

基于改进的孤立森林风电机组数据异常检测

钟秋惠, 李 勇

成都信息工程大学 统计学院, 成都 610225

摘要:目的 风电机组带来清洁能源的同时,也面临着一系列技术挑战,其中最为突出的是机组的稳定性和可靠性,针对风电机组数据的异常检测问题,提出一种科学且有效的改进方法——基于残差的孤立森林。方法 鉴于传统孤立森林方法在正常运行时波动的干扰和参数敏感性方面存在的问题,提出基于残差的孤立森林方法进行异常检测。首先采用 RANSAC 回归模型预测风速与功率之间的关系,并计算实际功率与预测功率之间的残差;进一步,将这些残差作为输入特征,在孤立森林模型中实施异常检测。此方法着重关注模型难以解释的部分,减少了正常运行状态下的自然波动对异常检测的干扰,增强了对潜在异常点的精确识别。结果 通过对异常值进行可视化验证结果表明:改进方法在识别功率曲线上的局部异常方面表现更加突出。结论 这种基于残差的孤立森林方法能够在多数操作条件下更精确地识别出异常,为风电场的运维管理提供强有力的数据支持;同时也为其他领域的异常检测提供了新的思路和参考,具有广泛的应用前景。

关键词:孤立森林算法;RANSAC 回归;异常检测;风电机组

中图分类号:TM315 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2025.0006.015

Wind Turbine Data Anomaly Detection Based on Improved Isolated Forest Method

ZHONG Qiuhui, LI Yong

School of Statistics, Chengdu University of Information Technology, Chengdu 610225, China

Abstract: Objective Wind turbines bring clean energy but also face a series of technical challenges. Among them, the most prominent issues are the stability and reliability of the turbines. Addressing the issue of anomaly detection in wind turbine data, a scientific and effective improvement method is proposed—residual-based isolation forest. **Methods** Given the disturbances from normal operational fluctuations and sensitivity to parameters in traditional isolation forest methods, a residual-based isolation forest approach is proposed for anomaly detection. Initially, a RANSAC regression model predicts the relationship between wind speed and power, calculating the residuals between actual and predicted power. These residuals are then used as input features in the isolation forest model for anomaly detection. This method focuses on parts of the model that are difficult to interpret, reducing interference from natural fluctuations during normal operation and enhancing precise identification of potential anomaly points. **Results** Visualizations of anomaly detection results demonstrate that the improved method excels in identifying local anomalies in power curves. **Conclusion** The residual-based isolation forest method can more accurately identify anomalies under various operational conditions, providing robust

收稿日期:2023-11-01 修回日期:2024-01-10 文章编号:1672-058X(2025)06-0115-08

基金项目:国家社科基金重大项目(21&ZD153);重庆市社科规划重点项目(2020ZDJ08);四川省高等教育人才培养质量和教学改革项目(JG2021-393);重庆市教育科学“十三五”规划课题(2020-GX-294)。

作者简介:钟秋惠(1998—),女,江西赣州人,硕士研究生,从事大数据统计研究。

通信作者:李勇(1970—),男,重庆南川区人,教授,从事智能大数据统计与智能社会治理研究。Email:397795585@qq.com.

引用格式:钟秋惠,李勇.基于改进的孤立森林风电机组数据异常检测[J].重庆工商大学学报(自然科学版),2025,42(6):115-122.

ZHONG Qiuhui, LI Yong. Wind turbine data anomaly detection based on improved isolated forest method[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2025, 42(6): 115-122.

data support for the maintenance management of wind farms. Additionally, this method offers new perspectives and references for anomaly detection in other fields, with broad application prospects.

Keywords: isolation forest algorithm; RANSAC regression; anomaly detection; wind turbine

1 引言

随着全球气候变化和对可再生能源的日益关注,风电作为一种清洁、可再生能源,在全球范围内得到了广泛的应用和发展。特别在中国,根据《能源生产和消费革命战略(2016—2030)》,国家积极推动能源生产和消费革命,以实现能源的低碳化、清洁化,确保国家能源安全并支持经济社会可持续发展。风电在此战略中扮演了至关重要的角色,其发展和应用受到了国家层面的高度重视和大力支持。我国风电机组的装机容量持续增长,这不仅反映了中国在风能利用方面的领导地位,也表明了推进能源结构调整、降低能源消费强度和排放强度方面取得的积极进展。然而,在风电机组带来清洁能源的同时,也面临着一系列技术挑战。其中最为突出的是机组的稳定性和可靠性问题。这主要归因于风电机组自身的复杂结构和其工作在恶劣环境中的特点。位于山区、海滨或其他偏远地区的风电场,其机组长时间在变化多端的气候条件下运行,这无疑增加了故障的风险。频繁的故障不仅对风电场的正常运行造成干扰,还会带来巨大的经济损失。

为了解决这一问题,学术界和工程界已经开始探索如何更有效地监测风电机组的健康状态。其中,SCADA(Supervisory Control and Data Acquisition)系统作为一种现代数据采集和监视技术,被广泛应用于风电机组的健康监测中。其优势在于可以实时、全面地收集机组的运行数据,为后续数据分析和故障预测提供宝贵的信息。如何从这些庞大的数据中提取有用的信息,进行准确的异常检测,仍然是一个挑战。针对时序数据异常检测领域的研究,贾子文等^[1]通过滑动窗口计算每个窗口区间内时间序列中各状态参数平均值的绝对值,将其中最大值与敏感度系数的积作为窗口区间的阈值来识别风电机组中的异常数据;戴邵武等^[2]通过设置时间序列窗口,对非参数数据进行遍历检测,并对每个窗口内的数据进行样本分位数提取,实现非参数数据异常值检测;高熠飞等^[3]用滑动窗口内的中位数和中位数绝对偏差代替均值和标准差,以消除极端异常值对检测算法的影响。

在机器学习异常检测方法中,基于相似度度量的检测方法引起了广泛关注,这类方法的核心理念是:异常数据和正常数据分布有显著差异,因此两者之间的相似度较低,或异常点通常远离正常点。这种观点催生了大量的算法,它们通常借助某种形式的相似度(如距离、密度或聚类)来识别异常值。例如,在 Breunig 等^[4]学者的研究中,他们提出局部离群因子(Local Outlier Factor,简称 LOF)来识别基于密度的局部异常。尽管 LOF 在某些情况下能有效识别异常,但其计算复杂度较高。为了优化计算效率,Tang 等^[5]引入基于连通的异常点因子(Connectivity-Based Outlier Factor,简称 COF),该方法通过计算数据点间的最短路径来寻找邻近点并计算局部密度,而不是采用 LOF 的欧几里德距离。另外,周春蕾等^[6]提出一种基于聚类分割与核密度估计的异常检测方法,它首先简化数据分布,然后应用假设检验进行异常识别。这些方法从不同角度探讨了如何更有效地进行基于密度的异常检测。胡聪等^[7]为提高用电异常识别的准确性,采用结合改进的 K-medoids 聚类算法和支持向量机(Support Vector Machine,简称 SVM)方法;吴蕊等^[8]通过优化 K-means 聚类的初始聚类中心选择策略,利用数据密度和最大近邻半径来更准确地选取初始聚类中心,从而提高电力数据异常检测的效率。

这些方法虽在一定程度上有效,但也伴随计算复杂度高,对噪声敏感等问题。陈宇轩等^[9]提出一种基于 Boosting 集成框架的新能源发电功率异常值检测方法,他们使用孤立森林作为基分类器,并通过 3 层递进式训练模式进行训练。陆秋琴等^[10]结合滑动窗口算法和时间序列分解与 DBSCAN(Density-Based Spatial Clustering of Applications with Noise)聚类方法进行异常值检测,并提出一种基于支持向量机回归的恢复模型。基于距离的检测方法通常将时序数据分割为一系列的子序列,并度量子序列之间的距离来检测异常。Sugiyama 等^[11]提出一种基于 KL 散度的重要性估计方法,该方法通过计算相邻子序列间的距离,能够更全面地检测多个异常。

然而,这些方法虽然在某些应用场景中取得了良好的效果,但也存在一些缺陷,如计算复杂度高,对噪声敏感等问题。为了解决这些问题,一些研究者开始探索集成学习、深度学习等^[12-15]先进方法来进行异常检测。但是,这些方法往往需要大量的数据、计算资源,而且对参数的选择非常敏感。

鉴于上述背景,本研究提出一种改进的异常检测方法——基于残差的孤立森林方法。该方法首先采用一种 RANSAC(Random Sample Consensus)拟合模型来预测风机功率与风速的关系,随后计算实际功率与预测功率之间的残差。这些残差捕捉了功率曲线的微小波动,这些波动可能由于各种因素(例如设备老化、损坏等)而在功率曲线中引入微小的、不规则的变化。接着,利用孤立森林模型对这些残差进行分析,以识别出潜在的异常点。相较于直接在原始数据上运用孤立森林,这种基于残差的方法更能够聚焦于那些微小但可能具有重要物理意义的功率波动,为风电场的运维决策提供更为精准的参考。

2 算法设计与改进

2.1 改进的孤立森林算法分析

孤立森林(Isolation Forest)作为一种基于树的模型,在异常检测领域得到了广泛应用。其核心优势在于高效的异常检测能力,它通过构建多个随机树来“孤立”观测点,简化了计算过程。传统的密度或距离方法需要计算每个数据点之间的相互关系,计算量随着数据量的增加而大幅增长。而孤立森林算法通过评估数据点到达孤立状态的路径长度来判断其异常程度,路径越短,数据点越可能是异常值。这一判断过程不涉及复杂的距离或密度计算,从而显著提升了计算效率。

然而,传统的孤立森林算法在某些领域应用中存在局限性。特别是在需要考虑数据间物理关系或领域知识的场景中,如风电领域、风速与功率之间的线性关系提供了重要的背景信息。这些信息如果不被考虑,算法可能无法准确识别异常,因为它忽略了数据的内在联系。

针对这一问题,改进的孤立森林算法首先引入 RANSAC 算法,这是一种鲁棒的线性模型拟合技术。通过 RANSAC,算法能够在存在噪声的数据中识别出稳健的线性关系。该模型对风速与功率之间的关系进行线性拟合,从而建立一个基线模型,有效抵抗异常点

对拟合结果的干扰。随后,算法计算残差,即实际功率与通过线性模型预测的功率之间的差值。这些残差成为孤立森林的新特征,为模型提供了一个新维度来评估异常,图 1 为改进的孤立森林算法模型图。




图 1 改进的孤立森林模型图

Fig. 1 Diagram of the improved isolated forest model

引入残差的改进孤立森林模型,不仅继承了原算法在异常检测上的高效性,而且通过融合领域知识,显著提高了对异常的识别准确率。这种方法充分利用了风电数据的物理特性,确保了模型在保持高效计算的同时,也能够特定应用环境中提供更为精确的检测结果。

2.2 改进的孤立森林算法步骤

2.2.1 RANSAC 线性拟合

(1) 特征与目标变量选择。选择风速和功率作为特征和目标变量,即利用公式

$$f(x) = ax + b \quad (1)$$

其中, x 是风速特征, y 是功率目标变量。

(2) 鲁棒性线性模型拟合。使用 RANSAC 策略:随机选择最小数据集并计算线性模型的参数 a 和 b ;使用式(1)计算所有点的预测值,并与实际值对比,得到误差 e ,即预测值和实际值的差值;选择误差范围内点数量最多的模型作为最终模型;计算残差 $r_i = y_i - f(x_i)$ 。

2.2.2 基于残差的孤立森林

(1) 构造新的特征矩阵 x' ,该矩阵包括原始风速

特征 x 和每个数据点的残差 r 。

(2) 确定最佳参数,如孤立森林中树的数量、样本大小等。

(3) 使用孤立森林模型,定义为

$$f(\mathbf{x}') = \begin{cases} 1 & \text{if } \frac{1}{|T|} \sum_{t \in T} L_{\text{path}}(\mathbf{x}', t) < T(c) \\ 0 & \text{otherwise} \end{cases}$$

其中, $\mathbf{x}'$ 为带有新特征矩阵的样本; T 为孤立森林; $|T|$ 代表孤立森林中树的总数; t 代表孤立森林中的树; $L_{\text{path}}(\mathbf{x}', t)$ 为计算样本点 $\mathbf{x}'$ 在树 t 中路径长度的函数; $T(c)$ 则是根据某些条件 c 计算而来的阈值,该条件往往与数据集特征、参数有关,可由模型自行学习生成。

总的来说,该模型算法是计算样本点 $\mathbf{x}'$ 在每棵树上的路径长度,然后求出这些路径长度的平均值,如果这个平均值小于某个预先设定的阈值,就认为 $\mathbf{x}'$ 是一个异常点。

2.2.3 关键参数设定

(1) contamination(c): 代表数据集中异常点的比例。其值设定为 auto,由孤立森林算法自主决定最优的异常值比例。

(2) max_samples(m): 定义了在建构每棵孤立树时使用的最大样本量。其值设定为 0.1,保证每棵树在建构过程中仅利用数据集的 10%。

3 仿真实验与结果分析

3.1 数据集介绍

本文数据集源自国家电力投资集团有限公司指导的 DataFountain 竞赛平台赛题“风电机组异常数据识别与清洗”。该数据集融合 12 台风电机组在一年内的 SCADA 运行数据,每条数据以 10 min 的间隔进行采集。本研究针对其中 3 台风电机组的数据进行深入异常检测研究。这些数据直接反映了风电机组在实际工况下的运行状态,并包含了丰富的异常数据点信息,每条记录主要涵盖 4 个维度的信息:时间戳、风速、功率和风轮转速。此外,为支持更精确的异常检测分析,数据集还提供了风电机组的详细参数,如风轮直径、额定功率和风轮转速范围等。本研究侧重于利用该数据集进行风电机组实际运行中的异常检测分析。

3.2 数据探索

在对风电机组的 SCADA 数据进行初步分析后,通过表 1 观察到一些异常信息:所有 3 台风电机的风速、

功率和风轮转速数据中都出现了不符合实际情况的负值,这在物理上是不可能的,可能归因于传感器故障或数据处理错误。尤其是风电机 3 在风速上的最小值为 -12.51 m/s ,远低于其他风电机,应引起特别关注。此外,虽然 3 台风电机的功率均值相近,但其标准差较大,显示出数据的变异性较强,这可能暗示不同风电机的运行状态和效率存在较大差异或数据质量问题。这些潜在的异常值和差异将在后续分析中进一步验证并着手解决。

表 1 风机描述性统计值

Table 1 Descriptive statistics of the fan

特 征	数 据	风电机 1	风电机 2	风电机 3
风速/ ($\text{m} \cdot \text{s}^{-1}$)	count	40 727	44 335	43 324
	mean	5.7	5.3	5.7
	std	2.8	2.8	3.1
	min	-0.1	0.0	-12.5
	25%	3.7	3.4	3.6
	50%	5.3	4.8	5.2
	75%	7.3	6.8	7.4
	max	26.5	22.7	24.6
功率/kW	count	40 727	44 335	43 324
	mean	372.9	352.4	332.6
	std	503.7	503.8	468.0
	min	-53.0	-57.8	-49.0
	25%	-8.8	-10.4	-10.0
	50%	184.3	154.3	165.3
	75%	522.0	474.2	466.0
	max	2 174.4	2 163.8	2 151.2
风轮转速/ ($\text{r} \cdot \text{min}^{-1}$)	count	40 727	44 335	43 324
	mean	7.3	7.8	7.2
	std	5.3	5.1	5.1
	min	0.0	-0.6	0.0
	25%	0.2	2.2	0.2
	50%	8.9	8.8	8.8
	75%	11.3	11.2	11.0
	max	35.0	15.5	15.5

图 2 分别展示了风机 1、2 和 3 的风速、功率和风轮转速分布情况。这些直方图更直观地理解 3 台风机在风速、功率和风轮转速这 3 个参数上的分布特性。




图2 特征分布直方图

Fig. 2 Histogram of feature distribution

在分布特性上,功率和风轮转速的分布呈现出明显的右偏态,即大多数情况下风电机工作在较低的功率和风轮转速下,而较高的值较为稀少。

图3为3个风机功率随风速变化散点图,风速与功率关系表明风能转换至电能的效率及风电机的运行状态。在分析的数据中,风速与功率展现出明确的正相关关系。低风速区间内,风电机的功率输出接近零,暗示在这些风速条件下,风电机未开始发电。而风速升高,功率输出逐步增加,表明风能被转化为电能。然而,数据集中也呈现出一些异常,例如在正常风速下功率为零或负值,这直接指出风电机的故障或数据采集问题。在3 m/s的切入风速下,功率输出应为零。但在

本文的数据中,存在非零的功率输出,这直接标识风电机实际操作问题,或者数据采集的误差。






图3 功率随风速变化散点图

Fig. 3 Scatter plot of power varying with wind speed


3.3 数据清洗

在风电领域,对 SCADA(监控和数据采集系统)数据的精确分析至关重要,以确保风电机组的稳定和高效运行。根据初步数据分析和可视化,本文设定了几条基于业务逻辑和物理原理的规则来识别可能的异常数据点。其中包括风速、风轮转速、功率任意一个小于等于 0;在风速小于切入风速时,风电机组功率大于 0;在风速大于切出风速时,风电机组功率大于 0;风电机组功率大于其额定功率的 1.2 倍。

这些规则基于风电机组的常规运行特性和物理限制。对这些异常值进行可视化(图 4),发现在时间维度上,异常数据在一天中的分布表现出明显的模式,特别是在白天的异常数据点较多。同时,异常值在 1 月和 12 月的分布明显增多,这可能与冬季的气候特征(例如,强风、低温等)有关,这些因素可能影响风电机组的运行和传感器的准确度。其次,在风机维度上,风机 1 和风机 3 表现出较多的异常数据点,而风机 2 相对较少,这暗示不同的风机可能存在不同的运行或维护问题。在风速与功率的关系中,异常数据主要集中在风速较低但功率不为零的区域,以及风速较高的区域,这可能与风速传感器的误差或风电机组在特定风速下的功率输出不稳定有关。基于物理规则成功识别并排除了 39 597 条潜在的异常数据点。



(c) 异常数据风机分布直方图



(d) 异常数据功率随风速变化散点图

图 4 异常数据分布图

Fig. 4 Distribution plot of anomalous data

3.4 异常检测算法对比

在风电领域的数据分析过程中,引入了一种基于残差的孤立森林方法,其核心目标是精准识别那些可能被传统异常检测方法忽略的细微异常。在图 5 中,分析了 3 个不同的风机,每一行对应一个风机的数据。左列图展示了单独使用孤立森林进行异常检测的结果,而右列图则展示了先利用 RANSAC 回归模型计算残差,并基于这些残差使用孤立森林进行异常检测的方法的结果。红点是识别为异常的数据,蓝点是识别为正常的数据。

通过上述两种方法,得到了两组异常值标签。通过可视化结果,可以明显看到两种方法在异常检测上的差异。基于残差的方法在识别出功率曲线上的局部异常(即功率曲线的微小波动)方面表现更加突出,孤立森林方法有时可能会因受到一些显著但正常的操作条件(例如风速突变)的影响而产生误报。




图5 孤立森林(左)算法和残差孤立森林算法(右)异常值可视化对比图

Fig.5 Visualization comparison plot of outliers using isolation forest algorithm(left) and residual isolation forest algorithm(right)

4 结论与展望

在风电领域的异常检测研究中,提出了一种更有效的基于残差的孤立森林方法,专注于揭示风电机组功率的微小波动和潜在异常。相较于传统的孤立森林方法,本方法通过利用 RANSAC 回归模型预测风速与功率的关系,能够更精确地捕获潜在的异常波动,而不仅仅是明显的离群值。该方法显著削减了正常运行波动对异常检测的干扰,尤其在风速较低、功率波动较大的场景下展现出更加精准的检测能力。而残差作为本方法的核心指标,其科学性和合理性得到了充分的体现。在多个科学研究中已广泛认可的残

差分析,不仅能有效评估模型预测的准确度,更能在风电机组中准确地指向可能的设备问题或微小损伤。本方法能够揭示出传统方法可能忽略的关键问题,例如在某些工况下的细微功率波动,这些波动可能源自风轮的微小损伤或驱动系统的轻微磨损。因此,建议在发现持续的微小波动时,及时进行风电机组的物理检查和必要的维护,以及通过定期的数据分析和监控,提前发现并预防可能的问题,最大程度上保证风电机组的稳定运行,并减少因故障停机带来的经济损失。展望未来,本研究将进一步关注算法的计算效率优化以及更多领域知识的融入,以提升模型的预测精

度和解释能力,为风电场的运维管理提供更加坚实的数据支持。

参考文献(References):

- [1] 贾子文, 顾煜炯. 基于数据挖掘的风电机组齿轮箱运行状态分析[J]. 中国机械工程, 2018, 29(6): 650-658.
JIA Zi-wen, GU Yu-jiong. Wind turbine gearbox operation state analysis based on data mining[J]. China Mechanical Engineering, 2018, 29(6): 650-658.
- [2] 戴邵武, 陈强强, 毛凯, 等. 基于样本分位数原理的飞参数据异常值检测算法[J]. 兵器装备工程学报, 2020, 41(5): 113-117.
DAI Shao-wu, CHEN Qiang-qiang, MAO Kai, et al. Flight data outliers detection method based on sample quantile[J]. Journal of Ordnance Equipment Engineering, 2020, 41(5): 113-117.
- [3] 高熠飞, 王建平, 李林峰. 基于柯西分布的水文序列异常值检测方法[J]. 河海大学学报(自然科学版), 2020, 48(4): 307-313.
GAO Yi-fei, WANG Jian-ping, LI Lin-feng. Outlier detection method of hydrological time series based on Cauchy distribution[J]. Journal of Hohai University (Natural Sciences), 2020, 48(4): 307-313.
- [4] BREUNIG M M, KRIEGER H P, NG R T, et al. OPTICS-OF: identifying local outliers[C]//European Conference on Principles of Data Mining and Knowledge Discovery. Berlin, Heidelberg: Springer, 1999: 262-270.
- [5] TANG J, CHEN Z, FU A W C, et al. Enhancing effectiveness of outlier detections for low density patterns[C]//Advances in Knowledge Discovery and Data Mining. Berlin, Heidelberg: Springer, 2002: 535-548.
- [6] 周春蕾, 田品卓, 杨晨琛, 等. 基于聚类和核密度估计假设检验的异常值检测方法[J]. 数据采集与处理, 2017, 32(5): 997-1004.
ZHOU Chun-lei, TIAN Pin-zhuo, YANG Chen-chen, et al. Outlier detection based on clustering and KDE hypothesis testing[J]. Journal of Data Acquisition and Processing, 2017, 32(5): 997-1004.
- [7] 胡聪, 徐敏, 洪德华, 等. 基于改进 K-medoids 聚类和 SVM 的异常用电模式在线检测方法[J]. 国外电子测量技术, 2022, 41(2): 53-59.
HU Cong, XU Min, HONG De-hua, et al. Online detection method for abnormal electricity model behavior based on improved K-medoids clustering and SVM[J]. Foreign Electronic Measurement Technology, 2022, 41(2): 53-59.
- [8] 吴蕊, 张安勤, 田秀霞, 等. 基于改进 K-means 的电力数据异常检测算法[J]. 华东师范大学学报(自然科学版), 2020(4): 79-87.
WU Rui, ZHANG An-qin, TIAN Xiu-xia, et al. Anomaly detection algorithm based on improved K-means for electric power data[J]. Journal of East China Normal University (Natural Sciences), 2020(4): 79-87.
- [9] 陈宇轩, 张耀, 徐杨, 等. 基于 Boosting 集成框架的新能源发电功率异常值检测方法[J]. 电网技术, 2023, 47(8): 3261-3268.
CHEN Yu-xuan, ZHANG Yao, XU Yang, et al. Outlier detection method of new energy power based on boosting integration framework[J]. Power System Technology, 2023, 47(8): 3261-3268.
- [10] 陆秋琴, 王璐, 黄光球. 考虑时序特征的污染物数据异常检测及恢复[J]. 安全与环境学报, 2023, 23(12): 4590-4599.
LU Qiu-qin, WANG Lu, HUANG Guang-qiu. Abnormal detection and recovery of pollutant data considering time series characteristics[J]. Journal of Safety and Environment, 2023, 23(12): 4590-4599.
- [11] SUGIYAMA M, SUZUKI T, NAKAJIMA S, et al. Direct importance estimation for covariate shift adaptation[J]. Annals of the Institute of Statistical Mathematics, 2008, 60(4): 699-746.
- [12] 金晓航, 许壮伟, 孙毅, 等. 基于 SCADA 数据分析和稀疏自编码神经网络的风电机组在线运行状态监测[J]. 太阳能学报, 2021, 42(6): 321-328.
JIN Xiao-hang, XU Zhuang-wei, SUN Yi, et al. Online condition monitoring for wind turbines based on scada data analysis and sparse auto-encoder neural network[J]. Acta Energiae Solaris Sinica, 2021, 42(6): 321-328.
- [13] 郝帅, 马瑞泽, 赵新生, 等. 基于卷积块注意模型的 YOLOv3 输电线路故障检测方法[J]. 电网技术, 2021, 45(8): 2979-2987.
HAO Shuai, MA Rui-ze, ZHAO Xin-sheng, et al. Fault detection of YOLOv3 transmission line based on convolutional block attention model[J]. Power System Technology, 2021, 45(8): 2979-2987.
- [14] 黄荣舟, 汤宝平, 杨燕妮, 等. 基于长短时记忆网络融合 SCADA 数据的风电齿轮箱状态监测[J]. 太阳能学报, 2021, 42(1): 235-239.
HUANG Rong-zhou, TANG Bao-ping, YANG Yan-ni, et al. Condition monitoring of wind turbine gearbox based on lstm neural network fusing scada data[J]. Acta Energiae Solaris Sinica, 2021, 42(1): 235-239.
- [15] 杜勉, 易俊, 郭剑波, 等. 神经网络技术在风电机组 SCADA 数据分析中的应用研究[J]. 电网技术, 2018, 42(7): 2200-2205.
DU Mian, YI Jun, GUO Jian-bo, et al. Research on the application of neural networks on wind turbine SCADA data analysis[J]. Power System Technology, 2018, 42(7): 2200-2205.

责任编辑:李翠薇