布式光伏规模化开发的层次聚类分析方法和聚合商运营模式,通过K-means算法综合考虑空间分布集中度和出力特性一致性,实现了具有空间集中和出力特性一致的光伏资源聚合。在此基础上,以两步制电价为基础设计面向上下层交互的业务模式和激励机制,以提高用户参与辅助服务的积极性,最终实现聚合商收益最大化,同时有效提升了系统的整体效率和稳定性。此外随着可再生能源越来越多地被应用于电力系统中以及虚拟电厂等分布式系统的不断发展,该方法有望在其他种类的可再生能源发电系统与虚拟电厂中得到应用,为实现电力系统安全稳定、可持续运行与发展提供技术支持。

参考文献

- [1] 徐俊俊,吴在军,胡秦然,等.考虑多类型分布式电源和负荷不确定性的主动配电网区间状态估计[J].中国电机工程学报,2018,38(11):3255-3266.
XU Junjun, WU Zaijun, HU Qinran, et al. Interval state estimation for active distribution networks considering uncertainties of multiple types of DGs and loads [J]. Proceedings of the CSEE, 2018, 38(11): 3255-3266.
- [2] 徐俊俊,吴在军,周力,等.考虑分布式电源不确定性的配电网鲁棒动态重构[J].中国电机工程学报,2018,38(16):4715-4725.
XU Junjun, WU Zaijun, ZHOU Li, et al. Robust dynamic reconfiguration for distribution networks considering uncertainty of distributed generations [J]. Proceedings of the CSEE, 2018, 38(16): 4715-4725.
- [3] 廖家齐,于若英,刘瑜俊,等.基于自适应高斯混合模型的含高渗透率分布式光伏电力系统风险评估[J].电力系统保护与控制,2024,52(19):144-156.
LIAO Jiaqi, YU Ruoying, LIU Yujun, et al. Risk assessment of a power system with a high penetration of distributed photovoltaic based on self-adaptive Gaussian mixture model [J]. Power System Protection and Control, 2024, 52(19): 144-156.
- [4] 杨海柱,李庆华,张鹏.基于tGSSA-DELM的短期光伏发电功率预测[J].智慧电力,2023,51(10):70-77.
YANG Haizhu, LI Qinghua, ZHANG Peng. Short-term Photovoltaic Power Generation Prediction Based on tGSSA-DELM [J]. Smart Power, 2023, 51(10): 70-77.
- [5] 郭自文,王子鉴,黄纯,等.考虑源荷储功率协调和不确定性的配电网集群划分方法[J/OL].电网技术,2024:1-13[2024-11-20]. <https://link.cnki.net/doi/10.13335/j.1000-3673.pst.2024.1579>.
GUO Ziwen, WANG Zijian, HUANG Chun, et al. A distribution network clustering method considering source-load-storage power coordination and uncertainty [J/OL]. Power System Technology, 2024: 1-13 [2024-11-20]. <https://link.cnki.net/doi/10.13335/j.1000-3673.pst.2024.1579>.
- [6] 李耐心,文艺林,杜鹏,等.配电网与电动汽车光储充电聚合商的协调互动策略[J].智慧电力,2023,51(12):38-44.
LI Naixin, WEN Yilin, DU Peng, et al. Coordinated Interaction Strategy between Distribution Network and Aggregators of Photovoltaic, Energy Storage and Electric Vehicles [J]. Smart Power, 2023, 51(12): 38-44.
- [7] 杨颂,王成龙,孙树敏,等.基于集群划分的配电网双层电压协调优化策略[J].山东电力技术,2024,51(3):55-64.

- YANG Song, WANG Chenglong, SUN Shumin, et al. Coordination optimization strategy for cluster partition-based two-stage voltage control for distribution network [J]. Shandong Electric Power, 2024, 51(3): 55-64.
- [8] 刘东铭, 曾庆彬, 张勇军, 等. 考虑多重不确定性和潜在博弈的楼宇群电能优化调度策略[J]. 电力自动化设备, 2024, 44(9): 136-144.
- LIU Dongming, ZENG Qingbin, ZHANG Yongjun, et al. Optimal energy scheduling strategy of building groups considering multiple uncertainties and potential game [J]. Electric Power Automation Equipment, 2024, 44(9): 136-144.
- [9] 张扬. 配电网负荷预测中信号分解和预测模型组合的双层优化策略[J]. 智慧电力, 2024, 52(9): 104-111.
- ZHANG Yang. Two-layer Optimal Strategy for Signal Decomposition and Prediction Model Combination in Load Forecasting of Distribution Network[J]. Smart Power, 2024, 52(9): 104-111.
- [10] 颜勤, 余国翔, 曾林俊. 考虑光伏场景聚合的配电网光储选址定容[J]. 湖南大学学报: 自然科学版, 2024, 51(8): 117-126.
- YAN Qin, YU Guoxiang, ZENG Linjun. Distribution grid siting and capacity sizing for distributed PV and storage considering PV scenario aggregation [J]. Journal of Hunan University: Natural Sciences, 2024, 51(8): 117-126.
- [11] SINGH H, JHA V. Optimization methods of location and capacity determination for distributed generation in distributed network: a review [C] // 2021 International Conference on Advances in Technology, Management & Education (ICATME). IEEE, 2021: 145-150.
- [12] YU H, CHENG M, YU W, et al. Optimal of upper and lower double-layer capacity configuration for multiple energy storage and wind-solar systems considering objective evaluation indicators [C] // 2023 3rd International Conference on New Energy and Power Engineering (ICNEPE). IEEE, 2023: 136-143.
- [13] WANG C, SHEN Z Y, ZHAO H B, et al. Research on cost-benefit analysis and arbitrage strategy of energy storage for industrial users [C] // 2022 IEEE 6th Conference on Energy Internet and Energy System Integration (EI2). IEEE, 2022: 2820-2824.
- [14] 李金雨, 宋福龙, 马俊杰, 等. 基于5G基站可调度潜力与配电网集群划分的储能选址定容方法[J]. 电力系统自动化, 2023, 47(18): 151-160.
- LI Jinyu, SONG Fulong, MA Junjie, et al. Siting and sizing method for energy storage based on dispatchable potential of 5G base station and cluster partition of distribution network [J]. Automation of Electric Power Systems, 2023, 47(18): 151-160.
- [15] 李梓仟, 袁伟, 凡鹏飞, 等. 基于关键规划参数的电力市场规划体系[J]. 全球能源互联网, 2023, 6(4): 390-397.
- LI Ziqian, YUAN Wei, FAN Pengfei, et al. Electricity market planning system based on key planning parameters [J]. Journal of Global Energy Interconnection, 2023, 6(4): 390-397.
- [16] AMIN U, HOSSAIN M J, TUSHAR W, et al. Energy trading in local electricity market with renewables—a contract theoretic approach [J]. IEEE Transactions on Industrial Informatics, 2021, 17(6): 3717-3730.
- [17] TIAN H P, SHEN X J, LI Y Q, et al. Coordination of competing supply chains: wholesale pricing vs. two-part tariff [C] // 2023 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM). IEEE, 2023: 78-82.
- [18] 裴林, 黄成, 杨啸, 等. 考虑隐私保护和去中心化的分布式能源交易模式研究[J]. 电力系统保护与控制, 2024, 52(2): 143-154.
- PEI Lin, HUANG Cheng, YANG Xiao, et al. A distributed energy trading model considering privacy protection and decentralization [J]. Power System Protection and Control, 2024, 52(2): 143-154.
- [19] 谢敬东, 周雪梅, 王诗瑶, 等. 基于区块链技术的分布式电力市场交易平台研究[J]. 电测与仪表, 2024, 61(1): 25-31.
- XIE Jingdong, ZHOU Xuemei, WANG Shiyao, et al. Research on distributed electricity market trading platform based on block chain technology [J]. Electrical Measurement & Instrumentation, 2024, 61(1): 25-31.
- [20] 马佳伊, 刘海涛, 仲聪, 等. 计及共享储能与光伏的园区多用户综合收益优化[J]. 电力工程技术, 2024, 43(1): 60-67.
- MA Jiayi, LIU Haitao, ZHONG Cong, et al. Comprehensive benefits optimization method for multiple types of users connected to the same industrial park considering shared energy storage and household photovoltaic [J]. Electric Power Engineering Technology, 2024, 43(1): 60-67.
- [21] 杨易达, 高红均, 刘挺坚, 等. 考虑CCER收益共享激励火电机组深度调峰的电力系统低碳调度[J]. 电力自动化设备, 2024, 44(9): 121-128.
- YANG Yida, GAO Hongjun, LIU Tingjian, et al. Low carbon dispatch of power system considering CCER revenue sharing incentive for deep peak-shaving of thermal power units [J]. Electric Power Automation Equipment, 2024, 44(9): 121-128.
- [22] 葛乐, 王庆园, 王明深, 等. 考虑充放电激励机制的电动汽车聚合商参与能量-调频市场多阶段运营策略[J]. 电力自动化设备, 2024, 44(6): 176-184.
- GE Le, WANG Qingyuan, WANG Mingshen, et al. Multi-stage operation strategy of electric vehicle aggregator participating in energy and frequency regulation markets considering charging and discharging incentive mechanisms [J]. Electric Power Automation Equipment, 2024, 44(6): 176-184.
- [23] 陈宇星, 梁芙蓉, 尤炜, 等. 含分布式光伏的配电网模型预测控制优化方法[J]. 电力工程技术, 2023, 42(6): 100-109.

- CHEN Yuxing, LIANG Furong, YOU Wei, et al. Model predictive control optimization method for distribution network containing distributed photovoltaics [J]. Electric Power Engineering Technology, 2023, 42(6):100-109.
- [24] 袁昌昊,朱金大,倪建富.含分布式光伏的配电网双层协调电压优化方法[J].电力工程技术,2023,42(6):74-82.
- YUAN Changhao, ZHU Jinda, NI Jianfu. Coordinated voltage optimization method in distribution network with distributed photovoltaic [J]. Electric Power Engineering Technology, 2023, 42(6):74-82.
- [25] 潘一凡,李华强,王子晓,等.基于日前预测与日内运行储能动作偏差量的多园区分布式储能云服务交易机制设计[J].电力自动化设备,2024,44(8):27-36.
- PAN Yifan, LI Huaqiang, WANG Ziyao, et al. Design of cloud service transaction mechanism for distributed energy storage in multi-park based on DAF-IDO energy storage action deviation quantity [J]. Electric Power Automation Equipment, 2024, 44(8): 27-36.
-
- 收稿日期:2024-11-27
修回日期:2025-03-11
- 作者简介:
徐嘉豪(2002),男,研究方向为电力系统自动化;
徐俊俊(1990),通信作者(jjxu@njupt.edu.cn),男,博士,副教授,研究方向为配电网态势感知与优化运行;
王福晶(1979),女,硕士,高级工程师,研究方向为电力企业专业技术和管理。
- (责任编辑 姜婷婷)

DOI: 10.20097/j.cnki.issn1007-9904.240308

适应新增电器的非侵入式负荷监测增量学习方法

杨国朝¹, 贾明辉¹, 李子墨^{2*}, 白辛雨¹, 于普瑶¹, 刘尧¹

(1. 国网天津市电力公司城东供电分公司, 天津 300250; 2. 天津大学电气自动化与信息工程学院, 天津 300072)

摘要:充分挖掘家用电器的细粒度能耗信息有助于电力用户做出明智的节能用电决策。非侵入式电力负荷监测(non-intrusive load monitoring, NILM)旨在根据用户电力入口处智能电表的测量数据来识别单个电器的运行状态。目前,基于机器学习的方法已在负荷识别中表现出良好的实验结果,但这些结果通常基于假设负荷种类和数量是固定的,然而现实用户中随时间演进会不断产生新负荷类别数据。因此,机器学习模型应能够不断学习新增负荷数据,从而增强自身的识别能力。针对此问题,提出了一种适应新增电器的NILM增量学习方法,该方法只需要存储少量的已知电器原型样本数据并进行动态更新,就可以不断识别新电器,同时不会遗忘学习的已知电器知识。在公开数据集上的对比实验结果,证实了所提出模型的有效性和优越性。

关键词:非侵入式电器分类;增量学习;暂态电流特征;电器分类

中图分类号:TP216

文献标志码:A

文章编号:1007-9904(2025)12-0061-09

Non-intrusive Load Monitoring Incremental Learning Method for New Appliances

YANG Guochao¹, JIA Minghui¹, LI Zimo^{2*}, BAI Xinyu¹, YU Puyao¹, LIU Yao¹

(1.State Grid Tianjin Chengdong Electric Power Supply Company, Tianjin 300250, China;

2.School of Electrical Automation and Information Engineering, Tianjin University, Tianjin 300072, China)

Abstract: Fully mining the fine-grained energy consumption information of household appliances is helpful for power users to make wise energy-saving decisions. Non-intrusive load monitoring (NILM) is aimed at identifying the operating state of individual appliances based on measurements from a smart meter at the user's power entrance. At present, machine learning-based methods have shown good experimental results in load identification, but these results are usually based on the assumption that the type and number of loads are fixed. However, in real users, new load category data will continue to be generated over time. Therefore, the machine learning model should be able to continuously learn new load data, thereby enhancing its recognition ability. To solve this problem, a NILM incremental learning method adapted to new electrical appliances is proposed. The method only needs to store a small amount of prototype data of known electrical appliances and dynamically update it, which can continuously identify new electrical appliances without forgetting the learned knowledge of known electrical appliances. The effectiveness and superiority of the proposed model are confirmed by the comparative experimental results on the open dataset.

Keywords: non-intrusive appliance classification; incremental learning; transient current characteristics; appliance classification

0 引言

现代社会中,城市化的加速推进、人们生活方式的深刻变革与日新月异的技术进步增加了对能源的

需求。然而能源的产生方式伴随温室气体的排放,导致气候变化加剧,对国际社会的福祉与稳定带来了严峻挑战。为应对有关气候变化的法规给传统集中式电网带来的压力,智能电网应运而生。智能电网技术与应用信息技术将保障电网运行的可靠性与智能化。这一举措代表了节能减排与促进可再生能源接入电网的关键步骤^[1]。

基金项目:国网天津市电力公司科技项目(城东-研发 2023-03)。Science and Technology Project of State Grid Tianjin Electric Power Company(Chengdong-R&D 2023-03)。

智能电表是智能电网不可或缺的组成部分,在促进非侵入式电力负荷监测(non-intrusive load monitoring, NILM)方面发挥着至关重要的作用^[2]。该技术使智能电表用户能够通过有策略地控制电器使用与关注反常的用电方式来提高电能的利用效率。近年来, NILM 技术更多地应用深度学习模型来监控电器的开启、关闭以及电器能耗信息^[3-4]。这是通过读取整个房屋的电力入口处的智能电表采集到的数据来实现的。NILM 可以立即获取智能电表用户的电能使用情况,并提供实时的反馈。研究结果显示,当获得户内电器级用电情况反馈时,整个家庭每年可以节省 3%~18% 的电能^[5]。

研究人员已经提出了多种算法以提高负荷分解技术的性能。NILM 技术通常可以分为两类,分别为基于事件的 NILM 算法和基于状态的 NILM 算法。使用监督或无监督的 NILM 算法取决于各电器真实功率数据是否容易获得。基于事件的方法使用边缘检测方法识别电器状态变化的时刻。这些算法通常从对聚合功率信号中的负荷事件进行无监督检测开始,在特征提取之后进行监督分类过程^[6-8]。采用聚类算法、支持向量机(support vector machine, SVM)^[9-11]、决策树(decision tree, DT)^[12-15]和深度神经网络(deep neural network, DNN)^[16-19]等方法进行分类,以保证准确高效的电器识别。在最新的研究中,将图信号处理(graph signal processing, GSP)算法应用于基于事件的 NILM 算法^[20-22]。这些最新的算法适用于监督与无监督的应用场景,通过在图形框架上表示信号以揭示数据集中的时空关系。

基于状态的方法进行电力负荷分解,通常将每一个电器建模为有限状态机。该过程需要根据电器模型对聚合功率数据进行分区,组合优化后与隐马尔可夫模型(hidden Markov model, HMM)在基于状态的非侵入式电力负荷分解算法中使用,以探索不同电器状态序列之间的最佳组合^[23-25]。

然而,随着电器数量的不断增加,状态组合数的指数级增长使得算法的时间复杂度急剧增大,导致算法难以实现与应用。且当应用场景中有未知电器时,需要对上述算法进行修改,才可以得到更高精度的分解结果。Makonin 等人创新地结合了资源高效 Viterbi 算法,设计了超状态 HMM,有效估计了电器

能耗^[26]。

虽然上述算法在电器识别领域性能令人满意,但这些方法是针对固定的场景而设计的。这些算法运行的前提是可以获得所有电器的数据用于训练模型。然而实际应用场景中,很难获得所有电器的运行数据,且由于用户会根据自己的实际需要不断添加新的电器^[27],因此电器识别模型应该允许不断适应新的数据,以更及时地响应系统中电器的变化。此外,传统方法遇到新的电器时,需要使用新旧电器的数据进行重新训练,对 NILM 系统的计算资源提出了更高的要求。

为应对以上非侵入式电力负荷分解问题的难题,Stavros 等提出了一种称作 ContiNILM 的方法,其中的上下文重要性采样功能使系统能够持续从输入的信息中获取知识,并用于重新训练模型与增强训练用数据库^[27]。文献[28]提出了一种可解释增量电压-电流表示注意力卷积神经网络用于非侵入式电力负荷监测和一种自适应的蒸馏增量学习策略(adaptive distillation incremental learning, ADIL),通过选择重新学习之前学习过的部分数据来应对增量学习过程中模型所对应的灾难性遗忘问题。文献[29]提出了一种基于一类支持向量机增量学习的电动自行车辨识方法,基于协同训练思想通过重复迭代更新三个分类器,更新训练样本集时只保留支持向量,以实现增量学习。文献[30]提出了一种使用人工免疫算法和增量学习对传统隐马尔可夫模型进行改进的非侵入式家居负荷识别方法,通过增量学习集成在新数据与旧数据上训练得到的参数实现模型参数的自主更新。

为解决上述问题,本文提出了一种利用增量学习的方法来识别电器的模型。增量学习可以有效降低在传统模型中重新训练模型的额外计算成本,让模型能够有效地适应新数据,避免占用过多的计算资源。此外,增量学习使模型能够灵活地适应不断变化的电器模式,同时保留所获取的已知电器的特征信息,无须重新收集和标记大量数据。这种适应性对于处理不同时期或特殊事件期间房屋中的电器变化至关重要。在公开数据集上进行实验,取电器的暂态电流数据作为模型的输入,实验结果证实了该模型具有增量学习的能力。

1 算法描述

1.1 类增量分类器学习

所提出的方法以类增量的方式训练特征提取网络与电器分类器。首先为每个电器建立原型样本库,用于存储电器的暂态电流原型样本。采用所提出的增量学习策略,当系统检测到有新增电器加入时,使用新增电器的原型样本与原有电器样本库中的样本更新特征提取网络的参数。随后更新样本库,新增电器加入前后,电器数量分别为 s 和 t 。由于系统存储原型样本的存储空间是固定的,共可存储 N 个原型样本。新增电器加入前,系统为每个已有电器分配的原型样本存储数量为 $m = N/s$ 。新增电器加入后,每个电器的原型库可存储原型样本的数量为 $m' = N/t$ 。首先对原有电器样本库中的样本进

行重要性排序,剔除原有电器样本库中相对不重要的 $m - m'$ 个超出限额的原型样本,本文所提增量学习算法流程如图 1 所示。电器原型样本的重要性排序与取舍过程将在 1.4 节中进行详细介绍。

所提方法使用时间卷积神经网络(temporal convolutional neural network, TCN)作为其底层算法。该模型用于表征电器的暂态电流特征,将网络输出的暂态电流特征作为聚类算法的输入,并在最后输出针对电器的分类结果。

θ 为网络参数,包括特征提取网络参数与电器 y 所对应的灵活权重向量集合 $W = \{\omega_y | \forall y = 1, 2, \dots, t\}$, 其中, ω_y 为电器 y 的权重向量,是一个 d 维向量; d 为通用特征提取网络输出的特征向量 $\varphi(x)$ 的维数,电器 y 的输出为

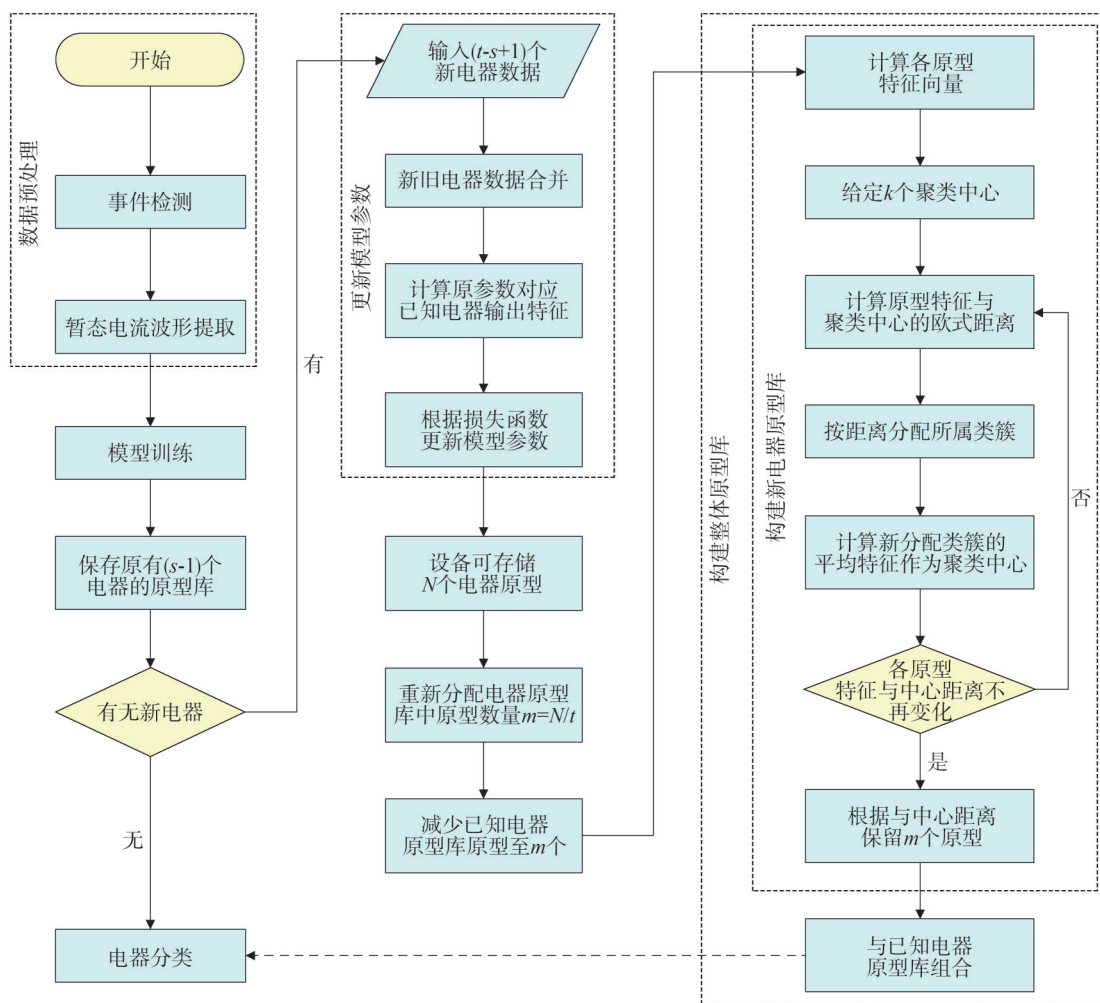


图 1 算法流程图

Fig.1 Algorithm flow chart

$$g_y(x) = \frac{1}{1 + \exp(-a_y(x))} \quad (1)$$

式中: $a_y(x) = \omega_y^T \varphi(x)$ 为样本原型数据 x 经通用特征提取网络与电器 y 对应的灵活权重向量映射得到的数值。虽然该输出可以解释为概率,但需要澄清所提方法仅利用网络进行特征提取,并不参与分类步骤。

由于所提方法的类增量性质,故无需电器类型或数量的先验信息。理论上,分类器可以不断进行分类增量学习。在整个运行过程中,内存需求包括通用特征提取网络参数、 N 个原型暂态电流原型数据的存储空间以及各电器的灵活权重向量。假设已知电器的数量有上限,这种情况下可以为所需权重向量预先分配空间,并且可以利用剩余的存储空间来存储暂态电流原型。如果电器的数量没有上限,权重向量和原型数据的数量会随着时间的推移而增加,因此用于原型数据存储的空间需要进行动态调整。每个用于学习的设备至少需要一个暂态电流原型数据及其相应的权重向量。因此,由于系统资源的限制,除非可以在算法运行时添加额外的存储资源,否则增量学习的能力是有限的。所提方法可以动态地容纳增加的样本数据,而且无须重新训练,除由于内存限制而需要删除特定原型的情况外,算法将保留电器的大部分原型数据。

1.2 最近原型均值分类

为预测输入暂态电流原型数据的电器种类标签,所提方法首先计算已知电器原型库中每种电器原型数据的均值特征向量,其中各原型数据的特征向量是由特征提取网络与对应灵活权重向量计算得到的,然后计算输入原型数据的特征向量,并且计算其与各电器原型数据的均值特征向量之间的欧氏距离,最后将该原型数据分类为与其特征向量欧氏距离最短的均值特征向量相应的电器类别。

1.3 表示学习

在接收新增电器的暂态电流原型数据的过程中,所提方法对原有模型的特征提取网络与数据原型库进行增强。首先,使用已有电器的数据原型库与新增电器的数据原型结合,形成增强的训练原型样本库。然后,使用现有的特征提取网络计算每个原型数据的输出。最后,通过最小化损失函数实现

网络参数的更新与优化。该方法使模型可以对新电器的暂态电流原型数据进行正确的特征表示和分类,并且对于已有电器,也将优化网络对其所对应的原型数据的特征表示能力。网络损失函数为

$$L = - \sum_{(x,y) \in D} [\sum_{y=s+1}^{\ell} \delta_{y=y_i} \lg g_y(x_i) + \delta_{y \neq y_i} \lg(1 - g_y(x_i)) + \sum_{y=1}^s q_{y,i} \lg g_y(x_i) + (1 - q_{y,i}) \lg(1 - g_y(x_i))] \quad (2)$$

式中: D 为训练原型样本集; x_i 为训练原型样本集中第 i 个原型数据; $g_y(x_i)$ 为模型将输入原型数据预测为电器 y 的概率; $\delta_{y=y_i}$ 为指示函数,当 $y = y_i$ 时,其值为 1,否则为 0; $\delta_{y \neq y_i}$ 为指示函数,当 $y \neq y_i$ 时,其值为 1,否则为 0; $q_{y,i}$ 为权重因子,用于调整不同类别的损失贡献。

1.4 原型管理

面对新增电器加入的情况,所提方法会动态地调整原型库,为所有的电器重新分配相同大小的原型数据存储空间。新增电器加入前,每一类电器的原型库中都有 $m = Nt$ 个原型数据,当加入新增电器原型数据时,所提方法会动态地根据规则剔除原有电器原型库中的原型数据。这保证了在类增量学习过程中原型存储所用的内存不会超出为其分配的限额。

原型管理方法主要包括两个方面:一是减少已知电器原型库中的原型数量;二是为新增电器原型库选择最佳的原型数据。在已知电器的原型数据筛选过程中,如果电器 y 已经有 m 个原型数据,为选取其中的 m' 个原型数据构建新的原型库,首先需要计算该电器原型数据的均值特征向量 μ_y 。然后,循环地从电器 y 的原型库中选取原型到对应的新原型库中,使得该电器的新原型库的均值特征向量能够尽可能地靠近原有原型库的均值特征向量,每一次迭代筛选都会通过在新原型库中增加原型的方式对新库进行扩展,直到新原型库中原型数据的个数达到新的原型数量限额 m' 。原型数据在新原型库中的排列顺序取决于该原型数据能够准确近似原有原型库的平均特征向量的能力。式(3)表示了新原型库中的第 r 个原型的选取过程。

$$p_r \leftarrow \underset{x \in X_r}{\operatorname{argmin}} \left\| \mu_y - \frac{1}{r} \left[\varphi(x) + \sum_{j=1}^{r-1} \varphi(p_j) \right] \right\| \quad (3)$$

式中: p_r 为被添加到电器新原型库的第 r 个原型数据; X_y 为电器 y 的原有原型库; p_j 为此前已经添加到电器新原型库中的第 j 个原型数据。

原型库作为一个优先列表,其中原型数据的排列顺序表示它们的重要性等级。如果后续有新的新增电器加入,需要继续筛选已有电器原型库中的原型数据,使其中原型数据的数量减少到新的限额。所提方法只需按顺序丢弃新的限额以外的原型数据,而无须重新按对原有原型库的表示能力选取原型。

1.5 新增电器原型库构建

所提方法在新增电器构建原型库的过程中,首先将新增电器的原型数据输入网络计算特征向量,并根据新增电器的工作状态数设定类簇数,随机选取 k 个原型的特征向量作为聚类中心。然后计算各原型特征向量与聚类中心间的欧氏距离,并按照与各聚类中心的距离为每个原型分配其所属的类簇,在所有原型数据都被分类之后,重新计算各类簇的平均特征向量作为新的聚类中心。循环上述步骤直至各原型数据特征向量与所属类簇中心的距离收敛。最后选取特征向量与所属类簇的均值特征向量距离最近的前 m' 个原型数据构建新增电器的原型库。

2 实验与结果分析

2.1 数据集与评价指标

本文使用公共负荷电器识别数据集(public load appliance identification dataset, PLAID)与热水器和室内温度电力数据集(water heater and indoor temperature electricity data, WHITED)评估所提算法的性能。PLAID数据集包括美国56个住宅的200多个共11种家用电器的实时电压和电流读数,采样频率为30 kHz。本文的研究重点为2017年发布的PLAID数据集^[31],包括1793个初始电压与电流读数。

WHITED数据集^[32]包含来自全球不同地区家庭和小型工业环境中的多种电器的高分辨率电流电压数据,采样频率为44.1 kHz,数据集中包含了110台电器的前5 s启动过程,涉及47种不同类型的电器。为评估实验结果,本文采用 F 分数作为评价指标,用于衡量模型精度与召回率的综合表现。

$$F_{\text{score}} = \frac{2 \times P \times R}{R + P} \quad (4)$$

$$P = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \quad (5)$$

$$R = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \quad (6)$$

$$F_{\text{macro}} = \frac{1}{t} \sum_{i=1}^t F_{\text{score},y} \quad (7)$$

式中: P 为分类准确率; R 为分类召回率; N_{TP} 为分类器将属于该电器的原型数据正确分类的样本数; N_{FP} 为分类器将该电器的原型数据错误分类为其他电器类别的样本数; N_{TN} 为分类器将属于其他电器的原型数据正确分类的样本数; N_{FN} 为分类器将属于其他电器的原型数据错误分类为该电器的样本数; F_{macro} 为所有电器的 F 分数均值; t 为当前房屋中的电器总数量; $F_{\text{score},y}$ 为电器 y 的 F 分数。

2.2 实验结果

在PLAID数据集的实验中,假设房屋中起初只有PLAID数据集中11种电器中的5种。模型首先使用这5种电器的数据进行训练从而得到模型参数,在之后的每次实验中增加两种新的电器来模拟房屋中新增安装两种电器,然后令模型进行增量训练,直到房屋中的电器数量增加到11种。利用负荷辨识实验来测试本文提出的增量学习模型学习新增电器的能力以及它在增量训练过程中是否会遗忘已经学习到的原有电器的信息。

实验中,本文使用TCN作为特征提取网络的架构,设置最大原型存储容量 $N=220$ (即最后一次实验中可以为每个电器分配存储20个原型数据的存储空间)。两种对比算法分别为:不采用增量学习策略,即每次有新电器加入就使用所有的原型数据重新训练的监督学习算法;文献[33]中提出的偏差校正增量学习策略(bias correction, BiC)。

图2—图5展示了所提方法与两种对比算法的辨识性能。最开始的实验使用PLAID数据集中的5种电器的原型数据来训练和测试模型。本文算法与监督算法的 F_{macro} 值都是0.9394, BiC算法的 F_{macro} 值为0.9176。实验2中,在拓展之后具有7种电器的数据集上使用三种方法分别进行模型训练与测试,监督算法的 F_{macro} 值最高为0.9379,而本文算法与BiC算法的 F_{macro} 值分别为0.8956和0.8461,显然本文算法相比BiC算法具有更高的精度。实验3中,随着模型进一步融合2种新的电器的知识,图4显

示了9种电器上三种训练策略的辨识性能,本文算法、监督算法与BiC算法的 F_{macro} 值分别为0.8799、0.9462和0.8164,本文算法相对监督算法的辨识精度指标衰减为0.0663,低于BiC算法的辨识精度指标衰减值0.1298。图5反映了模型在学习所有的11种电器的所有电器信息之后的辨识性能,采用本文增量训练策略的模型的 F_{macro} 值为0.8298、监督算法的 F_{macro} 值为0.9352以及BiC算法的 F_{macro} 值为0.7597,可见本文提出的增量学习算法为模型提供了比BiC算法更低的精度衰减。




图2 实验1各方法辨识结果 F 分数对比

Fig.2 Comparison of F scores of identification results of different methods in experiment 1

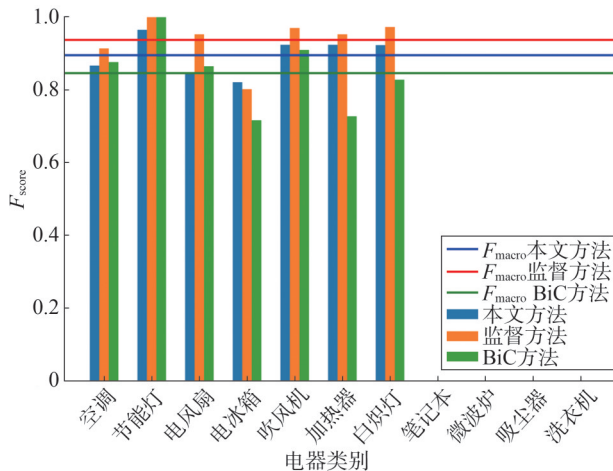


图3 实验2各方法辨识结果 F 分数对比

Fig.3 Comparison of F scores of identification results of different methods in experiment 2




图4 实验3各方法辨识结果 F 分数对比

Fig.4 Comparison of F scores of identification results of different methods in experiment 3




图5 实验4各方法辨识结果 F 分数对比

Fig.5 Comparison of F scores of identification results of different methods in experiment 4

尽管在PLAID数据集上的实验已经证明了所提增量学习策略的有效性,但是为进一步验证模型的泛化能力与鲁棒性,本文选择了另外一个公开数据集——WHITED数据集进行实验。从WHITED数据集中选择与前述PLAID数据集中选取的11个电器种类相同的11个电器进行增量学习实验,仍首先使用前5种电器对模型进行训练,随着实验的进行不断增加新的电器,使模型按照相应的增量训练策略

学习电器信息。如表 1 所示,使用监督学习方法对不断增加的电器信息进行学习,并进行负荷辨识测试时,其辨识精确率的下降值非常小。本文算法在设备存储容量有限的情况下,在相同的增量学习场景下相较于 BiC 增量学习方法具有更高的辨识准确率。

表 1 WHITED数据集上使用三种算法进行增量学习实验的 F_{macro} 值对比

Table 1 Comparison of F_{macro} values of incremental learning experiments using three algorithms on the WHITED ataset

电器数量	F_{macro} 值		
	本文方法	监督方法	BiC 方法
初始 5 种电器	0.948 5	0.952 3	0.940 7
第 1 次增量后 7 种电器	0.941 8	0.947 0	0.929 3
第 2 次增量后 9 种电器	0.931 6	0.941 9	0.915 4
第 3 次增量后 11 种电器	0.874 5	0.936 7	0.846 6

实验结果表明,随着模型学习新增电器的信息,模型对原有电器的辨识性能会下降,这被称为灾难性遗忘。增量学习模型具有稳定性和可塑性,其中可塑性为模型适应新应用数据的能力,模型能够灵活学习并适应新样本,快速捕捉数据分布的变化。在增量学习中,高可塑性意味着模型可以有效地整合新信息并适当适应新样本,而不会忘记以前学到的经验。稳定性是指模型保持先前学习得到的知识的程度。稳定的增量学习模型应该在接收新数据时尽可能保留以前学习的电器知识,并且防止旧的电器的知识因为引入新数据而被遗忘。实际应用中,平衡可塑性与稳定性至关重要。模型必须具有可塑性,以避免过度拟合新数据并失去对先前学习到的知识的保留。相反,如果模型过于稳定,可能会导致模型对新数据的适应性不足,无法充分利用新样本的信息。

在两个数据集上分别进行的实验可以证明,本文所提增量学习方法与 BiC 方法相比,能够更有效地学习新电器信息,并且不会过快地遗忘先前学习到的旧电器的信息。本文方法与系统存储空间无限的监督方法相比较,识别准确度虽有衰减,但考虑存储空间限制,可以认为该精度衰减并不显著。本

文提出的方法为非侵入式负荷辨识中增量分类器学习的实际部署提供了一种巧妙的思路。

3 结论

本文介绍了一种增量分类和表示学习的模型。该方法可以增量学习新电器的特征信息,同时减少对已学习旧电器信息的遗忘。这种方法仅有序地存储少量原有家电样本以适应实际非侵入式负荷监测系统有限的存储空间。所提模型不仅减少了存储空间和计算复杂度,而且通过在公开数据集上进行的实验证明了其有效性。

未来将进一步深入研究少样本电器增量学习方法,以提高非侵入式负荷监测技术的工程实用性,并探索非侵入式负荷监测技术在智能电网需求响应潜力分析、智能楼宇节能与供需互动、工业园区源网荷储协同优化等方面的实践应用。

参考文献

- [1] RUAN J Q, LIANG G Q, ZHAO J H, et al. Deep learning for cybersecurity in smart grids: review and perspectives [J]. Energy Conversion and Economics, 2023, 4(4): 233-251.
- [2] HART G W. Nonintrusive appliance load monitoring [J]. Proceedings of the IEEE, 1992, 80(12): 1870-1891.
- [3] 罗平,樊星驰,章坚民,等.基于电器运行状态和深度学习的非侵入式负荷分解[J].电力系统自动化,2021,45(12):49-56.
LUO Ping, FAN Xingchi, ZHANG Jianmin, et al. Non-intrusive load decomposition based on operation state of electrical appliances and deep learning [J]. Automation of Electric Power Systems, 2021, 45(12): 49-56.
- [4] 侯林超,朱武,汤德清.基于深度学习网络的非侵入式负荷分解方法[J].计算机仿真,2024,41(2):137-140.
HOU Linchao, ZHU Wu, TANG Deqing. Non-intrusive load decomposition method based on deep learning network [J]. Computer Simulation, 2024, 41(2): 137-140.
- [5] 余贻鑫,刘博,栾文鹏.非侵入式居民电力负荷监测与分解技术[J].南方电网技术,2013,7(4):1-5.
YU Yixin, LIU Bo, LUAN Wenpeng. Nonintrusive residential load monitoring and decomposition technology [J]. Southern Power System Technology, 2013, 7(4): 1-5.
- [6] 钱玉军,包永强,姜丹琪,等.非侵入式负荷监测技术研究进展[J].计算机与数字工程,2023,51(2):380-389.
QIAN Yujun, BAO Yongqiang, JIANG Danqi, et al. Research advances in non-intrusive load monitoring technology [J]. Computer & Digital Engineering, 2023, 51(2): 380-389.

- [7] DAMALA R B, PATNAIK R K, DASH A R. A simple decision tree-based disturbance monitoring system for VSC-based HVDC transmission link integrating a DFIG wind farm[J]. Protection and Control of Modern Power Systems, 2022, 7(1): 25.
- [8] 鲍海波, 杨舒惠, 陈子民, 等. 事件检测类非侵入式负荷监测算法综述[J]. 电力系统自动化, 2023, 47(13): 94-109.
BAO Haibo, YANG Shuhui, CHEN Zimin, et al. Review on event-inspection based non-intrusive load monitoring algorithms [J]. Automation of Electric Power Systems, 2023, 47(13): 94-109.
- [9] 牟魁翌, 杨洪耕. 基于PLA-GDTW支持向量机的非侵入式负荷监测方法[J]. 电网技术, 2019, 43(11): 4185-4192.
MOU Kuiyi, YANG Honggeng. Non-intrusive load identification method based on PLA-GDTW support vector machine [J]. Power System Technology, 2019, 43(11): 4185-4192.
- [10] 武昕, 严萌, 郭一凡, 等. 基于结构化特征图谱的组合支持向量机非侵入式负荷辨识[J]. 电力系统自动化, 2022, 46(12): 210-219.
WU Xin, YAN Meng, GUO Yifan, et al. Non-intrusive load identification by combined support vector machine based on structured characteristic spectrum [J]. Automation of Electric Power Systems, 2022, 46(12): 210-219.
- [11] 杜刃刃, 杨超, 马海建. 一种低功率家用负荷的非侵入式识别方法[J]. 电力科学与工程, 2020, 36(5): 1-6.
DU Renren, YANG Chao, MA Haijian. Non-intrusive identification method for low-power household load [J]. Electric Power Science and Engineering, 2020, 36(5): 1-6.
- [12] 吴润泽, 包正睿, 王文韬, 等. Hadoop架构下基于模式匹配的短期电力负荷预测方法[J]. 电工技术学报, 2018, 33(7): 1542-1551.
WU Runze, BAO Zhengrui, WANG Wentao, et al. Short-term power load forecasting method based on pattern matching in hadoop framework [J]. Transactions of China Electrotechnical Society, 2018, 33(7): 1542-1551.
- [13] 谢诗雨, 李君豪, 王劲峰, 等. 基于粒子群优化加权随机森林的非侵入式负荷辨识[J]. 电器与能效管理技术, 2019(9): 22-26.
XIE Shiyu, LI Junhao, WANG Jinfeng, et al. Non-invasive load identification of weighted random forest based on particle swarm optimization [J]. Electrical & Energy Management Technology, 2019(9): 22-26.
- [14] 王高红, 陈潇一. 基于遗传算法的智能电网非侵入式电器监控策略[J]. 智慧电力, 2017, 45(11): 42-46.
WANG Gaohong, CHEN Xiaoyi. Monitoring strategy with non-invasion for electric appliances in smart grid based on genetic algorithm [J]. Smart Power, 2017, 45(11): 42-46.
- [15] WANG H J, SI C, LIU G L, et al. Fed-NILM: a federated learning-based non-intrusive load monitoring method for privacy-protection [J]. Energy Conversion and Economics, 2022, 3(2): 51-60.
- [16] 王守相, 郭陆阳, 陈海文, 等. 基于特征融合与深度学习的非侵入式负荷辨识算法[J]. 电力系统自动化, 2020, 44(9): 103-110.
WANG Shouxiang, GUO Luyang, CHEN Haiwen, et al. Non-intrusive load identification algorithm based on feature fusion and deep learning [J]. Automation of Electric Power Systems, 2020, 44(9): 103-110.
- [17] 杨舒惠, 黎静华, 韦善阳. 基于图像分类网络的非侵入式负荷辨识算法的运算成本优化[J]. 电力自动化设备, 2024, 44(1): 141-146.
YANG Shuhui, LI Jinghua, WEI Shanyang. Computational cost optimization of non-intrusive load identification algorithm based on image classification network [J]. Electric Power Automation Equipment, 2024, 44(1): 141-146.
- [18] LI Z W, LIU Y, QIU P, et al. Highly transferable adversarial attack against deep-reinforcement-learning-based frequency control [J]. Energy Conversion and Economics, 2023, 4(3): 202-212.
- [19] 黄友金, 熊炜, 袁旭峰, 等. 深度学习与幅值特征相融合的低频采样非侵入式负荷辨识算法[J]. 电力科学与工程, 2020, 36(4): 10-16.
HUANG Youjin, XIONG Wei, YUAN Xufeng, et al. Non-intrusive load identification algorithm based on deep learning and amplitude feature fusion at low sampling frequency [J]. Electric Power Science and Engineering, 2020, 36(4): 10-16.
- [20] LI X H, ZHAO B C, LUAN W P, et al. A training-free non-intrusive load monitoring approach for high-frequency measurements based on graph signal processing [C] // 2022 7th Asia Conference on Power and Electrical Engineering (ACPEE). IEEE, 2022: 859-863.
- [21] LI Z B, JIAO Z B, HE A Y, et al. A denoising-classification neural network for power transformer protection [J]. Protection and Control of Modern Power Systems, 2022, 7(4): 1-14.
- [22] ZHANG B, ZHAO S J, SHI Q J, et al. Low-rate non-intrusive appliance load monitoring based on graph signal processing [C] // 2019 International Conference on Security, Pattern Analysis, and Cybernetics (SPAC). IEEE, 2019: 11-16.
- [23] KONG W C, DONG Z Y, HILL D J, et al. A hierarchical hidden Markov model framework for home appliance modeling [J]. IEEE Transactions on Smart Grid, 2018, 9(4): 3079-3090.
- [24] 于超, 覃智君, 阳育德. 基于启停状态识别改进因子隐马尔可夫模型的非侵入式负荷分解[J]. 电网技术, 2021, 45(11): 4540-4550.
YU Chao, QIN Zhijun, YANG Yude. Non-intrusive load disaggregation with improved factorial hidden Markov model considering ON-OFF status recognition [J]. Power System Technology, 2021, 45(11): 4540-4550.
- [25] CHENG S, YU Z H, LIU Y, et al. Power system transient stability assessment based on the multiple paralleled convolutional neural

- network and gated recurrent unit [J]. Protection and Control of Modern Power Systems, 2022, 7(3): 1-16.
- [26] HAN Y H, LI K K, WANG C, et al. Unknown appliances detection for non-intrusive load monitoring based on conditional generative adversarial networks [J]. IEEE Transactions on Smart Grid, 2023, 14(6): 4553-4564.
- [27] SYKIOTIS S, KASELIMI M, DOULAMIS A, et al. Continilm: a continual learning scheme for non-intrusive load monitoring [C] // ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2023: 1-5.
- [28] YIN L F, MA C X. Interpretable incremental voltage-current representation attention convolution neural network for nonintrusive load monitoring [J]. IEEE Transactions on Industrial Informatics, 2023, 19(12): 11776-11787.
- [29] 施雨松, 徐青山, 郑建. 基于特征选择与增量学习的非侵入式电动自行车充电辨识方法 [J]. 电力系统自动化, 2021, 45(7): 87-94.
SHI Yusong, XU Qingshan, ZHENG Jian. Non-intrusive charging identification method for electric bicycles based on feature selection and incremental learning [J]. Automation of Electric Power Systems, 2021, 45(7): 87-94.
- [30] 李昊洋. 低频采样下的非侵入式家居负荷识别方法研究 [D]. 北京: 华北电力大学, 2020.
- [31] GAO J K, GIRI S, KARA E C, et al. PLAID: a public dataset of high-resolution electrical appliance measurements for load identification research; demo abstract [C] // Proceedings of the 1st ACM Conference on Embedded Systems for Energy-Efficient Buildings. ACM, 2014: 198-199.
- [32] KAHL M, Haq A U, KRIECHBAUMER T, et al. WHITED - A Worldwide Household and Industry Transient Energy Data Set [C] // 3rd international workshop on non-intrusive load monitoring, 2016: 1-4.
- [33] WU Y, CHEN Y P, WANG L J, et al. Large scale incremental learning [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2019: 374-382.
- 收稿日期: 2024-09-29
修回日期: 2025-07-03
作者简介:
杨国朝(1988), 男, 工程师, 主要从事电力营销服务、需求侧管理工作;
贾明辉(1984), 男, 硕士, 高级工程师, 主要从事电力营销、智能用电工作;
李子墨(2002), 通信作者(jasonli201274@163.com), 男, 硕士在读, 主要研究方向为非侵入式电力负荷监测;
白辛雨(1991), 女, 硕士, 工程师, 主要从事电力营销、智能用电工作;
于普瑶(1991), 女, 工程师, 主要从事电力计量、用电检查工作;
刘尧(1993), 男, 工程师, 主要从事电力营销、大客户经理工作。
- (责任编辑 车永强)

基于动态电压反馈的变流器锁相同步稳定控制方法

武乃虎¹, 苗伟威¹, 刘露^{2*}, 周海全¹, 孙伶俐¹

(1. 国网山东省电力公司聊城供电公司, 山东 聊城 252000; 2. 山东大学电气工程学院, 山东 济南 250061)

摘要: 跟网型变流器(Grid-following voltage source converter, GFL-VSC)依赖锁相环(phase-locked loops, PLL)与电网保持同步,其在电网故障穿越期间由于电网传输极限降低而面临锁相同步失稳的风险。针对此问题,提出一种基于动态电压反馈的同步稳定控制方法,能够显著改善其在电网故障条件下的锁相同步稳定性。首先,建立了基于PLL同步的GFL-VSC等效摇摆方程,通过等面积准则阐明了故障穿越期间GFL-VSC在平衡点存在的条件下仍发生同步失稳的内在机理。其次,在此基础上构建了基于动态电压反馈的锁相同步稳定控制策略,通过 q 轴电压反馈来自适应地调整故障期间 d 轴电流指令值,能够减缓PLL的加速过程,改善变流器的锁相同步稳定性。最后,通过仿真与实验,验证了所提控制策略的有效性。

关键词: 跟网型变流器; 锁相环; 故障穿越; 等效摇摆方程; 同步稳定性

中图分类号: TM762

文献标志码: A

文章编号: 1007-9904(2025)12-0070-11

PLL Synchronization Stability Control Scheme for Converters Based on Dynamic Voltage Feedback

WU Naihu¹, MIAO Weiwei¹, LIU Lu^{2*}, ZHOU Haiquan¹, SUN Lingyan¹

(1. State Grid Liaocheng Power Supply Company, Liaocheng 252000, China;

2. School of Electrical Engineering, Shandong University, Jinan 250061, China)

Abstract: Grid-following voltage source converter (GFL-VSC) relies on phase-locked loops (PLL) to maintain synchronization with the grid. It faces the risk of PLL synchronization instability due to reducing the transmission limit during grid fault ride-through. To tackle this issue, we propose a PLL synchronization stability control scheme for converters that utilizes dynamic voltage feedback. This scheme significantly enhances the PLL synchronization stability during grid faults. Firstly, the equivalent swing equation of GFL-VSC based on PLL synchronization is established, and the internal mechanism of synchronization instability of GFL-VSC during fault ride-through is elucidated by the equal area criterion (EAC) in the existence of stable equilibrium point (SEP). Secondly, a PLL synchronization stability control scheme based on dynamic voltage feedback is constructed on this basis. This scheme slows down the acceleration process of PLL and improve the PLL synchronization stability of the converter based on the q -axis voltage feedback to adaptively adjust the d -axis current reference value during grid faults. Finally, the effectiveness of the proposed control scheme is verified by simulation and experiment.

Keywords: grid-following voltage source converter; phase-locked loop; fault ride-through; equivalent swing equation; synchronization stability

0 引言

随着新型电力系统中“双高”特征的日益显著,变流器(voltage source converter, VSC)型电源将会对

电力系统稳定性产生越来越严重的影响,这也促使电力系统对并网变流器提出了故障穿越与主动支撑等并网要求^[1-2]。然而,跟网型变流器(grid-following voltage source converter, GFL-VSC)在电网故障条件下面临严重的锁相同步失稳风险,锁相同步失稳将直接导致变流器脱网,影响变流器自身与电力系统的安全与稳定性。因此迫切需要开展GFL-VSC并

基金项目:国网山东省电力公司科技项目(520611230006)。
Science and Technology Project of State Grid Shandong Electric Power Company(520611230006)。

网系统同步稳定与控制方法的研究^[3-4]。

在研究 GFL-VSC 的同步稳定性时,一般将变流器视作理想的可控电流源,建立以锁相环(phase-locked loops, PLL)主导的非线性数学模型^[5-6]。在此模型主导下,GFL-VSC 保持锁相同步稳定存在两个必要条件:稳定平衡点(stable equilibrium point, SEP)的存在性^[7-9]以及系统运行状态能够顺利过渡至 SEP 处^[10]。其中,关于 SEP 的存在性问题已经有了大量的研究,国内外学者提出了多种控制方法以保证 SEP 存在性,因此本文主要关注第二个条件,即系统运行状态能够过渡至 SEP 处。

为分析 GFL-VSC 并网系统的锁相同步动态过程的稳定性,文献[11-13]类比了同步发电机同步稳定性的分析方法,利用等面积准则(equal area criterion, EAC)揭示 GFL-VSC 的同步稳定机理。然而,用 EAC 进行同步稳定分析的前提是忽略系统的阻尼效应,因而分析结果较为保守^[14]。文献[15]采用相图法,通过在 PLL 主导的状态空间平面刻画其 SEP 的稳定域,可以精确分析电网故障期间 PLL 的动态特性,但缺少进一步的定量分析^[14]。在变流器同步稳定性定量分析方面, Lyapunov 法已有较多应用,其原理是通过研究所构造暂态能量函数的临界等位面对系统的同步稳定性进行评估^[16-17]。但该方法只考虑了正阻尼效应下 SEP 的吸引域,因而评估结果具有一定的保守性^[18]。总体来说,虽然上述稳定性分析方法存在一定的局限,但仍是揭示锁相同步失稳内在机理以及刻画 PLL 动态行为的有效方法。

在变流器同步稳定控制的研究领域,当前主要有 PLL 闭锁控制^[19]、自适应电流控制^[20-21]及 PLL 频率反馈控制^[22]等方法。其中, PLL 闭锁控制通过在电网电压跌落后闭锁 PLL 的加减速过程,从而避免其在故障穿越期间与电网产生过大的频率偏差。其虽然能够保持 PLL 的稳定,但是由于无法对端电压正确锁相,会使得 GFL-VSC 无法准确控制输出电流,无法提供无功支撑,与现有并网标准相悖^[23]。自适应电流控制令 GFL-VSC 功率因数角与电网阻抗角保持一致,从而改善锁相同步稳定性。然而,由于需要在电网发生故障后准确辨识出电网的等效阻抗,这类方法难以应用于实际^[23-25]。频率反馈

控制通过引入一条由频率到有功电流指令值的反馈回路,从而能够在 PLL 频率变化后改变有功电流指令值以使其与电网恢复同步。然而,频率反馈控制得到的有功电流指令与系统动态过程相关,会造成有功输出的不确定性^[11]。因此,还需要进一步研究其他提升变流器并网系统同步稳定性的方法。

如前所述,在 SEP 存在的前提下,锁相同步失稳的发生与否取决于 PLL 过渡的过程^[12]。因此,本文主要针对 PLL 动态过程中系统运行状态无法过渡到 SEP 点处的问题,提出一种基于动态电压反馈的同步稳定控制策略。构建了基于锁相同步的等效摇摆方程,通过 EAC 揭示了 SEP 存在条件下仍发生同步失稳的本质原因,即故障穿越期间 PLL 动态引发的加速面积超出系统临界阈值。在此基础上创新性提出动态电压反馈控制策略,通过 q 轴电压反馈实时调整 d 轴电流指令值,本质上相当于增加阻尼以抑制 PLL 的加速过程。相较于 PLL 闭锁控制与频率反馈控制,所提策略在电流控制准确性和确定性方面具有优势,是一种提升锁相同步稳定性的实用方法。通过 DIgSILENT PowerFactory 仿真平台与硬件在环实验平台验证了所提策略的有效性。

1 锁相环同步模型

GFL-VSC 并网系统如图 1 所示。该变流器依托 PLL 与交流电网实现相位同步。图 1 中 PLL 与电流控制构成闭环控制,通过其可以探究 GFL-VSC 锁相同步稳定的基本特性。图 1 中, $U = U_d + jU_q$ 为并网点(point of common coupling, PCC)电压矢量, $E = E_d + jE_q$ 为交流电网内电势, $I = I_d + jI_q$ 为电流矢量, R 和 L 分别代表线路电阻和电感, L_f 和 C_f 分别为网侧滤波电感和电容, U_{dc} 和 i_{dc} 为直流母线电压和电流, $\Delta\omega_{PLL}$ 和 δ 分别为 PLL 坐标系相对于同步旋转坐标系的转速和相位角, I_{dqref} 为 dq 轴电流指令值。下标 dq 分别表示电压/电流在 dq 轴下的分量,下标 abc 表示三相静止坐标系下的电压/电流。

此外,为保证电流指令的快速跟踪,电流环带宽一般远大于 PLL 带宽,因此在研究 PLL 的动态同步过程时可以忽略电流环的动态特性,认为 dq 轴电流实际值等于其指令值。




图1 基于PLL同步的并网变流器

Fig.1 Grid-connected converter based on PLL synchronization

结合图1所示PLL控制原理,可得其控制方程为

$$\begin{cases} \frac{d\delta}{dt} = \Delta\omega_{PLL} \\ \frac{d\Delta\omega_{PLL}}{dt} = K_{PLL-p} \frac{dU_q}{dt} + K_{PLL-i} U_q \\ \Delta\omega_{PLL} = \Delta\omega_{PLL-p} + \Delta\omega_{PLL-i} \end{cases} \quad (1)$$

式中: K_{PLL-p} 和 K_{PLL-i} 分别为PLL控制器的比例和积分系数; $\Delta\omega_{PLL-p}$ 和 $\Delta\omega_{PLL-i}$ 分别为PLL的比例环节和积分环节。

结合图1,可得网络方程为

$$\begin{cases} U = E + (R + jX)I \\ jX = j\omega_n L \end{cases} \quad (2)$$

式中: ω_n 为系统基准频率。

将电压矢量投影至PLL坐标系中,可得 U 的 dq 轴分量为

$$\begin{bmatrix} U_d \\ U_q \end{bmatrix} = \begin{bmatrix} E \cos \delta \\ -E \sin \delta \end{bmatrix} + \begin{bmatrix} R & -X \\ X & R \end{bmatrix} \begin{bmatrix} I_d \\ I_q \end{bmatrix} \quad (3)$$

式中: I_d 和 I_q 分别为输出电流的 d 轴、 q 轴分量。

基于式(1)一式(3),选取 $x_1 = \delta$ 和 $x_2 = \Delta\omega_{PLL-i}$ 作为状态变量,则可得到其状态空间方程为

$$\begin{cases} \dot{x}_1 = x_2 + K_{PLL-p} (-E \sin x_1 + I_d X + I_q R) \\ \dot{x}_2 = K_{PLL-i} (-E \sin x_1 + I_d X + I_q R) \end{cases} \quad (4)$$

2 锁相同步失稳机理分析

系统存在SEP是变流器锁相同步稳定的前提。当PLL达到其平衡状态时, U 与PLL的 d 轴同向,表明此时 $U_q = 0$ 。将这一条件代入式(3),可得PLL与电网保持同步的准稳态方程为

$$-E \sin \delta + I_d X + I_q R = 0 \quad (5)$$

根据式(5)可得,在不考虑线路电阻的情况下,只要设定变流器的有功电流指令值 $|I_d| \leq E/X$,就能确

保SEP存在。

然而,即使满足上述静态稳定条件,并网变流器在PLL动态过程中仍存在锁相同步失稳的风险。考虑到基于PLL的同步方程与转子运动方程有相似形式,通过EAC对锁相同步失稳机理进行分析。

取式(3) q 轴电压分量并忽略交流网络电阻影响,对其关于 δ 求导为

$$\frac{dU_q}{dt} = -E \cos \delta \frac{d\delta}{dt} + LI_d \frac{d\Delta\omega_{PLL}}{dt} \quad (6)$$

结合式(1)并忽略系统阻尼对同步稳定性的影响,可得基于PLL的同步方程为

$$J \frac{d\Delta\omega_{PLL}}{dt} = I_d - I_{dmax} \sin \delta \quad (7)$$

式中: J 为等效惯性时间常数,表征系统抗干扰能力,满足 $J = (1 - K_{PLL-p} I_d L) / K_{PLL-i} X$; I_{dmax} 为有功电流传输极限,满足 $I_{dmax} = E/X$ 。

对式(7)等号两边积分,可以得到

$$\frac{J}{2} \Delta\omega_{PLL}^2 = \int_{\delta_a}^{\delta_t} (I_d - I_{dmax} \sin \delta) d\delta \quad (8)$$

式中: δ_a 为初始时刻等效功角; δ_t 为 t 时刻等效功角。与同步机功率同步相似,变流器扰动后重新稳定的条件为 I_d 与 $I_{dmax} \sin \delta$ 在 $[\delta_a, \delta_t]$ 区间形成的面积为零。

本节以故障穿越期间注入有功电流固定为分析场景,分析电网电压跌落时变流器的锁相同步失稳机理。图2给出了暂态过程中式(7)所示的 $I_d - \delta$ 曲线,其中 a 为变流器正常运行时的初始平衡点, u 为不稳定平衡点(unstable equilibrium point, UEP)。




图2 同步稳定性分析示意图

Fig.2 Transient stability analysis diagram

电网电压跌落时,并网变流器与外部电网间的有功功率传输容量会有所下降,使得 $I_{dmax} \sin \delta$ 曲线由

蓝色变为橙色,如图2所示。此时系统工作点由 a 变至 b ,可以发现 b 点处 $(I_d - I_{d2\max}\sin\delta) > 0$,根据式(7)可知 PLL 转速不断增加,在此过程中 PLL 动能增加。当 $\delta = \delta_s$ 时,系统到达了故障下的稳定运行点 s ,系统的加速面积可表示为

$$S_+ = \int_{\delta_c}^{\delta_s} (I_d - I_{d\max}\sin\delta) d\delta \quad (9)$$

当 $\delta > \delta_s$ 后,PLL 开始减速,相应地 PLL 动能降低,所降低的动能转变为势能。此时最大的减速面积如 S_- 所示,可表示为

$$S_- = \int_{\delta_s}^{\delta_c} (I_{d\max}\sin\delta - I_d) d\delta \quad (10)$$

综合上述分析,为了确保并网变流器在故障穿越期间的锁相同步稳定,必须满足条件 $S_+ < S_-$,否则 PLL 转速持续增大,最终到达频率上限与电网失去同步,出现频率上升型同步失稳现象。需要注意的是,EAC 方法虽然在忽略阻尼的条件下存在一定的保守性,但仍是反映锁相同步失稳内在机理的有效方法^[17]。

此外,在 EAC 法分析的基础上,可以进一步采用相图法对故障期间 PLL 的动态特性进行刻画,以分析考虑阻尼条件下的锁相同步稳定性^[15]。结合式(4)可以描绘并网变流器在故障发生后的动态过程,进而得到其 SEP 的吸引域,如若其动态过程超出稳定边界,即会引发锁相同步失稳,如图3所示。




图3 PLL吸引域

Fig.3 Stability region of PLL

3 基于动态电压反馈的同步稳定控制

3.1 控制策略设计

目前已有基于频率反馈的控制策略来保证锁相同步稳定。然而,文献[25]中已经指出,基于频率反馈的控制策略会造成故障后功率输出的不确定性,

因此本文将寻求除频率反馈控制之外的其他控制方法。

反馈控制策略设计的核心在于区分哪些信息能够反映系统的稳定状态。在频率反馈控制中,由于频率的高低可以反映系统的锁相同步稳定状态,因此可以通过频率反馈来实现稳定控制,如图4所示。

实际上,PLL 频率的高低是由其 q 轴电压所驱动的, q 轴电压的正负同样可以反映系统的稳定状态。因此本文提出一种基于动态电压反馈的变流器同步稳定控制策略,通过 q 轴电压反馈来实时反映故障穿越期间并网变流器与电网的同步状态,基于 q 轴电压偏差信号来修改注入的 d 轴电流指令值,从而改善变流器的锁相同步稳定性。所提策略的控制结构如图5所示。在 PLL 加速过程中,端电压相位超前于 PLL 相位,此时 q 轴电压为正值,在此期间通过减小 d 轴电流指令值可以减缓 PLL 的加速过程,能够有效避免锁相同步失稳。

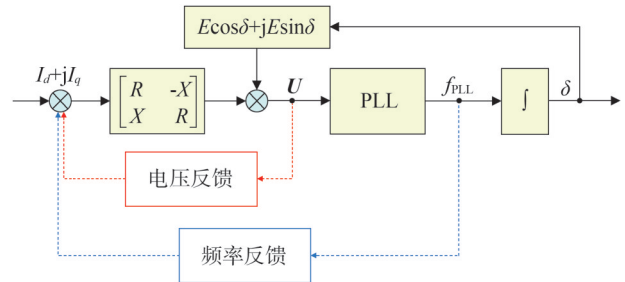


图4 频率反馈与电压反馈

Fig.4 Frequency feedback and voltage feedback

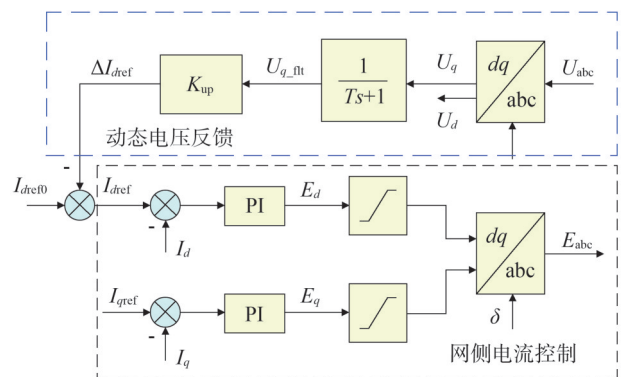


图5 基于动态电压反馈的同步稳定控制策略

Fig.5 Synchronous stability control scheme based on dynamic voltage feedback

当 PLL 与电网同步时,并网点电压 U 定向于 PLL 坐标系的 d 轴,此时 $U_q = 0$,而当系统受到大干扰导致 PLL 与电网不同步时, U 始终与 PLL 坐标系的 d 轴存在一定角度,从而使 $U_q \neq 0$ 。基于上述分析,所提控制策略本质上是通过 PLL 对端电压的跟踪状态来自适应地调整故障期间 d 轴电流指令值,提升系统的锁相同步稳定性。

结合图 5,采用所提控制策略后的 d 轴电流参考值可表示为

$$\begin{cases} U_{q_flt} = \frac{1}{Ts + 1} U_q \\ \Delta I_{dref} = -K_{uq} U_{q_flt} \\ I_{dref} = I_{dref0} + \Delta I_{dref} \end{cases} \quad (11)$$

式中: T 为 U_q 滤波时间常数,是根据 PLL 与电流环的动态响应时间差异来确定的,其选择要介于二者动态响应时间之间,一般可选取 $0.02 \sim 0.2 \text{ s}^{[26]}$; U_{q_flt} 为 U_q 滤波后的电压; I_{dref} 为 d 轴电流指令值; I_{dref0} 为 d 轴电流稳态值; ΔI_{dref} 为 d 轴电流变化量; K_{uq} 为动态反馈控制系数,其对锁相同步稳定性的作用可以通过对戴维南等值参数 X_{eq} 和 E_{eq} 的影响来表征。交流侧电网戴维南等值电路如图 6 所示。




图 6 交流侧电网戴维南等值电路

Fig.6 Thevenin equivalent circuit of the AC grid

根据图 6 可以写出 dq 坐标系下交流电网侧 q 轴电压的表达式为

$$U_q = I_{d0} X_{eq} - E_{eq} \sin \delta \quad (12)$$

而当采取动态电压反馈控制策略后, q 轴电压表达式变化为

$$\begin{cases} U_q = (I_{d0} - K_{uq} U_q) X_{eq} - E_{eq} \sin \delta \\ \Downarrow \\ U_q = \frac{1}{1 + K_{uq} X_{eq}} (I_{d0} X_{eq} - E_{eq} \sin \delta) \end{cases} \quad (13)$$

由式(13)可以看出,采取所提动态电压反馈控制策略后, U_q 以 $1/(1+K_{uq}X_{eq})$ 系数成比例缩小,导致 PLL 的加速过程减缓,从而避免 PLL 加速面积太大

造成的锁相同步失稳。定义 $1/(1+K_{uq}X_{eq})$ 为 U_q 所产生加速面积的缩放系数,该指标的大小影响了系统的锁相同步稳定性,由此可以依据该指标对动态反馈系数 K_{uq} 进行整定。

3.2 同步稳定性分析

所提控制策略考虑了 q 轴电压的一阶滤波,使得以 PLL 主导的状态空间方程维数发生变化。基于式(1)一式(3)以及式(11),并考虑交流网络电阻影响,选取 $x_1 = \delta$ 、 $x_2 = \Delta\omega_{PLL-i}$ 和 $x_3 = U_{q_flt}$ 作为状态变量,可得状态空间方程为

$$\begin{cases} \dot{x}_1 = x_2 + AK_{PLL-P} \\ \dot{x}_2 = AK_{PLL-i} \\ \dot{x}_3 = (A - x_3)/T \end{cases} \quad (14)$$

式中: A 为中间变量,其值为

$$A = -E \sin x_1 + I_{d0} X + I_q R - K_{uq} X x_3 \quad (15)$$

通过上述状态空间方程可以绘制无电压反馈策略、本文所提动态电压反馈策略的 SEP 吸引域及相应的系统状态过渡过程,基于相图法定量分析所提策略对锁相同步稳定性的影响,如图 7 和图 8 所示。

由图 7 可以看出,两种控制策略下所对应的 SEP 和 UEP 是不变的,当采取所提出的动态电压反馈控制策略时,SEP 的吸引域变大。无电压反馈时不能稳定的区域在所提策略下是可以稳定的,表明系统稳定性在所提策略下有所提升。




图 7 不同控制策略下 SEP 吸引域对比

Fig.7 Comparison of SEP stability region with different control schemes

图 8 展示了采取不同控制策略时不同初始点处系统状态的过渡过程。在故障发生前,GFL-VSC 与系统保持同步,因此不同初始运行点处均满足 $\Delta\omega_{PLL-i} = 0$ 。然而,如图 8 (a)中红色虚线圆中所示,当初始角度较小时,PLL 在故障发生后经历较长的加速过程,在越过 SEP 后由于不能及时减速从而

最终与外部电网失去同步。而当采取所提动态电压反馈控制策略时,动态电压反馈减缓了 PLL 的加速过程,使其在故障发生后能够快速过渡到稳定平衡点,有效提升了其同步稳定性,如图 8 (b)所示。

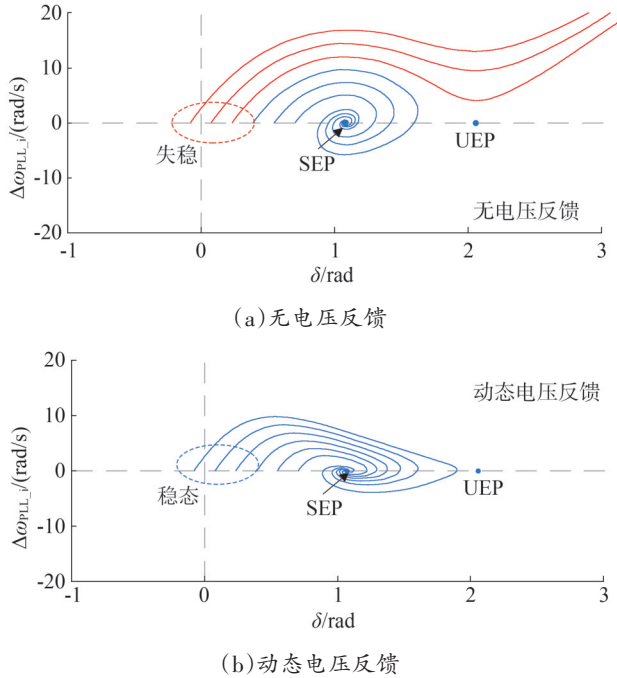


图8 不同控制策略动态过程对比

Fig.8 Comparison of dynamic processes with different control schemes

此外,当初始角度较大时,无电压反馈策略便能使系统状态过渡到 SEP 点处。与之相比,所提策略本质上是通过增大阻尼来减缓 PLL 的加速过程,使其在故障发生后更加快速地向 SEP 点处过渡。

3.3 与现有策略的对比分析

如表 1 所示,虽然当前三种典型的同步稳定控制方法具有一定的优势,但仍存在电流控制准确性、确定性方面的问题,为此本文提出一种基于动态电压反馈同步稳定控制方法,在一定程度上解决了当前方法存在的缺陷。

本文所提动态电压反馈控制策略是在 SEP 存在的前提下,通过 q 轴电压反馈调整有功电流指令值,确保在 PLL 的动态过程中系统运行点能够收敛于 SEP 点。但对于 PLL 不存在平衡点的情况,该策略无法保证系统的锁相同步稳定性,还需要与已有控制策略相配合以提升本文所提控制策略的普适性^[8]。

表 1 与现有稳定控制策略对比分析

Table 1 Comparative analysis with existing stability control schemes

方法	文献	优点	缺点
PLL 闭锁控制	[19]	易于实现	存在静态控制误差
PLL 频率反馈控制	[20]	易于实现	有功输出具有不确定性
自适应电流控制	[22]	保证最大的稳定裕度	实现困难 较大的保守性
本文控制		实现简单 无静态控制误差 确定性有功输出	具有一定的保守性 ^[8]

4 仿真实验

为验证所提策略的有效性,在 DIGSILENT PowerFactory 中搭建仿真模型进行仿真验证,电网的拓扑结构如图 9 所示。系统故障设置:电网电压 E 初始值为 1 pu, $t=0.5$ s 时突然跌落至 0.32 pu。仿真过程中假定 U_{dc} 保持恒定。仿真系统参数如表 2 所示。基于以下 3 个案例验证所提控制策略的有效性。

案例一:验证所提控制策略提升系统的锁相同步稳定性;

案例二:验证所提控制策略相比于 PLL 闭锁控制策略在电流控制准确性方面的优势;

案例三:验证所提控制策略相比于 PLL 频率反馈在有功控制确定性方面的优势。




图9 仿真拓扑图

Fig.9 Simulation topology diagram

4.1 所提控制策略有效性验证

如前所述,设定有功电流指令在有功电流限值内即可确保 SEP 存在。然而,在频率上升型同步失稳场景下,即使系统存在 SEP,并网变流器也可能面临着因 PLL 加速面积太大而导致的锁相同步失稳风险,下面验证所提控制策略对于上述场景下同步稳

定性的提升效果。

表2 系统参数
Table 2 System parameters

系统部分	参数	取值
系统基准	S_B/MW	2
	U_B/kV	0.69
	$\omega_B/(\text{rad/s})$	100π
VSC	L_f/pu	0.033
	I_{dref}/pu	0.55
	I_{qref}/pu	0.1
	K_{uq}	5
	T	0.1
	K_{PLL_p}/K_{PLL_i}	41/1 500
网络参数	E/pu	1
	$L/(\Omega/\text{km})$	40

图10展示了并网变流器分别采用无电压反馈策略以及本文所提动态电压反馈策略的仿真结果。由仿真结果可得:无电压反馈时,PLL转速在故障过程中始终大于1,说明PLL和外部电网间的角度差不断增大,从而引起锁相同步失稳,导致并网点电压振荡;而采用所提策略时,PLL能在故障后迅速锁定电网频率,避免了锁相同步失稳,保证了PLL转速和并网点电压的稳定,提升了系统的同步稳定性。




图10 锁相同步稳定仿真验证案例一仿真结果
Fig.10 PLL synchronization stability simulation results of case 1

此外,无电压反馈时系统虽然存在SEP($U_q=0$),但故障发生后 q 轴电压幅值持续波动,不能重新恢复至零,而所提策略使得 q 轴电压幅值在故障后逐渐趋向于0,PLL矢量控制恢复正常,实现了并网变流器的暂态同步稳定。

考虑到系统在实际运行中发生不对称故障导致电网电压不平衡的情况很多,本文在 $t = 0.5 \text{ s}$ 时设置电网电压跌落至0.32 pu后,在 $t = 1.5 \text{ s}$ 时再设置并网点电压两相短路故障,锁相环转速以及 q 轴电压的仿真结果如图11所示。

通过图11所示的无电压反馈策略以及本文所提动态电压反馈策略仿真结果的对比,进一步验证了所提策略能够在更复杂的故障场景中保证SEP存在条件下GFL-VSC的锁相同步稳定性。但不对称故障发生时并网点三相电压不再保持对称,因此会影响到PLL的同步性能,导致其输出转速和相角出现波动,如图11 PLL转速所示。




图11 不对称故障下锁相同步稳定仿真验证案例一仿真结果
Fig.11 PLL synchronization stability simulation results of case 1 under asymmetric fault

4.2 与其他控制策略效果对比

4.2.1 对比PLL闭锁控制策略

基于PLL闭锁控制策略的仿真结果如图12所示。图中 I_p 和 I_q 分别表示有功和无功电流。仿真结果表明:在该控制策略下,PLL转速能够保持恒定,从而有效保证了系统的锁相同步稳定性。但闭锁后

的 PLL 无法检测故障后端电压的相位角,导致稳态 q 轴电压存在静态误差,造成 dq 轴电流与有功/无功电流存在偏差,从而导致故障期间无法准确控制电流输出,与现有并网标准相悖。




图 12 锁相同步稳定仿真验证案例二仿真结果—基于 PLL 闭锁控制策略

Fig.12 PLL synchronization stability simulation results of case 2-PLL blocking-based control scheme

而本文所提策略既能保证锁相同步稳定,又能够准确控制有功/无功电流,其仿真结果如图 13 所示。




图 13 锁相同步稳定仿真验证案例二仿真结果-基于所提策略
Fig.13 PLL synchronization stability simulation results of case 2- the proposed control scheme

4.2.2 对比 PLL 频率反馈控制策略

PLL 频率反馈控制策略根据检测到的频率偏差来调节 d 轴电流指令,从而保证锁相同步稳定。然而,PLL 频率反馈控制策略受其积分环节的影响,无法给出确定的运行点,其最终得到的 d 轴电流指令与积分环节的动态过程相关,具有一定的不确定性。下面验证所提策略相对于 PLL 频率反馈在有功控制确定性方面的优势。PLL 转速以及 d 轴电流指令仿真结果如图 14 所示。




图 14 锁相同步稳定仿真验证案例三仿真结果
Fig.14 PLL synchronization stability simulation results of case 3

由图 14 可知,采用所提策略和 PLL 频率反馈控制均能够保证锁相同步稳定,并且两种控制策略均能使故障发生后的锁相环转速快速回到稳定平衡点。然而,受积分环节的影响,PLL 频率反馈控制给出的运行点具有不确定性,不同动态过程对应的积分终值是不同的,给定不同的频率反馈比例积分系数 K_p 和 K_i ,得到的稳态 d 轴电流不同,这将造成电流指令的不确定性,会对电力系统稳定分析与继电保护系统设计带来巨大的挑战。相比之下,由于所提控制策略中不基于频率信息,也不存在积分环节,故障后运行点的动态过渡过程不会对稳态电流造成影响,因此相比于 PLL 频率反馈控制策略在稳态电流的确定性方面具有优势。

5 实验验证

基于两电平逆变器对所提策略的有效性进行实验验证。以两电平逆变器模拟并网变流器,以电网模拟器模拟电网运行状态和故障行为,二者通过线路电阻和电感相连。系统故障设置:电网电压 E 从 1 pu 跌落至 0.22 pu。实验平台拓扑结构以及相应的参数分别如图 15 和表 3 所示。

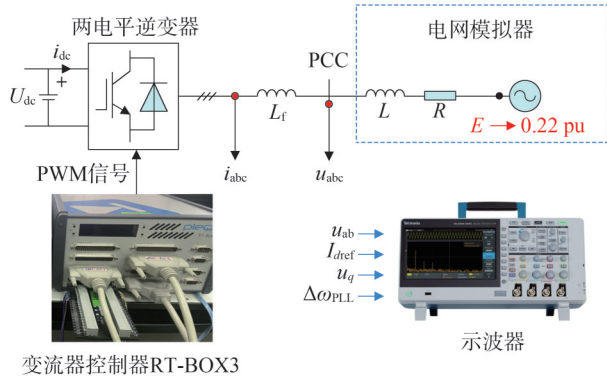


图 15 锁相同步稳定实验验证拓扑结构

Fig.15 Verification of topology structure through PLL synchronization stability experiment

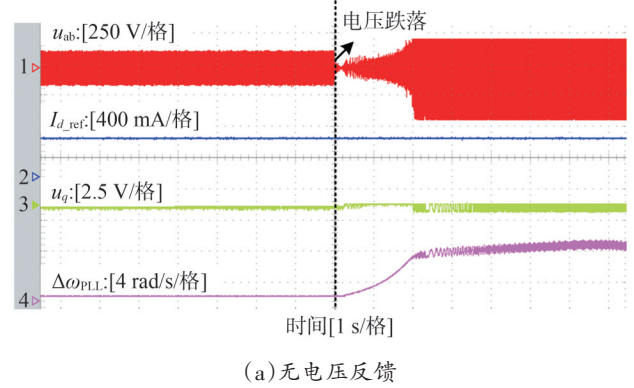
表 3 实验参数

Table 3 Experimental parameters


参数	取值
直流母线电压 U_{dc}/V	200
额定功率 S_B/W	750
额定电压 U_B/V	86.6
额定频率 $\omega_B/(rad/s)$	100π
网侧滤波电感 L_f/mH	5
PLL PI 调节系数 K_{PLL_d}/K_{PLL_i}	0.13/4.77
线路电阻 R/pu	0.02
线路电感 L/pu	0.4

故障前,并网变流器输出有功、无功功率分别为 0.5 pu 和 0.1 pu。在外部电网电压跌落,令并网变流器分别采用无电压反馈控制策略以及本文提出的动态电压反馈控制策略,实验结果如图 16 所示。从实验结果可知:无电压反馈时,在该故障场景下 PLL 转速持续增大,从而引起锁相同步失稳,进一步导致并网点电压失稳;而采用所提策略时,基于 q 轴电压

动态调节 d 轴电流指令值,有效减缓 PLL 的加速过程,保证了并网变流器的锁相同步稳定。



(a) 无电压反馈



(b) 动态电压反馈

图 16 锁相同步稳定实验结果

Fig.16 PLL synchronization stability experiment results

6 结论

提出了一种基于动态电压反馈的锁相同步稳定控制策略,通过 q 轴电压反馈自适应地调整故障期间 d 轴电流指令值,提升了 SEP 存在条件下的暂态稳定性。文章主要结论如下:

1) 在 SEP 存在的条件下,PLL 加速面积过大是导致并网变流器锁相同步失稳的主要原因。所提控制策略通过 q 轴电压反馈动态调整 d 轴电流指令,其实质是通过增大阻尼来减缓 PLL 的加速过程,从而使系统运行点在故障后快速向 SEP 点处过渡。

2) 相比于 PLL 闭锁控制策略,所提控制策略可以保证电流控制的正确性;相比于 PLL 频率反馈控制策略,所提控制策略可以避免电流指令和有功输出的不确定性。与现有控制策略相比,所提控制策略具有一定的优势,是一种提升锁相同步稳定性的实用方法。

参考文献

- [1] 杨霞,李琛,杨路勇,等.风电并网逆变器的双闭环自抗扰控制策略研究[J].山东电力技术,2022,49(11):70-77.
YANG Xia, LI Chen, YANG Luyong, et al. Research on double closed-loop active disturbance rejection control strategy of wind power grid-connected inverter[J].Shandong Electric Power, 2022, 49(11):70-77.
- [2] 弭轍,胡健祖,郭珍妮,等.新型电力系统体系下新能源发展态势及市场化消纳研究[J].山东电力技术,2023,50(10):1-8.
MI Zhe, HU Jianzu, GUO Zhenni, et al. Research on the development situation and market-oriented consumption of renewable energy under new power system architecture [J]. Shandong Electric Power, 2023, 50(10):1-8.
- [3] 黄林彬,辛焕海,鞠平,等.电力电子并网装备的同步稳定分析与统一同步控制结构[J].电力自动化设备,2020,40(9):10-25.
HUANG Linbin, XIN Huanhai, JU Ping, et al. Synchronization stability analysis and unified synchronization control structure of grid-connected power electronic devices [J]. Electric Power Automation Equipment, 2020, 40(9):10-25.
- [4] 田雨果,王彤,邢其鹏,等.计及虚拟惯量控制与低电压穿越的光伏发电系统暂态稳定分析[J].电力系统保护与控制,2022,50(2):52-59.
TIAN Yuguo, WANG Tong, XING Qipeng, et al. Transient stability analysis of a photovoltaic generation system considering virtual inertia control and low voltage ride-through [J]. Power System Protection and Control, 2022, 50(2):52-59.
- [5] 窦宇宇,林楠,任正,等.风电机组大扰动暂态过电压机理分析及优化抑制[J].山东电力技术,2023,50(5):28-33.
DOU Yuyu, LIN Nan, REN Zheng, et al. Mechanism analysis and optimization suppression strategy of large disturbance transient overvoltage of wind turbine [J]. Shandong Electric Power, 2023, 50(5):28-33.
- [6] 陈思谕,邹艳丽,傅杰.互联电网的同步及稳定性研究[J].山东电力技术,2021,48(5):29-36.
CHEN Siyu, ZOU Yanli, FU Jie. Study on synchronization and stability of interconnected power grid[J].Shandong Electric Power, 2021, 48(5):29-36.
- [7] WU H, WANG X F. Design-oriented transient stability analysis of PLL-synchronized voltage-source converters [J]. IEEE Transactions on Power Electronics, 2020, 35(4):3573-3589.
- [8] WANG Z H, DING L, GAO X S, et al. Improved active current control scheme of wind energy conversion systems with PLL synchronization during grid faults [J]. IEEE Transactions on Sustainable Energy, 2023, 14(1):717-729.
- [9] 李琳,张晓楠,李庚银,等.考虑内外环交互作用的VSG并网振荡特性[J].电力建设,2024,45(4):66-76.
LI Lin, ZHANG Xiaonan, LI Gengyin, et al. Characteristics of VSG grid-connected system oscillation considering the interaction between inner and outer loops [J]. Electric Power Construction, 2024, 45(4):66-76.
- [10] WANG X S, WU H, WANG X F, et al. Transient stability analysis of grid-following VSCs considering voltage-dependent current injection during fault ride-through [J]. IEEE Transactions on Energy Conversion, 2022, 37(4):2749-2760.
- [11] 柳飞扬,曾平,李征.电网故障下全功率风电场内部机组的暂态稳定性分析[J].电力系统保护与控制,2022,50(5):43-54.
LIU Feiyang, ZENG Ping, LI Zheng. Transient stability analysis of wind turbines with a full-scale converter under grid fault [J]. Power System Protection and Control, 2022, 50(5):43-54.
- [12] HU Q, FU L J, MA F, et al. Impact of LVRT control on transient synchronizing stability of PLL-based wind turbine converter connected to high impedance AC grid [J]. IEEE Transactions on Power Systems, 2023, 38(6):5445-5458.
- [13] HE X Q, GENG H, LI R Q, et al. Transient stability analysis and enhancement of renewable energy conversion system during LVRT [J]. IEEE Transactions on Sustainable Energy, 2020, 11(3):1612-1623.
- [14] TAUL M G, WANG X F, DAVARI P, et al. An overview of assessment methods for synchronization stability of grid-connected converters under severe symmetrical grid faults [J]. IEEE Transactions on Power Electronics, 2019, 34(10):9655-9670.
- [15] HU Q, FU L J, MA F, et al. Large signal synchronizing instability of PLL-based VSC connected to weak AC grid [J]. IEEE Transactions on Power Systems, 2019, 34(4):3220-3229.
- [16] 纪泰鹏,赵伟,李永达,等.基于能量函数法的含虚拟惯性控制直驱风电场内部暂态同步稳定性分析[J].电力系统保护与控制,2022,50(22):38-48.
JI Taipeng, ZHAO Wei, LI Yongda, et al. Transient synchronization stability analysis of PMSG-based wind farm with virtual inertial control based on an energy function method [J]. Power System Protection and Control, 2022, 50(22):38-48.
- [17] TIAN Z, TANG Y J, ZHA X M, et al. Hamilton-based stability criterion and attraction region estimation for grid-tied inverters under large-signal disturbances [J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2021, 10(1):413-423.
- [18] ZARIF MANSOUR M, ME S P, HADAVI S, et al. Nonlinear transient stability analysis of phased-locked loop-based grid-following voltage-source converters using Lyapunov's direct method [J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2022, 10(3):2699-2709.
- [19] WEISE B. Impact of K-factor and active current reduction during fault-ride-through of generating units connected via voltage-sourced converters on power system stability [J]. IET Renewable Power Generation, 2015, 9(1):25-36.
- [20] 刘璐,耿华,马少康,等.低电压穿越过程中DFIG型风电场同步

- 稳定及无功电流控制方法[J].中国电机工程学报,2017,37(15):4399-4407.
- LIU Lu, GENG Hua, MA Shaokang, et al. Synchronization stability and reactive current control method of DFIG wind farm during low voltage ride through [J]. Proceedings of the CSEE, 2017, 37(15): 4399-4407.
- [21] MA S K, GENG H, LIU L, et al. Grid-synchronization stability improvement of large scale wind farm during severe grid fault[J]. IEEE Transactions on Power Systems, 2018, 33(1): 216-226.
- [22] GÖKSU Ö, TEODORESCU R, BAK C L, et al. Instability of wind turbine converters during current injection to low voltage grid faults and PLL frequency based stability solution [J]. IEEE Transactions on Power Systems, 2014, 29(4): 1683-1691.
- [23] PEI J X, YAO J, LIU R K, et al. Characteristic analysis and risk assessment for voltage-frequency coupled transient instability of large-scale grid-connected renewable energy plants during LVRT [J]. IEEE Transactions on Industrial Electronics, 2020, 67(7): 5515-5530.
- [24] YUAN H, XIN H H, HUANG L B, et al. Stability analysis and enhancement of type-4 wind turbines connected to very weak grids under severe voltage sags [J]. IEEE Transactions on Energy Conversion, 2019, 34(2): 838-848.
- [25] WANG Z H, ZHU G F, WU H, et al. Current reference control scheme of voltage source converters to ensure the existence of stable equilibrium points during grid fault [J]. IEEE Transactions on Power Electronics, 2023, 38(9): 10750-10765.
- [26] 王一珺,王海风.直流电压动态时间尺度下大规模直驱风电场振荡稳定性及参数稳定域分析[J].中国电机工程学报,2021,41(增刊1):92-107.
- WANG Yijun, WANG Haifeng. Analysis of oscillation stability and stability region of parameters in large-scale direct-drive wind farms under DC voltage dynamic time scale [J]. Proceedings of the CSEE, 2021, 41(S1): 92-107.
-
- 收稿日期:2024-11-30
修回日期:2025-03-17
- 作者简介:
武乃虎(1984),男,硕士,高级工程师,主要研究方向为系统安全与保护;
苗伟威(1985),男,博士,高级工程师,主要研究方向为电力系统运行与控制;
刘露(1999),通信作者(202214622@mail.sdu.edu.cn),女,硕士在读,主要研究方向为新能源并网稳定与控制;
周海全(1986),男,硕士,高级工程师,主要研究方向为新能源并网技术;
孙伶俐(1995),女,博士,工程师,主要研究方向为系统保护与控制。
- (责任编辑 郑天茹)

DOI: 10.20097/j.cnki.issn1007-9904.240518

基于扰动观测器的并网逆变器鲁棒模型预测控制

滕飞^{1*}, 吴俊俊¹, 姜辰², 黄昊怡¹, 黄堃¹

(1. 中国能源建设集团浙江省电力设计院有限公司, 浙江 杭州 310000;

2. 国网浙江省电力有限公司杭州供电公司, 浙江 杭州 310000)

摘要: 并网逆变器的模型预测控制技术因其无须设计比例积分控制器等优点而得到诸多学者的探索和研究。然而, 常规的并网逆变器模型预测控制技术对逆变器参数变化较敏感, 一旦滤波电感等参数失配, 将显著降低模型预测的控制精度。为解决该问题, 提出一种利用扰动观测器进行参数扰动在线观测, 并将观测结果用于补偿改进型并网逆变器控制策略。该方法首先通过修改并网逆变器的数学模型将其表达为已知电压信号与未知集总扰动之和的形式, 然后设计一种扰动观测器, 对集总扰动进行观测, 并利用观测的扰动补偿模型预测控制策略, 从而得到一种对参数变化具有较强鲁棒性的模型预测控制方法。该方法显著克服了电感等参数的失配对模型预测控制的负面影响, 提高了并网逆变器的模型预测控制精度。基于 MATLAB/Simulink 的仿真结果证明了本文所提方法的优越性。

关键词: 并网逆变器; 扰动观测器; 模型预测控制; 鲁棒性

中图分类号: TM46

文献标志码: A

文章编号: 1007-9904(2025)12-0081-11

Robust Model Predictive Control for Grid-connected Inverters Based on Disturbance Observer

TENG Fei^{1*}, WU Junjun¹, JIANG Chen², HUANG Haoyi¹, HUANG Kun¹

(1. China Energy Engineering Group Zhejiang Electric Power Design Institute Co., Ltd., Hangzhou 310000, China;

2. State Grid Hangzhou Power Supply Company, Hangzhou 310000, China)

Abstract: The model predictive control technology of grid-connected inverters has been explored and studied by many scholars in academia and industry because of its advantages such as not being required to design proportional integral controllers. However, the conventional model predictive control technology of grid-connected inverters is sensitive to variations in inverter parameters. Once the filter inductance or other parameters are mismatched, the control accuracy of model predictive control will be significantly reduced. To solve this problem, an improved control strategy of the grid-connected inverter is proposed in this paper, which uses a disturbance observer to achieve parameter perturbation on-line observation and uses the observation results to compensate the model predictive control. The mathematical model of the grid-connected inverter is modified to be expressed as the sum of the known voltage signal and the unknown lumped disturbance first. Then, a disturbance observer is designed to observe the lumped disturbance, and the observed disturbance is used to compensate the model predictive control strategy. Finally, a model predictive control method with strong robustness to parameter mismatch is obtained. The proposed method effectively mitigates the adverse effects of parameter mismatches, such as inductance variations, on model predictive control, thereby improving the control accuracy of grid-connected inverters. Simulation results obtained using MATLAB/Simulink verify the superiority of the proposed method.

Keywords: grid-connected inverter; disturbance observer; model predictive control; robust

0 引言

近年来, 随着光伏发电、风力发电、储能、微电

网、新能源汽车等技术的飞速发展, 并网逆变器及其高性能控制技术得到越来越多的关注和研究^[1-4]。

并网逆变器的先进控制策略决定了其电能变换

效率及输出电能质量。常用的逆变器控制技术主要包括基于电网电压定向的矢量控制、基于虚拟磁链定向的矢量控制、基于开关表的直接功率控制等^[5-6]。然而,矢量控制技术需要多个坐标变换运算,需要设计多个比例积分控制器参数。这导致这类方法实现较为复杂。直接功率控制方法通过离线设计开关表,根据有功功率和无功功率控制误差直接选择开关状态输出,可实现功率的快速控制。然而,这类方法也存在开关频率不固定、功率纹波较大等缺点。

随着控制理论的飞速发展,模型预测控制技术因其具有动态特性快、能够同时控制多个非线性耦合目标、无需比例积分控制器等优点而被诸多学界和业界学者所探索和研究^[7-9]。其中,“动态特性快”主要是指模型预测控制是根据代价函数直接选择输出矢量,没有比例积分调节过程,所以其具有“动态特性快”的优点。“能够同时控制多个非线性耦合目标”主要是指模型预测控制可以通过设计代价函数,将多个控制目标集成到一个代价函数里去一起调节和控制,这也是传统控制无法做到的^[10-12]。“无需比例积分控制器”也是因为模型预测控制是根据预测的代价函数值直接选择输出的电压矢量的,因此,不需要专门设计比例积分控制器。

文献[7]系统研究了三相并网逆变器的模型预测控制策略,并进行对比仿真,证明了模型预测控制的优越性。文献[8]设计一种单相光伏逆变器的连续集模型预测电流控制策略,实现了功率解耦控制。文献[9]设计一种无电网电压传感器的并网逆变器模型预测控制策略,提高了系统的可靠性。

然而,作为一种基于模型的控制方法,并网逆变器的模型预测控制策略对模型参数有较强的依赖性^[13-15],一旦由于温度变化、励磁饱和等因素导致电感等参数发生变化时,势必会导致电流精度降低、控制误差增大。

为此,文献[16-17]设计了两种基于电感在线辨识的并网逆变器模型预测控制策略,通过在线实时辨识电感,克服了电感失配的影响,提高了模型预测控制的参数鲁棒性。然而,该方法未考虑电阻、系统未建模部分、逆变器非线性特性等其他因素的影响。文献[18]设计了基于迭代算法的未知参数在线辨识方法,也提高了模型预测控制的参数鲁棒性,但在线

迭代算法计算量较大。文献[19-22]设计了基于控制系统历史数据的模型预测控制策略,利用系统的历史电压、电流数据等信息构建预测模型,设计预测控制方法,实现了不依赖系统参数的鲁棒预测控制。然而,这类方法需要采集大量的数据进行模型拟合和训练,其计算量较大。

为削弱并网逆变器模型预测控制对模型参数的依赖性,简化控制算法,提出一种基于扰动观测器的鲁棒模型预测控制策略。该方法首先将并网逆变器的数学模型改写为集总扰动模型;然后通过设计一个扰动观测器对扰动进行观测;最后,将观测的扰动代入并网逆变器的集总扰动模型进行电流预测,从而实现模型预测控制,并显著降低模型预测控制对模型参数的依赖性。

1 并网逆变器的模型预测控制原理

1.1 并网逆变器的数学模型

图1为并网逆变器的数学模型。其中, U_{dc} 为直流电压, e_a, e_b, e_c 为三相电网电压, i_a, i_b, i_c 为三相并网电流, L 为滤波电感, R 为 L 上的寄生电阻。 S_1-S_6 表示6个IGBT全控器件,共同构成三相逆变器。




图1 并网逆变器电路结构

Fig.1 Circuit structure of grid-connected inverter

由图1和基尔霍夫电压定律可以推导出在静止 $\alpha\beta$ 坐标系上并网逆变器的数学模型为^[16-17]

$$\begin{cases} L \frac{di_{\alpha}}{dt} = u_{\alpha} - e_{\alpha} - Ri_{\alpha} \\ L \frac{di_{\beta}}{dt} = u_{\beta} - e_{\beta} - Ri_{\beta} \end{cases} \quad (1)$$

式中: i_{α}, i_{β} 分别为在 $\alpha\beta$ 坐标系中 α 轴、 β 轴的并网电流; e_{α}, e_{β} 为在 $\alpha\beta$ 坐标系中 α 轴、 β 轴电网电压; u_{α}, u_{β} 为并网逆变器输出电压矢量 $u_0 \sim u_7$ 在 $\alpha\beta$ 坐标系中 α 轴、 β 轴分量,如图2所示^[7]。




图2 并网逆变器输出电压矢量

Fig.2 Output voltage vector of grid-connected inverter

1.2 并网逆变器的模型预测控制原理

考虑到控制周期 T_s 很短(通常为 $10\sim 1000\ \mu\text{s}$),根据一阶欧拉公式对式(1)所示的电流微分方程进行离散化,可以推导为

$$\begin{cases} i_\alpha(k+1) = (1 - \frac{RT_s}{L})i_\alpha(k) + \frac{T_s}{L}(u_\alpha(k) - e_\alpha(k)) \\ i_\beta(k+1) = (1 - \frac{RT_s}{L})i_\beta(k) + \frac{T_s}{L}(u_\beta(k) - e_\beta(k)) \end{cases} \quad (2)$$

式中: k 为时刻。

经过采样和坐标变换可得 k 时刻的电流 $i_\alpha(k)$ 、 $i_\beta(k)$ 和电网电压 $e_\alpha(k)$ 、 $e_\beta(k)$,通过采样直流电压 U_{dc} 可以计算出图2所示8个电压矢量对应的电压值 $u_\alpha(k)$ 、 $u_\beta(k)$ 。通过将8个 $u_\alpha(k)$ 、 $u_\beta(k)$ 依次代入式(2)可以预测出 $k+1$ 时刻的电流值。

然后,通过将预测的8个 $k+1$ 时刻的电流值依次代入式(3)所示代价函数,可以预测出8个电压矢量对应的8个代价函数值。

$$g = (i_\alpha^* - i_\alpha(k+1))^2 + (i_\beta^* - i_\beta(k+1))^2 \quad (3)$$

式中: i_α^* 、 i_β^* 分别为在 $\alpha\beta$ 坐标系上 α 轴、 β 轴的电流参考值; g 为代价函数。

最后,通过比较8个代价函数值的大小,并选择使代价函数值最小的电压矢量作为最优矢量,并将该最优矢量用于输出,即可实现并网逆变器的模型预测电流控制。

1.3 参数灵敏性分析

如上文所述,模型预测控制的核心是根据式(2)进行电流预测。然而,由式(2)可见,该电流预测精度严重依赖于参数 L 和 R ,一旦参数出现误差,势必会导致预测误差增大,进而降低预测控制精度。

以 i_α 为例,当参数失配时,预测的电流满

足式(4)。

$$i_{\text{cp}}(k+1) = (1 - \frac{\hat{R}T_s}{\hat{L}})i_\alpha(k) + \frac{T_s}{\hat{L}}(u_\alpha(k) - e_\alpha(k)) \quad (4)$$

式中: $i_{\text{cp}}(k+1)$ 为预测的 $k+1$ 时刻的电流; \hat{R} 为失配的电阻值; \hat{L} 为失配的电感值。

由式(2)和式(4)可得,参数失配时产生的预测误差为

$$i_\alpha(k+1) - \hat{i}_{\text{cp}}(k+1) = \frac{\hat{R}L - RL}{\hat{L}L}T_s i_\alpha(k) + \frac{\hat{L} - L}{\hat{L}L}T_s(u_\alpha(k) - e_\alpha(k)) \quad (5)$$

取 $R=0.1\ \Omega$ 、 $L=10\ \text{mH}$ 、 $T_s=100\ \mu\text{s}$ 、 $i_\alpha(k)=10\ \text{A}$ 、 $u_\alpha(k)-e_\alpha(k)=100\ \text{V}$,可得 \hat{R} 和 \hat{L} 变化时电流预测误差的变化规律如图3所示。




图3 参数灵敏性分析结果

Fig.3 Parameter sensitivity analysis result

由图3可见,由于电阻 R 较小,其变化对电流预测误差的影响很小,而 L 失配对电流预测误差的影响很大,尤其是当 L 为 $10\ \text{mH}$ 时,电流预测误差约为 $0.5\ \text{A}$ 。

由上述分析可见,参数失配对并网逆变器的模型预测控制有较大的影响。因此,研究一种基于扰动观测器的并网逆变器鲁棒模型预测控制策略,以减小参数失配的影响。

2 并网逆变器鲁棒模型预测控制策略

2.1 集总扰动模型

根据超局部建模理论,并网逆变器的数学模型可以改写为集总扰动模型^[23],满足式(6)。

$$\begin{cases} \frac{di_\alpha}{dt} = \eta u_\alpha + F_\alpha \\ \frac{di_\beta}{dt} = \eta u_\beta + F_\beta \\ \frac{dF_\alpha}{dt} = -\omega_g F_\beta \\ \frac{dF_\beta}{dt} = \omega_g F_\alpha \end{cases} \quad (6)$$

式中： η 为一个比例系数，通常可设置为 $1/L$ ； F_α 、 F_β 分别为包含参数扰动、电网电压等信息的集总扰动在 $\alpha\beta$ 坐标系上 α 轴 β 轴的分量； ω_g 为电网电压的角频率。

如果能够通过观测器实现扰动 F_α 和 F_β 的观测，则可以直接对式(6)进行离散化设计鲁棒预测控制策略，满足式(7)。

$$\begin{cases} i_\alpha(k+1) = i_\alpha(k) + \eta T_s u_\alpha(k) + T_s F_\alpha(k) \\ i_\beta(k+1) = i_\beta(k) + \eta T_s u_\beta(k) + T_s F_\beta(k) \end{cases} \quad (7)$$

2.2 扰动观测器设计

为实现集总扰动观测和鲁棒模型预测控制，基于式(6)设计一种扰动观测器，满足式(8)。

$$\begin{cases} \frac{d\hat{i}_\alpha}{dt} = \eta u_\alpha + \hat{F}_\alpha + k_1 \text{sgn}(i_\alpha - \hat{i}_\alpha) \\ \frac{d\hat{i}_\beta}{dt} = \eta u_\beta + \hat{F}_\beta + k_1 \text{sgn}(i_\beta - \hat{i}_\beta) \\ \frac{d\hat{F}_\alpha}{dt} = -\omega_g \hat{F}_\beta + k_2 \text{sgn}(i_\alpha - \hat{i}_\alpha) \\ \frac{d\hat{F}_\beta}{dt} = \omega_g \hat{F}_\alpha + k_2 \text{sgn}(i_\beta - \hat{i}_\beta) \end{cases} \quad (8)$$

式中：“ $\hat{\cdot}$ ”表示对应变量的观测值； k_1 和 k_2 为观测器增益； $\text{sgn}(\cdot)$ 为符号函数。

由式(6)和式(8)可得电流与集总扰动观测误差满足式(9)。

$$\begin{cases} \frac{d\Delta i_\alpha}{dt} = \Delta F_\alpha - k_1 \text{sgn}(\Delta i_\alpha) \\ \frac{d\Delta i_\beta}{dt} = \Delta F_\beta - k_1 \text{sgn}(\Delta i_\beta) \\ \frac{d\Delta F_\alpha}{dt} = -\omega_g \Delta F_\beta - k_2 \text{sgn}(\Delta i_\alpha) \\ \frac{d\Delta F_\beta}{dt} = \omega_g \Delta F_\alpha - k_2 \text{sgn}(\Delta i_\beta) \end{cases} \quad (9)$$

式中： $\Delta i_\alpha = i_\alpha - \hat{i}_\alpha$ ； $\Delta i_\beta = i_\beta - \hat{i}_\beta$ ； $\Delta F_\alpha = F_\alpha - \hat{F}_\alpha$ ； $\Delta F_\beta = F_\beta - \hat{F}_\beta$ 。

为了保证所设计的扰动观测器能够稳定运行和收敛，定义李雅普诺夫函数 V_1 满足式(10)。

$$V_1 = \frac{1}{2} (\Delta i_\alpha^2 + \Delta i_\beta^2) \quad (10)$$

由式(10)可得

$$\frac{dV_1}{dt} = -k_1 |\Delta i_\alpha| - k_1 |\Delta i_\beta| + \Delta i_\alpha \Delta F_\alpha + \Delta i_\beta \Delta F_\beta \quad (11)$$

为了保证扰动观测器收敛，需使式(11)小于零，所以可得

$$k_1 > \max \{ |\Delta F_\alpha|, |\Delta F_\beta| \} \quad (12)$$

当电流观测器收敛后，可得

$$\begin{cases} \frac{d\Delta i_\alpha}{dt} = \Delta i_\alpha = 0 \\ \frac{d\Delta i_\beta}{dt} = \Delta i_\beta = 0 \end{cases} \quad (13)$$

由式(9)和式(13)可得

$$\begin{cases} \Delta F_\alpha = k_1 \text{sgn}(\Delta i_\alpha) \\ \Delta F_\beta = k_1 \text{sgn}(\Delta i_\beta) \end{cases} \quad (14)$$

将式(14)代入式(9)后两式可得

$$\begin{cases} \frac{d\Delta F_\alpha}{dt} = -\omega_g \Delta F_\beta - \frac{k_2}{k_1} \Delta F_\alpha \\ \frac{d\Delta F_\beta}{dt} = \omega_g \Delta F_\alpha - \frac{k_2}{k_1} \Delta F_\beta \end{cases} \quad (15)$$

为了进一步分析所设计扰动观测器的稳定性，定义李雅普诺夫函数 V_2 满足式(16)。

$$V_2 = \frac{1}{2} (\Delta F_\alpha^2 + \Delta F_\beta^2) \quad (16)$$

所以可得

$$\frac{dV_2}{dt} = -\frac{k_2}{k_1} (\Delta F_\alpha^2 + \Delta F_\beta^2) \quad (17)$$

为了保证扰动观测器收敛，须使式(17)小于零，所以可得

$$k_2 > 0 \quad (18)$$

式(12)和式(18)给出了本文所设计扰动观测器的收敛条件。

2.3 扰动观测器增益影响分析

为了进一步分析观测器增益 k_1 和 k_2 对观测器动态特性的影响，本节推导集总扰动观测的传递函数，并基于该传递函数分析 k_1 和 k_2 的选取原则。

将式(14)代入式(8)可得

$$\begin{cases} \frac{d\hat{F}_\alpha}{dt} = -\omega_g \hat{F}_\beta + k_2 \frac{F_\alpha - \hat{F}_\alpha}{k_1} \\ \frac{d\hat{F}_\beta}{dt} = \omega_g \hat{F}_\alpha + k_2 \frac{F_\beta - \hat{F}_\beta}{k_1} \end{cases} \quad (19)$$

考虑到 \hat{F}_α 和 \hat{F}_β 的正交关系,可以得到

$$\begin{cases} \hat{F}_\alpha = j\hat{F}_\beta \\ \hat{F}_\beta = -j\hat{F}_\alpha \end{cases} \quad (20)$$

由式(19)一式(20)可得

$$\begin{cases} \frac{d\hat{F}_\alpha}{dt} = j\omega_g \hat{F}_\alpha + k_2 \frac{F_\alpha - \hat{F}_\alpha}{k_1} \\ \frac{d\hat{F}_\beta}{dt} = j\omega_g \hat{F}_\beta + k_2 \frac{F_\beta - \hat{F}_\beta}{k_1} \end{cases} \quad (21)$$

由式(21)可得

$$G(s) = \frac{\hat{F}_\alpha}{F_\alpha} = \frac{\hat{F}_\beta}{F_\beta} = \frac{\frac{k_2}{k_1}}{s - j\omega_g + \frac{k_2}{k_1}} \quad (22)$$

取 $\omega_g=314$ rad/s,并分别取 k_2/k_1 为 30、300、3 000,可得传递函数 $G(s)$ 的波特图如图 4 所示。




图 4 传递函数 $G(s)$ 的波特图

Fig.4 Bode diagram of the transfer function $G(s)$

由图 4 可见,参数 k_2/k_1 对本文所提扰动观测器的低频和高频观测性能均有较大的影响。

首先,无论参数 k_2/k_1 为多大,取 $\omega_g=314$ rad/s 且当 $s=j314$ rad/s 时,传递函数的幅值增益和相角均为 0。这表明本文所提扰动观测器能够对频率为 ω_g 的交流信号实现无静差跟踪。若电网频率为 50 Hz 并保持不变,则取 $\omega_g=314$ rad/s 时即可保证所提扰动观测器实现集总扰动的无静差跟踪。

其次, $s \neq j314$ rad/s 时,由图 4 可见,参数 k_2/k_1 变化时对所提扰动观测器的扰动观测性能有较显著的影响。当 k_2/k_1 为 30 时,由图 4 可见,传递函数 $G(s)$ 的低频增益和高频增益均较小。高频增益较小表明

了该扰动观测器对高频噪声的抑制能力较强,即稳态特性较好。然而,低频增益较小则表明该扰动观测器的动态响应较慢,即收敛特性较慢。

同理,当 k_2/k_1 由 30 增大到 300 和 3 000 时,由图 4 可以清晰看到传递函数 $G(s)$ 的低频增益和高频增益均得到明显增大。然而,当 k_2/k_1 为 3 000 时,传递函数 $G(s)$ 对高频噪声的抑制能力很弱,容易放大噪声,进而降低扰动观测的稳态特性。

综合考虑 3 个不同的 k_2/k_1 取值,为了兼顾高频噪声抑制特性和动态特性,本文最终选择令 $k_2/k_1=300$ 。

为了清晰起见,图 5 给出了本文所设计的扰动观测器的控制框图。由图 5 可知,本文所设计的扰动观测器主要包含相互耦合的电流观测和集总扰动观测两部分。其中,虚线框内为集总扰动观测部分。

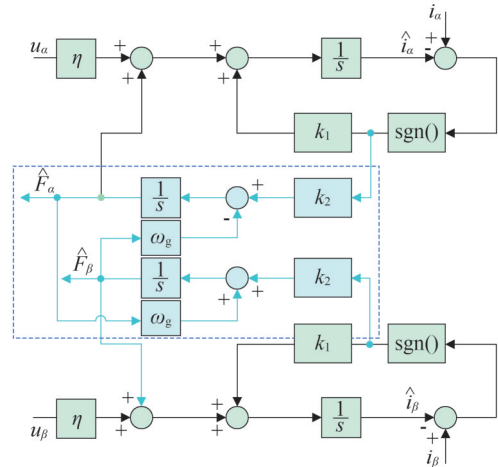


图 5 所提扰动观测器的控制框图

Fig.5 Control block diagram of the presented disturbance observer

2.4 鲁棒模型预测控制策略

为了说明本文所提鲁棒模型预测控制的鲁棒性,这里进行了简要的说明^[24]。

首先,由式(6)可知,本文所述集总扰动模型仅含有参数 η 和集总扰动。当采用扰动观测器进行集总扰动观测时,式(6)所示模型仅依赖于参数 η 。若参数 η 失配,则式(6)可改写为

$$\begin{cases} \frac{di_\alpha}{dt} = \eta u_\alpha + (F_\alpha + \Delta\eta \cdot u_\alpha) \\ \frac{di_\beta}{dt} = \eta u_\beta + (F_\beta + \Delta\eta \cdot u_\beta) \end{cases} \quad (23)$$

式中: $\Delta\eta$ 为参数 η 失配的误差。

此时,式(23)中 $F_\alpha + \Delta\eta u_\alpha$ 构成了新的集总扰动 $F_{\alpha new}$,而式(23)中 $F_\beta + \Delta\eta u_\beta$ 构成了新的集总扰动 $F_{\beta new}$ 。当采用扰动观测器对 $F_{\alpha new}$ 和 $F_{\beta new}$ 进行观测时,可以很好地补偿参数 α 失配的影响,从而克服参数的影响,实现“鲁棒预测控制”^[24]。

在根据图5所示扰动观测器完成集总扰动观测后,可将观测的扰动代入式(7)进行电流预测,并将预测的电流代入式(3)进行代价函数计算。最后通过比较代价函数可获得最优矢量,从而实现鲁棒模型预测控制策略。本文所提鲁棒模型预测控制策略的控制流程如图6所示, m 为循环次数。

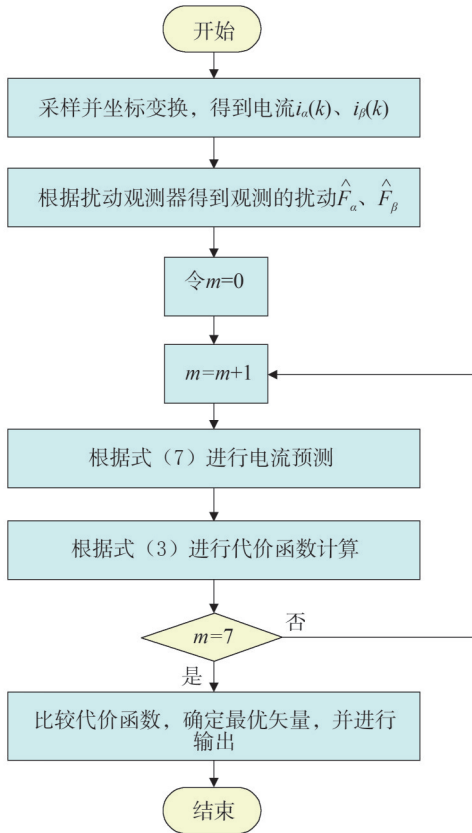


图6 所提鲁棒模型预测控制策略控制流程图

Fig.6 Control flow chart of the proposed robust model predictive control strategy

所提方法的整体控制框图如图7所示,该方法通过采样电网电压,并经过锁相环得到电网电压的

角频率和角度。电网角频率和采样的电网电流、逆变器输出电压矢量一起输入所设计的扰动观测器,进行集中扰动观测。电网角度用于生成电流参考值,实现电网电压定向的矢量控制。观测的集总扰动、采样的电网电流和逆变器可输出的8个电压矢量值一起输入鲁棒电流预测模块,实现电流预测。最后,通过计算8个电压矢量对应的代价函数值,并进行比较获得最优电压矢量进行逆变器控制,最终实现了基于扰动观测器的并网逆变器鲁棒模型预测控制。

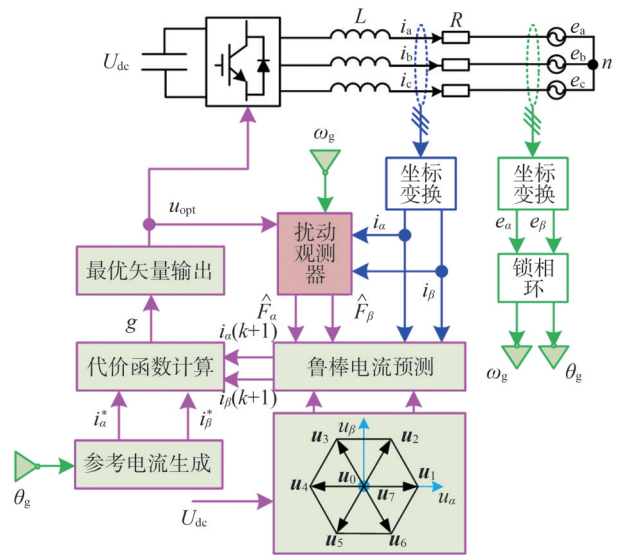


图7 所提方法的整体控制框图

Fig.7 The overall control block diagram of the proposed method

3 仿真分析

为证明本文所提控制策略的可行性和优越性,基于 MATLAB/Simulink 建立了并网逆变器鲁棒模型预测控制策略的仿真模型,并进行了对比仿真研究。仿真所用参数如表1所示。仿真中,采样频率设为10 kHz,扰动观测器参数 $k_1=1\ 000, k_2=300\ 000$ 。

表1 仿真参数

Table 1 Simulation parameters

参数	数值
直流电压/V	600
电网电压/V	380
电感/mH	20
电阻/ Ω	0.1

3.1 参数准确时的仿真结果

本节对比参数准确时常规模型预测控制(文献[7]所提)和本文所提鲁棒模型预测控制的电流控制性能。

仿真中,参考电流在 0.1 s 时先由 5 A 突增为 25 A,后又在 0.2 s 时突减为 15 A。常规方法的仿真结果如图 8 所示,本文所提方法的仿真结果如图 9 所示。

对比图 8 和图 9 可见,在模型参数准确时,本文所提鲁棒模型预测控制策略和常规方法的电流动态与稳态控制性能类似,证明了参数准确时所提方法的可行性。




图8 参数准确时常规方法仿真波形

Fig.8 Simulation waveforms of the conventional method with accurate parameters





图9 参数准确时所提方法仿真波形


Fig.9 Simulation waveforms of the proposed method with accurate parameters

3.2 参数失配时的仿真结果

本节对比参数失配时常规模型预测控制和所提鲁棒模型预测控制的电流控制性能。仿真中,参考电流设为 25 A。模型预测控制中使用的电感 L 在 0.1 s 时先由 50% 电感真实值增大到 75% 电感真实值,然后在 0.2 s 时又由 75% 电感真实值增大到 100% 电感真实值。常规方法的仿真结果如图 10 所示,本文所提方法的仿真结果如图 11 所示。



(a) 电流波形



(b) 电流误差波形

图10 参数失配时常规方法仿真波形

Fig.10 Simulation waveforms of the conventional method with inaccurate parameters

由图 10 可见,在电感失配时,模型预测控制系统仍然能都稳定运行。然而,当电感比真实值小时,电流预测误差 Δi 显著变大。当模型中使用的电感为真实值的 50% 时,电流预测误差高达 4.8 A。随着电感误差的减小,电流预测误差也随之减小。这说明常规模型预测控制对参数

失配十分敏感。

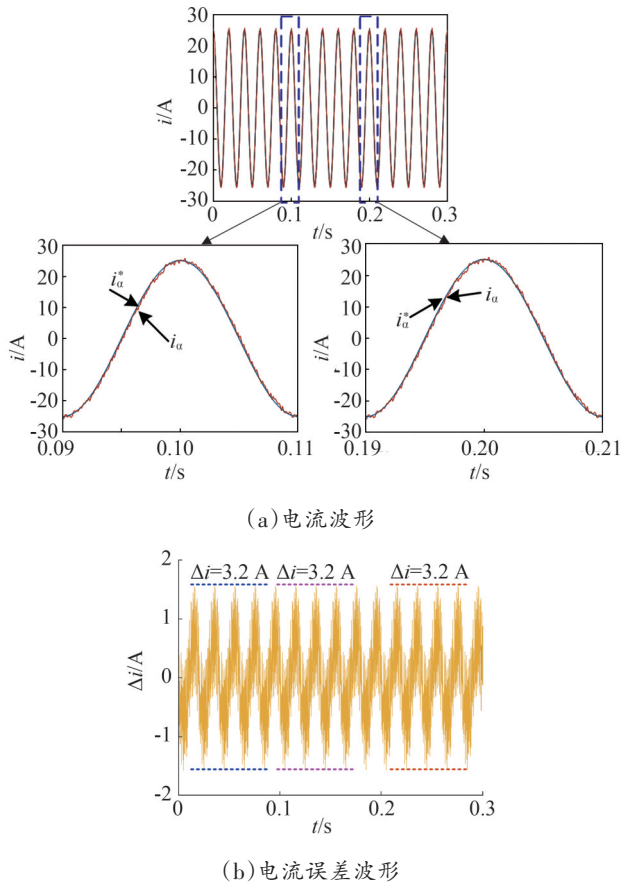


图11 参数失配时所提方法仿真波形

Fig.11 Simulation waveforms of the proposed method with inaccurate parameters

由图 11 可见,采用本文所提方法时,在电感失配时,模型预测控制系统仍然能够稳定运行,且电流预测误差始终较小,约为 3.2 A。对比图 10 和图 11 可见,所提鲁棒模型预测控制策略在参数失配时仍然具有较好的电流控制效果,证明了所提方法的有效性。

最后,为验证参数失配时所提模型预测控制策略的动态特性,进行电感失配时的电流突变动态仿真研究。在该仿真中,电感设为真实值的 50%,在 0.5 s 时电流由 25 A 突减为 15 A,常规方法的电流动态仿真结果及电流误差波形如图 12 所示,所提方法的电流动态仿真结果及电流误差波形如图 13 所示。

对比图 12 与图 13 可见,在 0.1 s 电流突变时,常

规方法和本文所提方法均具有较好的电流动态响应性能,这表明参数失配未显著影响模型预测控制的电流动态响应特性。

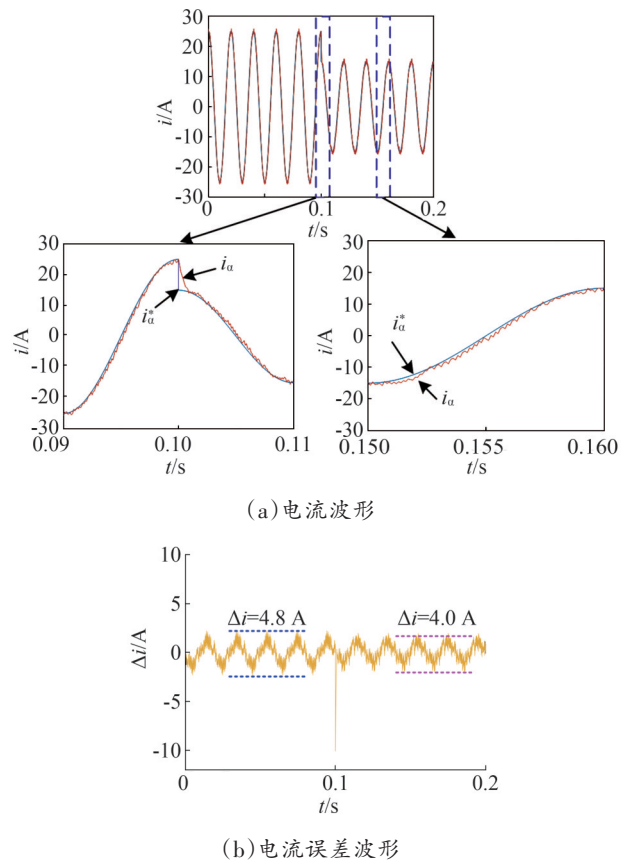
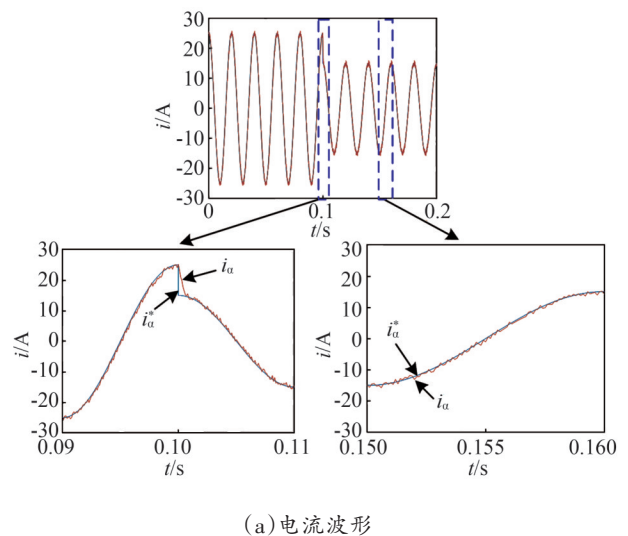


图12 参数失配时常规方法动态仿真波形

Fig.12 Dynamic simulation waveforms of the conventional method with mismatched parameters






图 13 参数失配时所提方法动态仿真波形

Fig.13 Dynamic simulation waveforms of the proposed method with mismatched parameters

然而,由图 12 与图 13 可见,参数失配时,常规方法参考电流与实际电流明显不能完全重合,其电流误差较大。在参考电流为 25 A 时,常规方法电流误差 Δi 高达 4.8 A,在参考电流减小为 15 A 时,常规方法电流误差 Δi 高达 4.0 A。然而,由图 13 可见,所提方法在参数失配时仍具有较好的电流稳态控制性能,参考电流与实际电流仍然能够较好地重合,表明其电流跟踪控制性能更佳,且其电流误差较小。在参考电流为 25 A 时,所提方法电流误差 Δi 减小为 3.2 A,在参考电流为 15 A 时,所提方法电流误差 Δi 减小为 2.4 A。

由该对比结果可见,在电感失配时,常规并网逆变器模型预测控制方法和本文所提方法均仍具有较好的电流动态响应性能。然而,所提方法具有更好的稳态性能,电感失配时其电流控制误差更小,表明其对电感参数失配具有较弱的依赖性。当并网逆变器在复杂工作环境中因温度、磁场等原因发生参数失配时,本文所提方法仍具有较好的电流控制性能,表明其对复杂运行工况具有较强的适应能力。

3.3 与现有方案的对比分析

为了进一步说明本文所提方案与常规方法的优越性,本节对比研究了文献[25–28]所提方法与本文所提方法的区别与联系。

文献[25–28]提出了基于扩张状态观测器的鲁棒模型预测控制策略。该观测器可表示为

$$\begin{cases} \frac{d\hat{i}_\alpha}{dt} = \eta u_\alpha + \hat{F}_\alpha + \gamma_1(i_\alpha - \hat{i}_\alpha) \\ \frac{d\hat{i}_\beta}{dt} = \eta u_\beta + \hat{F}_\beta + \gamma_1(i_\beta - \hat{i}_\beta) \\ \frac{d\hat{F}_\alpha}{dt} = \gamma_2(i_\alpha - \hat{i}_\alpha) \\ \frac{d\hat{F}_\beta}{dt} = \gamma_2(i_\beta - \hat{i}_\beta) \end{cases} \quad (24)$$

式中: γ_1 和 γ_2 为观测器增益。

根据式(24)可以得到扩张状态观测器观测的总扰动传递函数为

$$G_2(s) = \frac{\hat{F}_\alpha}{F_\alpha} = \frac{\hat{F}_\beta}{F_\beta} = \frac{\gamma_2}{s^2 + \gamma_1 s + \gamma_2} \quad (25)$$

根据文献[25–28]可知,参数 γ_1 和 γ_2 通常设置为

$$\begin{cases} \gamma_1 = 2\omega_c \\ \gamma_2 = \omega_c^2 \end{cases} \quad (26)$$

式中: ω_c 为扩张状态观测器的截止频率。

根据式(25),取 $\omega_c=1\ 000\ \text{rad/s}$, $2\ 000\ \text{rad/s}$, $3\ 000\ \text{rad/s}$,可得传递函数 $G_2(s)$ 的波特图如图 14 所示。



 图 14 传递函数 $G_2(s)$ 的波特图

 Fig.14 Bode diagram of the transfer function $G_2(s)$

由图 14 可见,常规的扩张状态观测器为一个低通滤波器,在 $s=j314\ \text{rad/s}$ 时,常规扩张状态观测器的幅值增益不为 0 dB,相角也不是 0° 。虽然增大 ω_c 可以使幅值增益接近于 0 dB、相角减小到接近于 0° ,但是这需要 ω_c 取很大的值,这会降低扩张状态观测器的高频噪声抑制能力。因此,常规的扩张状态观测器

难以平衡集总扰动观测精度和高频噪声抑制性能。

与常规扩张状态观测器不同,本文所提扰动观测器无论观测器增益为多大,其在 $s=j31.4\text{rad/s}$ 时,均能实现集总扰动的准确观测,其幅值增益在 $s=j314\text{rad/s}$ 时恒为0dB,相角恒为 0° 。这说明本文所提扰动观测器具有更好的稳态观测精度。此外,通过调节观测器增益 k_2/k_1 ,可以调节本文所提扰动观测器的动态性能和高频噪声抑制性能,从而获得较好的动态和控制效果。

综合上述对比可见,所提扰动观测器比文献[25-28]所提扩张状态观测器具有更好的观测性能,从而保证基于扰动观测器的鲁棒模型预测控制具有更好的控制性能。

此外,本节还对比了文献[16-22]所提方法与本文方法的计算量。本文所提方法的计算量为 $35\mu\text{s}$,文献[16]所提方法的计算量为 $44\mu\text{s}$,文献[17]所提方法的计算量为 $40\mu\text{s}$,文献[18]所提方法的计算量为 $42\mu\text{s}$,文献[19]所提方法的计算量为 $41\mu\text{s}$,文献[20]所提方法的计算量为 $48\mu\text{s}$,文献[21]所提方法的计算量为 $51\mu\text{s}$,文献[22]所提方法的计算量为 $46\mu\text{s}$ 。对比可见,本文所提方法由于实现较为简单,其计算量最少。

4 结束语

研究并网逆变器的改进型模型预测控制策略,以削弱模型参数失配的影响。简要介绍常规模型预测控制的原理,并分析其参数灵敏性,然后设计一种扰动观测器以实现参数扰动观测和鲁棒模型预测控制。给出所提扰动观测器的设计方法,进行了稳定性分析和参数设计。最后,给出所提控制策略的控制流程图和控制框图,对比仿真结果验证所提方法对模型参数失配具有较强的鲁棒性。

参考文献

[1] 杨霞,李琛,杨路勇,等.风电并网逆变器的双闭环自抗扰控制策略研究[J].山东电力技术,2022,49(11):70-77.
YANG Xia, LI Chen, YANG Luyong, et al. Research on double closed-loop active disturbance rejection control strategy of wind power grid-connected inverter[J]. Shandong Electric Power, 2022, 49(11):70-77.

[2] 朱胜杰,张厚升,王文成.三相并网DC/AC变换器控制策略研究[J].山东电力技术,2021,48(7):36-42.

ZHU Shengjie, ZHANG Housheng, WANG Wencheng. Research on control strategy of three-phase grid-connected DC/AC converter [J]. Shandong Electric Power, 2021, 48(7):36-42.

[3] 沈赋,李施伟,王健,等.融合储能的光伏发电系统并网逆变器建模与稳定性分析[J].电力系统保护与控制,2024,52(19):131-143.
SHEN Fu, LI Shiwei, WANG Jian, et al. Modeling and stability analysis of a photovoltaic grid-connected inverter integrated with an energy storage system[J]. Power System Protection and Control, 2024, 52(19):131-143.

[4] 曹文君,张岩,张安彬,等.弱电网条件下分布式光伏并网系统谐振机理及影响特性[J].电力建设,2024,45(3):149-159.
CAO Wenjun, ZHANG Yan, ZHANG Anbin, et al. Resonance mechanism and influence characteristics of distributed photovoltaic grid-connected system under weak grid conditions[J]. Electric Power Construction, 2024, 45(3):149-159.

[5] 张兴辉,杜茗茗,赵宇琪,等.基于虚拟磁定向控制的改进型三电平NPC光伏并网逆变器研究[J].山东电力技术,2018,45(7):1-5.
ZHANG Xinghui, DU Mingming, ZHAO Yuqi, et al. Research of improved three level NPC photovoltaic grid inverter based on control strategy of VFOC [J]. Shandong Electric Power, 2018, 45(7):1-5.

[6] 张永熙,朱亮亮,柯振宇,等.变压器集成级联混合无功补偿设备研究[J].山东电力技术,2022,49(9):22-28.
ZHANG Yongxi, ZHU Liangliang, KE Zhenyu, et al. Research on transformer integrated cascade hybrid reactive power compensation equipment [J]. Shandong Electric Power, 2022, 49(9):22-28.

[7] 靳舵,张厚升,蒋俊杰,等.三相并网逆变器模型预测控制研究[J].山东电力技术,2023,50(4):7-12.
JIN Duo, ZHANG Housheng, JIANG Junjie, et al. Research on model predictive control of three-phase grid-connected inverter [J]. Shandong Electric Power, 2023, 50(4):7-12.

[8] 程巍,茆美琴,汪海军,等.新型单相光伏逆变器电流连续控制集模型预测功率解耦控制[J].中国电机工程学报,2023,43(24):9655-9667.
CHENG Wei, MAO Meiqin, WANG Haijun, et al. Power decoupling control for a new single-phase photovoltaic inverter based on current continuous control set model prediction [J]. Proceedings of the CSEE, 2023, 43(24):9655-9667.

[9] 郭磊磊,崔蕾,王波,等.抗直流偏置与频率偏移的并网逆变器无电网电压传感器模型预测控制[J].电力自动化设备,2024,44(11):142-148.
GUO Leilei, CUI Lei, WANG Bo, et al. Grid voltage sensorless model predictive control of grid-connected inverter resistant to DC-offset and frequency deviation [J]. Electric Power Automation Equipment, 2024, 44(11):142-148.

[10] 刘偲艳.不平衡电网下并网逆变器多目标模型预测功率控制[J].电气工程学报,2023,18(1):77-85.
LIU Siyan. Multi-objective model predictive control of grid-connected inverters in unbalanced grids [J]. Journal of Electrical

- Engineering, 2023, 18(1): 77–85.
- [11] 吴强,林道鸿,陈川刚,等.基于多目标模型预测控制的ANPC并网逆变器[J].电力电子技术,2021,55(7):93–97.
WU Qiang, LIN Daohong, CHEN Chuangang, et al. ANPC grid-connected inverter based on multi-objective optimal model predictive control[J].Power Electronics, 2021, 55(7): 93–97.
- [12] 闫涵,吕建国,丁金勇,等.非理想电网下NPC三电平逆变器多目标模型预测控制方法研究[J].电气工程学报,2019,14(3): 23–32.
YAN Han, LÜ Jianguo, DING Jinyong, et al. Research on the multi-target grid-connected control method of NPC three-level inverter based on model prediction under non-ideal grid conditions [J]. Journal of Electrical Engineering, 2019, 14(3): 23–32.
- [13] 吴振军,刘震坤,郭磊磊,等.基于抗频率偏移电感辨识的并网逆变器模型预测控制[J].电力系统保护与控制,2023,51(22): 99–107.
WU Zhenjun, LIU Zhenkun, GUO Leilei, et al. Model predictive control for a grid-connected inverter based on inductance identification resistant to frequency deviation [J]. Power System Protection and Control, 2023, 51(22): 99–107.
- [14] 李洪凤,徐浩博,徐越.扩展卡尔曼滤波参数辨识下永磁同步电机模型预测转矩控制[J].电机与控制学报,2023,27(9):19–30.
LI Hongfeng, XU Haobo, XU Yue. Model prediction torque control of PMSM based on extended Kalman filter parameter identification [J]. Electric Machines and Control, 2023, 27(9): 19–30.
- [15] 党超亮,王飞,穆晓宇,等.引入电感参数辨识的Vienna整流器双矢量预测恒频控制[J].中国电机工程学报,2022,42(增刊1):246–255.
DANG Chaoliang, WANG Fei, MU Xiaoyu, et al. Dual vector model predictive with constant frequency control for Vienna rectifier based on inductance parameters identification [J]. Proceedings of the CSEE, 2022, 42(S1): 246–255.
- [16] WU Z J, LIU Z K, ZHU H, et al. A robust inductance estimation method for model predictive control of grid-connected inverters[J]. IEEE Transactions on Industrial Electronics, 2025, 72 (1) : 589–599.
- [17] GUO L L, XIAO H, ZHAO H L, et al. A virtual-flux state observer-based inductance identification method for model predictive control of grid-tied inverters with a finite phase angle set-based PLL [J]. IEEE Transactions on Industrial Electronics, 2023, 70 (8): 8009–8021.
- [18] 肖强晖,张雨爽,罗朝旭,等.基于时间序列的改进型永磁同步电机三矢量无模型预测电流控制策略[J].湖南电力,2024,44 (5):29–36.
XIAO Qianghui, ZHANG Yushuang, LUO Zhaoxu, et al. Improved three-vector model-free predictive current control strategy based on time series for PMSM drives[J]. Hunan Electric Power, 2024, 44 (5): 29–36.
- [19] YANG C S, ZHANG Y C, JIANG T, et al. Data-driven model-free predictive current control for brushless doubly-fed induction generator [C]// 2023 26th International Conference on Electrical Machines and Systems (ICEMS). IEEE, 2023: 4110–4115.
- [20] WU W J, QIU L, LIU X, et al. Data-driven iterative learning predictive control for power converters [J]. IEEE Transactions on Power Electronics, 2022, 37(12): 14028–14033.
- [21] WU W J, QIU L, RODRIGUEZ J, et al. Data-driven finite control-set model predictive control for modular multilevel converter [J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2023, 11(1): 523–531.
- [22] WEI Y, YOUNG H, WANG F X, et al. Generalized data-driven model-free predictive control for electrical drive systems [J]. IEEE Transactions on Industrial Electronics, 2023, 70(8): 7642–7652.
- [23] 苏光靖,李红梅,李争,等.永磁同步直线电机无模型电流控制[J].电工技术学报,2021,36(15):3182–3190.
SU Guangjing, LI Hongmei, LI Zheng, et al. Research on model-free current control of permanent magnet synchronous linear motor [J]. Transactions of China Electrotechnical Society, 2021, 36(15): 3182–3190.
- [24] ZHANG Y C, JIANG T, JIAO J. Model-free predictive current control of a DFIG using an ultra-local model for grid synchronization and power regulation [J]. IEEE Transactions on Energy Conversion, 2020, 35(4): 2269–2280.
- [25] ZHANG Y C, LIU X, LI B Y, et al. Robust predictive current control of PWM rectifier under unbalanced and distorted network [J]. IET Power Electronics, 2021, 14(4): 797–806.
- [26] GAO S Y, WEI Y J, ZHANG D, et al. Model-free hybrid parallel predictive speed control based on ultralocal model of PMSM for electric vehicles [J]. IEEE Transactions on Industrial Electronics, 2022, 69(10): 9739–9748.
- [27] WANG F X, WEI Y, YOUNG H, et al. Continuous-control-set model-free predictive fundamental current control for PMSM system [J]. IEEE Transactions on Power Electronics, 2023, 38(5): 5928–5938.
- [28] WU X, ZOU P L, HUANG S, et al. Model-free predictive current control of SPMSM based on enhanced extended state observer [J]. IEEE Transactions on Industrial Electronics, 2024, 71(4): 3461–3471.

收稿日期:2024–12–05

修回日期:2025–03–12

作者简介:

滕 飞(1987),通信作者(16877758@qq.com),男,硕士,高级工程师,主要研究方向为输电线路设计、新能源发电技术;

吴俊俊(1971),男,正高级工程师,主要研究方向为输电线路设计;

姜 辰(1988),女,硕士,高级工程师,主要研究方向为系统通信传输;

黄昊怡(1993),男,硕士,工程师,主要研究方向为输电线路设计;

黄 莹(1990),男,硕士,工程师,主要研究方向为输电线路设计。

(责任编辑 娄婷婷)

考虑城轨杂散电流的主变压器隔直装置最优配置

宋景博^{1*}, 陈晨¹, 齐桓若¹, 张金凤¹, 薛文杰¹, 刘铜锤²

(1. 国网河南省电力公司经济技术研究院, 河南 郑州 450052; 2. 华北水利水电大学电气工程学院, 河南 郑州 450045)

摘要:针对城轨动态运行中随机杂散电流引发城网主变压器直流偏磁不确定超标问题,提出了一种基于多目标霜冰算法的主变压器隔直装置最优配置策略,能够在隔直装置安装数量最小条件下有效抑制城网主变压器直流偏磁现象。首先,以最小化主变压器中的直流偏磁电流和减少电容型隔直装置的数量为多目标函数,以限制主变压器直流偏磁电流为约束条件,构建多目标优化问题的主变压器隔直装置最优配置模型,并采用多目标霜冰算法对上述优化问题进行求解。其次,通过蒙特卡罗模拟来处理城轨负载电流的不确定性问题,并纳入多目标优化模型的求解过程。最后以深圳城轨和城网耦合系统为例验证所提方法的有效性和可行性,结果表明该配置策略不仅能够有效抑制主变压器直流偏磁现象,同时也实现了安装最少数量的隔直设备。

关键词:城轨;直流偏磁;随机负荷;隔直装置;多目标霜冰优化

中图分类号:TM41

文献标志码:A

文章编号:1007-9904(2025)12-0092-10

Optimal Configuration of DC Blocking Devices for Main Transformers Considering Stray Currents in Urban Rail

SONG Jingbo^{1*}, CHEN Chen¹, QI Huanruo¹, ZHANG Jinfeng¹, XUE Wenjie¹, LIU Tongchui²

(1.State Grid Henan Economic Research Institute, Zhengzhou 450052, China;

2.College of Electrical Engineering, North China University of Water Resources and Electric Power, Zhengzhou 450045, China)

Abstract: In response to the issue of uncertain overshoot of direct current magnetic bias (DCMB) in the main transformers of urban power grid, caused by random stray currents during dynamic operations of urban rail, an optimal configuration strategy of DC blocking devices for main transformers is proposed based on a multi-objective rime (MORIME) algorithm, which can effectively mitigate the DCMB phenomenon in the main transformers of urban power grid while minimizing the numbers of DC blocking devices installed. First, a multi-objective optimization is formulated for the optimal configuration model of the main transformer DC blocking devices, with the objective function of minimizing the DCMB current in the main transformer and reducing the number of capacitor-type DC blocking devices, and the constraint condition of limiting the DCMB current in the main transformer. The MORIME algorithm is then employed to solve this optimization problem. Next, Monte Carlo simulations are employed to address the uncertainty of the urban rail load currents, which are integrated into the solving process of the multi-objective optimization model. Lastly, the effectiveness and feasibility of the proposed method are demonstrated through a case study of the Shenzhen urban rail and city network coupled system. The results indicate that this configuration strategy not only effectively mitigates DCMB phenomenon of the main transformers but also achieves the installation of the minimum number of DC blocking devices.

Keywords: urban rail; direct current magnetic bias; stochastic load; DC blocking devices; multi-objective rime optimization

0 引言

随着我国各大城市兴修直流城轨并将其作为市
基金项目:国网河南省电力公司科技项目(5217L024000W)。
Science and Technology Project of State Grid Henan Electric Power
Company (5217L024000W)。

民的重要出行方式,城轨杂散电流入侵城网系统导致主变压器直流偏磁现象频发,给城市电力系统可靠运行带来严峻挑战^[1-2]。而复杂的城轨运行工况和城网拓扑结构为治理主变压器直流偏磁带来更大的困难^[3-4]。城轨动态运行时,不确定负荷电流将引

发杂散电流随机分布,进而导致城网主变压器直流偏磁随机超标,因此在隔直装置安装数量最小条件下能有效抑制城网主变压器直流偏磁是当前最为急迫的问题。

变压器的直流励磁分量将会使主变压器发生异常震动、噪声增加和谐波含量上升等直流偏磁效应^[5]。而目前研究普遍认为是地磁暴和直流输电系统的接地电流造成主变压器直流偏磁^[6-7]。地磁感应电流沿着电力线路入侵主变压器绕组,进而引发主变压器直流偏磁现象^[8]。当前研究重点关注地磁感应电流对电力系统产生的直流大小和分布、系统谐波畸变的影响。同时通过测量主变压器在不同接地方式和操作条件下的磁通泄露和谐波失真的励磁电流等参数,进一步研究该电流对偏磁效应的影响^[9-10]。直流系统采用单极或双极非对称输送电能时,地中直流入侵直接接地电力系统,将引发主变压器绕组发生直流偏磁现象^[11]。文献[12]建立了直流接地极运行方式可调节的直流偏磁仿真模型,并提出了直流偏磁的评估方法,可为直流输电工程邻近区域新建变电站提供参考。文献[13]提出了特高压工程中大型变压器直流偏磁度的量化方法,依据不同偏磁度分析变压器振动机制和频谱特征。

抑制直流接地极入地电流引发主变压器直流偏磁现象的现有手段主要是在变压器中安装隔直装置。文献[14]针对武汉特高压换流站附近的新能源电网,采用中性点接地切换技术实时评估直流偏磁,提出修正电位分布方法,并确定了该区域最优的直流偏磁抑制方案,为电网直流偏磁治理提供了实践依据。文献[15]提出了有效偏磁电流的概念,以此来量化该电流对主变压器的影响。通过构建优化模型,在主变压器有效偏磁电流满足安全限值的前提下,优化隔直装置安装数量。文献[16]提出了一种协同多接地极主动互联和隔直装置的入地电流抑制技术。该策略深入考量了超出规范的变压器数量以及接地极可能达到的最大入地电流等关键参数,为了增强主变压器直流偏磁的治理效能,并提高对交流电网结构变化的适应能力。

城轨系统中的杂散电流分布与地磁感应电力

和直流感地极电流的长期稳定特性存在显著差异,其分布模式受列车间隔、运行位置及运行工况等多种因素的动态变化影响^[17]。因此,城轨杂散电流在城网中的分布表现出高度的非线性和不确定性,难以进行准确预测。基于此,现有的针对直流输电引起的主变压器直流偏磁问题的抑制措施可能无法有效解决由城轨杂散电流引发的相关问题。考虑城轨动态运行中的随机性负荷和杂散电流引发城网主变压器直流偏磁随机超标,本文提出了一种基于多目标霜冰(multi-objective rime, MORIME)算法优化抑制方法,旨在实现最小化主变压器直流偏磁电流与减少电容隔直装置安装数量之间的平衡,并使主变压器直流偏磁电流满足限制要求。采用蒙特卡罗方法反映城轨随机性负荷,并利用多目标霜冰算法解决上述优化问题。以深圳城轨线路和城网的耦合系统为例验证了所提方法的有效性和可行性。

1 考虑城轨杂散电流的主变压器直流偏磁电流计算

1.1 城轨杂散电流入侵城网交流主变压器

城轨运行时,牵引电流通过电缆铠装或牵引变电站接地线入地形成杂散电流,并通过城市电网中直接接地系统进入主变压器造成直流偏磁,如图1所示。

城轨系统的动态运行受多种随机因素影响,其中包括发车时间的变化以及驾驶员行为的差异,这些因素导致城轨位置的不确定性。此外,牵引负载电流呈现随机分布,这对杂散电流分布特征产生影响,并最终引起城市电网主变压器直流偏磁现象出现不确定性的波动。

1.2 考虑城轨杂散电流的主变压器直流偏磁电流模型

基于城轨杂散电流的形成机理及在城网中的传播路径,主变压器直流偏磁电流模型将构建城轨网络模型和电网模型及二者的电气耦合模型。城轨线网模型包含上下接触网、牵引变电站、上下行轨道电路模型。城轨场站模型构建单向导通装置等效电阻实现场站与轨道的电气连接^[18-19]。城市电网模型中包含交流电网 220 kV 主变压器接地变




图1 杂散电流入侵城网主变压器路径

Fig.1 Paths of stray currents intrusion into the main transformers of the urban network

电站、500 kV 变电站以及地铁 110 kV 变电站的电路模型^[20]。

城轨杂散电流引发城市电网主变压器的直流偏磁,通过串联电容,主变压器中性点能够实现直流隔离,这是利用电容器的电气特性抑制主变压器的直流偏磁电流。在额定电压为 220 kV 或以下的非自耦变压器中,高压与低压绕组之间相互电气隔离,因此,在此类主变压器中性点位置接入电容后,可有效阻止城轨杂散电流入侵主变压器绕组。对于 500 kV 及以上的自耦变压器,该类主变压器内部存在高低压绕组间的电气连通路,仅在中性点串联电容并不足以完全消除城轨杂散电流的影响。图 2 给出了自耦变压器中性点串联电容的等效电路模型。




图2 自耦变压器等效模型

Fig.2 The equivalent model of an autotransformer

当直流隔离装置连接至自耦变压器的中性点,通过主变压器的直流偏磁电流为

$$I = I_h = (V_h - V_m) / R_h \quad (2)$$

定义矩阵 Φ , 基于节点电压计算主变压器直流偏磁电流的向量形式为

$$I = \Phi V = (\Phi Y^{-1}) I \quad (3)$$

式中: Φ 为变压器参数相关矩阵,受是否安装中性点

自耦变压器的中性点未接入直流隔离电容时,主变压器的直流偏磁电流^[15]为

$$I = I_h + I_m / K \\ = (V_h - V_m) / R_h + \frac{(V_h - V_m) / R_h - (V_m - V_1) / R_l}{K} \quad (1)$$

式中: V_h 、 V_m 和 V_1 分别对应自耦变压器的高压、中压和中性点电压; R_h 、 R_l 分别为高压绕组电阻、低压绕组电阻; K 为变压器变比; I_h 和 I_m 分别为从高、中压侧流入变压器的直流电流。

隔直装置影响; I 为节点注入电流矩阵; Y 为节点导纳矩阵; V 为节点电压向量。假设城网主变压器共安装 S 个隔直装置,此时矩阵 I 、 Φ 、 Y 均会变化,主变压器偏磁电流亦随之发生变化。此时主变压器偏磁电流为

$$I(S) = \left(\Phi - \sum_{s \in \xi} \Phi_s \right) \left(Y - \sum_{s \in \xi} Y_s \right)^{-1} I \quad (4)$$

式中: Φ_s 和 Y_s 分别为主变压器 s 隔直装置安装后 Φ 和 Y 矩阵的变化量; ξ 为主变压器编号的集合,且 $\xi = \{1, 2, \dots, S\}$ 。

1.3 最优主变压器隔直装置配置模型

城网接地主变压器数量较多,若在其所有中性点安装电容隔直设备,则可以有效地解决直流偏磁的问题。然而,这种做法可能会对系统的继电保护可靠性产生不利影响,且会增加设备安装及维护方面的经济成本。鉴于此,需要探索一种既能有效抑制直流偏磁现象又能通过优化电容隔直装置布局来实现成本效益最大化的方案^[21],以确保主变压器直流偏磁电流总含量降至最低的同时尽量减少电容隔直装置的安装数量。以此为优化目标建立多目标函数模型为

$$\min f = F(f_x, f_1) = F\left(\sum_s^k x_s, \sum_s^k |I_s|\right) \quad (5)$$

$$\text{s.t. } I_s \leq I_{Ns} \quad (6)$$

式中: f_x 为隔直装置投入运行的数量; f_1 为主变压器偏磁电流的绝对值之和; I_s 为第 s 台主变压器偏磁电流; I_{Ns} 为第 s 台主变压器偏磁电流限值; k 为主变压器总数; $F(\cdot)$ 为最优多目标函数。

考虑城轨行驶过程位置的动态变化,采用蒙特卡罗方法随机抽样城轨位置,并以此为基础计算城网主变压器所受直流偏磁电流的分布情况。若在列车运行过程中,主变压器直流偏磁电流始终低于设定的限值,则无须安装任何电容隔直装置。然而,当发现该电流水平超出规定限值时,说明存在潜在的直流偏磁问题,此时有必要重新评估并优化电容隔直设备的最佳安装位置。


2 多目标霜冰算法的主变压器隔直装置最优配置

考虑霜冰算法具有较强的全局搜索能力和局部


开发能力,引入多目标霜冰算法对上述多目标优化问题进行求解,探讨了如何通过优化策略减少电容隔直装置的安装数量,同时解决最小化主变压器中性点直流电流总和的多目标优化问题。

2.1 霜冰算法

霜冰算法通过模拟自然界中霜冰形成及融化过程,提出了一种创新的搜索策略—软霜搜索^[22]。该策略模仿了软霜颗粒在运动过程中的特性。同时,还模拟了硬冰颗粒间的相互作用,并据此开发了硬冰穿刺机制,以增强算法的性能。这一穿刺机制通过模拟硬冰颗粒的交叉过程,引入了一种创新的优化技术,如图3所示。此外,该算法优化了元启发式算法的选取策略,引入了一种积极的贪婪选择方法,并结合软霜搜索、硬冰穿刺以及正向贪婪选择,形成了霜冰算法。



(a) 软霜搜索策略



(b) 硬冰穿刺机制

图3 霜冰算法迭代机制

Fig.3 Iteration mechanism of RIME algorithm

2.1.1 软霜搜索策略

在轻微风力作用下,软霜的形成过程显示出明显的随机性,尽管其沿特定方向的生长速度较慢,其仍均匀地覆盖物体表面。提出软霜搜索策略,该算法借鉴了软霜的生长特性,利用了霜粒的随机分布和广泛的覆盖能力,使算法能够迅速探索整个搜索空间,有效避免陷入局部最优解。霜粒更新过程为

$$X_{new_i}^j = X_{best}^j + r_1 \cdot \cos\theta \cdot \beta \cdot (h \cdot (U_i^j - L_i^j) + L_i^j), r_2 < E \quad (7)$$

式中: $X_{new_i}^j$ 为第*i*个霜粒代理中第*j*个粒子的新位置; X_{best}^j 为第*j*个粒子当前迭代中最佳霜粒代理的位置; r_1 为控制参数,决定了粒子的移动方向,且取值在 $[-1, 1]$ 之间,是一个特定的极限值; r_2 为随机数,取值在 $(0, 1)$ 之间; $\cos\theta$ 为随着迭代次数变化的系数; U_i^j 和 L_i^j 分别为第*i*个霜粒代理中第*j*个粒子在搜索空间的上下限; β 为环境因素,其随着迭代的变化而变化; E 为附着系数,影响代理的凝结概率,并随着迭代次数的增加而增加; h 为黏附程度。

θ 为与迭代次数有关的变量,应满足

$$\theta = \pi \cdot (g/10 \cdot G) \quad (8)$$

式中: G 为最大迭代次数; g 为当前迭代次数。

β 的数学模型是阶梯函数,满足

$$\beta = 1 - \left\lfloor \frac{wg}{G} \right\rfloor / w \quad (9)$$

式中: w 为用于控制阶梯函数的分段数量,默认值为5; $\lfloor \cdot \rfloor$ 表示四舍五入。

$$E = \sqrt{(g/G)} \quad (10)$$

2.1.2 硬冰穿刺机制

在疾风的环境下,硬冰的生成呈现更明显的规律性,而软霜的生成则带有更高的随机性。硬冰在特定方向上以累积的方式增长,并且更易发生穿透作用。因此,该算法设计了硬冰穿刺机制,目的是提升算法的收敛速度和避免陷入局部最优的能力,可表示为

$$X_{new_i}^j = X_{best}^j, r_3 < \Gamma^{sow}(X_i^j) \quad (11)$$

式中: $\Gamma^{sow}(X_i^j)$ 为选择概率,即第*i*个霜粒代理归一化适应度值; r_3 为系数,并满足 $r_3 \in [-1, 1]$ 。

2.1.3 积极贪婪选择机制

在元启发式优化算法的种群更新环节中,采用了一种积极的贪婪选择方法。该方法依据个体适应

度的前后变化来判断是否进行更新,并对涉及的两个个体解进行替换。

2.2 多目标霜冰算法

在处理多目标优化问题时,若某一解决方案能够在至少一个目标函数上实现更优表现,并保持其他目标不变,则该解就被认为是优于或支配另一个解。因此,帕累托最优解为任何给定的多目标问题提供了主要的解决方案^[23]。关于支配概念及其相关术语的定义如图4所示。图4中,帕累托前沿(Pareto front, PF)表示为 $\{f(\vec{x}) \mid \vec{x} \in (\vec{x}_1, \vec{x}_2, \dots, \vec{x}_n)\}$;帕累托支配(Pareto dominance, PD)满足 $\vec{x} \in (\vec{x}_1, \vec{x}_2, \dots, \vec{x}_n) < \vec{x}'$;帕累托最优(Pareto optimal, PO)表示为 $f(\vec{x}) \leq f(\vec{x}') \mid \vec{x} \in (\vec{x}_1, \vec{x}_2, \dots, \vec{x}_n)$;帕累托解(Pareto solution, PS)表示为 $\vec{x} \in (\vec{x}_1, \vec{x}_2, \dots, \vec{x}_n)$;NDS为非支配解(non-dominated solutions, NDS)集。

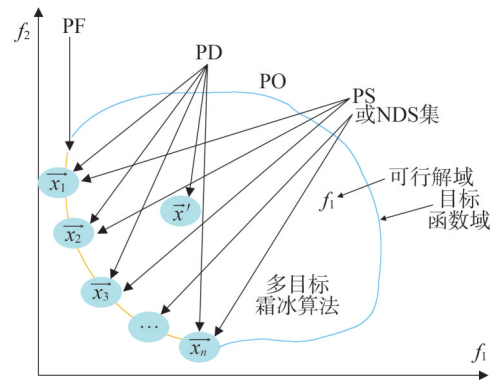


图4 多目标问题的所有定义

Fig.4 All definitions of multi-objective problem

MORIME 算法采用 NSGA-II 中的非支配排序方法和保持多样性的拥挤距离方法,将种群划分为不同的非支配层级,每个层级都有一个计算出的拥挤距离。这一过程从精英非支配排序开始,以区分各种非支配层级,然后利用拥挤距离方法确保最优解集合内的多样性^[24]。

在拥挤距离评估方法中,种群会根据各个目标函数的值从小到大进行排序^[25]。排序后的首尾解(序列中的第一个和第1个解,1代表该非支配集合中解的总数)被赋予极大的拥挤距离值。对于中间的解(从第二个解至倒数第二个解),对于每个目标*b*

(b 取值范围是 $1 \sim n$), 其拥挤距离 d_b^a 是基于相邻解 (即第 $a+1$ 个目标函数解 F_b^{a+1} 和第 $a-1$ 个目标函数解 F_b^{a-1}) 在目标函数 b 上的值的差异来确定的。

$$d_b^a = \frac{F_b^{a+1} - F_b^{a-1}}{F_b^{\max} - F_b^{\min}} \quad (12)$$

MORIME 算法采用基于帕累托支配和拥挤距离的选择过程。在初始化种群时,通过随机生成初始父代种群 P_0 开始,依据 RIME 算法生成种群 Q_0 。然后在 t 代,父代和子代种群合并,形成联合种群 $R_t = P_t \cup Q_t$,并进行非支配排序,将其划分为不同的非支配级 (F_1, F_2, \dots, F_l)。若构建的新种群 S_t 满足 $|S_t| \geq N$ 的数量目标,那么从该种群选择解。若不满足,将 $P_{t+1} = S_t/F_1$ 代入父代种群。上述步骤持续进行,直到满足所有个体。如果最后 F_l 的个体数量超过所需数量,则使用拥挤度比较算子 C^a 对解进行排序,选择下一代 P_{t+1} 。算法流程如图 5 所示,其中新种群 $S_t = (F_1, F_2, \dots, F_l)$; 拥挤距离 $C^a = \frac{F^{a+1} - F^{a-1}}{F^{\max} - F^{\min}}$ 。

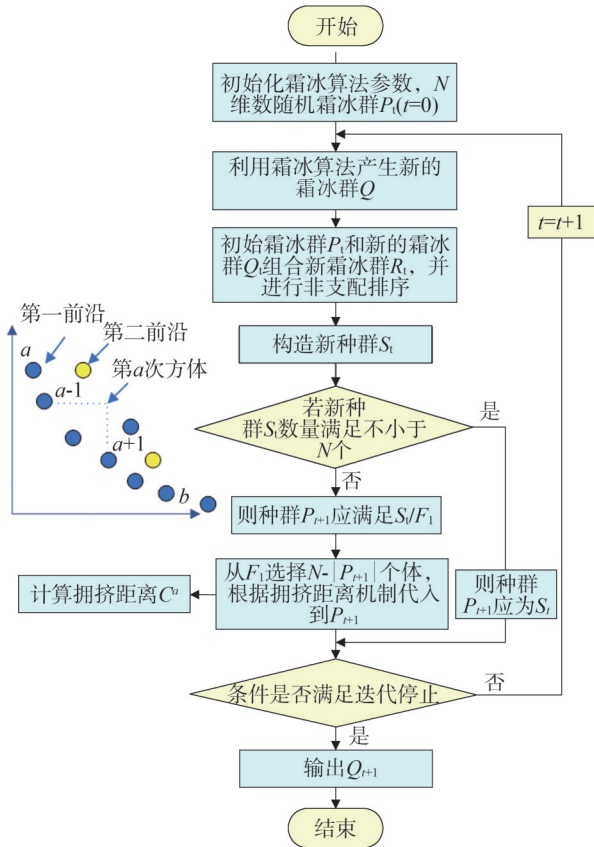


图 5 多目标霜冰算法的优化过程

Fig.5 The optimization process of MORIME algorithm

3 算例分析

以深圳的城轨网络和城市电网为算例进行分析,电力系统中 220 kV 及更高电压等级的接地主变压器共有 73 台^[4]。考虑到城轨负荷的不确定性,采用蒙特卡罗方法随机抽样城轨的位置,通过分析城轨运行图表确定轨道上其他城轨的分布情况,采用蒙特卡罗方法对列车的误差进行抽样分析,从而得到列车在轨道上的位置概率分布。同时,通过对城轨系统中城轨牵引电流的计算,结合城轨的具体位置和牵引电流数据,计算各节点的电压值,最终给出主变压器直流偏磁电流。

3.1 主变压器直流偏磁分布

根据南方电网相关标准,主变压器的直流偏磁电流被限制为 5 A^[15]。该电流的分布通过对城轨位置进行随机抽样并计算得出,如图 6 所示。从图 6 中可以看出,在所选取的所有样本中,有 8 台主变压器出现了直流偏磁电流超出规定值的情况,占比达到 10.95%,有必要采取相应措施来控制或减少这种现象的发生。




图 6 主变压器直流偏磁电流

Fig.6 The DCMB current of the main transformer

通过在偏磁电流超标的 8 台变压器安装隔直装置,确保主变压器直流偏磁满足规范要求并抑制偏磁现象。则计算此时各主变压器偏磁电流,结果如图 7 所示。

图 7 表明,在 7、10、12 号主变压器安装隔直装置后,尽管中性点电流完全被隔离,但主变压器的偏磁电流仍然超标。说明隔直装置没有彻底消除主变压器的直流偏磁现象。在偏磁电流超标的主变压器

节点安装隔直装置,依然有四组主变压器的偏磁电流继续抬升。可见若不进行优化配置,仅安装隔直装置处理偏磁电流超限问题,可能会引发城网中其他节点主变压器偏磁电流增加,无法实现预期治理效果。

3.2 所提方法的计算效率和有效性

对比多目标粒子群优化和哈里斯鹰优化方法,通过求取最大主变压器直流偏磁电流的最小分布和隔直装置数量的求解,验证所给出多目标霜冰算法的计算效率优越性,如图8和图9所示。

图8展示了最小化迭代过程中主变压器最大偏磁电流的变化。采用多目标霜冰算法经过迭代21次,主变压器直流偏磁电流满足限值,且电流小于5 A,用时13 s。而迭代41次,偏磁电流为0.257 A,电流值已经收敛。而采用多目标粒子群优化方法求解,迭




图7 增加隔直装置后的主变压器直流偏磁电流

Fig.7 The DCMB current of the main transformer with DC blocking devices installed




图8 最大主变压器直流偏磁电流的最小分布

Fig.8 The minimum distribution of the maximum DCMB current of the main transformer




图9 迭代中隔直装置安装数量

Fig.9 Numbers of DC blocking devices installed in the iteration

代45次时主变压器直流偏磁电流达到限值以下,经过63次迭代时主变压器直流偏磁电流达到收敛,用时45 s。采用多目标哈里斯鹰优化方法求解,经过78次迭代,主变压器直流偏磁电流满足限值要求。而经过96次迭代,主变压器直流偏磁电流才趋于收敛,用时57 s。对比多目标粒子群算法和哈里斯鹰算法,采用多目标霜冰算法可提高计算效率,并快速收敛,在最短的计算用时实现主变压器偏磁电流最小且符合规范要求。

图9给出了隔直装置数量随迭代次数的变化。采用多目标霜冰优化算法时,系统能够在120次迭代后确定隔直装置的最佳安装数量为38台。而采用多目标粒子群优化方法求解,隔直装置安装数量随迭代次数呈动态变化,收敛困难。采用多目标哈里斯鹰优化方法,经过62次迭代,隔直装置安装数量趋于收敛,但是隔直装置安装数量较高,需要安装52台隔直装置。相比多目标粒子群算法和哈里斯鹰算法,多目标霜冰算法可快速完成迭代并给出安装数量最小的优化方案。

3.3 考虑城轨负荷随机性的主变压器位置优化配置策略

采用蒙特卡罗方法对深圳城轨系统内的列车位置进行随机抽样,仿真模拟了城轨负荷的随机性。设定列车的发车间隔为180 s,停站时间为40 s,在城轨网络中任意时刻运行的列车总数为330列。通过执行10 000次蒙特卡罗抽样模拟,可得到隔直装置的最优安装点。

图 10 给出了主变压器隔直装置的安装概率,即每个变电站在所有抽样实例中的隔直装置安装比例。由图 10 可知,在城轨正常运行中,主变压器隔直装置安装概率超过 90% 的共有 38 台,分别为 2、12、13、22、23、30—56、61、62、64、67、70、71 号主变压器。而编号为 7、26、72、73 的主变压器隔直装置安装比例低于 20%。考虑城轨负荷随机性,为确保城网主变压器直流偏磁均满足要求,建议在 38 台主要变压器上加装隔直设备,特别是为城轨主变压器供电的 220 kV 变电站,均应加装隔直装置。

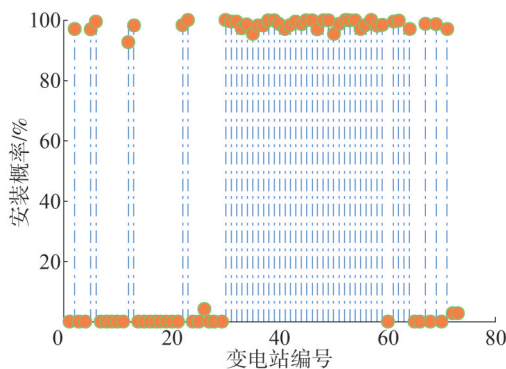


图 10 城网主变压器隔直装置安装位置

Fig.10 Installation location of DC blocking devices for the urban power grid main transformer

4 结论

提出一种利用多目标霜冰算法优化并控制主变压器直流偏磁现象超过标准限制的方法。该方法将主变压器的直流偏磁电流维持在标准限值之内设定为约束条件,以最小化主变压器直流偏磁电流的最大值和电容隔直装置的数量为目标函数,给出主变压器隔直装置的最优配置方案。结论如下:

1)使用多目标霜冰优化算法解决城网主变压器电容隔直装置的优化配置问题,结果表明该算法能够迅速且稳定地收敛。最优配置策略不仅有效解决了主变压器直流偏磁电流超标的问题,而且最大程度地减少了所需电容隔直装置的数量,进而实现了对直流偏磁电流的有效管理和隔直装置使用量减少之间的平衡优化。

2)以深圳城轨和电网耦合系统为例,采用了蒙特卡罗仿真技术来模拟轨道交通负荷的随机变化,并纳入优化求解过程中,结果表明完全抑制深圳电网主变压器直流偏磁需要在 38 个主变压器安装隔直装置,所有为城轨供电的 220 kV 变电站也应当配备该设备。

本研究考虑了城轨运行的随机性,但未深入分析城轨操作策略或高比例新能源出力的不确定性对主变压器直流偏磁概率分布的影响。与电容隔直设备相比,电阻隔直设备在安装成本方面具有更大优势。因此,下一步研究中可将电容和电阻隔直装置结合使用,以减少城网主变压器的直流偏磁现象。

参考文献

- [1] 黄华,陈璐,吴天逸,等.城市轨道交通动态运行对交流电网变压器偏磁直流的影响[J].电网技术,2022,46(11):4524-4533.
HUANG Hua, CHEN Lu, WU Tianyi, et al. Influence of dynamic operation of urban rail transit on DC magnetic bias of AC power grid transformer [J]. Power System Technology, 2022, 46 (11) : 4524-4533.
- [2] 吴晓文,周年光,胡胜,等.城市轨道交通引起的变压器直流偏磁噪声与振动特性[J].电测与仪表,2017,54(17):117-122.
WU Xiaowen, ZHOU Nianguang, HU Sheng, et al. Audible noise and vibration characteristics of DC-bias in power transformers caused by urban mass transit system [J]. Electrical Measurement & Instrumentation, 2017, 54(17) : 117-122.
- [3] 吴天逸,冯楠,高凯,等.轨道交通影响下上海电网直流偏磁多参量监测及治理研究[J].高压电器,2023,59(11):84-91.
WU Tianyi, FENG Nan, GAO Kai, et al. Research on multi parameters monitoring and suppression of DC bias in Shanghai power grid under influence of rail transit [J]. High Voltage Apparatus, 2023, 59(11) : 84-91.
- [4] 王爱民,林圣,李俊逸,等.城市轨道交通长线路杂散电流仿真模型[J].高电压技术,2020,46(4):1379-1386.
WANG Aimin, LIN Sheng, LI Junyi, et al. Stray current simulation model of the long line of DC metro systems [J]. High Voltage Engineering, 2020, 46(4) : 1379-1386.
- [5] 李嘉思,刘曳君,潘卓洪,等.复杂土壤结构下直流接地极选址及直流偏磁风险评估[J].电测与仪表,2021,58(2):13-18.
LI Jiasi, LIU Yejun, PAN Zhuohong, et al. Site selection of DC grounding electrodes in complex soil and risk assessment of DC bias [J]. Electrical Measurement & Instrumentation, 2021, 58(2) : 13-18.

- [6] 宋许鹏,杨小洋,樊征臻.基于电流合成矢量轨迹特性的双馈风电场主变压器差动保护[J].中国电力,2025,58(2):9-21.
SONG Xupeng, YANG Xiaoyang, FAN Zhengzhen. Differential protection of main transformer of doubly-fed wind farm based on current synthesized vector trajectory characteristics [J]. Electric Power, 2025, 58(2): 9-21.
- [7] 郑涛,于佳旭,陆程曦,等.基于磁路耦合的Sen变压器差动保护方案[J].中国电力,2025,58(3):108-118.
ZHENG Tao, YU Jiaxu, SUI Chengxi, et al. Sen transformer differential protection scheme based on magnetic circuit coupling [J]. Electric Power, 2025, 58(3): 108-118.
- [8] 邓雯瀚,苗宇,许逵,等.电力变压器状态评估方法的应用及展望[J].智慧电力,2023,51(10):93-102.
DENG Wenhan, MIAO Yu, XU Kui, et al. Application and prospect of condition assessment method of power transformer [J]. Smart Power, 2023, 51(10): 93-102.
- [9] 陈青恒,马宏彬,何金良.直流偏磁引起的500kV电力变压器振动和噪声的现场测量与分析[J].高压电器,2009,45(3):93-96.
CHEN Qingheng, MA Hongbin, HE Jinliang. Field monitoring and analysis on vibration and noise of 500 kV electrical transformer under DC current biasing [J]. High Voltage Apparatus, 2009, 45(3): 93-96.
- [10] 罗超月岭,郑韵馨,徐帧雨,等.基于Borderline-SMOTE-IHT混合采样的改进GWO-SVM变压器故障诊断方法[J].智慧电力,2023,51(7):108-114.
LUO Chaoyueling, ZHENG Yunxin, XU Zhenyu, et al. Improved GWO-SVM transformer fault diagnosis method based on Borderline-SMOTE-IHT mixed sampling [J]. Smart Power, 2023, 51(7): 108-114.
- [11] 胥建文,李书连,杜建平,等.基于1000 MVA/1000 kV特高压变压器的直流偏磁物理效应仿真研究[J].山东电力技术,2018,45(7):29-34.
XU Jianwen, LI Shulian, DU Jianping, et al. Study on DC bias magnetic effects of UHV transformer based on 1 000 MVA/1 000 kV [J]. Shandong Electric Power, 2018, 45(7): 29-34.
- [12] 刘焯,傅晨钊,赵文彬,等.直接地极运行方式调整过程对变压器直流偏磁影响的研究[J].高压电器,2021,57(12):110-116.
LIU Ye, FU Chenzhao, ZHAO Wenbin, et al. Study on influence of operation mode adjustment of DC grounding pole on DC magnetic bias of transformer [J]. High Voltage Apparatus, 2021, 57(12): 110-116.
- [13] 何良,吴天宝,李荣,等.直流偏磁对500 kV变压器振动特性的影响分析[J/OL].电力自动化设备,2023:1-6[2024-11-10].
<http://kns.cnki.net/KCMS/detail/detail.aspx?filename=DLZS2024013000I&dbname=CJFD&dbcode=CJFQ>.
HE Liang, WU Tianbao, LI Rong, et al. Influence of DC bias on vibration characteristics of 500 kV transformer [J/OL]. China Industrial Economics, 2023: 1-6 [2024-11-10]. <http://kns.cnki.net/KCMS/detail/detail.aspx?filename=DLZS2024013000I&dbname=CJFD&dbcode=CJFQ>.
- [14] 吴传奇,李晓辉,阮羚,等.特高压直接地极近区新能源接入电网的直流偏磁评测与抑制[J].高电压技术,2022,48(10):4172-4180.
WU Chuanqi, LI Xiaohui, RUAN Ling, et al. DC bias evaluation and suppression of power grid with renewable energy near grounding electrode of UHVDC transmission project [J]. High Voltage Engineering, 2022, 48(10): 4172-4180.
- [15] 刘春明,黄彩臣,潘明明,等.抑制变压器直流偏磁的电容器直装置优化配置[J].高电压技术,2016,42(7):2308-2314.
LIU Chunming, HUANG Caichen, PAN Mingming, et al. Optimal configuration of capacitor blocking devices for suppressing DC bias in transformers [J]. High Voltage Engineering, 2016, 42(7): 2308-2314.
- [16] 韩宝明,杨智轩,余怡然,等.2020年世界城市轨道交通运营统计与分析综述[J].都市快轨交通,2021,34(1):5-11.
HAN Baoming, YANG Zhixuan, YU Yiran, et al. Statistical analysis of urban rail transit operation in the world in 2020: a review [J]. Urban Rapid Rail Transit, 2021, 34(1): 5-11.
- [17] 仰枫,李春茂,郭裕钧,等.列车运行工况对电力变压器直流偏磁影响的仿真分析[J].都市快轨交通,2022,35(2):50-54.
YANG Feng, LI Chunmao, GUO Yujun, et al. Simulation analysis of the effect of train operating conditions on DC bias of power transformer [J]. Urban Rapid Rail Transit, 2022, 35(2): 50-54.
- [18] 澹台乐琰,韩肖清,王磊,等.多列车运行下地铁杂散电流建模仿真[J].电测与仪表,2020,57(22):7-16.
TANTAI Leyan, HAN Xiaoqing, WANG Lei, et al. Modeling and simulation of stray current in subway with multi-train operation [J]. Electrical Measurement & Instrumentation, 2020, 57(22): 7-16.
- [19] 夏能弘,唐文涛,李怀慎,等.地铁轨道局部绝缘损坏下动态杂散电流及地电位梯度建模与分析[J].电力系统保护与控制,2023,51(4):53-61.
XIA Nenghong, TANG Wentao, LI Huaishen, et al. Modeling and analysis of dynamic stray current and ground potential gradient under partial insulation damage of a metro track [J]. Power System Protection and Control, 2023, 51(4): 53-61.
- [20] 栾士岩,魏颖莉,杨晶鑫,等.基于改进GWO-PSO算法的变电站二次系统保护策略[J].智慧电力,2024,52(8):122-128.
LUAN Shiyan, WEI Yingli, YANG Jingxin, et al. Secondary system protection strategy of substation based on improved GWO-PSO algorithm [J]. Smart Power, 2024, 52(8): 122-128.
- [21] 宋雨妍,王渝红,刘天宇,等.基于多目标离散粒子群算法的电容器直装置优化配置[J].电网技术,2019,43(1):266-274.
SONG Yuyan, WANG Yuhong, LIU Tianyu, et al. Optimal

- configuration of capacitor blocking devices based on multi-objective discrete PSO [J]. Power System Technology, 2019, 43(1):266-274.
- [22] SU H, ZHAO D, HEIDARI A A, et al. RIME: a physics-based optimization[J]. Neurocomputing, 2023, 532:183-214.
- [23] ABU KHURMA R, BRAIK M, ALZAQEBAH A, et al. Advanced RIME architecture for global optimization and feature selection[J]. Journal of Big Data, 2024, 11(1):89.
- [24] PANDYA S B, KALITA K, JANGIR P, et al. Multi-objective RIME algorithm-based techno economic analysis for security constraints load dispatch and power flow including uncertainties model of hybrid power systems[J]. Energy Reports, 2024, 11:4423-4451.
- [25] YANG W L, ZHANG Z Q, MENG K, et al. CEEMDAN-RIME-bidirectional long short-term memory short-term wind speed prediction for wind farms incorporating multi-head self-attention

mechanism[J]. Applied Sciences, 2024, 14(18):8337.

收稿日期:2024-11-12

修回日期:2025-05-07

作者简介:

宋景博(1987),通信作者(283848794@qq.com),男,硕士,高级工程师,主要研究方向为电力系统接地及变电站设计;

陈晨(1984),女,硕士,正高级工程师,研究方向输变电工程设计及管理;

齐桓若(1989),女,硕士,高级工程师,研究方向为电力系统规划设计;

张金凤(1990),女,硕士,工程师,研究方向为高压与绝缘技术;

薛文杰(1991),女,硕士,工程师,研究方向为工程造价;

刘铜锤(1989),男,博士,高级工程师,主要研究方向为综合能源系统优化调度及防雷接地。

(责任编辑 郑天茹)

DOI: 10.20097/j.cnki.issn1007-9904.240414

基于电场等效的 ± 800 kV 直流输电线路直线塔无人机 灭火安全距离研究

过 羿¹, 胡圣涛², 刘宇舜¹, 赵玉顺², 张佳庆^{1*}

(1. 国网安徽省电力有限公司电力科学研究院, 安徽 合肥 230091; 2. 合肥工业大学, 安徽 合肥 230009)

摘要: 无人机(unmanned aerial vehicle, UAV)灭火已逐渐成为输电线路灭火作业重要手段,对于特高压(ultra high voltage, UHV)输电线路,由于导线周围场强高,易导致无人机放电,需要控制无人机与导线间的安全距离,但目前缺乏灭火过程中的安全距离设置依据。文中基于电场等效的原则,通过仿真与试验相结合的方法,定量研究并确定了 ± 800 kV 直流(direct current, DC)输电线路直线塔无人机灭火的安全距离。首先,构建 ± 800 kV 直流输电线路直线塔无人机灭火作业电场仿真模型,基于无人机几何形状、电气性能及周围环境电场分布,利用有限元法确定无人机不同灭火位置及距离下的空间电场分布。然后,搭建灭火氛围下空气间隙放电试验平台,模拟灭火环境下灭火剂对空气间隙放电的影响,定量分析灭火环境中无人机初始感应放电场强。最后,结合空间电场分布及初始感应放电场强,得到了 ± 800 kV 直流输电线路直线塔无人机灭火作业最小安全距离为3.0 m。上述研究可为特高压输电线路的无人机灭火作业安全距离设置提供理论依据,为类似高电压环境下无人机的安全作业提供有效参考。

关键词: 电场等效; 电场分布; 直流输电线路; 无人机灭火; 最小安全距离

中图分类号: TM81

文献标志码: B

文章编号: 1007-9904(2025)12-0102-11

Research on the Safety Distance for UAV Fire Extinguishing on ± 800 kV DC Transmission Line Linear Tower Based on Electric Field Equivalence

GUO Yi¹, HU Shengtao², LIU Yushun¹, ZHAO Yushun², ZHANG Jiaqing^{1*}

(1.State Grid Anhui Electric Power Co., Ltd. Electric Power Research Institute, Hefei 230091, China;

2.Hefei University of Technology, Hefei 230009, China)

Abstract: Unmanned aerial vehicle (UAV) fire extinguishing has gradually become an important means for fire fighting on transmission lines. For ultra high voltage (UHV) transmission lines, due to the high electric field strength around the wires, UAVs are prone to discharging, and the safe distance between the UAV and the wires needs to be controlled. However, there is currently a lack of a basis for setting the safe distance during fire-fighting operations. Based on the principle of electric field equivalence, this paper quantitatively studies and determines the safe distance for UAV fire-fighting operations on the ± 800 kV direct current (DC) transmission line linear tower by combining simulation and experiment. Firstly, the electric field simulation model for UAV fire extinguishing operation on the linear tower of a ± 800 kV current transmission line is constructed. Based on the UAV's geometric shape, electrical performance and the surrounding electric field distribution, the spatial electric field distribution of UAV under different fire extinguishing positions and distances is determined using the finite element method. Then, an air gap discharge testing platform is built to simulate the influence of fire extinguishing agents on air gap discharge in fire fighting environment, and the initial induced discharge field strength of the UAV in fire fighting environment is quantitatively analyzed. Finally, by combining with the spatial electric field distribution and the initial induced discharge field strength, the minimum safe distance for UAV fire extinguishing operation on ± 800 kV DC transmission line linear towers is determined to be 3.0 meters. The above research can provide a theoretical basis for the safe distance setting of UAV fire fighting operation of UHV transmission lines, and provide an effective reference for the safe operation of UAV in similar high-voltage environments.

Keywords: electric field equivalence; electric field distribution; direct current transmission lines; Unmanned aerial vehicle fire extinguishing; minimum safe distance

基金项目: 国网安徽省电力公司科技项目(521205220001)。

Science and Technology Project of State Grid Anhui Electric Power Company(521205220001).

0 引言

我国输电线路架设地域大,存在区域气候多变、地形复杂等问题^[1-3],特别是位于山区的输电线路发生火灾后,灭火困难。作为传统灭火方式的人工灭火,存在灭火速度慢、特殊地形和气候下灭火困难、无法第一时间处置高处火情等问题^[4-6]。无人机灭火具有灭火速率高、受地形及气候限制小、可及时处理高处火情等优点,可大幅度提高灭火作业的质量和效率^[7-10]。研究和发​​展输电线路无人机灭火技术,对于保障电力系统安全运行具有重要意义。

目前国内外针对输电线路无人机灭火的研究较少,大多集中于输电线路无人机灭火巡检监测的阶段。吴传平^[11]等提出了输电线路山火预测、监测与应急处置于一体的输电线路山火防治技术体系,并研发了相应的系统和装备,有效提高输电线路抵御山火灾害的能力,提高线路运行的安全性。周特军^[12]等应用无人机搭载三维激光进行山火风险评估,提出了无人机弹道发射、投掷灭火球以及小流量防蒸发喷射等输电线路初发山火的灭火方法,可快速扑灭初发山火。王启飞^[13]等基于流程程序分析法和 Petri 网模型法,合并重组优化现有无人机巡检和灭火流程步骤,减少了 39.1% 作业时间和 50% 搬运距离。Liu^[14]等基于输电线路割线斜率特性,采用最小二乘多项式曲线拟合方法增强输电线路的几何特征,提高了定位精度与实时性。文献[15]通过无人机融合惯性测量单元、深度读数和光流传感器计算环境特征,并采用虚拟势场和局部深度测量来避障和探测火源。文献[16]混合遗传算法、蚁群优化和粒子群优化三种算法,以此简化电磁干扰和最小接近距离为主要约束的无人机输电线路巡检任务规划,提高了无人机巡检的效率性与安全性。

综上所述,目前国内外学者的研究主要集中在输电线路火情监测、灭火方式开发和巡检及灭火流程优化的阶段。输电线路无人机灭火作业安全距离的研究较少,缺乏无人机灭火的安全距离设定方法,无量化数据支撑。现阶段仍处于灭火作业人员在确保不出事故的前提下使用遥控装置操控无人机灭火的主观经验判断阶段^[17-19]。该灭火方式存在坠机率高、无法充分发挥无人机的高效率等问题^[20-23]。

因此亟须开展相关研究,得出无人机灭火量化精确结论,确定无人机灭火作业范围和安全间距,提升输电线路灭火效率,保障输电线路安全。

确定无人机灭火作业范围和安全间距需要实地试验,进行灭火剂氛围下无人灭火作业范围和安全间距测试,易对输电线路及测试人员安全产生威胁。为提高安全性,本文基于电场等效原则,首先对 ± 800 kV 输电线路直线塔无人机灭火作业进行电场仿真分析,确定了无人机不同灭火位置及距离下的电场分布;然后开展了灭火氛围下空气间隙击穿试验,得到了灭火氛围下间隙击穿特性,结合电场分布,得到无人机灭火作业最小安全距离,并进行模拟试验,验证了理论分析。

1 灭火安全距离电场等效法

电场等效原理是一种通过简化复杂电场问题来分析电场分布和电场强度的理论方法,主要应用于电气、电子、环境物理等多个领域,它源于电磁场理论中的“等效源”概念。其核心思想是:通过选取一种或多种假设的场源来模拟和替代真实的电场源,使得该替代电场具有与真实电场相同的电场强度和电场分布等电场特性。其理论基础源于静电场的基本规律,尤其是高斯定律和叠加原理。根据高斯定律,静电场的源是电荷分布所产生的电场。叠加原理则表明,多个电荷产生的电场可以视为单个电荷产生的电场的叠加。因此,对于复杂电场问题,可以通过选择适当的等效场源来替代实际的电荷分布,简化计算,并为工程应用提供可靠的理论支持。基于此,电场等效原理被广泛应用于高压电力系统、电气安全分析等领域,减小电气安全事故的发生。

电场等效原理的计算过程通常包括以下步骤。

1) 建立问题的物理模型:将实际问题转化为电场的模型。

2) 选择等效源:选择等效源,使计算得到的电场与实际电场相匹配。

3) 求解电场分布:采用适当的数学方法计算等效模型中的电场分布。

4) 应用边界条件:电场计算需要在边界上应用适当的条件。

5) 校验和调整模型:通过试验数据或更精确的计算方法校验等效模型的准确性。

6)利用仿真软件计算:借助有限元分析仿真软件在给定边界条件和材料特性下,计算电场分布,并根据需要进行优化设计。

无人机机身通常由碳纤维复合材料等导电媒质组成,无人机在输电线路走廊内灭火作业时,也同时处于导线周围的强电场中,由于悬空作业,会成为电位悬浮导体而产生感应电位。无人机电位与导线电位间存在电位差,该电位差会随无人机与导线间距离的缩小而非线性增大,当距离小于安全距离时,无人机表面会发生电晕放电或火花放电,放电产生的脉冲电流会对无人机的电控系统产生干扰或破坏作用^[24-25],影响无人机灭火作业安全性。

无人机感应放电的实质就是无人机上的感应电场强度超过了周围空气绝缘介质的放电起始场强。因此,可基于电场等效原理,将灭火氛围下极不均匀电场的典型棒-板间隙的击穿场强作为无人机各部位之间及无人机与杆塔等高压设备间是否发生感应放电的判据。仿真测量得到无人机距输电线路杆塔不同距离下的最大感应电场强度,再通过该无人机感应放电判据即可得到无人机输电线路杆塔区域灭火作业安全距离。

2 ±800 kV 线路无人机灭火电场仿真


2.1 有限元模型

利用仿真软件建立±800 kV 输电线路直线塔与无人机模型。模型如图1所示。空气域为半径50 m、高度100 m的圆柱体。直线塔选用典型的JC1塔,参数如表1所示。导线采用直径33.6 mm、分裂间距400 mm的六分裂钢芯铝绞线,型号为LGJ-630/45。绝缘子采用V型串布置的800 kV复合绝缘子,结构高度为10.6 m。无人机长、宽、高分别为1 800 mm、1 340 mm、700 mm。


表1 JC1塔设计参数

Table 1 JC1 tower design parameters


参数	数值
呼高/m	39
水平档距/m	550
垂直档距/m	700
转角度数/(°)	0~20



(a)杆塔模型



(b)无人机模型



(c)总体模型

图1 仿真模型

Fig.1 Simulation models

2.2 参数设置

空气域采用灭火剂/空气混合物,灭火剂选择干粉灭火剂、泡沫灭火剂和水基灭火剂,由于输电线路直线塔区域火灾大多发生在野外,着火范围大,因此难以应用气体灭火剂,因此采用固体干粉、液气混合泡沫和液体水基这三种灭火剂进行研究;杆塔材料选用铁;导线和无人机材料采用铝;绝缘子为复合绝缘子。上述材料的相关参数如表2所示。

表2 参数设置
Table 2 Parameter setting

材料	相对介电常数	电导率/(S/m)	网格划分
杆塔	1×10^{10}	1×10^7	常规
导线	1×10^{10}	3.8×10^7	超细化
绝缘子	8	1×10^{-16}	常规
无人机	1×10^{20}	3.8×10^7	超细化
空气	干粉	2.66×10^{-10}	常规
	泡沫	1.21×10^{-5}	
	水基	1.50×10^{-6}	

2.3 多物理场控制方程

±800 kV 直流输电线路承受的电压为直流电压,该区域内的传导电流场是稳恒的。在该情况下,电导率是电场分布关键影响因素,因此电场计算为恒定电流场的计算问题。

在电压频率较低时,电磁波的波长远大于设备的长度,设备内部磁场和电场的耦合很小,此时,可以忽略磁场的影响,恒定电流场稳态电场方程如式(1)所示。

$$\begin{cases} \nabla \cdot J = Q \\ \nabla \times E = 0 \\ J = \sigma E \end{cases} \quad (1)$$

式中: ∇ 为哈密顿算子; \cdot 表示散度计算; \times 表示旋度计算; J 为电流密度; Q 为电荷; E 为电场强度; σ 为电导率。

式(1)的解给出了电流源在介质中的电位分布。±800 kV 直流输电线路区域电流场计算实质就是对恒定电场和具有边界条件麦克斯韦方程组求解。根据恒定电流场的无旋场特性,由式(1)可以得出

$$E = -\nabla\phi \quad (2)$$

式中: ϕ 为电位; $-\nabla$ 表示电位与电场强度方向相反。对于恒定电场,利用式(2)可以确定电位函数与电荷密度的关系,由电荷分布求出电位函数,继而求出电场强度。

电场计算中,无人机为悬浮电位,稳态电场方程如式(3)所示。

$$\int -n \cdot J dS = I_0 \quad (3)$$

式中: n 为电流密度所在边界面的单位法向量; I_0 为

初始电流; S 为电流密度所在面的面积。

2.4 仿真结果及分析

±800 kV 直流输电线路区域无人机灭火作业安全距离电场仿真的边界条件如下。


1)导线的运行电压,边界电位为导线运行电压,两侧导线分别施加±800 kV 电压。

2)杆塔及地面的电位 $\phi = 0$,接地处理。

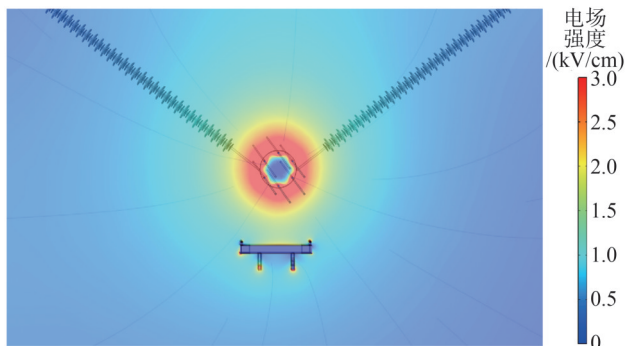
3)无人机模型电位为悬浮电位。

4)设置模型边界,为贴近实际情况,减小空间电荷对电场的影响,边界需要离导线、杆塔等模型较远,模型边界与地面围成一个完全封闭的计算场域。


对无人机进行空间电场仿真,空间电场分布如图2所示。由图2可知,当无人机靠近导线时,空间电场产生了明显的畸变,无人机各处电场强度均有较大幅度的增强,尤其是机翼、脚架处,增强现象极为明显。这是由于无人机相较于输电线路可视为棒状尖端,易发生电荷积聚与电场畸变现象,尤其是机翼和脚架处,曲率较小,更易产生该现象。因输电线路所产生的电场畸变可能会对无人机的电子设备(如飞控、导航系统、通信系统等)产生影响,导致设备出现误操作、信号干扰或误差,影响无人机的定位精度、姿态控制和通信稳定性。电场畸变还可能引起其他类型传感器(如气压计、加速度计等)出现错误信号,使飞行控制系统无法精确计算无人机的高度、速度等关键飞行数据,从而增加飞行失控的风险。同时,当电场强度足够高时,机翼或其他部件可能会发生电晕放电,即电荷通过空气放电。放电的瞬间可能会导致无人机的电气系统出现短暂的电压波动,影响其稳定性,甚至损坏电气元件。



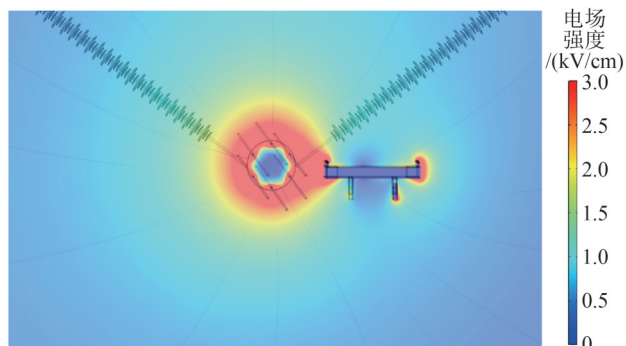
(a)无人机位于导线下方0.5 m



(b) 无人机位于导线下方 1.0 m



(c) 无人机位于导线内测 0.5 m



(d) 无人机位于导线外测 0.5 m

图2 空间电场分布

Fig.2 Spatial electric field distribution

对无人机处于导线内侧、下方和外侧进行仿真,距离为 0.5~3.5 m,依次递增 0.5 m。不同灭火剂氛围下无人机电场强度分如表 3—表 5 所示。

由表 3—表 5 可知,随着无人机与导线的距离增大,无人机在灭火剂灭火形成的环境下的最大电场强度逐渐减小,无人机在导线内侧衰减速度较快,在导线下方衰减速度较慢;与导线距离相同时,无人机在导线内侧电场强度较大,危险程度较高,易被击穿。这是由于在相同距离处,无人机在导线内侧时距离零电位较近,感应形成的电场较大。干粉、泡沫、水基灭火剂氛围下的无人机不同位置及距离的

表3 干粉灭火剂氛围下±800 kV 线路无人机不同位置距离电场强度

Table 3 Electric field intensity at different positions of ±800 kV line UAV under the dry powder extinguishing agent atmosphere

位置	不同距离下电场强度/(kV/cm)						
	0.5 m	1.0 m	1.5 m	2.0 m	2.5 m	3.0 m	3.5 m
内侧	29.3	22.8	16.6	14.4	12.3	10.2	8.8
下方	12.6	10.1	7.8	5.7	4.2	3.7	3.4
外侧	27.6	20.5	15.8	12.7	10.9	9.6	8.3

表4 泡沫灭火剂氛围下±800 kV 线路无人机不同位置距离电场强度

Table 4 Electric field intensity at different positions of ±800 kV line UAV under the atmosphere of foam extinguishing agent

位置	不同距离下电场强度/(kV/cm)						
	0.5 m	1.0 m	1.5 m	2.0 m	2.5 m	3.0 m	3.5 m
内侧	29.6	22.6	17.3	14.3	12.2	10.4	9.7
下方	13.2	9.9	8.2	6.3	4.4	3.8	3.7
外侧	27.3	20.5	15.8	12.8	10.7	9.5	8.1

表5 水基灭火剂氛围下±800 kV 线路无人机不同位置距离电场强度

Table 5 Electric field intensity at different positions of ±800 kV line UAV under the atmosphere of water-based fire extinguishing agent

位置	不同距离下电场强度/(kV/cm)						
	0.5 m	1.0 m	1.5 m	2.0 m	2.5 m	3.0 m	3.5 m
内侧	30.0	22.6	16.5	14.4	12.4	10.1	9.0
下方	12.4	10.2	7.8	5.7	4.3	3.7	3.3
外侧	28.4	21.5	15.9	12.8	11.2	9.6	8.2

最大电场强度相近。这是由于干粉灭火剂对电场的影响较小,不会显著改变电场分布;而泡沫、水基灭火剂具有一定的电场屏蔽作用,但其导电性较大,增大了电场强度,综合这两方面因素,泡沫、水基灭火剂改变电场分布程度较小。因此三者最大电场强度相近。但在实际应用中,由于泡沫、水基灭火剂会导致空气湿度增加,增大无人机电子元件的故障率,因此干粉灭火剂更有利于保障无人机灭火作业的安全。

3 灭火氛围下空气间隙击穿特性

3.1 试验平台

搭建如图 3 所示的间隙击穿试验平台,构建典型棒-板间隙,板电极一端接地,棒电极连接高压端。棒-板间隙需要全部置于雾室中,雾室接地处理。




图3 间隙击穿试验平台

Fig.3 Gap breakdown testing platform

3.2 试验及结果

在雾室内喷射灭火剂以模拟灭火形成的环境,施加直流电压,在不同间隙距离下采用逐步升压法,逐步增大电压值,直至击穿,并重复进行试验。试验结果如表 6—表 8 所示,测试 1—测试 5 为重复试验。

表 6 干粉灭火剂氛围下棒板间隙击穿电压测试

Table 6 Test of rod-plate gap breakdown voltage under the atmosphere of dry powder extinguishing agent

间隙距离/cm	不同间隙距离下击穿电压/kV				
	测试 1	测试 2	测试 3	测试 4	测试 5
1	11.4	12.6	12.2	11.7	11.9
2	23.8	24.3	22.9	24.6	23.5
3	50.3	52.1	52.3	51.8	50.6
4	66.6	67.3	68.4	66.8	67.1
5	81.9	82.2	81.4	82.5	81.3

表 7 泡沫灭火剂氛围下棒板间隙击穿电压测试

Table 7 Test of rod-plate gap breakdown voltage under the atmosphere of foam extinguishing agent

间隙距离/cm	不同间隙距离下击穿电压/kV				
	测试 1	测试 2	测试 3	测试 4	测试 5
1	17.5	16.8	17.2	16.5	17.6
2	24.1	23.5	22.7	23.6	23.3
3	35.4	37.1	36.5	36.7	36.6
4	46.4	48.2	47.6	47.5	47.1
5	66.3	65.7	65.8	66.7	67.1

表 8 水基灭火剂氛围下棒板间隙击穿电压测试

Table 8 Test of rod-plate gap breakdown voltage under the atmosphere of water based fire extinguishing agent

间隙距离/cm	不同间隙距离下击穿电压/kV				
	测试 1	测试 2	测试 3	测试 4	测试 5
1	15.3	14.5	15.1	13.7	14.2
2	21.6	23.6	22.7	22.4	21.9
3	33.5	33.0	32.4	34.1	33.8
4	44.0	45.7	46.1	44.9	44.7
5	67.2	68.1	66.8	67.3	67.4

对表 6—表 8 数据进行处理,得到不同灭火剂氛围下棒板间隙击穿场强,结果如图 4 所示。由图 4 可知,在干粉灭火剂、泡沫灭火剂和水基灭火剂氛围下的间隙击穿场强为 11~18 kV/cm。在间隙较小时,干粉灭火剂易进入间隙,干粉浓度大,粉尘颗粒易形成导电通道,因此击穿强度较小;而泡沫、水基灭火剂不易进入间隙,浓度较小,因此击穿强度相对较大。间隙较大时,干粉灭火剂在间隙中分布均匀,而相对间隙小时,浓度变小,形成导电通道难度增大,因此击穿强度增大;而泡沫、水基灭火剂在间隙中分布均匀,由于其含有水分,导电性较强,因此击穿强度减小。




图 4 不同灭火剂氛围下间隙击穿场强

Fig.4 Gap breakdown field strength under atmosphere of different extinguishing agents

无人机灭火作业时,无人机各部件会与杆塔、地面等形成棒-板间隙,因此采用灭火氛围下间隙击穿场强作为无人机起电的临界电场强度。且为防止无人机因起电导致性能下降或故障,无人机周围空间电场强度应低于临界击穿场强值且应留有一定裕度。由图4与表3—表5可知,无人机灭火作业理论最小安全距离应不小于3.0 m,实际数值须结合试验研究确定。

4 模拟试验

4.1 试验平台

搭建如图5所示起始放电距离试验平台,导线与无人机均置于雾室中,雾室接地处理,利用紫外成像仪进行放电检测。环境中的温度、湿度和气压会对电场强度产生影响:温度升高会加剧空气流动,使得电场强度和分布会在局部区域产生较大的波动;湿度升高会加大空气电导率,从而增强电场;气压升高会增加空气中的分子数目,使得空气的导电性提升,电场中的电荷更容易进行迁移,从而使电场强度有所变化。由于是模拟灭火作业,因此,选择常温、10%湿度、常压进行试验。





图5 放电距离试验平台


Fig.5 Discharge distance testing platform

4.2 试验及结果

在雾室内喷射灭火剂以模拟灭火形成的环境,施加+100 kV 直流电压,逐步增大无人机与导线距离,直至紫外成像仪无法检测到感应放电。紫外成像如图6所示。



(a)放电



(b)未放电

图6 紫外成像

Fig.6 Ultraviolet imaging

试验结果如表9所示。由表9可知,在+100 kV 直流电压下,干粉灭火剂灭火环境内的无人机起始感应放电距离为50 cm,泡沫灭火剂灭火环境内无人机起始感应放电距离为60 cm,水基灭火剂灭火环境内无人机起始感应放电距离为60 cm,且感应放电大都发生在机翼或脚架等尖锐处。

表9 不同灭火剂氛围内无人机初始感应放电距离

Table 9 Initial induced discharge distance of UAV under different extinguishing agent atmospheres

距离/cm	不同灭火剂放电情况		
	干粉灭火剂	泡沫灭火剂	水基灭火剂
5	放电	放电	放电
10	放电	放电	放电
20	放电	放电	放电
30	放电	放电	放电
40	放电	放电	放电
50	未放电	放电	放电
60	未放电	未放电	未放电
70	未放电	未放电	未放电

4.3 模拟试验仿真及结果

4.3.1 有限元模型

利用仿真软件建立模拟试验模型。模型如图7所示。空气域为直径3 m、高度3 m的圆柱体;导线采用6×LGJ-240/30 钢芯铝绞线,直径为22.5 mm,

分裂间距为 100 mm,分裂股数为六分裂,采用六棱柱的方式排列,长度 1.5 m;导线两端使用直径 25 cm 的均压罩匀化电场;采用直径 80 mm 的波纹管连接导电;无人机模型为图 1(b)的模型缩小 10 倍所得,无人机的长、宽、高分别为 180 mm、134 mm、70 mm。




图7 模拟试验仿真模型

Fig.7 Simulation models for experimental tests

4.3.2 参数设置

空气域采用灭火剂/空气混合物;杆塔材料选用铁;导线和无人机材料采用铝;绝缘子为复合绝缘子。上述材料的相关参数如表 10 所示。

4.3.3 电场计算的有限元法

模拟试验电压为直流电压,该区域内的传导电流场是稳恒的,电场计算问题为恒定电流场的计算问题。恒定电流场稳态电场方程如式(1)所示。

模拟试验区域电流场计算实质就是对恒定电场

和具有边界条件麦克斯韦方程组求解。根据恒定电流场的无旋场特性,可得电位与场强的关系如式(2)所示。

无人机为悬浮电位,稳态电场方程如式(3)所示。

表 10 模拟试验仿真参数设置

Table 10 Simulation parameter settings for simulated testing

材料	相对介电常数	电导率/(S/m)	网格划分
无人机	1×10^{10}	3.8×10^7	超细化
导线	1×10^{10}	3.8×10^7	超细化
波纹管	1×10^{10}	3.8×10^7	超细化
均压罩	1×10^{10}	3.8×10^7	超细化
空气	干粉	7.5	2.66×10^{-10}
	泡沫	54.3	1.21×10^{-5}
	水基	52.6	1.50×10^{-6}

4.3.4 仿真结果及分析

模拟试验电场仿真的边界条件如下。

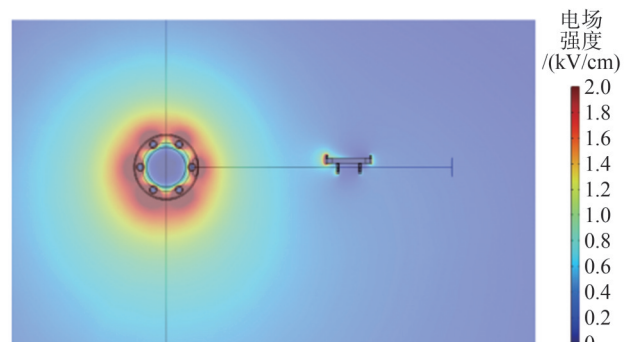
1)导线的运行电压,边界电位为导线运行电压,导线施加+100 kV 电压。

2)地面的电位 $\phi = 0$ 。

3)无人机模型电位为悬浮电位,位于导线侧方。

4)设置模型边界,为贴近实际情况,减小空间电荷对电场的影响,边界需要离导线、无人机等模型较远,模型边界与地面围成一个完全封闭的计算场域。

将无人机模型置于试验模型中,放置距离为 4.2 节中不同灭火环境下无人机初始感应放电距离。仿真结果如图 8、表 11 所示。



(a) 干粉灭火剂

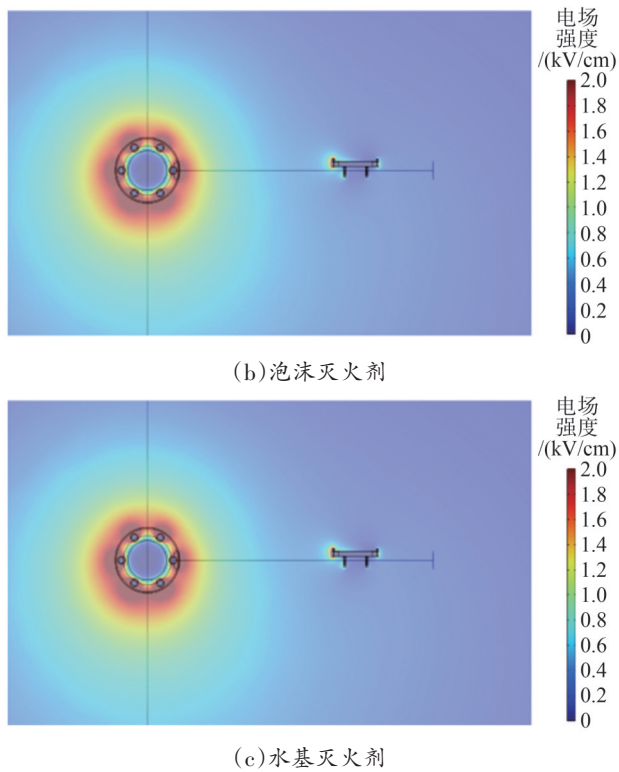


图8 电场强度仿真结果

Fig.8 Simulation results of electric field strength


表11 不同灭火剂氛围内无人机初始感应放电强度

Table 11 Initial induced discharge intensity of UAV under different fire extinguishing agent atmospheres


灭火剂	初始感应放电距离/cm	电场强度/(kV/cm)
干粉	50	11.76
泡沫	60	10.75
水基	60	10.72

结合表3、表4、表5、表11,可得图9,在保留裕度的情况下,干粉、泡沫和水基灭火剂灭火环境下无人机灭火作业最小安全距离应大于3.0 m,此数值与仿真理论结果相同。


若无人机灭火作业距输电线路小于3.0 m,则会产生电击风险,损坏无人机电子元件,导致无人机失去控制,飞行偏离预定轨道,甚至坠毁。因此,为减小无人机灭火作业的坠毁可能性,除注意无人机灭火作业安全距离外,还须提高无人机对电场的耐受性,如对无人机电子器件加入高强度的电气隔离和绝缘保护措施,设计适当的电磁屏蔽层及使用抗电场影响的复合材料。



(a) 干粉灭火剂



(b) 泡沫灭火剂



(c) 水基灭火剂

图9 电场强度对比

Fig.9 Comparison of electric field intensity

5 结论

文中从电场等效的角度出发,对±800 kV 输电线路直线塔无人机灭火作业进行电场仿真分析,分析了无人机不同灭火位置及距离下的电场分布,开展了灭火氛围下空气间隙击穿试验,得到了灭火氛围下间隙击穿特性,结合电场分布,得到无人机灭火作业最小安全距离,并进行模拟试验验证,具体结论如下:

1)由空间电场仿真试验得出,无人机在±800 kV 输电线路直线塔周围空间开展灭火作业会对电场分布产生较明显的影响,且在导线内侧处最易被击穿。

2)由间隙击穿特性试验得出,无人机灭火作业理论最小安全距离应不小于 3.0 m。

3)由模拟试验研究得出,在保留裕度的情况下,无人机灭火作业最小安全距离应不小于 3.0 m,此数值与仿真实验结果相同。

参考文献

- [1] 冯子毅,马恒瑞,王红霞,等.基于多类型传感器的变电站火灾预警技术研究综述[J].智慧电力,2024,52(10):103-111.
FENG Ziyi, MA Hengrui, WANG Hongxia, et al. A Research review of substation fire prevention and control technology based multi-type sensors[J]. Smart Power, 2024, 52(10): 103-111.
- [2] 麦晓明,刘正军,彭向阳,等.无人机电力线路安全巡检航线及任务规划软件系统设计[J].广东电力,2013,26(12):81-85.
MAI Xiaoming, LIU Zhengjun, PENG Xiangyang, et al. Design of helicopter based power line safety inspection route and mission plannings of ware system[J]. Guangdong Electric Power, 2013, 26(12): 81-85.
- [3] 王锐,王柯,徐晓刚,等.无人机输电线路巡检地面测控站及运输保障系统设计[J].广东电力,2014,27(2):87-92.
WANG Rui, WANG Ke, XU Xiaogang, et al. Design of ground measurement & control station and transportation support system for unmanned aerial vehicle on power transmission line inspection [J]. Guangdong Electric Power, 2014, 27(2): 87-92.
- [4] 罗泽雄,刘秀,罗志勇,等.高精度无人机在变电站巡检中的应用[J].工程技术研究,2020,5(23):244-245.
LUO Zhexiong, LIU Xiu, LUO Zhiyong, et al. Application of high precision UAV in substation inspection [J]. Engineering and Technological Research, 2020, 5(23): 244-245.
- [5] 李永明,何胜鱼,徐禄文,等.500 kV 变电站中巡检机器人对人体的电场分布影响[J].电工电能新技术,2020,39(9):74-80.
LI Yongming, HE Shengyu, XU Luwen, et al. Effect of patrol robot on electric field distribution of human body in 500 kV substation [J]. Advanced Technology of Electrical Engineering and Energy, 2020, 39(9): 74-80.
- [6] 许忠雄,邵瑰玮,谢予星,等.基于编码标志的无人机电力巡检自主定位方法[J].应用科学学报,2018,36(5):845-858.
XU Zhongxiong, SHAO Guiwei, XIE Yuxing, et al. Method of UAV autonomous positioning based on encoded sign during power inspection [J]. Journal of Applied Sciences, 2018, 36(5): 845-858.
- [7] 彭向阳,钱金菊,麦晓明,等.大型无人直升机电力线路全自动巡检技术及应用[J].南方电网技术,2016,10(2):24-31.
PENG Xiangyang, QIAN Jinju, MAI Xiaoming, et al. Automatic power line inspection technology of large unmanned helicopter and its application [J]. Southern Power System Technology, 2016, 10(2): 24-31.
- [8] 徐云鹏,毛强,李庭坚.架空输电线路直升机、无人机及地面人工巡视互补机制探讨与研究[J].广西电力,2013,36(5):72-75.
XU Yunpeng, MAO Qiang, LI Tingjian. Discussion on inspection complementary mechanism of overhead transmission line [J]. Guangxi Electric Power, 2013, 36(5): 72-75.
- [9] 彭向阳,陈驰,徐晓刚,等.基于无人机激光扫描的输电通道安全距离诊断技术[J].电网技术,2014,38(11):3254-3259.
PENG Xiangyang, CHEN Chi, XU Xiaogang, et al. Transmission corridor safety distance diagnosis based on point cloud and unmanned aerial vehicle loaded airborne laser scanning [J]. Power System Technology, 2014, 38(11): 3254-3259.
- [10] MATIKAINEN L, LEHTOMÄKI M, AHOKAS E, et al. Remote sensing methods for power line corridor surveys [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 119: 10-31.
- [11] 吴传平,陆佳政,刘毓,等.输电线路山火防治技术及其在湖南电网的应用[J].湖南电力,2014,34(4):28-30.
WU Chuanping, LU Jiazheng, LIU Yu, et al. Technology of field fire prevention near transmission lines and its application in Hunan power grid [J]. Hunan Electric Power, 2014, 34(4): 28-30.
- [12] 周特军,李波,谭艳军,等.输电线路山火无人机监测与灭火技术研究[J].消防科学与技术,2020,39(2):239-242.
ZHOU Tejun, LI Bo, TAN Yanjun, et al. Research on monitoring and fire extinguishing technology for wildfires near transmission line based on UAV [J]. Fire Science and Technology, 2020, 39(2): 239-242.
- [13] 王启飞,侯程浩,李聪,等.输电线路无人机山火察灭一体化作业流程优化[J].中国安全科学学报,2023,33(增刊1):162-168.
WANG Qifei, HOU Chenghao, LI Cong, et al. Integrated operation process optimization of UAV fire detection and extinguishing in transmission lines [J]. China Safety Science Journal, 2023, 33(S1): 162-168.
- [14] LIU C A, SHAO Y, CAI Z Q, et al. Unmanned aerial vehicle positioning algorithm based on the secant slope characteristics of

- transmission lines[J].IEEE Access, 2020, 8:43229-43242.
- [15] UTKU H U, DIMITRIS C, ATHANASIOS T, et al. UAV indoor exploration for fire-target detection and extinguishing[J].Journal of Intelligent & Robotic Systems, 2023, 108(3):54-62.
- [16] FAHMANI L, BENHADOU S. Optimizing 2D path planning for unmanned aerial vehicle inspection of electric transmission lines [J].Scientific African, 2024, 24:e02203.
- [17] 李游, 刘卫东, 邓维, 等. 变电站高压设备无人机巡检安全距离确定方法研究[J]. 电工电能新技术, 2023, 42(3):76-84.
LI You, LIU Weidong, DENG Wei, et al. Research on determination method of safety distance for UAV inspection of substation high voltage equipment [J]. New Technology of Electroengineering and Electric Energy, 2023, 42(3):76-84.
- [18] 李栋, 林靖宇, 高鹏宇, 等. 无人机输电线路巡检中安全距离测量方法[J]. 广西大学学报, 2016, 41(2):498-505.
LI Dong, LIN Jingyu, GAO Pengyu, et al. Safty distance measurement for power transmission line inspection by UAVs [J]. Journal of Guangxi University, 2016, 41(2):498-505.
- [19] ZHANG Y, YUAN X X, LI W Z, et al. Automatic power line inspection using UAV images [J]. Remote Sensing, 2017, 9(8):824.
- [20] 霍红刚, 周鑫, 蔡杰, 等. 基于先验知识 Faster R-CNN 的输电线路无人机图像识别方法[J]. 智慧电力, 2024, 52(6):108-115.
HUO Honggang, ZHOU Li, CAI Jie, et al. UAV Image recognition method for transmission line based on prior knowledge Faster R-CNN[J]. Smart Power, 2024, 52(6):108-115.
- [21] 王杨杨, 曹晖, 莫文昊. 基于深度学习的改进型 YOLOv4 输电线路鸟巢检测与识别[J]. 智慧电力, 2023, 51(01):101-107.
WANG Yangyang, CAO Hui, MO Wenhao. Bird's nest detection and identification on improved YOLOv4 transmission line based on deep learning[J]. Smart Power, 2023, 51(01):101-107.
- [22] 王振华, 黄宵宁, 梁焜, 等. 基于四旋翼无人机的输电线路巡检系统研究[J]. 中国电力, 2012, 45(10):59-62.
WANG Zhenhua, HUANG Xiaoning, LIANG Kun, et al. Study on the transmission line inspection system based on quadrotor UAVs [J]. Electric Power, 2012, 45(10):59-62.
- [23] 郑天茹, 孙立民, 娄婷婷, 等. 基于电磁场计算的输电线路无人机巡检安全飞行区域确定方法[J]. 山东电力技术, 2018, 45(2):27-34.
ZHENG Tianru, SUN Limin, LOU Tingting, et al. Determination method of safe flight area for UAV inspection for transmission line based on the electromagnetic field calculation [J]. Shandong Electric Power, 2018, 45(2):27-34.
- [24] PIEJAK R B, GODYAK V A, ALEXANDROVICH B M. A simple analysis of an inductive RF discharge [J]. Plasma Sources Science & Technology, 1992, 1(3):179-186.
- [25] TUSZEWSKI M. An electronegative inductive discharge instability [J]. Journal of Applied Physics, 1996, 79(12):8967-8975.

收稿日期:2024-11-04

修回日期:2025-02-05

作者简介:

过 羿(1988),男,博士,高级工程师,主要研究方向为电力安全防护技术;

胡圣涛(2000),男,硕士在读,主要研究方向为电压与绝缘技术;

刘宇舜(1990),男,博士,高级工程师,主要研究方向为输电设备状态评价;

赵玉顺(1980),男,博士,教授,主要研究方向为电压与绝缘技术;

张佳庆(1987),通信作者(dkyzjq@163.com),男,博士,高级工程师,从事电力火灾与安全防护研究与管理工。

(责任编辑 车永强)

DOI: 10.20097/j.cnki.issn1007-9904.240305

基于数据质量提升的变压器顶层油温预测模型

张若愚*, 石 峥, 郭 建, 官 鑫, 雷 敏

(国网山东省电力公司青岛供电公司, 山东 青岛 266000)

摘要: 变压器顶层油温用于表征变压器热特性, 是评价变压器状态的重要参量。由于现场复杂的工作环境, 顶层油温在线监测数据往往存在大量缺失值, 严重影响顶层油温的预测工作, 同时其受到负载、环境温度、环境风速、太阳辐射等多种因素影响, 造成其监测数据中不同时间尺度的信息混叠, 采用单一模型对变压器顶层油温进行预测难以达到理想的准确度。文中提出了基于数据质量提升的变压器顶层油温预测模型。首先, 利用灰色马尔可夫模型对含有缺失值的变压器顶层油温数据进行补全, 获得完整连续的时间序列; 然后, 利用集合经验模态分解方法, 提取变压器顶层油温时间序列内在的多个本征模态分量, 实现对不同时间尺度信息的解耦, 降低时间序列复杂度; 最后, 在集成学习框架下, 为各分量建立极限学习机(extreme learning machine, ELM)子模型, 并将其预测值重构, 从而获得顶层油温的最终预测结果。通过现场数据进行验证, 利用文中所提出的模型预测未来两天变压器的顶层油温, 平均相对误差为5.27%, 均方根误差为2.459 2, 相关系数为0.832 6, 决定系数为0.682 9, 相较反向传播(back propagation, BP)神经网络模型、支持向量机(support vector machines, SVM)模型和长短期记忆递归网络(long short term memory network, LSTM)模型, 平均相对误差分别降低了69.56%、61.92%、43.45%; 均方根误差分别降低了67.02%、59.87%、36.58%。; 相较LSTM模型, 相关系数与决定系数分别提升了289.61%、559.1%。

关键词: 变压器; 顶层油温; 马尔可夫过程; 集合经验模态分解; 极限学习机

中图分类号: TM835

文献标志码: A

文章编号: 1007-9904(2025)12-0113-10

Transformer Top Oil Temperature Prediction Model Based on Data Quality Improvements

ZHANG Ruoyu*, SHI Zheng, GUO Jian, GONG Xin, LEI Min

(State Grid Shandong Electric Power Company Qingdao Power Supply Company, Qingdao 266000, China)

Abstract: Transformer top oil temperature can be used to measure the thermal characteristics of the transformer, and is an important parameter for assessing transformer condition. Due to the on-site complex working environment, the on-line monitoring data of top oil temperature often have a large number of missing values, which seriously affects the prediction of top oil temperature. Meanwhile, affected by many factors such as load, environmental temperature, environmental wind speed, solar radiation, etc., the information of different time scales are aliased within the monitoring data, making it difficult to achieve the desired accuracy by single prediction model. This paper proposes a method for predicting the top oil temperature of transformer based on data quality improvements. First, supplement the top oil temperature data of transformer containing missing values by the Gray-Markov model to obtain a complete and continuous time series. Then, ensemble empirical mode decomposition is used to decompose the transformer top oil temperature time series into multiple time series components to eliminate the interaction between different time scale information and reduce the prediction difficulty. Finally, extreme learning machine (ELM) sub-prediction models are established to predict the components, and the prediction results of all sub-models are summed to obtain the final prediction results for the transformer top oil temperature. Through field data verification, the proposed method was used to predict the transformer top oil temperature in the next two days. Mean absolute percentage error (MAPE) is 5.27%, root mean square error (RMSE) is 2.459 2, correlation coefficient (CC) is 0.832 6, and coefficient of determination (CD) is 0.682 9. Compared with back propagation (BP) neural network model, support vector machines (SVM) model and long short term memory network (LSTM) model, MAPE is respectively reduced by 69.56%, 61.92% and 43.45%, and RMSE is respectively reduced by 67.02%, 59.87% and 36.58%. Compared with LSTM model, CC and CD are respectively improved 289.61% and 559.1%.

Keywords: transformer; top oil temperature; Markov process; ensemble empirical mode decomposition; extreme learning machine

0 引言

电力变压器的健康运行是可靠电网的重要一环。其内部热状态不仅制约着设备的预期使用寿命,更是决定其当前瞬时负载能力的核心制约因素。绕组热点温度与顶层油温是当前工程实践中评估变压器内部热状态的主要指标^[1-2]。变压器绕组热点温度可以通过光纤传感器直接测得,但由于光纤传感器成本较高,维护困难,尚未推广使用^[3-4]。而变压器顶层油温测量难度较低,根据相关导则,变压器绕组热点温度可由变压器顶层油温估算得到^[1-2,5]。因此,对变压器顶层油温进行预测,能够提前对变压器热状态进行评估,有助于合理的安排运维。

目前对于变压器顶层油温预测主要有两类方法。一是基于经验模型的预测方法,IEEE C57.91导则对变压器内部热分布进行简化,给出了计算变压器顶层油温温升的一阶导数模型^[1],但未考虑环境温度的动态变化,模型过于简化,误差较大。Swift等^[6]基于热电类比原理,提出了变压器顶层油温的动态计算模型,预测效果较好。但该模型中的变压器相关传热参数,需要通过热试验等获取,存在一定误差。二是基于机器学习的预测方法,该类方法不需要建立数理模型,而是通过模糊聚类^[7]、支持向量机(support vector machine, SVM)^[8-9]、灰色模型^[10]、神经网络^[11-15]等机器学习算法,对现场实测数据进行挖掘,实现对顶层油温变化趋势的非线性拟合,预测精度优于数理模型方法^[16-20]。但上述方法均需要实时的负载电流、环境温度作为依据,间接地反映油温的变化规律^[21-22],对样本数据量要求高,对时间序列内在规律挖掘不足,难以实现对未来较长时间尺度下顶层油温的有效预测。

在线监测直接采集到的顶层油温数据受变压器自身及环境多种因素的影响,数据质量不高,难以直接挖掘其内在变化规律。目前主要存在以下两大问题。

第一,现场的电磁干扰及环境变化等因素会影响油温数据的采集与传输,监测系统采集的数据往往含有大量的缺失值,破坏了时间序列的连续性,改

变了其数据特征,使采集的顶层油温数据难以用于后续的预测工作^[23]。针对这一问题,本文利用灰色模型对顶层油温时间序列进行拟合,将拟合误差序列转化为马尔可夫链,根据马尔可夫链本身特性,将误差数值映射到对应状态区间,通过状态区间的转移概率能够更好地描述顶层油温数据的波动,对缺失数据进行补全,提升数据质量。

第二,变压器顶层油温受到负载、环境温度、太阳辐射、风速等多元因素的动态影响,致使其时间序列中不同时间尺度的时序特征相互混叠,具有非线性与非平稳性特征,对原始序列直接分析,难以发掘变压器顶层油温的变化规律。集合经验模态分解(ensemble empirical mode decomposition, EEMD)能够自适应地将时间序列分解为多个本征模态分量(intrinsic mode functions, IMF),削弱不同时间尺度信息间的相互影响^[24-25]。同时利用高斯白噪声进行辅助分析,抑制端点效应和模态混叠,进一步降低时间序列复杂度,提升数据质量。

对于分解得到的各个时间序列分量,需要分别建立预测模型,进行组合预测。极限学习机(extreme learning machine, ELM)隐含层的权重和偏置不需要迭代寻优,具有结构简单、训练高效、非线性拟合能力强的特点,适合作为组合学习的基学习器,能够在保证精确度的前提下,大大节省计算时间^[26]。

本文提出了基于数据质量提升的变压器顶层油温组合预测模型。首先,利用灰色马尔可夫模型对含有缺失值的变压器顶层油温数据进行补全,获得完整连续的时间序列,提升数据质量;然后,利用集合经验模态分解方法,提取变压器顶层油温时间序列内在的多个本征模态分量,实现对不同时间尺度信息的解耦,进一步提升数据质量,降低预测难度;最后,在集成学习框架下,为各分量建立极限学习机子模型,并将其预测值重构,从而获得顶层油温的最终预测结果。通过现场采集的历史运行数据集对模型性能模型进行了验证,并与反向传播(back propagation, BP)神经网络模型、SVM模型和长短期记忆递归网络(long short term memory network, LSTM)模型进行对比,文章提出的模型预测效果最优。

1 基于灰色马尔可夫模型的顶层油温监测数据补全方法

通过灰色马尔可夫模型对顶层油温数据进行补全,首先,基于连续的顶层油温数据,构建灰色预测模型(GM(1,1)),预测时间序列的主导趋势,所得结果记为趋势补全值。随后,计算趋势补全值与实际监测值之间的残差。将连续取值的残差离散化,映射到对应的状态区间,形成残差状态链,并据此计算马尔可夫状态转移概率矩阵。选取缺失段前邻采样点的残差状态作为初始状态,通过状态转移矩阵模拟其后续波动,生成波动补全值。最后,将波动补全值与趋势补全值叠加,得到序列的最终补全值。补全方法流程如图1所示。

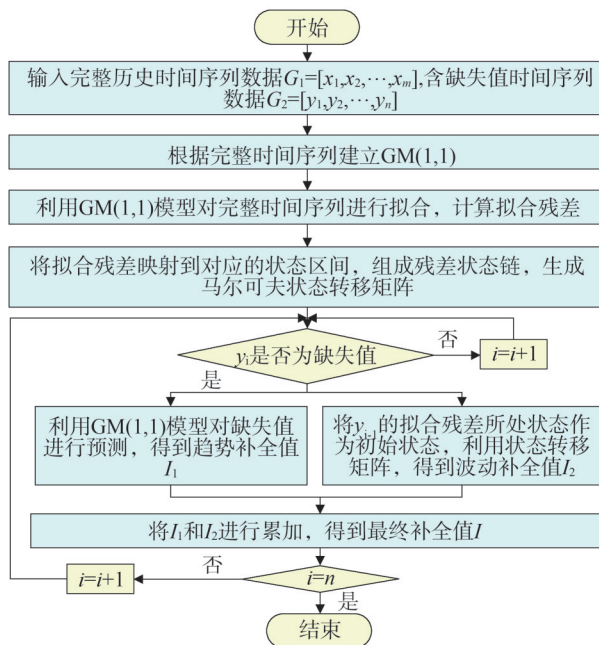


图1 基于灰色马尔可夫模型的顶层油温数据补全方法流程图

Fig.1 Flow chart of data completion method of top oil temperature based on gray-Markov model

选取现场某变压器 2013 年顶层油温数据作为研究对象,采样时间间隔为 6 h,以连续 75 日的顶层油温在线监测数据作为训练集训练灰色马尔可夫模型。对随后 25 日共 100 组数据随机删除 25 组数据作为测试集进行验证。含有缺失值的时间序列如图 2 所示。




图2 含缺失值的顶层油温时间序列
Fig.2 Time series of top oil temperature containing missing values

利用完整数据训练得到的灰色马尔可夫模型补全测试集,如图 3 所示。




图3 经补全的顶层油温时间序列
Fig.3 Time series of top oil temperature after complement

选取均值、平均相对误差、变异系数等指标对补全效果进行综合评估,并与传统的均值插值法进行对比,如表 1 所示。

灰色马尔可夫补全方法相较于传统的均值插值,在整体统计特性和数据波动性两方面均更为准确,均值误差和变异系数误差分别降低了 73.72%、40.70%,能够较好地恢复顶层油温时间序列的完整性与连续性,提升数据质量,为后续的预测工作提供帮助。

表1 补全效果综合评估
Table 1 Comprehensive evaluation of completion effect

参数	真实值	灰色马尔可夫	均值插值
平均相对误差/%	0	10.468	14.565
均值	32.738	32.671	32.995
均值误差/%	0	0.206	0.784
变异系数	0.132	0.119	0.110
变异系数误差/%	0	10.136	17.093

2 时间序列分解

变压器顶层油温受到负载、环境温度、太阳辐射、风速等多元因素的动态影响,不同因素所引起的变压器顶层油温变化的时间尺度是不同的,多种时间尺度的信息相互影响,使变压器顶层油温时间序列具有较强的非线性与非平稳性,对其进行时间序列分解,解除不同时间尺度信息的耦合,可以降低时间序列的复杂度,为之后的预测工作提供帮助。

2.1 集合经验模态分解

集合经验模态分解是一种利用噪声辅助的经验模态分解(empirical mode decomposition, EMD)方法,能够抑制 EMD 的模态混叠问题,更有效地降低时间序列复杂度,其具体分解步骤如下。

步骤 1: 设定经验模态分解参数: 分解次数 M 、白噪声幅值 A 。

步骤 2: 通过向原始时间序列叠加一组给定幅值的随机高斯白噪声, 构造出噪声辅助的叠加序列。

$$Y_i(t) = y(t) + \omega_i(t) \quad (1)$$

式中: $Y_i(t)$ 为第 i 次叠加得到的叠加序列; t 为采样时间点; $y(t)$ 为原始时间序列; $\omega_i(t)$ 为第 i 次叠加的高斯白噪声序列。

步骤 3: 利用经验模态分解, 分解叠加序列 $Y_i(t)$, 提取本征模态分量及与叠加序列的残差。

$$Y_i(t) + \sum_{j=1}^n c_{ij}(t) + r_i(t) \quad (2)$$

式中: $c_{ij}(t)$ 为第 i 次叠加得到的叠加序列的第 j 个本征模态分量; $r_i(t)$ 为第 i 次叠加得到的叠加序列的残差; n 为本征模态分量的数量。

步骤 4: 假如 $i < M$, 则返回步骤 2, 并令 $i = i + 1$ 。

步骤 5: 集成平均 M 次重复迭代得到的 IMF, 以

获取最终的 IMF。基于高斯白噪声的零均值特性, 其在集成平均过程中相互抵消, 从而确保 IMF 中只保留原始时间序列的信息。

$$C_j(t) + \frac{1}{M} \sum_{i=1}^M c_{ij}(t) \quad (3)$$

式中: $C_j(t)$ 为原始时间序列的本征模态分量。

2.2 分解效果评价

近似熵通过计算时间序列中新模式产生的可能性来量化时间序列的复杂度, 时间序列越复杂则其近似熵越大。利用近似熵对变压器顶层油温时间序列及分解得到的时间序列分量的复杂度进行定量评估, 从而对分解效果进行评价, 其计算过程如下。

1) 定义算法相关参数 m, r , 其中 m 为整数, 表示比较向量的长度, r 为实数, 表示“相似度”的度量值。

2) 对 N 维时间序列 $w(1), w(2), \dots, w(N)$ 进行重构, 得到 m 维向量 $X(1), X(2), \dots, X(N - m + 1)$, 其中 $X(u) = [w(u), w(u + 1), \dots, w(u + m - 1)]$, $u \in [1, N - m + 1]$ 。

3) 对于 u , 统计满足式(4)的向量个数。

$$C_{mi}(r) = \frac{\text{num} \{ d[X(u), X(v)] \leq r \}}{N - m + 1} \quad (4)$$

$$d[X(u), X(v)] = \max |w(a) - w^*(a)|$$

式中: $C_{mi}(r)$ 为向量距离小于 r 的个数与向量总数的比值; $d[X(u), X(v)]$ 为向量距离; $w(a), w^*(a)$ 为向量 X 中的元素; $v \in [1, N - m + 1]$ 。

4) 定义

$$\phi_m(r) = \frac{\sum_{u=1}^{N-m+1} \ln(C_{mi}(r))}{N - m + 1} \quad (5)$$

则近似熵 E 为

$$E = \phi_m(r) - \phi_{m+1}(r) \quad (6)$$

为验证不同分解方法的分解效果, 选取现场某变压器连续 30 日的顶层油温监测数据作为验证对象, 采样时间间隔为 6 h, 共得到 120 组数据构成的时间序列。分别用经验模态分解及集合经验模态处理变压器顶层油温时间序列, 结果如图 4、图 5 所示。图中 IMF1—IMF5 为分解得到的五个本征模态分量, RES 为残差(residual, RES)。

分别计算原始时间序列、本征模态分量及残差的近似熵, 结果如表 2 所示。




图4 EMD分解结果

Fig.4 The decomposition result of EMD




图5 EEMD分解结果

Fig.5 The decomposition result of EEMD

表2 时间序列近似熵

Table 2 Approximate entropy of time series

方法	原始时间序列	IMF1	IMF2	IMF3	IMF4	IMF5	RES
EMD	0.750 7	0.503 1	0.058 3	0.044 1	0.013 0	0.011 9	0
EEMD		0.354 9	0.043 2	0.025 3	0	0	0

通过案例验证,对变压器顶层油温时间序列进行分解可以得到多个复杂度较低的时间序列分量。集合经验模态分解通过引入噪声,有效抑制了经验模态分解的模式混叠,其时间序列分量相较于原始序列,以近似熵衡量的复杂度降低了 52.72%~100%,为后续预测工作降低了难度。

3 变压器顶层油温预测模型

3.1 极限学习机

极限学习机是一种单隐含层前馈神经网络,模型架构如图 6 所示。图中 D 为输入层节点数量, F 为输出层节点数量。




图6 极限学习机模型

Fig.6 Extreme learning machine model

模型的目标函数为:

$$O = \left\| \sum_{p=1}^L \beta_p h(a_p, b_p, x) - z \right\| \quad (7)$$

式中: O 为整个网络的学习误差; β_p 为隐含层第 p 个节点与输出层之间的权重; $h(a_p, b_p, x)$ 为隐含层输出函数; x 为输入数据; a_p 为隐含层第 p 个节点的权重; b_p 为隐含层第 p 个节点的偏置; z 为样本标签。

用 H 表示隐藏层输出矩阵,则式(7)可以简化为

$$O = \|H\beta - Z\| \quad (8)$$

式中: O 为误差矩阵; β 为输出权重矩阵; Z 为样本标签矩阵。

当使得目标函数最小时,即为最优解。

$$H\beta = Z \quad (9)$$

计算输出层权重矩阵 β 。

$$\beta = H^\dagger Z \quad (10)$$

式中: H^\dagger 为矩阵 H 的 Moore - Penrose 广义逆矩阵。

其核心特性在于:模型初始化时随机生成并固定隐含层的输入权重与偏置,通过广义逆矩阵理论计算隐含层至输出层的连接权值,从而获得极高的训练效率。适合作为组合学习的子学习器。

3.2 EEMD-ELM预测模型

本文提出了基于集合经验模态分解和极限学习机的变压器顶层油温预测模型。首先,利用集合经验模态分解方法,提取变压器顶层油温时间序列内在的多个本征模态分量,实现对不同时间尺度信息的解耦,降低时间序列复杂度;然后,在集成学习框架下,为各分量建立 ELM 子模型,预测未来一段时间各时间序列分量变化情况;最后,将各子预测模型的预测结果线性叠加,重构出变压器顶层油温的最终预测结果。预测流程如图 7 所示。

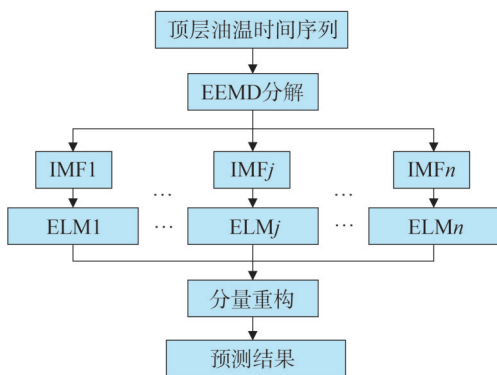


图7 基于EEMD-ELM的变压器顶层油温预测流程图
Fig.7 Flow chart for predicting transformer top oil temperature based on EEMD-ELM

4 案例验证

选取现场某变压器 2013 年顶层油温数据作为研究对象,采样时间间隔为 6 h,连续采集 4 个月共 463 组数据,选取前 86 天共 343 组数据作为训练集。首先,通过 EEMD 方法分解训练集,得到 7 个本征模

态分量及残差,共 8 个时间序列分量,结果如图 8 所示。




图8 变压器顶层油温时间序列 EEMD 分解结果

Fig.8 EEMD decomposition result of transformer top oil temperature time series

利用各分量数据训练针对性的 ELM 预测模型,隐含层神经节点数设置为 20,随机生成权重和偏置,以前 4 日共 16 个采样点的分量数据作为模型输入,以后 2 日共 8 个采样点的分量数据作为模型输出。选取 120 组数据作为测试集,利用滑窗理论对各时间序列分量滚动预测,预测结果如图 9 所示。

重构得到变压器顶层油温的预测值,并与 BP 神经网络、SVM、LSTM 模型的预测效果进行对比,结果如图 10 所示。

选用平均相对误差 (mean absolute percentage error, MAPE)、均方根误差 (root mean square error, RMSE)、互相关系数 (correlation coefficient, CC) 和决定系数 (coefficient of determination, CD) 作为评价预测效果的 4 个指标,结果如表 3 所示。




图9 变压器顶层油温时间序列分量预测

Fig.9 Prediction of time series components of transformer top oil temperature




图10 不同模型预测效果对比

Fig.10 Comparison of prediction effects with different models

由表3可知,所提出的EEMD-ELM模型的预测误差最小,相较于BP神经网络、SVM与LSTM模型,平均相对误差分别降低了69.56%、61.92%、43.45%;

均方根误差分别降低了67.02%、59.87%、36.58%。决定系数与相关系数越接近1,则代表预测越准确,相较于LSTM模型,EEMD-ELM模型的相关系数与决定系数分别提升了289.61%、559.10%。

表3 不同模型预测性能指标对比

Table 3 Comparison of prediction performance indexes with different models

模型	MAPE/%	RMSE	CC	CD
BP神经网络	17.31	7.456 7	-0.049 1	0.002
SVM	13.84	6.127 6	0.026	0
LSTM	9.32	3.878 4	0.213 7	0.103 6
EEMD-ELM	5.27	2.459 2	0.832 6	0.682 9

对极限学习机与不同分解方法结合的模型预测效果进行对比,结果如图11所示,预测效果的评价指标如表4所示。

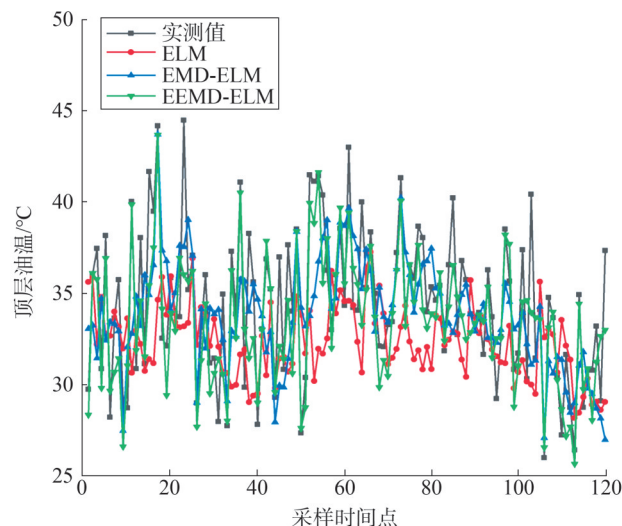


图11 不同分解方法预测效果对比

Fig.11 Comparison of prediction effects with different decomposition methods

表4 不同分解方法预测性能指标对比

Table 4 Comparison of prediction performance indexes with different decomposition methods

方法	MAPE/%	RMSE	CC	CD
ELM	10.18	4.728 9	0.138 8	0.019 2
EMD-ELM	8.33	3.623 6	0.621 3	0.345 1
EEMD-ELM	5.27	2.459 2	0.832 6	0.682 9

由表4可知,通过对变压器顶层油温时间序列进行分解,能够降低时间序列复杂度,有效提高预测模型的准确度。EEMD-ELM模型对变压器顶层油温的预测结果最为准确。相较于ELM及EMD-ELM模型,平均相对误差分别降低了48.23%、36.73%,均方根误差分别降低了47.99%、32.13%,相关系数分别提高了499.85%、34.00%,决定系数分别提高了3456.77%、97.88%。

分别构建EEMD-SVM模型、EEMD-BP模型和EEMD-LSTM模型,对未来2日的变压器顶层油温进行预测,并与EEMD-ELM模型预测结果进行对比,结果如图12所示,预测效果的评价指标如表5所示。




图12 经EEMD分解的不同模型预测效果对比

Fig.12 Comparison of prediction effects with different models based on EEMD

表5 经EEMD分解的不同模型预测性能指标对比

Table 5 Comparison of prediction performance indexes with different models based on EEMD

模型	MAPE/%	RMSE	CC	CD
EEMD-BP	8.47	3.826 9	0.360 9	0.130 2
EEMD-SVM	5.48	2.613 4	0.694 2	0.481 9
EEMD-LSTM	5.34	2.546 2	0.783 1	0.613 2
EEMD-ELM	5.27	2.459 2	0.832 6	0.682 9

由表5可知,同样通过EEMD分解方法进行分解,本文所提出的EEMD-ELM模型的预测最准确,

相较于EEMD-LSTM模型,平均相对误差降低了1.31%,均方根误差降低了3.41%,相关系数提高了6.32%,决定系数提高了11.37%。

5 结束语

本文建立了基于马尔可夫过程的顶层油温监测数据补全模型,对含有缺失值的顶层油温时间序列进行补全,恢复其完整性及连续性,提升数据质量,相较于传统的均值插值,补全后的均值误差和变异系数误差分别降低了73.72%、40.70%,为预测工作提供可靠依据。

将集合经验模态分解引入变压器顶层油温预测中,对其包含的不同时间尺度信息进行解耦,提取多个规律性更强的本征模态分量,相较于原始序列,以样本熵衡量的复杂度降低了52.72%~100%,提高了数据可预测性。

本文建立了基于EEMD-ELM的变压器顶层油温预测模型。对顶层油温时间序列先分解预测,再集合重构,通过组合学习的方法,显著提高了预测效果。利用现场数据验证了所提出的模型,根据前4日的数据对未来2日的变压器顶层油温进行预测,平均相对误差为5.27%,均方根误差为2.459 2,相关系数为0.832 6,决定系数为0.682 9,相较于EEMD-LSTM模型,平均相对误差降低了1.31%,均方根误差降低了3.41%,相关系数提高了6.32%,决定系数提高了11.37%。

参考文献

- [1] 陈忠贤,谢虎波,任文军,等.基于FBG的35kV油浸式变压器绕组变形监测研究[J].智慧电力,2023,51(1):115-122.
CHEN Zhongxian, XIE Hubo, REN Wenjun, et al. 35 kV oil immersed transformer winding deformation monitoring based on FBG[J]. Smart Power, 2023, 51(1): 115-122.
- [2] 郑业爽,李世春,鲁玲.基于多策略ISOA优化SVM的变压器故障诊断研究[J].智慧电力,2023,51(2):38-44.
ZHENG Yeshuang, LI Shichun, LU Ling. Transformer fault diagnosis based on multi-strategy ISOA optimized svm [J]. Smart Power, 2023, 51(2): 38-44.
- [3] ZHANG X, YAO S J, HUANG R H, et al. Oil-immersed transformer online hot spot temperature monitoring and accurate life lose calculation based on liber Bragg grating sensor technology [C] // 2014 China International Conference on Electricity Distribution (CICED). IEEE, 2014: 1256-1260.

- [4] 邓建钢,王立新,聂德鑫,等.内置光纤光栅油浸式变压器的研制[J].中国电机工程学报,2013,33(24):160-167.
DENG Jiangan, WANG Lixin, NIE Dexin, et al. Development of oil-immersed transformers with built-in fiber Bragg grating sensors [J]. Proceedings of the CSEE, 2013, 33(24): 160-167.
- [5] 于达,张玮,王辉.基于LSTM神经网络的油浸式变压器异常声纹诊断方法研究[J].智慧电力,2023,51(2):45-52.
YU Da, ZHANG Wei, WANG Hui. Abnormal voiceprint diagnosis method of oil-immersed transformer based on LSTM neural network [J]. Smart Power, 2023, 51(2): 45-52.
- [6] SWIFT G, MOLINSKI T S, LEHN W. A fundamental approach to transformer thermal modeling. I. Theory and equivalent circuit [J]. IEEE Transactions on Power Delivery, 2001, 16(2): 171-175.
- [7] 熊浩,陈伟根,杜林,等.基于T-S模型的电力变压器顶层油温预测研究[J].中国电机工程学报,2007,27(30):15-19.
XIONG Hao, CHEN Weigen, DU Lin, et al. Study on prediction of top-oil temperature for power transformer based on T-S model [J]. Proceedings of the CSEE, 2007, 27(30): 15-19.
- [8] 吕鹏飞,裴愉涛,金盛,等.面向智能变电站保护的FMM测试及改进SVM校验诊断技术[J].中国电力,2025,58(6):76-82.
LV Pengfei, QIU Yutao, JIN Sheng, et al. FMM testing and improved SVM diagnostic verification technology for intelligent substation protection [J]. Electric Power, 2025, 58(6): 76-82.
- [9] 罗超月岭,郑韵馨,徐帧雨,等.基于Borderline-SMOTE-IHT混合采样的改进GWO-SVM变压器故障诊断方法[J].智慧电力,2023,51(7):108-114.
LUO Chaoyueling, ZHENG Yunxin, XU Zhenyu, et al. Improved GWO-SVM transformer fault diagnosis method based on Borderline-SMOTE-IHT mixed sampling [J]. Smart Power, 2023, 51(7): 108-114.
- [10] 徐名,方洋洋,杨鹏.基于灰色模型算法的电力变压器油温预测[J].电力学报,2018,33(5):359-364.
XU Ming, FANG Yangyang, YANG Peng. Study on prediction of oil temperature for power transformer based on improved grey model [J]. Journal of Electric Power, 2018, 33(5): 359-364.
- [11] 杨欢红,丁宇涛,宋亮,等.基于热路和BP神经网络的变压器顶层油温预测研究[J].水电能源科学,2018,36(8):171-174.
YANG Huanhong, DING Yutao, SONG Liang, et al. Study on prediction of top-oil temperature for transformer based on thermal circuit and BP neural network [J]. Water Resources and Power, 2018, 36(8): 171-174.
- [12] 林梅芬,吴学先.一种基于Adam算法优化的神经网络变压器顶层油温预测[J].电工技术,2023(19):45-48.
LIN Meifen, WU Xuexian. Transformer top oil temperature prediction based on neural network model modified by Adam algorithm [J]. Electric Engineering, 2023(19): 45-48.
- [13] 董雪倩,荆澜涛,田瑞,等.基于LSTM模型的变压器顶层油温预测方法[J].电力学报,2023,38(1):38-45.
DONG Xueqing, JING Lantao, TIAN Rui, et al. Prediction method of transformer top oil temperature based on LSTM model [J]. Journal of Electric Power, 2023, 38(1): 38-45.
- [14] 宗琳,周晓华,罗文广,等.蜣螂算法优化概率神经网络的变压器故障诊断[J].智慧电力,2024,52(5):98-104.
ZONG Lin, ZHOU Xiaohua, LUO Wenguang, et al. Transformer fault diagnosis based on probabilistic neural network optimized by dung beetle optimizer [J]. Smart Power, 2024, 52(5): 98-104.
- [15] 何晔,殷若宸,陆之洋,等.基于VMD-CNN-BiLSTM-CBAM的配变短期负荷预测方法[J].电力大数据,2024,27(6):1-10.
HE Ye, YIN Ruochen, LU Zhiyang, et al. Short-term load forecasting method for distribution transformers based on VMD-CNN-BiLSTM-CBAM [J]. Power Systems and Big Data, 2024, 27(6): 1-10.
- [16] 缪希仁,林蔚青,肖洒,等.基于条件互信息与LSTNet的特高压变压器顶层油温预测方法[J].电网技术,2022,46(7):2601-2609.
MIAO Xiren, LIN Weiqing, XIAO Sa, et al. Forecasting method for top oil temperature in ultra-high voltage transformers based on conditional mutual information and LSTNet [J]. Power System Technology, 2022, 46(7): 2601-2609.
- [17] 李香龙,张宝群,张宇,等.基于EEMD-BP神经网络的含电采暖的配变变压器短期负荷预测[J].电测与仪表,2018,55(10):101-107.
LI Xianglong, ZHANG Baoqun, ZHANG Yu, et al. Short-term load forecasting of distribution transformer with electric heating based on EEMD - BP neural network [J]. Electrical Measurement & Instrumentation, 2018, 55(10): 101-107.
- [18] 谭风雷,陈昊,何嘉弘.基于最佳分段和改进半物理模型的特高压并联电抗器顶层油温预测[J].电网技术,2021,45(8):3314-3324.
TAN Fenglei, CHEN Hao, HE Jiahong. Prediction of UHV shunt reactor top oil temperature based on optimal segmentation and improved semi - physical model [J]. Power System Technology, 2021, 45(8): 3314-3324.
- [19] 林蔚青,缪希仁,肖洒,等.基于时空特征挖掘的特高压变压器热状态参量预测方法[J].中国电机工程学报,2024,44(4):1649-1661.
LIN Weiqing, MIAO Xiren, XIAO Sa, et al. Forecasting method for thermal state parameters in ultra-high voltage transformers based on spatial-temporal features mining [J]. Proceedings of the CSEE, 2024, 44(4): 1649-1661.
- [20] 王德文,吕哲.基于局部加权周期趋势分解算法和注意力机制的变压器顶层油温多步预测[J].电力科学与工程,2022,38(11):1-8.
WANG Dewen, LV Zhe. Multi-step prediction of transformers top oil temperature based on STL and attention mechanism [J]. Electric Power Science and Engineering, 2022, 38(11): 1-8.

- [21] 谭风雷,徐刚,李义峰,等.基于相似日和相似时刻的变压器顶层油温预测方法[J].电力工程技术,2022,41(2):193-200.
TAN Fenglei, XU Gang, LI Yifeng, et al. A method of transformer top oil temperature forecasting based on similar day and similar hour [J]. Electric Power Engineering Technology, 2022, 41 (2) : 193-200.
- [22] 谭风雷,朱超,徐刚,等.基于解耦分析和欧式距离的特高压变压器顶层油温预测方法[J].高电压技术,2022,48(1):298-306.
TAN Fenglei, ZHU Chao, XU Gang, et al. Method of UHV transformer top oil temperature forecasting based on decoupling analysis and euclidean distance [J]. High Voltage Engineering, 2022, 48(1):298-306.
- [23] 张若愚,齐波,张鹏,等.面向电力变压器状态评价的油中溶解气体监测数据补全方法[J].电力自动化设备,2019,39(11):181-187.
ZHANG Ruoyu, QI Bo, ZHANG Peng, et al. Method for interpolating monitoring data of dissolved gas in oil for power transformer state assessment [J]. Electric Power Automation Equipment, 2019, 39(11):181-187.
- [24] HUANG N E, SHEN S P. 希尔伯特-黄变换及其应用[M]. 张海勇,韩冬,王芳等,译.北京:国防工业出版社,2017.
- [25] WU Z H, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009, 1(1):1-41.
- [26] 苑津莎,张利伟,王瑜,等.基于极限学习机的变压器故障诊断方法研究[J].电测与仪表,2013,50(12):21-26.
YUAN Jinsha, ZHANG Liwei, WANG Yu, et al. Study of transformers fault diagnosis based on extreme learning machine [J]. Electrical Measurement & Instrumentation, 2013, 50(12):21-26.

收稿日期:2024-09-29

修回日期:2025-01-10

作者简介:

张若愚(1995),通信作者(z1045087967@126.com)男,硕士,工程师,主要研究方向为电气设备在线监测与状态评价;

石 峥(1992),女,硕士,工程师,主要研究方向为电气设备在线监测与状态评价;

郭 建(1996),男,硕士,工程师,主要研究方向为电气设备在线监测与状态评价;

宫 鑫(1995),男,硕士,工程师,主要研究方向为电气设备在线监测与状态评价;

雷 敏(1987),女,硕士,高级工程师,主要研究方向为电气设备在线监测与状态评价。

(责任编辑 车永强)

《山东电力技术》2025年总目次

(期.页)

·新型电力系统灵活性提升关键技术·

基于改进边界收缩算法的灵活性资源聚合模型 翁亮涛,王思远,郑伟业,杨 苓,朱继忠(1.1)

不确定环境下基于动态税和电动汽车时空灵活性的配电网阻塞管理方法

..... 林思瑶,马 晓,贺 坤,王 灿,沈非凡(1.12)

基于改进遗传算法的交直流混联电网的无功优化方法 雷宇立,周承君,幸爱玲,牛 涛,方斯顿(1.28)

计及负荷运行风险的电氢热耦合微电网区域零碳优化调度技术

..... 邢家维,程 艳,孙树敏,杨 颂,王玥娇(1.38)

·源网荷储协调互动·

基于“分级-协同”思想的分布式光伏柔性参与电网调峰技术研究及应用

..... 张 强,李 娜,蔺晨晖,吴继平,张文栋,刘宏雷(1.46)

基于深度强化学习的空气源热泵供热系统温度控制策略 刘 伟,高 嵩,宋宗勋,许晓康,刘 萌(1.54)

考虑火力发电深度调峰的高渗透率新能源电力系统优化调度

..... 刘 科,张利孟,孟令彤,刘恩生,王 太,宋文浩(1.62)

考虑时空分布特性的异构柔性负荷模态研究 温志鹏,宋显锦,杨 冰(7.1)

基于深度确定性策略梯度算法的乡村光-沼虚拟电厂低碳调度方法 王 琛,孙哲夫,张自伟(7.14)

V2G模式下电动汽车多目标需求响应调度策略 刘 洋,于海东,刘文彬,文祥宇,刘明林(7.27)

考虑新能源不确定性的电力系统灵活性评价方法与提升措施 冯树海,史新红,郑亚先,石 飞(9.32)

考虑时序特性的高比例新能源电力系统运行方式聚类分析方法

..... 高 嵩,庞向坤,陈思颖,曹 齐,谢海鹏(9.44)

考虑集群电动汽车可行域聚合的电氢能源微网功率波动平抑优化策略 童宇轩,李 灿(9.58)

基于电动汽车负荷预测误差优化广播电价的光伏微电网调度策略

..... 李 萌,石雨帆,王者龙,江 源,许 帅(11.76)

基于分级需求响应机制的微电网优化调度策略 张 杰,潘守翡,胡丛飞,刘 浩,王晓璐(11.88)

·输变电·

邻近变电站终端塔级联接地降阻策略研究 毛惠卿,高 涛,张建伟,张 凯,穆明亮,田海鹏(1.72)

非晶合金变压器出口短路状态下绕组温度分布特性研究 刘兴华,李 飞,赵彦龙,咸日常,陈 磊(1.81)

基于回归分析的人体工频电场畸变影响分析预测研究 巩泉泉,杨柳倩,侯 琛,李 奎,张兆波(1.89)

不同运行年限高压电缆 XLPE 绝缘特性及温度场仿真研究 ... 段玉兵,徐庆文,罗 文,兰 锐,李国倡(4.81)

具身智能:变电站开关柜自主作业机器人	潘慧超,王延安,李鑫,贾昭鑫,王海磊(4.89)
变压器短路实验下基于WOA-SVM的顶层油温声学反演方法	杨超,薛帅,李承振,郭昊鑫,杨梦娇(7.76)
基于数字化映射的开关柜状态监测技术研究	霍凌宇,苏国强,和家慧,刘合金,张林利(7.86)
架空输电线路舞动风险定量评价方法研究	何勇军,孙国磊,张斌,赵彬,程剑(7.97)
基于台风强风实测的输电线路设计风荷载特性及规范对比研究	邵帅,杨风利,彭波,张宏杰,管明健(8.79)
多应力下变压器油纸绝缘寿命评估模型	刘建,孙锐,高俊营,李长云(8.85)
热氧老化下聚丙烯共混绝缘微观形貌及电气机械性能演变规律研究	曹建梅,杜宝帅,杜伯学,张猛,李忠磊(8.94)
基于ERGAN和BO-BiGRU的变电站高压开关柜凝露临界温度预测	王鹏飞,陈雪,李继宇,陈大才,蔡旺昕,赖举添(9.87)
基于回波损耗的GIS特高频内置传感器现场校验方法研究	张丕沛,朱振龙,于吉,成鲁钰,宋磊(9.96)
GIS盆式绝缘子温升特性及其影响规律研究	李杰,王丹,孙承海,孙艳迪,徐冉(9.104)
考虑城轨杂散电流的主变压器隔直装置最优配置	宋景博,陈晨,齐桓若,张金凤,薛文杰,刘铜锤(12.92)
基于电场等效的±800 kV直流输电线路直线塔无人机灭火安全距离研究	过羿,胡圣涛,刘宇舜,赵玉顺,张佳庆(12.102)
基于数据质量提升的变压器顶层油温预测模型	张若愚,石峥,郭建,宫鑫,雷敏(12.113)
·城市综合能源系统运行调控关键技术·	
钢铁能源局域网:概念、架构及应用	谷鹏飞,孙宏斌,薛屹洵,常馨月,李泽宁,杜源(2.1)
基于自适应神经动力学算法的电-氢综合能源系统分布式能量管理方法	管文博,李基源,常馨月,薛屹洵,苏珈,李泽宁(2.13)
基于改进麻雀搜索算法的建筑综合能源系统优化调度	张春霞(2.23)
能源转型背景下虚拟电厂技术综述与应用展望	邓月,邓浩,郑武,李天鹭,刘诗语,薛屹洵(10.1)
考虑电池仓一致性的V2G换电站二次调频控制策略	范晨辰,黄新凯,张圣祺,周喆(0.14)
考虑储能荷电状态均衡的低频减载优化控制策略	罗凯明,徐艺敏,张大林,李骁,岳帅,于海龙(0.25)
·新能源·	
基于NWP风速修正与VMD-DBO-DELM残差建模的风电功率预测研究	屈伯阳,付立思(2.32)
考虑涉网一次调频考核要求面向风储联合系统收益优化的储能容量配置	丁杨,唐培全,张文奎,王福晶,王俊杰(2.46)
超短期光伏功率预测技术分析综述	王士柏,王凯,孙树敏,程艳,王楠(2.55)

基于多尺度主导成分分析与混合数据驱动模型的短期风电功率预测	范晨亮,尚浩,闫喜宏,付文龙(11.100)
考虑安全约束的新能源电力系统低碳经济调度	郭岩,杨凡,邱生敏(11.108)
基于CWOA-BiLSTM的光伏功率双层预测结构建模及研究	仇志鑫,唐亮,王洪礼(11.118)
基于偏最小二乘和改进时间卷积网络的风电场超短期发电功率预测	郑广宇,辛征,迟蔚然,陈立征,王士柏(12.1)
基于地基云图与卫星云图相结合的光伏功率预测方法	马文文,胡思雨,杨凡,李登宣,卜强生(12.17)
基于储能惯量支撑的高比例新能源基地效益提升优化方法	李红刚,李勇,李晓宁,穆明亮(12.27)
融合多元时间序列与TCN-BiLSTM的分布式光伏功率超短期预测研究	高任龙,李峰,马天东,吴骥(12.38)
·配电网·	
基于同步提取变换和卷积神经网络的有源配电网单相接地故障选线方法	翟乐庆,刘益青,魏元健,徐枫,张宸恺(2.65)
基于混合海鸥优化算法的主动配电网双层规划	方磊,孙光亮,郭啸,孙华忠,王娟娟(2.78)
就地型馈线自动化快速自愈策略研究	张林利,李建修,李立生,刘合金,苏国强(2.88)
智能配电网全方位一键转供技术	宋圣兰,张超,刘晓亮,李琰,张乃刚(3.32)
考虑不确定性分布式电源的电能质量概率性选址定容策略	李建杰,钟文涛,穆明亮,李平,王志(3.40)
台风灾害中配电网故障抢修策略	吴龙腾,郭乾,吴杰康,陈冠熹(3.49)
基于双层优化柔性共享VDAPF的配电网谐波治理	朱岩松,谢振刚,黄志敏,叶梦豆,江友华(4.29)
含电热综合能源系统的直流配电网分布式优化调度	王岩,李冠冠,邸蕴鹏,李慧鹏,杨磊,刘学堃(4.40)
平抑负荷峰谷差的配电网协同控制技术研究	贾东梨,杨晓雨,叶学顺(4.49)
基于零序电压投影量的小电阻系统单相接地故障测距方法	朱文贺,李守钦,李广,齐兰涛,仇志华(9.1)
计及网损的碳排放流配电网优化运行	徐建军,王贝,彭程,赵书琪(9.10)
基于相电压模变换和混沌振子的配电网故障选线方法研究	吕东飞,马涛,郭艳,刘广,孔雪城(9.23)
基于分布鲁棒的主动配电网多时间尺度优化调度	张启亮,李开灿,孔维娜,周科,刘学祺(10.34)
基于多源信息融合的有源配电网故障定位方法	夏天宇,牛欢,文玉杰,程雪颖,柳进(10.46)
计及虚假信息注入攻击检测的主动配电网预测辅助状态估计	张晟,姜宇森,林瞳,阮欣雨,徐俊俊(11.42)
基于改进K-means和Cluster-GAN的配电网网格划分与负荷聚类	徐春雷,焦昊,马洲俊,肖茂然,殷俊杰(11.52)
基于改进型Yolov10的配电架空线路绝缘子缺陷检测	刘合金,苏国强,左新斌,和家慧,张鹏平(11.67)

·能源互联网·

- 含光-储-充的微电网日前经济调度方法研究…………… 郭 杉,郭 洋,刘小恺,董文娟(3.1)
- 考虑需求响应和碳交易的水泥企业生产调度方法研究…………… 刘鹏龙,王平欣,夏晓东,杨 剑,王 清(3.12)
- 计及阶梯碳交易机制的热电氢联供型综合能源系统多目标优化调度
…………… 邢家维,赵 帅,杨 颂,王玥娇,孙立群(3.21)
- 基于新型多变量灰色预测模型的电能替代潜力预测研究…………… 卜凡鹏,周 旻,张思瑞,方景辉,张 旭(5.79)
- 考虑碳排放约束的山东省能源转型成效评价及碳达峰策略研究
…………… 赵 昕,厉 艳,刘之琳,薛万磊,冀星沛(5.88)
- 考虑配电网承载力的建筑领域电能替代潜力测算…………… 庞 超,丁 一,赵晨阳,霍现旭(7.54)
- 基于L-M优化BP算法的多因素协同电力负荷预测…………… 白 卓,郭 啸,孙华忠(7.68)

·电网运行与控制·

- 基于时频域多特征和优化KELM的电能质量扰动检测…………… 徐 琳,范松海,赵 淳,隗 震,刘 畅(3.59)
- 一种快速动态响应同步调相机低励限制定值整定方法…………… 解笑苏,朱应峰,李 明,孙福春,许金阳(3.68)
- 基于振荡特征监测的分布式电源振荡抑制策略研究…………… 王文正,赵仁德(5.30)
- 模块化大功率制氢电源参与电网一次调频控制策略研究…………… 周一鸣,季振东,荣亿君,桂吉祥(5.41)
- 基于降阶高增益观测器的构网型光储系统滑模控制…………… 薛瑞泽,李 星,王嘉力,任俊恒,皇金锋(6.33)
- 基于二阶混合卷积窗双谱线插值的谐波检测算法…………… 龙艳萍(6.44)
- 雷击条件下柔性直流输电同杆并架线路相互影响仿真分析… 陈 瑞,郑少明,刘 博,董 鹏,黄天啸(7.35)
- 面向MMC-HVDC换流站的构网型和跟网型控制无缝切换技术…………… 孙孔明,李 宽,冯忆文,张远实(7.44)
- 跟网型和构网型混联场站暂态过电压评估与参数影响分析…………… 刘鑫帝,曹嘉文,李常刚,于 越(10.55)
- 混合调制下的可变整流结构宽增益LLC谐振变换器…………… 朱建文,张建华,侯 文,李国亮(10.69)
- 基于动态电压反馈的变流器锁相同步稳定控制方法…………… 武乃虎,苗伟威,刘 露,周海全,孙伶雁(12.70)
- 基于扰动观测器的并网逆变器鲁棒模型预测控制…………… 滕 飞,吴俊俊,姜 辰,黄昊怡,黄 堃(12.81)

·发电技术·

- 基于CiteSpace的核电机组故障诊断发展趋势分析… 李 蔚,李 翱,方兴煜,卢韩斌,林小杰,尚宪和(3.75)
- 局部配水对高位收水冷却塔防冻节能特性影响的数值研究
…………… 杨 利,李 旋,李禹江,韩 强,张智慧,赵元宾(3.86)

·新能源发电系统优化调控与智能运维·

- 计及负荷侧惯量和故障概率的两阶段鲁棒机组组合…………… 叶 婧,周正坤,何杰辉,郭紫昱,杨子龙(4.1)
- 基于时频交叉注意力机制和多域特征融合的风电机组齿轮箱故障诊断研究
…………… 贾树旺,黄 海,吕 洋,杜 波,付文龙(4.11)
- 基于差分隐私保护的智能电网分布式经济调度方案…………… 解国庆,梁 添,周兵兵,李鸿伟,付文龙(4.20)

·人工智能·

基于改进HPO-ELM与证据推理规则的变压器状态评估方法

..... 陈继明,陶志雄,沈志彬,高 辉,宋军志(4.58)

基于神经网络的分布式光伏故障外特性聚合等值建模 范荣奇,李 宽,王安宁,高 帅,黄 涛(4.69)

机器学习在风力发电功率预测中应用综述 李 特,黄孜滢(8.45)

基于MLSTM-CI的配电系统多时刻量测缺失数据修复 郭凌旭,王天昊,黄 盼,王冬阳,李振斌(8.56)

基于DPE-MFOA-ELM模型的综合母线负荷日前预测方法 ... 赵永波,林浩然,孔维娜,李开灿,窦震海(8.67)

·电力视觉技术及应用·

基于改进YOLOv8的输电线路外力破坏检测算法 赵文清,蔡建颖,马玉梅,翟永杰(5.1)

结合对比损失和并联残差注意力的绝缘子多缺陷检测 肖甜甜,杨 珂,王乾铭,翟永杰(5.9)

电力钢绞线多尺度损伤图像检测方法 陈 宇,缪进荣,杨辰飙,颜钰霆,贺润平(5.18)

·数字新基建·

基于改进PSO优化RBF神经网络的新型电力系统虚假数据攻击检测研究 王新宇,张明月(5.50)

基于改进注意力机制的多类型数据分类分级方法 张 昊,翟雨佳,黄秀丽(5.57)

架空线路塔上作业VR安全仿真技术与应用 周子程,郑永威,刘 腾,赵晓黎,薛广涛(5.69)

基于无监督自适应机制的电力工控流量异常检测方法 马 力,王 丹,计士禹,刘锦利,石 贺(6.52)

基于自注意力混合模型的电力物联网流量分类 王 聪,郑海杰,黄 振,王高洲,曲海鹏(6.62)

面向智能变电站的时间敏感网络动态时间窗口划分方法 李 伟,白 杨,祁步仁,徐 建(6.75)

面向海缆作业应用的空天地海一体化通信组网关键技术研究

..... 隋 灿,韩志骏,朱坤双,侯 炜,宫梓超(9.68)

基于CBR指数与EoFgu的电力系统高隔离性以太网技术研究

..... 江 崧,贾 平,李 沛,汪大洋,赵金城(9.79)

·储能支撑低碳高品质新型配电系统构建关键技术研究·

基于线性自抗扰控制的离网虚拟同步发电机频率调节方法 ... 丁宏志,潘 波,郭晓瑞,文 安,叶 润(6.1)

计及变流器频率支撑与容量约束的孤岛微电网多源协同调度方法

..... 邓美玲,江通财,白振毅,林 健,陈永进,吴子龙(6.10)

多利益主体互动下光储系统联合配置的优化方法 冯德品,徐 兵,沈 涛,马晓慧(6.22)

·设备检测与故障诊断·

碰摩诱发大型同步调相机转子低频振动故障机理研究 汪海洋,刘晓锋,刘一丹,何小锋,蔡 丹(6.86)

调相机空冷岛风机故障仿真分析及措施建议 郝亚楠,王 俊,颜 庆,李贵海,郭 语(6.95)

·考虑多元灵活资源协同的新型电力系统低碳安全运行技术·

基于时空关联定价机制的跨园区综合能源系统优化调度策略 ... 陈 颀,周子龙,张巧龙,牛哲文,谢李为(8.1)

基于多源MEMS传感器的架空线电流精确测量方法	周展帆,严宇,何泽宇,毕岚溪,喻 锐(8.16)
基于供电能力动态提升的配电网故障抢修与恢复协调优化 ...	陈冰冰,刘家腾,吴浩天,梁 睿,王海威(8.25)
新型电力系统LFC的时滞相关鲁棒 H_{∞} 控制	范春玲,练红海,刘泳志,贾 睿,李芷阳(8.36)
·综合能源·	
考虑电网电压稳定性的电-氢混合储能系统优化配置	
.....	胡文波,刘建飞,陈 杰,张天闻,苗 霞,杨 博(10.81)
云储能与含数据中心的多微网系统双层优化调度	岳佳明,钟建伟,梁会军,朱占春,魏云龙(10.91)
电能共享下考虑电动汽车移动储能特性的综合能源楼宇群日前投标策略	
.....	吉 杨,何海航,穆睿智,张卫欣,冯相龙(10.102)
·高寒地区电网规划与运行控制技术·	
高寒地区综合能源系统示范工程现状与展望	赵曰浩,孙 允,王 悦,李知艺(11.1)
考虑灵活资源参与的多能耦合系统风险响应与调控	何荣凯,李万信,唐 华,张 涛,潘 超(11.13)
地线取能装置低温稳定性分析及优化	赵东生,范亚洲,王开金,杨 军(11.33)
·电力市场运营·	
面向光储集群接入的有源配电网两阶段交易机制设计	徐嘉豪,徐俊俊,王福晶(12.50)
适应新增电器的非侵入式负荷监测增量学习方法 ...	杨国朝,贾明辉,李子墨,白辛雨,于普瑶,刘 尧(12.61)



庆祝迎新年

《山东电力技术》期刊祝您元旦快乐！

致作者读者、审稿专家、编委专家及所有帮助支持我们的朋友：

辞旧迎新，岁启华章，

值此2026年元旦佳节，

恭祝大家新年快乐，阖家安康！



关注《山东电力技术》