

DOI:10.20033/j.1003-7241.(2026)10-0184-05

基于深度极限学习机的高压电气设备失效自动判定方法

苑学贺, 郭文钧, 许冰

(北京中电普华信息技术有限公司, 北京 100089)

摘要: 由于高压电气设备内部结构复杂、运行环境多变且易受外部因素干扰, 导致难以捕捉设备运行模态特征, 从而实现失效判定。为提高设备故障诊断效果, 提出基于深度极限学习机的高压电气设备失效自动判定方法。通过采集设备的振动、温度等物理参数, 并利用 Mean Shift 算法进行非参数化聚类。通过迭代更新均值漂移向量, 根据聚类结果识别不同模态状态。利用 Fisher Score 计算各特征参数与设备状态标签之间的线性相关性, 并排序。采用最大信息系数分析特征间的非线性冗余性, 实现设备模态特征筛选。构建深度极限学习机模型 (deep extreme learning machine, DELM), 结合新特征向量的预测结果以及阈值比较结果, 对设备失效状态进行判定。在实验中, 对提出的方法进行了判定准确性的检验。最终的测试结果表明, 采用提出的方法对设备失效状态进行判定时, 判定结果的 kappa 系数更高, 具备较为理想的判定效果。

关键词: 深度极限学习机; 电气设备; 失效判定; 故障检测; 特征筛选; 均值漂移聚类

中图分类号: TP183; TM762

文献标志码: A

文章编号: 1003-7241(2026)10-0184-05

Automatic failure determination method for high voltage electrical equipment based on deep extreme learning machine

Yuan Xuehe, Guo Wenjun, Xu Bing

(Beijing CLP Hua Information Technology Co., Ltd., Beijing 100089, China)

Abstract: Due to the complexity of the internal structure of high-voltage electrical equipment, the operating environment is variable and susceptible to the interference of external factors, which makes it difficult to capture the modal characteristics of the equipment operation and thus realize the failure determination. In order to improve the effect of equipment fault diagnosis, the automatic determination method of high-voltage electrical equipment failure based on deep limit learning machine is proposed. Physical parameters such as vibration and temperature of the equipment are collected and nonparametric clustering is performed using Mean Shift algorithm. By iteratively updating the Mean Shift vector, different modal states are recognized according to the clustering results. The linear correlation between each feature parameter and the device state label is calculated and ranked using Fisher Score. Analyze the nonlinear redundancy between features using Maximum Information Coefficient to realize the device modal state feature screening. The deep extreme learning machine model (DELM) is constructed to determine the equipment failure state by combining the prediction results of the new feature vectors and the threshold comparison results. In the experiments, the proposed method is tested for determination accuracy. The final test results show that when the proposed method is used to determine the equipment failure state, the kappa coefficient of the determination result is higher, and the determination effect is more ideal.

Keywords: deep extreme learning machine; electrical equipment; failure judgment; fault detection; feature screening; mean shift clustering

高压电气设备在长期运行过程中, 由于自身质量、环境因素以及操作不当等多种原因, 常常会出现各种故障, 如绝缘老化、接触不良、过热等。这些故障如果不及时发现和处理, 不仅会导致设备损坏, 甚至可能引发严重的电力事故, 对人们的生命财产安全构成严重威胁。因此, 如何实现高压电气设备的失效自动判定, 及时发现和处理故障, 成为当前电力行业亟待解决的重要问题。

近年来, 智能算法在电力设备故障诊断领域取得了显著进展。例如, 文献[1]利用主成分分析 (principal component

analysis, PCA) 技术对高维数据进行降维处理, 提取出主要故障特征。采用支持向量机 (support vector machine, SVM) 作为分类器, 对提取的特征进行分类识别, 实现对电气设备的故障诊断。尽管 PCA 在数据降维方面表现出色, 但该方法在复杂故障模式识别上存在局限性, 特别是当故障特征不明显或数据噪声较大时, 诊断精度可能会受到影响。文献[2]通过采用机器学习算法, 从历史数据中学习故障特征与故障类型之间的映射关系, 从而对设备的失效状态进行精准判定。但对于复杂设备, 故障类型多样且相

收稿日期: 2025-05-24; 录用日期: 2025-07-13

作者简介: 苑学贺 (1983—), 男, 高级工程师, 研究方向为人工智能。

引用本文: 苑学贺, 郭文钧, 许冰. 基于深度极限学习机的高压电气设备失效自动判定方法[J]. 自动化技术与应用, 2026, 45(10): 184-188. (Yuan Xuehe, Guo Wenjun, Xu Bing. Automatic failure determination method for high voltage electrical equipment based on deep extreme learning machine[J]. Techniques of Automation and Applications, 2026, 45(10): 184-188.)

互之间存在耦合关系,单一机器学习算法往往难以准确捕捉所有故障特征,限制了诊断的准确性。文献[3]构建了一个包含多种故障模式的故障样本库,然后利用人工鱼群算法对故障样本进行搜索和优化,以找到最优的故障特征组合。这些特征被用于训练神经网络模型,实现对船舶电子设备故障的自动诊断。但该方法的局限性在于,人工鱼群算法在搜索过程中可能陷入局部最优解,导致故障特征的选择不够全面,影响诊断的精度。文献[4]构建了设备故障的关系超图,通过超图表示设备之间的故障关联关系。然后利用 Transformer 模型对关系超图进行特征提取和表示学习,实现对设备故障的自动诊断。但关系超图的构建依赖于对设备故障关系的深入理解,如果关系定义不准确或遗漏,将影响诊断的准确性。

本文采用自适应优化算法对深度极限学习机模型进行优化,使其能够更好地适应高压电气设备失效判定的实际需求,提高模型的泛化能力和鲁棒性。

1 高压电气设备失效判定方法

1.1 高压电气设备模态检测

电气设备的模态是指其振动、温度等物理参数在不同工作状态下的表现模式。因此为了获取设备的实时运行状态信息,为失效判定提供重要依据,首先结合 Mean Shift 算法对设备的模态状态进行获取。

通过调取传感器的监测记录,对高压电气设备的振动信号以及温度信号等物理参数进行采集^[5]。设定初始带宽为 h ,对于每个电气设备运动数据点 x_i, x_j , 计算其核密度估计下的加权均值 m_{i+1} , 具体更新表达式如下所示。

$$m_{i+1} = \frac{\sum_{x_j \in S_{h(x_i)}} K\left(\frac{\|x_i - x_j\|^2}{h^2}\right) x_j}{\sum_{x_j \in S_{h(x_i)}} K\left(\frac{\|x_i - x_j\|^2}{h^2}\right)} \quad (1)$$

式中, $S_{h(x_i)}$ 代表以 x_i 为中心, h 为半径的球内所有点集合, $K(\cdot)$ 代表核函数^[6]。对此,本文采用高斯核函数,其具体函数表达式如下所示。

$$K(u) = \exp\left(-\frac{u}{2}\right) \quad (2)$$

式中, u 代表核函数中的参数。

在迭代过程中,每个数据点都会根据其邻域内的数据点进行移动,直到达到终止条件^[7]。设定一个小的阈值 ε , 当 m_{i+1} 与 m_i 之间的变化小于 ε 时,停止迭代。根据最终的加权均值 m_i , 将靠近的点归为同一类。每个聚类簇可以对应一个模态状态。通过对聚类结果的分析,识别不同模态下的数据点。每个聚类簇中的数据点具有相似的特征,可以认为它们属于同一模态状态。根据聚类簇中的数据点,计算模态参数,如模态频率等^[8]。这些参数可以反映高压电气设备的健康状态。模态频率 f_m 的变化可以反映设备结构的刚度变化,其具体计算公式如下所示。

$$f_m = \frac{\sqrt{\frac{k}{m}}}{2\pi} \quad (3)$$

式中, k 代表刚度系数, m 代表质量。

通过上述步骤,可以使用 Mean Shift 算法对数据点进行迭代更新,使其向高密度区域移动,直至收敛到模态中心^[9]。通过聚类分析,将数据点划分为不同的模态状态。

1.2 高压设备运行模态特征筛选

基于上述的电气设备模态检测结果,本文将 Fisher Score 法与最大信息系数(maximal information coefficient, MIC)进行结合,通过分析模态特征之间的非线性冗余性,实现模态特征筛选。

Fisher Score 是一种衡量特征与目标变量之间线性相关性的方法。对于高压电气设备运行模态特征筛选,本文选择计算每个特征参数与设备运行状态(例如正常、异常等)之间的 Fisher Score^[10]。假设有 n 个特征参数 $X_1, X_2, \dots, X_n$, 和一个目标变量 Y , 该变量代表设备的运行模态,则 Fisher Score 的具体计算公式如下所示。

$$F_i = \frac{(\mu_{Y=1,i} - \mu_{Y=0,i})^2}{\sigma_{Y=1,i}^2 + \sigma_{Y=0,i}^2} \quad (4)$$

式中, $\mu_{Y=1,i}$ 和 $\mu_{Y=0,i}$ 分别代表当 $Y=1$ 和时 $Y=0$, 特征 X_i 的均值, $\sigma_{Y=1,i}$ 和 $\sigma_{Y=0,i}$ 分别代表当 $Y=1$ 和时 $Y=0$, 特征 X_i 的方差^[11]。

计算完所有特征的 Fisher Score 后,可以按照得分进行排序,得到特征的相关性排序。MIC 是一种衡量两个变量之间非线性相关性的方法。在得到特征的相关性排序后,利用 MIC 对特征进行冗余性分析^[12]。假设高压电气设备运行模态特征分别为 X_i 和 X_j , 则它们之间的 MIC 可以表示为

$$\text{MIC}(X_i; X_j) = \max_{a \times b \leq B} \frac{I(X_i; X_j)}{\log_2 \min(a, b)} \quad (5)$$

式中, $I(X_i; X_j)$ 代表特征 X_i 和 X_j 之间的互信息, $a \times b$ 代表将特征 X_i 和 X_j 的取值范围分别划分为 a 和 b 个区间, B 代表预设的上限值,用于限制网格划分的复杂度^[13]。MIC($X_i; X_j$) 的值在 0~1 之间,该值越大,代表模态特征之间的相关性越强。

从相关性最高的特征开始,依次考虑每个特征。对于当前考虑的特征 X_i , 检查它与其他已选特征之间的 MIC 值^[14]。如果 X_i 与某个已选特征的 MIC 值较高,即超过某个设定阈值,则认为二者之间存在冗余性。此时优先保留相关性排名靠前的特征,并去除冗余特征。通过不断重复上述步骤,直到所有的特征都被考虑过。

通过上述过程,可以得到一个与高压电气设备状态标签相关性大、所选特征之间冗余性低且可解释性强的最优特征子集样本。

1.3 高压电气设备失效自动判定

假设筛选后的特征集为 $X = \{x_1, x_2, \dots, x_n\}$, 其中 n 代表电气设备运行模态特征数量, 每个 x_i 均代表一个特征

向量,其中包含多个设备的运行模态特征值。其对应的设备状态标签集为 $Y = \{y_1, y_2, \dots, y_m\}$, 其中 m 代表样本数量,每个 y_i 均为一个二值标签,其中 0 代表正常,1 代表失效。设定 DELM 模型输入层的神经元数量为 n , 输出层神经元数量为 1,输出设备失效的概率值。对于每个输入特征向量 $\mathbf{x}_i$, 通过隐藏层逐层计算,得到输出层的预测值。假设 $\mathbf{W}_j^T$ 和 $\mathbf{W}_{out}^T$ 分别代表隐藏层和输出层的权重向量,由此可以得到两层输出表达式如下所示。




图 1 深度极限学习机模型结构

Fig. 1 Structure of deep extreme learning machine model

$$h_j = \sigma(\mathbf{W}_j^T \mathbf{x}_i + b) \tag{6}$$

$$y' = \sigma(\mathbf{W}_{out}^T \mathbf{h} + b_{out}) \tag{7}$$

式中, b, b_{out} 代表两层对应的偏置值, h_j 代表第 j 个隐藏层

神经元的输出, $\mathbf{h}$ 代表隐藏层输出向量的拼接, y' 代表设备失效概率预测值。采用下述损失函数衡量失效概率预测值 y_i' 与真实标签 y_i 之间的差异,具体表达式如下所示。

$$L = - \frac{\sum_{i=1}^n [y_i \log(y_i') + (1 - y_i) \log(1 - y_i')]}{n} \tag{8}$$

根据上述函数的梯度,可以对 DELM 模型的参数进行更新,从而直到函数收敛。参数更新表达式如下所示。

$$\mathbf{W}' = \mathbf{W} - \alpha \frac{\partial L}{\partial \mathbf{W}} \tag{9}$$

式中, α 代表学习率, $\mathbf{W}$ 和 $\mathbf{W}'$ 分别代表原始模型权重以及更新后的权重, $\frac{\partial L}{\partial \mathbf{W}}$ 代表损失函数对权重的梯度。

通过上述方式,可以对 DELM 模型进行训练。待模型训练完成后,对于新的高压电气设备运行模态特征向量,将其输入到训练好的模型中,可以得到失效概率预测值^[15-17]。并设定失效判定阈值,如果预测值高于该阈值,则判定设备失效,否则判定设备正常。将本节内容与上述提到的设备模态检测以及模态特征筛选等相关内容进行结合,至此,基于深度极限学习机的高压电气设备失效自动判定方法设计完成。

2 实验论证

2.1 实验准备

实验选取了五类不同型号与功能的高压电气设备作为实验对象。这些设备覆盖了电力系统中的关键组件,用于全面评估判定方法的准确性和适用性。具体包括高压断路器、高压隔离开关、电流互感器、电压互感器以及高压避雷器。具体设备型号以及性能参数如表 1 所示。

表 1 高压电器设备性能参数

Tab. 1 Performance parameters of high-voltage electrical equipment

设备类型	型号	数量	性能参数 1	性能参数 2
高压断路器	ZW32-12/630-20	10	额定电压:12 kV 额定频率:50 Hz	额定电流:630 A 机械寿命:30 000 次
高压隔离开关	GN19-12D/630	8	额定电压:12 kV 额定短路耐受电流:20 kA	额定电流:630 A 绝缘水平:工频 1 min 40 kV
电流互感器	LZZBJ9-10 0.5/10P10	12	额定电压:10 kV 额定负荷:10 VA/ 10 VA/ 10 VA/ 10 VA	额定二次电流:5 A 二次绕组数量:4
电压互感器	JDZX10-10Q	6	额定电压:10 kV 额定频率:50 Hz	额定二次电压:100 V 绝缘电阻:≥1 000 MΩ
高压避雷器	YH5WZ-17/45	4	持续运行电压:17 kV 额定电压下持续电流:≤ 1 mA	雷电冲击残压:≤42 kV 陡波冲击电流下残压:≤65 kV

所有实验设备均经过严格筛选,确保其处于良好的工作状态,并在实验前进行了必要的预防性试验,以确保实验结果的可靠性。实验中,将对这些设备施加模拟失效条件(如过热、绝缘击穿、机械故障等),并使用基于深度极限学习机的失效判定方法进行自动检测,以评估该方法的

准确性和效率。

针对模拟出的不同失效条件下的设备模态数据集,实验将其分为 3 种不同的样本集,每个样本集下的样本数目以及特征数目均有所不同。在对 3 个样本集下的特征进行筛选时,本文方法主要结合 Fisher Score 分数对其进行

筛选以及排序,由此得到的排序结果如表 2 所示。

以上述排序结果为基准,将排名靠前的特征作为输入项,输入到 DELM 模型中,从而实现模型训练与测试集分析。为保证实验效果,实验还选取了两种常规的设备故障诊断方法作为对比对象,分别为基于 PCA 技术的设备故障诊断技术以及基于人工鱼群算法的设备故障诊断技术。

表 2 基于 Fisher Score 分数的模态特征排序结果

Tab. 2 Ranking results of modal features based on Fisher Score

样本集编号	样本数目/个	总特征数目/个	基于 Fisher Score 分数的排序结果
01	351	34	3-5-12-14-28-6-9-23
02	1 473	9	2-1-18-16-4-26-4-11
03	178	13	7-10-25-13-20-27-15

2.2 高压电气设备失效判定结果

采用训练集对 DELM 模型进行训练时,模型的收敛情况如图 2 所示。

值较为接近,由此可以证明本文提出的 DELM 模型具备较高的预测精度。




图 2 模型的收敛情况

Fig. 2 Model convergence

通过图 2 可以看出,在采用不同的训练集对模型进行训练时,模型均能够在 100~200 次迭代区间达到收敛,表明模型已经充分学习了训练数据的特征,并达到了一个相对较好的收敛状态。由此得到的测试集测试结果如图 3 所示。

通过上述实验结果可以看出,在采用本文方法对不同的样本数据进行失效状态判定时,其判定结果与真实标签




图 3 本文方法下的失效判定结果

Fig. 3 Failure determination results of the proposed method

2.3 判定准确性对比

实验以不同方法 Kappa 系数作为实验指标,对方法的失效判定准确性进行衡量。其值越高,表示自动判定方法的判定结果与实际分类结果之间的一致性越好,即判定精度越高。具体实验结果如表 3 所示。

表 3 判定准确性对比结果

Tab. 3 Comparison results of determination accuracy

测试集规模	DELM 方法 Kappa 系数	PCA 方法 Kappa 系数	AFSA 方法 Kappa 系数
100	0.85	0.78	0.72
200	0.88	0.80	0.75
500	0.90	0.83	0.78
1 000	0.92	0.85	0.80
2 000	0.93	0.87	0.82
5 000	0.94	0.89	0.84
10 000	0.95	0.90	0.85

从表 3 中可以看出,随着测试集规模的增加,3 种方法的 Kappa 系数均有所上升,但本文提出的 DELM 方法的 Kappa 系数始终高于其他两种方法。这表明在不同规模的测试集上,DELM 方法都具有更高的判定精度和一致

性,能够更好地识别高压电气设备的失效情况。

3 结论

本研究围绕基于深度极限学习机的高压电气设备失

效自动判定方法展开,通过对高压电气设备运行数据的深度挖掘与分析,构建出了一种高效、准确且稳定的失效判定方法。深度极限学习机的引入,使得模型能够从海量的设备数据中自动学习并识别出失效的先兆特征,大大提升了判定的准确性和时效性。这一转变,不仅减轻了运维人员的工作负担,更提高了电网运行的安全性和可靠性,对于预防电力事故的发生、保障社会经济的平稳运行具有不可估量的价值。

参考文献

- [1] 聊方伦,周平. 基于PCA的火电厂电气设备故障诊断方法[J]. 自动化技术与应用, 2022,41(3):39-43.
- [2] Cen J, Yang Z, Liu X, et al. A review of data-driven machinery fault diagnosis using machine learning algorithms[J]. Journal of Vibration Engineering & Technologies, 2022, 10(7):2481-2507.
- [3] 阮佳. 基于人工鱼群算法的船舶电子设备故障智能诊断方法[J]. 舰船科学技术, 2023,45(24):188-191.
- [4] 周海成,石恒初,曾令森,等. 基于关系超图增强Transformer的智能站二次设备故障诊断研究[J]. 电力系统保护与控制, 2024,52(12):123-132.
- [5] 魏东辉,李昊泽. 基于多源信息融合的船舶电气设备状态识别方法[J]. 舰船科学技术, 2024,46(10):186-189.
- [6] 梁英杰,韩玥莹,张俊,等. 混频输入下基于MF-LSTM的电气设备故障诊断方法[J]. 海军工程大学学报, 2024,36(4):22-27.
- [7] 朱哲华. 基于小波神经网络的船舶电气故障诊断[J]. 舰船科学技术, 2023,45(20):172-175.
- [8] 彭曙蓉,刘登港,何洁妮,等. 基于改进YOLOv4的架空线路电力设备故障检测[J]. 电力科学与技术学报, 2023,38(5):169-176.
- [9] 郑文杰,杨伟,乔木,等. 基于改进YOLO和Resnet的变电设备热缺陷识别及诊断方法[J]. 重庆理工大学学报(自然科学), 2023, 37(9):261-269.
- [10] 洪祥,房淑华,王学永. 基于机器学习算法的船舶电气故障分类与诊断方法[J]. 舰船科学技术, 2023,45(15):143-146.
- [11] 李岩,刘玉娇,李国亮,等. 基于改进BEMD与Res-LSTM电气设备故障辨识方法[J]. 高压电器, 2022,58(11):82-87,105.
- [12] 贾俊,袁栋,戴永东,等. 基于深度学习算法的配网设备状态智能巡检方法[J]. 自动化技术与应用, 2024,43(12):80-83,158.
- [13] 欧阳金鑫,张澳归,蒋航,等. 基于深度置信网络的电网安全稳定控制系统故障诊断方法[J]. 电测与仪表, 2024,61(7):1-6.
- [14] 叶志晖,石钉科,王柳婧,等. 基于小波熵理论的动力发电设备故障自动检测方法[J]. 自动化技术与应用, 2023,42(6):66-69.
- [15] 单显明,李长伟,张忠传. 基于神经网络的复杂电子设备故障诊断系统的设计[J]. 电子测量技术, 2022,45(11):52-56.
- [16] 邵芳. 基于监督机器学习的配电网电力智能运维检修研究[J]. 自动化技术与应用, 2024,43(11):169-173.
- [17] 金萍,侯娟. 面向新型电力系统的粗糙集和双流网络自动化物联设备故障诊断方法研究[J]. 电测与仪表, 2024,61(9):166-171.
- [18] Monajemi S, Sanei S, Ong S H. Information reliability in complex multitask networks[J]. Future Generation Computer Systems, 2018, 83:485-495.
- [19] Schlüter N, Binfet P, Kim J, et al. Encrypted distributed state estimation via affine averaging[C]//2022 IEEE 61st Conference on Decision and Control (CDC). Mexico City, Mexico: IEEE, 2022:7754-7761.
- [20] He J, Cai L, Zhao C, et al. Privacy-preserving average consensus: privacy analysis and algorithm design[J]. IEEE Transactions on Signal and Information Processing over Networks, 2018, 5(1):127-138.
- [21] He J, Cai L, Guan X. Differential private noise adding mechanism and its application on consensus algorithm[J]. IEEE Transactions on Signal Processing, 2020, 68:4069-4082.
- [22] Shen X, Liu Y. Privacy-preserving distributed estimation over multitask networks[J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 58(3):1953-1965.
- [23] 王瑞玺,孙书利. 传感器网络多重融合分布式一致性滤波算法[J]. 系统科学与数学, 2023,43(11):2773-2788.
- [24] Yan X, Chen B, Qiu X. Distributed dimensionality reduction fusion Kalman filtering with quantized innovations[J]. Circuits, Systems, and Signal Processing, 2021, 40(10):5234-5247.
- [25] Huang W, Yang X, Shen G. Communication-reducing diffusion LMS algorithm over multitask networks[J]. Information Sciences, 2017, 382:115-134.
- [26] Zha L, Guo Y, Liu J, et al. Protocol-based distributed security fusion estimation for time-varying uncertain systems over sensor networks: Tackling DoS attacks[J]. IEEE Transactions on Signal and Information Processing over Networks, 2024, 10:119-130.
- [27] Okamoto K, Hayashi N, Takai S. Distributed online adaptive gradient descent with event-triggered communication[J]. IEEE Transactions on Control of Network Systems, 2023, 11(2):610-622.
- [28] Ge X, Han Q L, Zhang X M, et al. Distributed event-triggered estimation over sensor networks: A survey[J]. IEEE transactions on cybernetics, 2019, 50(3):1306-1320.
- [29] Guo N, Kostina V. Optimal causal rate-constrained sampling of the wiener process[J]. IEEE Transactions on Automatic Control, 2022, 67(4):1776-1791.
- [30] Li J, AlRegib G. Distributed estimation in energy-constrained wireless sensor networks[J]. IEEE Transactions on Signal Processing, 2009, 57(10):3746-3758.
- [31] Li J Y, Wang Z, Lu R, et al. Distributed filtering under constrained bit rate over wireless sensor networks: dealing with bit rate allocation protocol[J]. IEEE Transactions on Automatic Control, 2022, 68(3):1642-1654.
- [32] Shamsi M, Zayyani H, Marvasti F. Robust diffusion LMS with masked measurements[J]. Signal Processing, 2025, 225:110163.

(上接第134页)