

DOI:10.20033/j.1003-7241.(2026)04-0035-05

## 基于多维度数据优化融合的电力数据异常精准检测

余向前, 喻见, 张瑞, 王婷婷, 辛亚峰

(国网甘肃省电力公司 张掖供电公司, 甘肃 张掖 734000)

**摘要:** 电力数据因时空分布的高度异质性和电磁干扰的影响, 导致采集数据不准确, 单一特征提取易忽略短期剧烈波动, 增加异常检测误检率。为此, 提出基于多维度数据优化融合的电力数据异常精准检测方法。采用多维度数据融合技术, 综合考虑时间和空间等多个维度的信息, 有效整合和分析不同时空下的电力数据, 以适应电力数据的时空异质性。提取多维度电力数据的波动性、趋势性和变动性等特征, 构建考虑电网动态行为的异常检测模型, 并利用误差计算验证检测结果的有效性, 实现对电力数据异常的准确高效识别。实验结果表明, 该方法查全率高、误检率低, 能全面精准识别异常, 为电力系统的安全稳定运行提供有力支持。

**关键词:** 多维度数据优化融合; 电力数据异常检测; 电网动态行为; 关键异常特征; 误差计算

中图分类号: TP391.3

文献标志码: A

文章编号: 1003-7241(2026)04-0035-05

## Accurate anomaly detection of electric power data based on multidimensional data optimization fusion

YU Xiangqian, YU Jian, ZHANG Rui, WANG Tingting, XIN Yafeng

(Zhangye Power Supply Company, State Grid Gansu Electric Power Company, Zhangye 734000, Gansu, China)

**Abstract:** Due to the high heterogeneity of spatiotemporal distribution and the influence of electromagnetic interference, power data collection is inaccurate, and single feature extraction can easily ignore short-term fluctuations, increasing the false detection rate of anomaly detection. Therefore, a precise detection method for power data anomalies based on multi-dimensional data optimization fusion is proposed. Adopting multidimensional data fusion technology, comprehensively considering information from multiple dimensions such as time and space, effectively integrating and analyzing power data under different spatiotemporal conditions to adapt to the spatiotemporal heterogeneity of power data. Extracting the volatility, trend, and variability features of multidimensional power data, constructing an anomaly detection model considering the dynamic behavior of the power grid, and verifying the effectiveness of the detection results through error calculation to achieve accurate and efficient identification of power data anomalies. The experiment shows that this method has a high recall rate and low false detection rate, and can comprehensively and accurately identify anomalies, providing strong support for the safe and stable operation of the power system.

**Keywords:** multi dimensional data optimization and fusion; abnormal detection of power data; dynamic behavior of the power grid; key abnormal features; error calculation

电力数据之间存在着复杂的关联关系, 发电、输电、变电、配电和用电等各个环节的数据相互影响、相互制约。发电功率的变化会直接影响电网的频率和电压, 而用户侧的负荷变化又会反作用于发电端的调度。这种复杂的关联关系使得电力系统的运行状态变得难以简单描述和预测。如果不能准确检测出数据中的异常, 就无法及时发现电网潜在的故障隐患, 进而影响整个电力系统的安全稳定运行。因此, 为了深入理解和把握电力系统的运行规律, 精准检测数据异常成为必然需求。然而, 电力系统周围存在各种电磁干扰源, 如无线电发射塔、大型电机等。只提取单一特征或者少数与异常关联性不强的特征, 会忽略数

据的短期剧烈波动, 导致异常检测的误检率较高。传统的异常检测方法往往侧重于单一特征的分析, 如只关注电压或电流的平均值, 而忽视了数据的波动性、趋势性等其他重要特征。然而, 电力系统中的异常情况往往表现为数据的短期剧烈波动, 如雷击、短路等故障瞬间会导致电流、电压的急剧变化。为此, 需要研究一种电力数据异常精准检测新方法。

文献[1]收集并清洗电力大数据, 根据数据的特点和研究问题, 选择合适的数据预处理方法, 在改进 PSO-PFCM 聚类算法的支持下, 对电力数据进行聚类处理, 并通过动态适应的方式对其进行异常检测。该方法由于仅

收稿日期: 2024-12-10; 录用日期: 2025-01-14

基金项目: 国家电网公司科技项目(52272320003T)

作者简介: 余向前(1973—), 男, 硕士, 高级工程师, 研究方向: 计算机科学与技术。

引用本文: 余向前, 喻见, 张瑞, 等. 基于多维度数据优化融合的电力数据异常精准检测[J]. 自动化技术与应用, 2026, 45(4): 35-39. (YU Xiangqian, YU Jian, ZHANG Rui, et al. Accurate anomaly detection of electric power data based on multidimensional data optimization fusion[J]. Techniques of Automation and Applications, 2026, 45(4): 35-39.)

提取了少数特征,且这些特征与异常的关联性不强,无法及时捕捉到电力数据的短期剧烈波动。文献[2]先采集变电站监控实时数据,并对采集的数据进行整理和转换,再从中提取与异常检测相关的特征,计算出相应的特征值,在改进决策树算法的作用下,对提取的特征进行特征筛选,并构建相应的检测模型,实现对监控数据的异常检测。改进决策树算法对特征筛选,但结果无法全面反映变电站监控数据的复杂性和动态性,当数据中存在短期剧烈波动时,这些波动会包含重要的异常信息,但由于特征提取不全面,这些信息可能被忽略。文献[3]在电力系统中,采集到相应的电力数据,构建相应数据集,再对数据集进行重塑或转换,从中提取出多域特征,利用特征选择算法,按照特征的重要性对特征进行排序,由此生成异常检测模型,对电力数据的异常进行检测。主观性排序会忽略潜在的重要特征即短期剧烈波动,而过分关注一些弱相关的特征,从而影响异常检测的准确性。

在以上研究的基础上,本文提出基于多维度数据优化融合的电力数据异常精准检测方法,通过对原始数据的优化处理、多维度数据融合以及构建考虑电网动态行为的异常检测模型,提取关键异常特征,旨在实现更高效、精准的电力数据异常检测,为保障电力系统的安全稳定运行提供有力支撑。

## 1 电力数据异常精准检测方法

### 1.1 多维度数据优化融合

电力数据的时空分布具有高度异质性,时间维度上如夏季空调负荷剧增、深夜用电需求较低,空间维度上如城市中心负荷密度远高于偏远农村地区。单一维度数据难以适应这种复杂性,导致异常检测不准确。多维度数据优化融合技术<sup>[4]</sup>通过整合时间和空间等多维度信息,有效分析不同时空下的电力数据,提升异常检测的适应性和准确性。

为了提升数据的准确性和完整性,需要根据采集数据的实际情况,选择合适的优化方式对电力数据进行处理<sup>[5-6]</sup>,具体优化方式如下:

#### 1) 重复数据处理

若采集的数据中存在大量重复数据,这些重复数据不仅会占用存储空间,还可能影响后续分析的准确性。因此,需将重复数据进行删除,以确保数据的唯一性。

#### 2) 缺失数据处理

当存在部分数据不完整的情况时,可以选择相应的方式将数据信息补全。例如,可以采用均值插补法、回归预测法等方法来补充缺失值。均值插补法<sup>[7]</sup>是指用该属性的均值来填充缺失值;回归预测法<sup>[8]</sup>是通过建立回归模型,根据其他相关属性的值来预测缺失值。回归模型的具体形式如式(1)所示。

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (1)$$

式中,  $y$  表示缺失值;  $x_1, x_2, \dots, x_n$  表示相关属性;  $\beta_0, \beta_1,$

$\beta_2, \dots, \beta_n$  表示回归系数;  $\varepsilon$  表示误差项。

通过最小二乘法估计回归系数,从而预测缺失值。

#### 3) 噪声数据处理

对于存在干扰因素(即噪声数据)的情况,采用平滑处理的方式将干扰因素去除。若采集的数据维度不一,则对其进行标准化处理,为后续的检测模型构建减轻计算压力<sup>[9]</sup>。具有的优化过程如式(2)所示。

$$\begin{cases} X = \text{sqrt}\left(\frac{1}{N} \times \sum (x - y)^2\right) \\ X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \end{cases} \quad (2)$$

式中,  $X$  表示对电力数据进行平滑处理后的计算结果<sup>[10]</sup>,  $N$  表示电力数据的数量,  $x$  表示原始的电力数据,  $y$  表示电力数据的均值,  $X'$  表示电力数据标准化处理后的结果,  $X_{\min}$  表示平滑处理后,电力数据的最小值,  $X_{\max}$  表示平滑处理后,电力数据的最大值。

通过上述公式,完成对电力数据的优化处理,提高数据的精度和质量,为后续的方法设计奠定基础。完成数据优化后,为了更好地提取数据特征,减轻后续计算压力,需要对优化后的数据  $X'$  融合处理<sup>[11-12]</sup>。其具体融合过程如式(3)所示。

$$\begin{cases} G(X') = \frac{T_B}{(\rho N)^2} \prod K(t)^2 - \eta' \frac{\partial J}{\partial w} \left( \pi T_B \left( f - \frac{l}{NT_C} \right) \right) \\ K(t) = T_C^2 N \sin^2(\pi f T_C) + R \left( \frac{l'}{w \cdot l} \right) \\ T_C = \frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} x_n \exp(-j2\pi f n T_B) \end{cases} \quad (3)$$

式中,  $G(X')$  表示电力数据的融合结果,  $T_B$  表示电力数据的概率密度函数,  $\rho$  表示电力数据的融合参数,  $K(t)$  表示电力数据在采集过程中的阈值,  $\eta'$  表示电力数据的分布参数,  $J$  表示电力数据的预测参数,  $w$  表示电力数据的分布密度,  $f$  表示电力数据的随机特征参数,  $l$  表示密度特征量,  $T_C$  表示电力数据的频率特征,  $R$  表示电力数据的自相关函数,  $l', l$  分别表示在不同时刻下电力数据的分布概率值,  $w$  表示电力数据的自相关参数,  $x_n$  表示电力数据的能量函数,  $j$  表示随机常数,  $n$  表示电力数据的特征数量。

通过上述数据融合技术<sup>[13]</sup>,能够整合来自不同维度和来源的电力数据,提升数据的质量和精度。融合后的数据再进行特征提取,提取出的数据特征更具有代表性,从而提高电力数据异常检测模型的精度<sup>[14-15]</sup>。至此,电力数据的优化与融合处理的设计完成。

### 1.2 数据异常检测

电力系统周围的电磁干扰(如无线电发射塔、大型电机)会导致数据出现瞬间波动或噪声,易与真实异常混淆。电力趋势动态波动特性通过分析数据的变化趋势,能够区分电磁干扰引起的短期波动和真实故障导致的动态波动。结合多维度数据优化融合结果,构建考虑电网动态

行为的异常检测模型,提取波动性、趋势性和变动性等特征,并通过误差计算验证结果有效性,实现对电力数据异常的精准识别<sup>[16]</sup>。

构建的电力数据异常检测模型如图1所示。

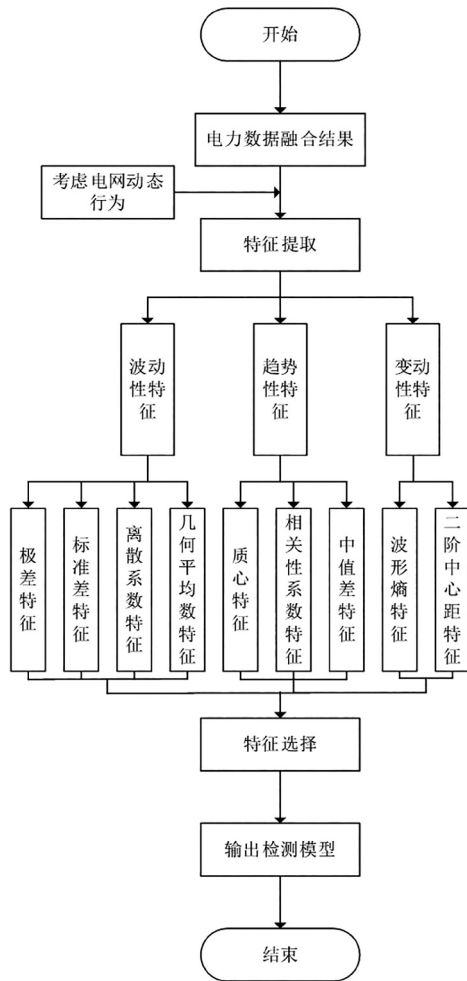


图1 考虑电网动态行为的电力数据异常检测模型

Fig. 1 Anomaly detection model for power data considering dynamic behavior of the power grid

在上述构建的检测模型中,输入电力数据的融合结果作为基础,在考虑电网动态行为的前提下,进行特征提取<sup>[17-18]</sup>。在本文的设计中,提取的电力数据异常特征分别为波动性特征、趋势性特征和变动性特征3种,对这3种特征进行计算,根据计算结果,进行特征选择,筛选出具有代表性和区分性的特征,从而完成对电力数据异常检测模型的构建<sup>[19]</sup>。

在上述过程中,在考虑电网动态行为的前提下,提取的波动性特征如式(4)所示。

$$\begin{cases} \lambda_1 = \max x - \min x \\ \lambda_2 = \frac{1}{E} \sum_{i=1}^E [x - \bar{x}]^2 \\ \lambda_3 = \frac{\lambda_2}{2} \\ \lambda_4 = E \sqrt{\prod_{i=1}^E x} \end{cases} \quad (4)$$

式中,  $\lambda_1, \lambda_2, \lambda_3, \lambda_4$  分别表示波动性特征的4个子特征,  $E$  表

示电力数据采集时间序列的长度,  $\bar{x}$  表示电力数据的平均值。

趋势性特征通过动态时间规整 (dynamic time warping, DTW) 算法计算<sup>[20]</sup>,能够准确捕捉数据在不同时间段内的波动模式和变化趋势,尤其是对于短期剧烈波动的情况,能够进行精准识别。提取的趋势性特征如式(5)所示。

$$\begin{cases} \alpha_1 = \frac{1}{E} \sum_{i=1}^E p_i x \\ \alpha_2 = \frac{\sum_{i=1}^{E/2} (x - \bar{x}) \sum_{i=(E/2)+1}^{E/2} (x - \bar{x})}{\sqrt{\sum_{i=1}^{E/2} (x - \bar{x})^2 \sum_{i=(E/2)+1}^{E/2} (x - \bar{x})^2}} \\ \alpha_3 = x_{i1} - x_{i2} \end{cases} \quad (5)$$

式中,  $\alpha_1, \alpha_2, \alpha_3$  分别表示趋势性特征的3个子特征,  $x_{i1}, x_{i2}$  分别表示不同采样点的中值。

变动性特征通过熵值分析方法进行量化评估,反映数据的复杂性和不确定性,进一步丰富了异常特征的表达,提取的变动性特征如式(6)所示。

$$\begin{cases} \beta_1 = -\frac{1}{E} \sum_{i=1}^E p_i \log p_i \\ \beta_2 = \sum_{i=1}^E (t - \bar{t})^2 p_i \end{cases} \quad (6)$$

式中,  $\beta_1, \beta_2$  分别表示变动性特征的子特征,  $t, \bar{t}$  表示电力数据在不同时间序列下的质心分布情况。

通过式(4)~(6),完成对电力数据异常特征的提取,将提取的特征作为基础,进行异常特征的筛选,根据特征筛选结果,构建对应的电力数据异常检测模型<sup>[21-22]</sup>。其特征选择与电力数据异常检测模型的具体构建结果如式(7)所示。

$$\begin{cases} m(\lambda, \alpha, \beta) = \frac{p(\lambda, \alpha, \beta) \lg p(\lambda, \alpha, \beta)}{p(\lambda) p(\alpha) p(\beta)} \\ F = \gamma \times \frac{\phi(m(\lambda, \alpha, \beta))}{c} \end{cases} \quad (7)$$

式中,  $m(\lambda, \alpha, \beta)$  表示特征选择结果,  $p(\cdot)$  表示特征出现的概率,  $F$  表示构建的电力数据异常检测模型,  $\gamma$  表示检测参数,  $\phi(\cdot)$  表示电力数据异常和检测函数,  $c$  表示特征参数。

通过上述公式,完成对电力数据异常检测模型的设计。利用该数据异常检测模型,为后续实现对电力数据的异常检测奠定基础。至此,完成考虑电网动态行为的电力数据异常检测模型的设计。

在完成电力数据的优化融合以及构建了考虑电网动态行为的电力数据异常检测模型的基础上,提出了一种电力数据异常精准检测方法,该方法能够更加准确、高效地识别电力数据中的异常情况。其具体检测过程如图2所示。

在上述检测过程中,利用上述构建的检测模型,对输入的电力数据进行检测,判断当前电力数据是否存在异常,并对判断结果进行误差计算,若检测结果中存在误差,且计算的误差符合设定的阈值,则直接输出当前检测结果,若计算的误差不符合设定的阈值,则需要利用检测模型重新进行检测<sup>[23-24]</sup>。在上述过程中,误差计算的具体过程如式(8)所示。通过式(8),完成对电力数据异常的检测。

$$P = 1 - [(1 - P_a)^\mu \times (1 - P_b)^\nu] \quad (8)$$

式中,  $P$  表示计算的误差,  $P_a$  表示模型检测结果,  $P_b$  表示实际检测结果,  $\mu$ 、 $\nu$  分别表示误差测算参数。

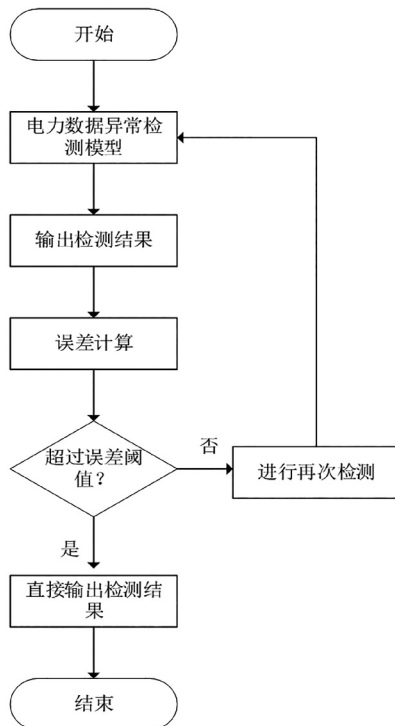


图2 电力数据异常检测过程

Fig. 2 Shows the process of power data anomaly detection

根据上述检测结果,对电力数据异常进行分析。根据对电力数据异常的检测结果,对电力系统的运行情况进行分析,并寻找出现电力数据异常的原因,同时,针对电力数据异常的情况,制定相应的解决措施,保证电力系统的稳定性<sup>[25]</sup>。

至此,基于多维度数据优化融合的电力数据异常精准检测方法的设计完成,为电力系统的安全稳定运行提供了有力的技术支持。

## 2 实验测试

为提高本次实验结果的可靠性,设置对照实验。其中,本文设计的基于多维度数据优化融合的电力数据异常精准检测方法为方法1,基于数据分析和孤立森林算法的电力数据异常检测方法为方法2,基于神经网络和数据特性的电力数据异常检测方法为方法3。为对比上述3种检测方法在实际应用中的性能,设计的实验具体如下。

### 2.1 实验准备

为验证本文设计的基于多维度数据优化融合的电力数据异常精准检测方法在实际应用中的性能,进行相关实验测试。实验中,以某电力系统为例,利用相关设备进行相关电力数据的采集,将采集的电压数据作为本次实验数据。在数据采集过程中,设定采样频率为1000 Hz,以确保能够捕捉到电压的细微变化。采集时间跨度设定为24 h,共获得24000组电压数据样本,其具体采集结果如图3所示。

在采集的实验电压数据中,随着采集时间的增长,电压的波动幅度先逐渐变大,再缓慢变小,然后波动起伏再次增

大。这说明电压在采集过程中外界因素对电压的干扰程度较大,或者采集的实验数据存在异常。因此,在将上述实验电压进行应用前,需要先将数据进行优化处理,根据优化结果,对其进行判断,保证数据的精度。




图3 实验数据

Fig. 3 Experimental data

完成数据的优化后,为保证数据提取结果的准确性,对其进行特征选择,筛选出具有代表性的数据特征。将上述提取的电力数据异常特征按照顺序进行编号处理,再对其进行特征选择。特征分别为峰值、平均值、方根平均值、频率、相位、谐波含量、闪变、波形畸变。特征选择结果如图4所示。特征编号8即波形畸变的特征权值远高于其他特征,因此,相对于其他特征,该特征更具有代表性。因此,在本次实验中,将电压的波形畸变作为电力数据的异常,进行以下实验测试。




图4 特征选择结果

Fig. 4 Feature selection results

### 2.2 实验结果讨论

为对比所提方法(方法1)、文献[1]方法(方法2)以及文献[2]方法(方法3)3种方法的性能,以方法的查全率为评价指标,对比3种方法的性能。实验中,利用上述方法对数据集进行检测,根据检测结果,对比不同方法的查全率。其具体统计结果如图5所示。

在上述实验结果中,方法1的查全率高于其他两种方法。因此,方法1的实际应用效果较好。

为进一步对比上述3种方法在实际应用中的效果,以方法的误检率为评价指标,进行实验测试。实验中,利用上述3种方法对多个实验数据集进行检测,每个实验数据集中存在3200个数据样本,对比不同方法的检测结果。其具体检测结果如表1所示。




图5 3种方法的检测结果

Fig. 5 Detection results of the three methods

表1 3种方法的检测结果

Tab. 1 Detection results of the three methods

实验数据集编号	误检率/%		
	方法1	方法2	方法3
#S01	2.8	9.8	12.3
#S02	2.7	9.6	12.7
#S03	1.2	8.8	13.1
#S04	1.3	10.9	14.6
#S05	1.9	10.2	14.9
#S06	2.9	9.7	14.8
#S07	1.3	10.1	16.9
#S08	1.1	8.9	16.8
#S09	1.6	9.6	16.2
#S10	1.3	10.8	16.4

如表1所示,从上述实验结果中可以看出,针对不同的数据集,方法1的误检率保持在3%以下,方法2的误检率在8.8%以下,方法3的误检率在12.3%以下。可见,方法1的误检率最低。因此,本文设计的检测方法实际应用效果较好。

综上所述,本文设计的基于多维度数据优化融合的电力数据异常精准检测方法在实际应用中,查全率较高,误检率较低,检测效果较好。

### 3 结论

综上所述,电力系统运行的复杂性和动态性使原始数据存在诸多问题,影响数据异常模式的准确识别。本文提出的基于多维度数据优化融合的电力数据异常精准检测方法,通过对原始数据进行优化处理、采用数据融合技术整合数据、构建考虑电网动态行为的异常检测模型并提取筛选关键异常特征,最终实现精准检测,且通过误差计算验证结果准确性。实验测试表明,该方法查全率高、误检率低,能全面精准识别异常并准确分辨正常与异常数据,在实际应用中效果良好,为电力数据异常检测提供了有力支持,对提高电力数据异常检测的效率和精度具有重要价值。

### 参考文献

[1]李清. 基于改进 PSO-PFCM 聚类算法的电力大数据异常检测方法[J]. 电力系统保护与控制, 2021, 49(18):161-166.

[2]文沛,王海东,范林源,等. 基于改进决策树算法的变电站监控数据异常检测研究[J]. 自动化应用, 2023, 64(19):152-154.

[3]孙滢涛,张锋明,陈水标,等. 基于多域特征提取的电力数据异常检测方法[J]. 电力系统及其自动化学报, 2022, 34(6):105-113.

[4]李慧芳,黄姜杭,徐光浩,等. 基于多维度特征融合的云工作任务执行时间预测方法[J]. 自动化学报, 2023, 49(1):67-78.

[5]宋世军,樊敏. 基于随机森林算法的大数据异常检测模型设计[J]. 吉林大学学报(工学版), 2023, 53(9):2659-2665.

[6]李杉,闵帆. 基于 GAT-GRU 的增量式 KPI 时序数据异常检测模型[J]. 昆明理工大学学报(自然科学版), 2023, 48(4):55-63.

[7]WANG X, CHEN H, ZHANG J, et al. Generative adversarial learning for missing data imputation[J]. Neural Computing and Applications, 2025, 37(3):1403-1416.

[8]黄州,薛瑞. 融合 PSO 与 SVR 算法的软土抗剪强度参数分析[J]. 自动化技术与应用, 2025, 44(11):32-36.

[9]何黎,陈磊,纪莎莎,等. 基于 K-shape 聚类的连续液位监测数据异常检测方法[J]. 中国给水排水, 2023, 39(11):56-61.

[10]孙园林. 基于空间变换与平滑处理的 PACS 医学影像数据存储系统研究[J]. 自动化技术与应用, 2024, 43(1):95-98,152.

[11]李江涛,康凯,丁键,等. 数据简约及配电网分区的无功补偿配置优化方法[J]. 自动化技术与应用, 2025, 44(10):47-51,133.

[12]GLIOZZO J, SOTO-GOMEZ M, GUARINO V, et al. Intrinsic-dimension analysis for guiding dimensionality reduction and data fusion in multi-omics data processing[J]. Artificial Intelligence In Medicine, 2025(160):103049.

[13]李春生,田梦晴,张可佳. 基于 Bi-LSTM 网络的管道异常数据检测方法[J]. 计算机技术与发展, 2023, 33(6):215-220.

[14]张仁斌,左艺聪,周泽林,等. 基于多模态生成对抗网络的多元时序数据异常检测[J]. 计算机科学, 2023, 50(5):355-362.

[15]LI J J, LÜ Yifan, ZHOU Z, et al. Identification and correction of abnormal, incomplete power load data in electricity spot market databases[J]. Energies, 2025(18):176.

[16]ATTARHA S, FRSTER A. Assuresense: a framework for enabling sensor fault detection in low-power iot edge devices[J]. IEEE Sensors Journal, 2024, 24(20):33791-33805.

[17]加雪莲,吴睿辉,刘静. 基于变分自编码器和 LSTM 网络的会计数据异常检测框架[J]. 淮阴师范学院学报(自然科学版), 2023, 22(2):118-124.

[18]EXTERKOETTER R, DUTRA G R, FIGUEIREDO L P D, et al. Feature extraction in time-lapse seismic using deep learning for data assimilation[J]. SPE Journal, 2024, 29(4):2014-2025.

[19]LUO X, JIANG R, YANG B, et al. Air quality visualization analysis based on multivariate time series data feature extraction[J]. Journal of Visualization, 2024, 27(4):567-584.

[20]LI T, CHEN L, SUN H, et al. Exploring diversity and time-aware recommendations: an LSTM-DNN model with novel bidirectional dynamic time warping algorithm[J]. Soft Computing, 2025, 29(4):2003-2013.

[21]欧阳舒歆,王铭钧,荣垂田,等. 基于改进 LSTM 的多维 QAR 数据异常检测[J]. 广西师范大学学报(自然科学版), 2023, 41(5):49-60.

[22]宁子俊,陈涛,徐峰,等. 复杂工况下综合传动装置状态监测数据异常检测方法[J]. 机电工程, 2023, 40(9):1387-1394.

[23]刘杰. 基于孤立森林算法的巡检机器人通信异常数据自动检测方法[J]. 信息与电脑(理论版), 2023, 35(3):86-88.

[24]李松轩,丁勇,李登华. 基于影响因子分解法的大坝监测数据异常检测算法[J]. 人民长江, 2023, 54(4):234-240.

[25]宋文燊,周海波,吴宗培,等. 图记忆诱导的大气排污时序数据异常检测算法[J]. 华东理工大学学报(自然科学版), 2023, 49(3):341-350.