

DOI:10.20033/j.1003-7241.(2026)02-0138-05

基于流形学习的电网客服中心实时数据自动监测方法

侯咎宇

(国网辽宁省电力有限公司, 辽宁 沈阳 110006)

摘要:针对电网客服中心的网络安全问题,研究搭建了实时数据自动监测模型。首先,引入类内距离最小与类间距离最大的思想来对局部保持投影算法进行改进,用于检测异常数据。然后利用模糊规则和层次分析法来对电网实时数据自动监测进行优化。结果表明,改进局部保持投影算法的运行时间与传统局部保持投影算法相差不大。改进局部保持投影算法的检测准确率更高,为99.43%。基于层次分析的实时数据监测算法的监测准确率始终最高,在数据样本集为500时,准确率为99.84%,召回率为99.62%。实验结果证明了所提实时数据自动监测模型的异常数据检测和实时数据监测性能较好,有助于提高电网的安全性和稳定性。

关键词:流形学习;数据自动监测;电网客服;层次分析法;局部保持投影

中图分类号: TP391

文献标志码: A

文章编号: 1003-7241(2026)02-0138-05

Real time data automatic monitoring method for power grid customer service center based on manifold learning

HOU Zanyu

(State Grid Liaoning Electric Power Supply Co., Ltd., Shenyang 110006, Liaoning, China)

Abstract: A real-time data automatic monitoring model is developed to address the network security issues of the power grid customer service center. Firstly, the idea of minimizing intra class distance and maximizing inter class distance is introduced to improve the local preserving projection algorithm for detecting abnormal data. Then, fuzzy rules and Analytic Hierarchy Process are used to optimize the real-time data automatic monitoring of the power grid. The results indicate that the running time of the improved local preserving projection algorithm is not significantly different from that of the traditional local preserving projection algorithm. The improved local preserving projection algorithm has a higher detection accuracy of 99.43%. The real-time data monitoring algorithm based on Analytic Hierarchy Process always has the highest monitoring accuracy, with an accuracy of 99.84% and a recall rate of 99.62% when the data sample set is 500. The experimental results demonstrate the abnormal data detection and real-time data monitoring performance of the proposed real-time data automatic monitoring model are good, which helps to improve the safety and stability of the power grid.

Keywords: manifold learning; automatic data monitoring; power grid customer service; analytic hierarchy process; locally preserving projection

网络安全是信息时代的重要议题,关乎着国家安全、社会稳定、经济发展等多个方面,确需采取有效的技术手段和管理措施来保障网络安全。数据监测在维护网络安全中起到了不可小觑的作用,可以帮助组织和个人了解数据的当前状态、趋势和异常情况,以便及时做出相应的决策和行动^[1]。许多学者对数据监测进行了大量的研究。刘天松等针对铝电解过程的数据监测算法实时性和稳定性较差的问题,提出了基于自适应生长层次神经元的奇异性监测模型,结果表明所提模型具有较好的奇异性监测能力^[2]。陈晖等针对灾害性气象观测数据的数据监测问题,提出了基于多源卫星遥感的数据监测系统,实验结果证明了所提系统的湿度、气压和风速监测准确性^[3]。Xu Z 等针对配电网的拓扑结构监测问题,提出了一种基于变压器终端

单元的拓扑自动识别方法,在测试系统中进行的案例研究证明了所提出方法的有效性和效率^[4]。Bogedale L 等针对工艺监控和优化系统的工艺数据由标量数据和时序序列组成的问题,提出了一种仅使用时间序列数据对注塑过程建模的新方法。结果表明,这些时间序列的采样率对可以从这些数据中得出的信息有很大影响^[5]。尽管国内外的许多学者对数据监测进行了大量的研究,但随着互联网技术的飞速发展和网络攻击手段的复杂化,网络数据安全面临着更高的准确性和实时性挑战,传统的数据监测技术的实时性较差。为此,研究搭建了基于流形学习的实时数据自动监测模型。研究旨在对电网客服中心的数据进行有效的监测,以提高电网服务的安全性。研究的创新性在于利用模糊规则特征量挖掘和层次分析法来对数据进行自动监测,

收稿日期:2024-05-08;录用日期:2024-05-21

基金项目:辽宁省教育厅面上项目(LJKZ0138)

作者简介:侯咎宇(1986—),男,硕士,高级工程师,研究方向:电力营销。

引用本文:侯咎宇. 基于流形学习的电网客服中心实时数据自动监测方法[J]. 自动化技术与应用, 2026,45(2):138-142. (HOU Zanyu. Real time data automatic monitoring method for power grid customer service center based on manifold learning[J]. Techniques of Automation and Applications, 2026, 45(2):138-142.)

以帮助客服中心更好地处理数据和做出决策。

1 模型构建

1.1 异常数据检测算法

在数据挖掘中,异常检测对不匹配预期模式或数据集中其他的项目、事件或观测值的识别,即在一个数据集中寻找与预期不符合的数据^[6]。流形学习是一类借鉴了拓扑流形概念的降维方法,就是从高维采样数据中恢复低维流形结构,并求出相应的嵌入映射,以实现维数约简或者数据可视化^[7]。由于异常数据检测是一种实时系统,因此需要获得显式的降维投影,而传统的流形学习无法得出显式的降维投影,因此研究采用局部保持投影(locally preserving projection, LPP)算法。LPP算法是一种流形学习线性降维方法,其同时具备流形学习方法和线性降维方法的优点,能够有效挖掘高维数据的局部流形结构,使得其中的相似样本在低维空间中更加靠近,具有较高的泛化能力,能够有效地反映高维数据的局部结构^[8-9]。LPP算法利用K近邻算法来确定高位数据的局部近邻结构并推广到全局,假设原始高维数据集为 $X = \{x_1, x_2, \dots, x_n\}$,经特征提取后的低维数据集为 $Y = \{y_1, y_2, \dots, y_n\}$,投影中的目标函数计算公式为

$$\min \sum_{i,j} \|y_i - y_j\|^2 S_{ij} = \min \sum_{i,j} \|A^T x_i - A^T x_j\|^2 S_{ij} \quad (1)$$

式中, S_{ij} 表示第*i*个数据点与第*j*个数据点之间的相似度, A 表示投影降维矩阵。但LPP算法属于无监督降维算法,忽视了样本的类别信息,因此投影后有可能发生混淆^[12]。因此,研究将LPP算法的目标函数计算公式为

$$\min \sum_{i,j} \|y_i - y_j\|^2 S_{ij} = S_{ij}^{in} + S_{ij}^{out} \quad (2)$$

式中, S_{ij}^{in} 和 S_{ij}^{out} 分别表示局部近邻图的类内图和类间图部分。为尽可能使同类数据在投影后较为聚集,研究引入了类内距离最小与类间距离最大的思想,目标函数计算公式为

$$\begin{cases} \min L^{in} \\ \min L^{out} \end{cases} \quad (3)$$

式中, L^{in} 和 L^{out} 分别表示类内距离和类间距离,其计算公式为

$$\begin{cases} L^{in} = \sum_{i,j=1}^N (y_i - y_j)^2 m_{ij}^{in} \\ L^{out} = \sum_{i,j=1}^N (y_i - y_j)^2 m_{ij}^{out} \end{cases} \quad (4)$$

式中, m_{ij}^{in} 表示类内权重, m_{ij}^{out} 表示类间权重。因此可将目标函数转化为公式(5)。

$$\begin{cases} \min L^{in} = \min A^T X E X^T A \\ \min L^{out} = \max A^T X Q^{out} X^T A \end{cases} \quad (5)$$

式中, E 表示单位矩阵, Q^{out} 表示类间散度矩阵。最后,研究利用线性加权法来解决多目标决策问题,根据各目标的重要性赋予相应的权系数,对式(5)中的目标函数进行线性加权求和,转化为单目标函数,将加权系数设为 α 。具体而言,改进LPP算法的优化目标为

$$\begin{cases} \min A^T X L X^T A \\ \min A^T X H X^T A \end{cases} \quad (6)$$

s. t. $A^T X D X^T A = 1$

式中, L 表示拉普拉斯矩阵, H 表示类间散度矩阵, D 表示对角矩阵,约束条件s. t. $A^T X D X^T A = 1$ 是为了确保优化问题有解。随后,利用线性加权法将多目标优化转化为单目标优化问题,即

$$\begin{cases} \min A^T X (L - \eta H) X^T A \\ \text{s. t. } A^T X D X^T A = 1 \end{cases} \quad (7)$$

式中, η 表示权重参数。最后,使用拉格朗日乘子法来求解约束条件下优化问题,将单目标优化问题转化为无约束问题,从而求解最优解的计算公式为

$$\frac{\partial [A^T X (L - \eta H) X^T A - \lambda (A^T X D X^T A - I)]}{\partial A} = 0 \quad (8)$$

式中, λ 表示 $X(L - \eta H)X^T A$ 和 XDX^T 的广义特征值,由式(8)可得到 $X(L - \eta H)X^T A = \lambda XDX^T A$ 。研究所提网络数据异常检测算法如图1所示。

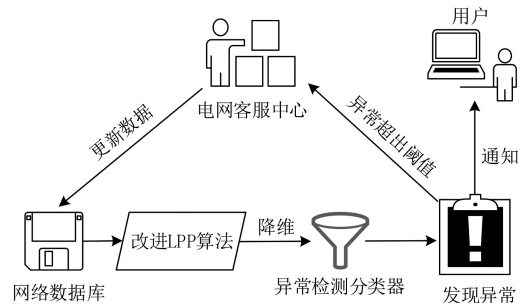


图1 网络数据异常检测算法

Fig. 1 Network data anomaly detection algorithm

网络数据流是一组有序、有起点和终点的字节数据序列,涉及数据的传输过程,包括输入流和输出流。数据流强调以非常高的速度到达的输入数据,因此数据监测也需要强调实时性。而时间序列性则是由于在网络数据流中,一个时间区间内顺序到达的报文序列构成了一个流,因此异常数据检测过程需要同时注重实时性以及根据需要更新训练样本库^[13-14]。

1.2 实时数据监测算法

实时监控是一种通过实时收集、分析和展示数据的方式,以及时获取某种活动、事件或过程的最新状态和信息,可以通过各种传感器、数据采集设备和数据处理软件等技术手段来实现^[15-16]。为实现对电网客服中心实时数据的自动监测,研究在进行了异常数据检测后,进一步对网络数据进行自动监测。研究对电网的实时网络数据情况进行了统计分析,数据的分布情况如图2所示。

假设实时数据监测中产生的候选集为 $A = \{a_1, a_2, \dots, a_n\}$,在网络数据实时监测聚类空间中,得到的主特征量 $X_p(u)$ 的计算公式为

$$X_p(u) = s_c(t) e^{j2\pi f_0 t} = \frac{1}{\sqrt{B}} \text{rect}\left(\frac{t}{B}\right) e^{j2\pi(f_0 t + \kappa t^2)/2} \quad (9)$$

式中, $e^{j2\pi f_0 t}$ 表示特征属性, t 表示时间索引, B 表示时间延

迟, f_0 表示特征主频率, $e^{j2\pi f_0 t}$ 表示结构相似度量。得到的有限数据集为 $X = \{x_1, x_2, \dots, x_n\} \subset R^s$ 。得到实时信息提取其他关联参数的关系为

$$h(t) = \sum_i a_i(t) e^{j\theta_i(t)} \delta(t - iT_s) \quad (10)$$

式中, T_s 表示采样间隔。对 K 个子空间进行搜索和模糊预测控制, 得到的子序列输出为

$$X = [X_\alpha(0), X_\alpha(1), \dots, X_\alpha(K-1)]^T \quad (11)$$

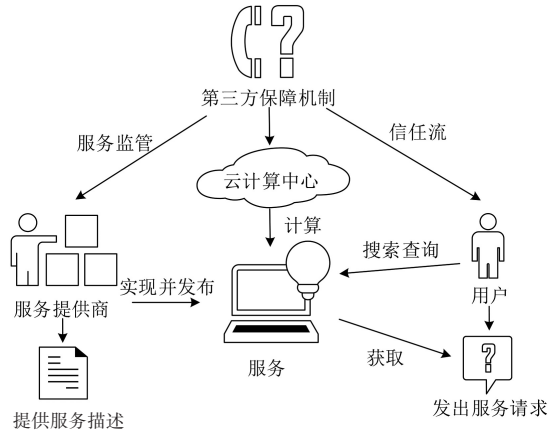


图 2 电网的实时网络数据

Fig. 2 Real-time network data of the power grid

研究利用模糊规则和层次分析法来对电网实时数据自动监测进行优化, 以提高工作效率和客户服务质量。模糊规则特征量挖掘是一种基于模糊集和模糊逻辑的数据挖掘方法, 用来发现数据中的模糊规则和特征量。通过模糊规则特征量挖掘, 可以发现数据中模糊的规律和特征, 帮助分析数据和做出决策^[11]。层次分析法是一种定性和定量相结合的、系统化、层次化的多目标决策方法^[12]。这种方法通过对问题进行层次划分, 对不同层次的因素进行比较和评价, 最终得出最优的决策结果, 在处理复杂的决策问题上具有实用性和有效性。假设干扰向量 n_i 的种类为 r_j , 则存在最大独立集 $P(n_i) = \{p_k \mid prkj = 1, k = 1, 2, \dots, m\}$, 提取的数据的模糊隶属函数为

$$\begin{cases} P_F = \sum_{j=k}^N \sum_{\sum_{i=1}^N} \prod (P_{fi})^{u_i} (1 - P_{fi})^{1-u_i} \\ P_D = \sum_{j=k}^N \sum_{\sum_{i=1}^N} \prod (P_{di})^{u_i} (1 - P_{di})^{1-u_i} \end{cases} \quad (12)$$

式中, P_{fi} 表示数据的融合的聚类中心, P_{di} 表示数据的采样频率, N 表示样本数量。在各个子空间中对电网客服中心数据进行匹配检测, 得到的统计特征量方差 σ^2 的计算公式为

$$\begin{cases} \sigma^2 = \frac{1}{N} \sum_{i=1}^N |x_i - \bar{x}|^2 \\ \bar{x} = \frac{1}{N} \sum_{i=1}^N |x_i| \end{cases} \quad (13)$$

式中, \bar{x} 表示特征量分量的均值。层次性聚类算法是一种基于数据之间相似度的聚类算法, 将数据集中的每个数据点都视为一个单独的聚类, 然后在每一次迭代中将最接近的两个聚类合并, 直到满足某个停止条件^[13]。最后进行

量化特征分解和信息融合, 得到层次分析挖掘结果为

$$x'_i = \frac{x_i}{\|x_i\|} = \left(\frac{x_{i1}}{\|x_i\|}, \frac{x_{i2}}{\|x_i\|}, \dots, \frac{x_{iN}}{\|x_i\|} \right) \quad (14)$$

式中, x_{iN} 表示监测数据的终点值。自回归分析是一种统计和时间序列模型, 主要用于根据数据点的先前值进行分析和预测。研究进一步采用自回归分析来对电网数据进行预测, 假设当前时间变量的值与其过去的值线性相关, 收敛约束函数 F_j 为

$$F_j = \sum_{k=1}^n X_{kj}, Q_j = \sum_{k=1}^n (X_{kj})^2 \quad (15)$$

式中, F_j 表示第 j 个特征的样本和, Q_j 表示第 j 个特征的样本平方和, X_{kj} 表示数据矩阵中第 k 个样本的第 j 个特征值。客服中心的模糊聚敛控制函数为

$$\begin{aligned} M_v = w_1 \sum_{i=1}^{mn} (H_i - S_i) + M_{hu2} \sum_{i=1}^{mn} (S_i - V_i) + \\ w_3 \sum_{i=1}^{mn} (V_i - H_i) \end{aligned} \quad (16)$$

式中, w 表示权重, M_h 表示数据预测的负载, V_i 表示聚类属性特征。客服中心实时数据流监测的主成分特征量即为主频特征量, 如式(9)所示。实时监测数据属性集的向量量化特征分解函数计算公式为

$$f(k) = \begin{cases} f(k-1) - \frac{1}{n}, 1 \leq k \leq n \\ 1, k = n \end{cases} \quad (17)$$

式中, k 表示特征融合中心。研究遵循先进先出的原则来组织数据, 并将其视为一个组块来对特定时间区域内的数据进行统一处理或分析, 以更清晰地观察数据的变化动态, 得到预测空间向量的信息融合集合为

$$P = \{p_1, p_2, \dots, p_m\}, m \in N \quad (18)$$

式中, m 表示自动监测系统的嵌入维。在统计回归分析模型中, 训练样本集为 $X = [X_1, X_2, \dots, X_k, \dots, X_N]^T$, 训练样本为 $X_k = [x_{k1}, x_{k2}, \dots, x_{km}, \dots, x_{kM}]$ 。

2 模型效果分析

为验证研究所提改进 LPP 算法的效率, 研究采用 Moore 数据集进行实验, 来衡量算法的运行实际情况。研究将加权系数 α 设置为 0.6, 将权重参数 β 设置为 1, 将数据规模设置为 6 400。并与主成分分析 (principal component analysis, PCA) 算法、局域密度近似 (local-density approximation, LDA) 算法、局部线性嵌入 (locally linear embedding, LLE) 算法和 LPP 算法进行对比。5 种算法的运行时间对比结果如图 3 所示。从图 3 中可以看出, 随着数据规模的增大, 5 种算法的运行时间均逐渐增大。改进 LPP 算法的运行时间长于 PCA 算法、LDA 算法和 LLE 算法, 但与传统 LPP 算法相差不大, 因此在可接受范围内。

为验证改进 LPP 算法的异常数据检测性能, 研究将其召回率和准确率与传统 LPP 算法和 PCA 算法进行对比, 对比结果如图 4 所示。从图 4(a) 中可以看出, 相较于 PCA 算法和传统 LPP 算法, 研究所提改进 LPP 算法的检

测准确率更高,最高可达到 99.43%。从图 4(b)中可以看出,在三种算法中,研究所提改进 LPP 算法的检测召回率仍然最高,可达到 99.84%。其次是传统 LPP 算法。结果表明,研究所提改进 LPP 算法具有较好的检测性能,在准确率和召回率方面均取得了较好的表现,能够有效提高传统 LPP 算法的检测性能,具有一定的可行性和有效性。


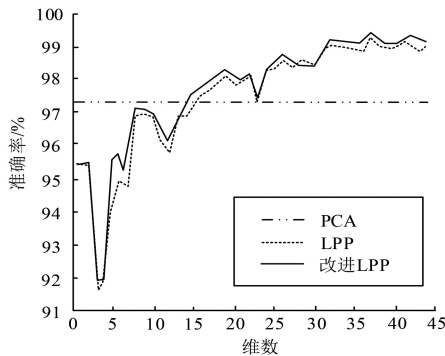
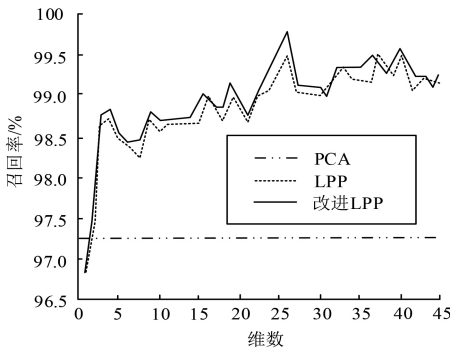


图 3 五种算法的运行时间对比结果

Fig. 3 Comparison of running times for five algorithms



(a) 准确率对比



(b) 召回率对比

图 4 三种算法的准确率和召回率对比结果

Fig. 4 Comparison results of the accuracy and recall rates of the three algorithms

为验证研究所提基于层次分析的实时数据监测算法的性能,研究采用 C++和 Matlab 7 混合编程进行大数据层次聚类分析处理,将最大迭代次数设置为 2 000,将单组数据时间序列采样的长度设置为 800,将采样频率设置为 20 kHz,得到的电网客服中心实时数据监测输出如图 5 所示。从图 5 中可以看出,研究所提基于层次分析的实时数据监测算法能有效实现对客服中心实时数据流监测,具有一定的可行性和有效性。

为进一步验证基于层次分析的实时数据监测算法的性能,研究以准确率和召回率为评价指标,将所提算法与基于双

线性配对的跨域联合认证协议(cross domain joint authentication protocol,CDJAP)和不确定分数阶混沌系统鲁棒性的模糊状态反馈控制器(feedback controller,FC)进行对比,结果如图 6 所示。从图 6(a)中可以看出,随着数据样本集的增加,三种算法的监测准确率均逐渐增加。其中,基于层次分析的实时数据监测算法的监测准确率始终最高,在数据样本集为 500 时,准确率为 99.84%。CDJAP 算法的监测准确率最低,在数据样本集为 500 时准确率为 92.82%,比研究所提算法低 7.02%。从图 6(b)中可以看出,相较于另外两种算法,研究所提算法的召回率始终最高,在数据样本集为 500 时,召回率为 99.62%。其次是 FC 算法,在数据样本集为 500 时,召回率为 94.74%。结果表明,基于层次分析的实时数据监测算法具有较好的数据监测性能,准确率和召回率较高,具有一定的可行性和优越性。



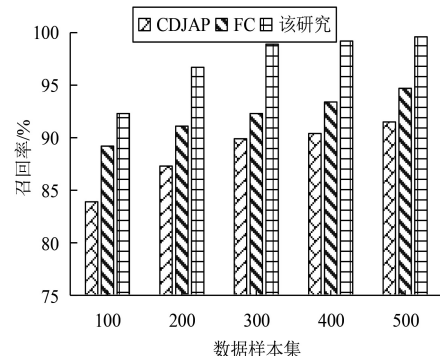


图 5 电网客服中心实时数据监测输出

Fig. 5 Real-time data monitoring output of the power grid customer service center



(a) 准确率对比



(b) 召回率对比

图 6 准确率和召回率对比结果

Fig. 6 Comparison results of accuracy rate and recall rate

3 结论

随着互联网技术的快速发展,网络攻击技术也得到了发展,因此实时数据监测越来越受到重视。针对电网客服中心的实时数据监测问题,研究搭建了基于流形学习的实时数据自动监测模型。结果表明,随着数据规模的增大,5种算法的运行时间均逐渐增大。改进LPP算法的运行时间长于PCA算法、LDA算法和LLE算法,但与传统LPP算法相差不大,因此在可接受范围内。所提改进LPP算法的检测准确率更高,最高可达到99.43%;召回率仍然最高,可达到99.84%。研究所提基于层次分析的实时数据监测算法能有效实现对客服中心实时数据流监测。基于层次分析的实时数据监测算法的监测准确率始终最高,在数据样本集为500时,准确率为99.84%。CDJAP算法的监测准确率最低,在数据样本集为500时准确率为92.82%,比研究所提算法低7.02%。相较于另外两种算法,研究所提算法的召回率始终最高,在数据样本集为500时,召回率为99.62%。综上所述,研究提出的实时数据自动监测模型具有较好的异常数据监测和实时数据监测性能。但研究提出的改进LPP算法在运行时间上与传统LPP算法相差不大。因此在未来的研究中,应进一步对算法进行简化,搭建出更加高效的实时数据自动监测模型。

参考文献

- [1] 严峻, 马路遥, 龙铭, 等. 基于大数据抓取的供应商不良行为数据监测方法[J]. 微型电脑应用, 2023, 39(6):193-195.
- [2] 刘天松, 吴永明, 李少波, 等. 基于自适应GHNG的铝电解过程异常性数据监测方法[J]. 计算机集成制造系统, 2023(11):3614-3623.
- [3] 陈晖, 谢勇, 徐昕, 等. 基于多源卫星遥感的灾害性气象观测数据监测系统[J]. 计算机测量与控制, 2023, 31(4):24-29.

(上接第57页)

参考文献

- [1] 赵莎莎, 袁葆, 安亚刚, 等. 智能电网需求侧用户参与度研究模型[J]. 电网与清洁能源, 2024, 40(3):60-66.
- [2] 刘迪迪, 程鹏鹏, 王小华, 等. 智能电网中家庭型产消者实时电力管理优化算法[J]. 南方电网技术, 2022, 16(11):20-28.
- [3] 冯小峰, 冯霞山, 张正峰, 等. 基于最大似然法和决策树的智能电能表计量误差检测方法[J]. 电测与仪表, 2024, 61(12):205-211.
- [4] KIRUBADEVI S, HEMALATHA N, SANKARAN E, et al. Autonomous smart grid management and control by using IoT[J]. International Journal of System Assurance Engineering and Management, 2022, 13(1):625-632.
- [5] 柳扬, 沈建良, 开末平, 等. 基于区块链的智能电网安全管控研究与应用[J]. 制造业自动化, 2023, 45(6):23-28.
- [6] 牛荣泽, 张凯, 谢芮芮, 等. 基于随机森林的电缆管网综合监测系统研究[J]. 电测与仪表, 2024, 61(10):74-81.
- [7] 张鹏, 刘超, 赵毓鹏, 等. 数字新基建下电力智能终端设备安全管控机制研究[J]. 华电技术, 2021, 43(2):66-71.
- [8] 郭文杰, 黄镇坤, 李蔚, 等. 基于直觉模糊逻辑的智能电网数据管

- [4] XU Z, JIANG W, XU J, et al. Distribution network topology identification using asynchronous transformer monitoring data[J]. IEEE Transactions on Industry Applications, 2023, 59(1):323-331.
- [5] BOGEDALE L, SCHRODT A, HEIM H. Time series data for process monitoring in injection molding: a quantitative study of the benefits of a high sampling rate[J]. International Polymer Processing, 2023, 38(2):167-174.
- [6] 吴石松, 董召杰. 基于深度语义匹配模型的智能客服系统设计[J]. 自动化技术与应用, 2024, 43(7):176-180.
- [7] 张思雨, 吴佐平, 谢敏, 等. 大数据背景下电力数据交互平台的实时监控与异常检测模型[J]. 自动化技术与应用, 2025, 44(5):182-187.
- [8] 赵光华, 杨焘, 付冬梅. 数据流形边界及其分布条件的增量式降维算法[J]. 智能系统学报, 2023, 18(5):975-983.
- [9] 李宏, 段文强, 李富. 多信息融合的LPP算法[J]. 吉林大学学报(信息科学版), 2023, 41(4):599-607.
- [10] 葛孟婷, 万鸣华. 基于近邻监督局部不变鲁棒主成分分析的特征提取模型[J]. 计算机应用, 2023, 43(4):1013-1020.
- [11] 杨景崙, 辛巍, 刘全, 等. 基于自监督学习的输电线路螺栓螺母异常检测技术[J]. 计算机测量与控制, 2023, 31(5):87-93.
- [12] 高勇, 范龙. 多参数优化下的智能电源箱物联态势实时监控方法[J]. 微型电脑应用, 2023, 39(11):130-133.
- [13] 许四平, 李琳. 模糊规则下IM换相转矩脉动控制方法仿真[J]. 计算机仿真, 2023, 40(1):354-358.
- [14] 王子慧, 任宁宁, 周毅, 等. 优化多层次分析法的影响因素绩效评价模型[J]. 计算机工程与设计, 2023, 44(7):2039-2046.
- [15] 张佩, 游晓明, 刘升. 融合动态层次聚类及邻域区间重组的蚁群算法[J]. 计算机应用研究, 2023, 40(6):1666-1673.
- [16] 张文冰, 刘灵蛟, 刘雪敏. 基于大数据分析的电力营销稽查全过程监测技术研究[J]. 自动化技术与应用, 2024, 43(12):204-206,215.
- [17] 臧奕若, 李卓满, 张少春, 等. AI与量子技术在未来电网中的融合模式与应用展望[J]. 高压技术, 2025, 51(4):1708-1726.
- [18] 白荣华. 多源一体化政务网络安全监测平台设计与应用[J]. 计算机应用与软件, 2024, 41(7):20-24,73.

理平台风险评估[J]. 数学的实践与认识, 2023, 53(12):90-99.

- [9] 曹志强, 陈洁. 智能电网中基于批标准化LSTM的互感器故障诊断技术[J]. 电力科学与技术学报, 2023, 38(6):152-158.
- [10] 张跃, 张雪莹, 赖来源. 考虑负荷动态模型的智能电网灵活规划方法[J]. 电网与清洁能源, 2023, 39(5):106-112.
- [11] 袁博, 葛少云, 刘洪, 等. 基于压缩感知的智能电网高级量测体系[J]. 高压技术, 2024, 50(5):2088-2096.
- [12] 何馥彤, 李存斌. 考虑信息物理融合系统的韧性电网风险研究现状及发展趋势可视化分析[J]. 中国安全生产科学技术, 2024, 20(2):35-43.
- [13] 谢旭, 施学鸿, 杨柳, 等. 一种基于k-Means的电力传感网信任决策方法[J]. 传感技术学报, 2023, 36(10):1643-1648.
- [14] 金耀. 基于ITSO-XGBoost算法的智能电能表误差估计模型研究[J]. 电测与仪表, 2025, 62(11):53-60.
- [15] 廖银玲, 李金灿, 王冰, 等. 基于深度学习的智能电网窃电检测混合模型研究[J]. 电信科学, 2024, 40(2):72-82.
- [16] 宋杰, 甘海庆, 徐晨波, 等. 基于区块链技术的电力碳排放权分配模型[J]. 自动化技术与应用, 2025, 44(10):134-137.