Sigmoid Identification Method for Secondary Equipment Plug-in Fault of 220 kV Intelligent Substation

GENG Bo*, LI Wei, CHU Anqi, NIU Jianfei, MU Zhe
(State Grid Shandong Electric Power Company Binzhou Power Supply Company, Binzhou Shandong 256600, China)

Abstract: In the plug-in function that combines measured data and visual images, the probability of injecting faults into the secondary equipment plug-in of the substation is higher, making it difficult to distinguish the fault category and confirm the difference in remaining life parameters. To address this, a 220 kV intelligent substation secondary equipment plug-in fault Sigmoid recognition method is proposed. By using the principle of equivalent superposition to process historical data, the current values of bipolar load faults are obtained. At the same time, the grayscale gradient information matrix is used to normalize the infrared image texture information, and these fault characteristic parameters are organized into a structured data form to construct a substation secondary equipment plug-in fault characteristic database. On the pooling layer, redundant feature removal is performed on real-time data to obtain the maximum pooling calculation feature map. The cosine similarity between the feature map and the data in the fault feature database is calculated and input into the Sigmoid function to obtain an output value as the probability of the plugin failing. The reason is that the Sigmoid function image matches the fault features. This process utilizes the classification function of the Sigmoid function to reduce the impact of redundant features and solve the problem of inaccurate recognition results caused by communication network anomalies. The output value of the Sigmoid function is compared with the three-phase current value on the high voltage side, whether there is a fault in the plug-in is determined based on the comparison result, temperature probability density detection on the faulty plug-in state is performed, and the result is input into the Sigmoid function. Bernoulli distribution is used to automatically match the fault characteristics and achieve fault identification of secondary equipment plug-in in the substation. The experimental results show that the Sigmoid identification method for plug-in faults in the secondary equipment of a 220 kV intelligent substation can identify various types of faults. The average difference between the remaining life parameter values and the actual values is low, and the F1 values are all above 0.9.

Key words: equivalent superposition; bipolar loads; Sigmoid function; Bernoulli distribution; temperature probability density
EEACC: 7220; 8140 **doi**: 10.3969/j.issn.1005-9490.2026.04.023

220 kV 智能变电站二次设备插件故障 Sigmoid 识别方法

耿 波*, 李 巍, 褚安琪, 牛健飞, 牟 哲
(国网山东省电力公司滨州供电公司, 山东 滨州 256600)

摘 要: 实测数据和可视图像相结合的插件功能中, 变电站二次设备插件故障注入概率更高, 导致难以区分故障类别, 无法确认剩余寿命参数差值, 对此, 提出了 220 kV 智能变电站二次设备插件故障 Sigmoid 识别方法。利用等效叠加原理处理历史数据, 以获取发生双极负荷故障情况的电流数值, 同时利用灰度-梯度信息矩阵归一化处理红外图像纹理信息, 将这些故障特征参数整理成结构化的数据形式, 构建成变电站二次设备插件故障特征数据库; 在池化层上对实时数据进行冗余特征去除工作, 得到最大池化计算特征图, 对特征图与故障特征数据库中数据进行余弦相似度计算, 并将其输入至 Sigmoid 函数, 得到一个输出值作为该插件发生故障的概率, 理由是 Sigmoid 函数图像与故障特征匹配。该过程利用 Sigmoid 函数的分类功能, 减少了冗余特征产生的影响, 解决了因通信网络异常造成的识别结果不准确的问题。比较 Sigmoid 函数输出值与高压侧三相电流数值, 根据比较结果判断插件是否存在故障, 将存在故障的插件状态进行温度概率密度检测, 并将其输入至 Sigmoid 函数中, 利用伯努利分布对故障特征进行自动匹配, 实现变电站二次设备插件故障识别。实验结果表明: 220 kV 智能变电站二次设备插件故障 Sigmoid 识别方法, 可以识别出各种故障类型, 剩余寿命参数数值与实际值相差的平均值较低, 且 F1 值均在 0.9 以上。

关键词: 等效叠加; 双极负荷; Sigmoid 函数; 伯努利分布; 温度概率密度
中图分类号: TP399 **文献标识码**: A **文章编号**: 1005-9490(2026)04-0861-07

收稿日期: 2025-07-28 **修改日期**: 2025-10-11

220 kV 智能变电站作为最常用的变电站类型,其运行的稳定性影响着整个电网的安全状况。然而,在实际运行过程中,智能变电站的二次设备插件发生故障的几率较高,这导致变电站的正常运行受到严重影响。因此,及时、准确地识别二次设备插件故障,对于保障电网的安全运行具有重要意义。相关学者对其进行了深度研究。

金萍与侯娟[1]以计算高压侧三相电流为目标,构建针对连续、定性属性的故障判定函数以判定物联设备状态,在故障判定函数中加入离散化算法,得到约简后的故障特征集。在此条件下,利用卷积神经网络与门控循环单元训练智能变电站二次设备插件历史故障信息,从而完成故障诊断工作。该方法在智能变电站中极易受到通信网络异常的影响,导致诊断结果不准确。常仲学等[2]利用配电网分相重合模型,对瞬时性和永久性故障进行推导,从而得到插件有功功率不同故障性质下的数值,并根据该数值对过渡电阻、负荷大小进行分析,最后根据分析结果实现了故障识别功能。该方法太过依赖历史故障数据,难以适应通信网络异常造成的影响,导致识别结果不准确。闵伟菘等[3]针对故障波动长度特征值、故障电流积分、双端初相位差和双端接地电流方向差异度等 4 个智能变电站二次设备插件数据波形进行了特征定位与识别,并利用核极限学习机对这些特征进行快速简化,从而完成实时数据与故障波形的匹配,通过大量仿真数据训练识别 RKELM 模型,从而达到故障识别的目的。该方法改善了对于历史数据过于依赖的问题,但该方法针对冗余信息的处理不够充分,从而导致其故障识别精确度较低。许守东等[4]通过分析单相接地故障输出特性,构建相关电流输出函数,以短路电流矢量占比系数为依据,判断不同故障的类型和位置,从而实现故障识别工作。该方法的推理规则受到规则库完整性和准确性的限制,对于某些特定故障现象,识别结果不够准确。

本文提出了一种基于 Sigmoid 函数的故障识别方法。利用 Sigmoid 函数的非线性映射能力、分类能力对故障特征以及故障类型进行精准识别和分类。同时,由于 Sigmoid 函数的适应性较强,可以根据不同的故障特征信息进行调整和优化,提高故障识别的准确性和可靠性。

1 智能变电站二次设备插件故障识别方法的设计

1.1 构建变电站二次设备插件故障特征数据库

在智能变电站的多端柔性接口处,采集二次设备插件的相应参数,从而得出在等效运行过程中,二次设备插件产生的电流数值[5],其计算公式如下所示:

$$I=\frac{\mathrm{e}^{-t}}{\sin(\omega t+\beta)} \tag{1}$$

式中:I 代表该处电流数值,ω 代表柔性等效电容数值,β 代表二次设备插件内部的电抗参数数值,t 代表运行时间。

结合等效叠加原理,得出在发生双极负荷故障时的双极电流数值[6],其计算公式如下所示:

$$I_1=I-\frac{L}{R_c} \tag{2}$$

式中:L 代表插件内产生的叠加参数数值,R_c 代表插件导通等效电阻的电阻值。

判断插件内的限流电抗器是否出现放电现象,其计算公式如下所示:

$$I_b=\begin{cases}\dfrac{U_d+U_c}{\dfrac{L}{3}} & L>1\\ \dfrac{U_d-\mathrm{e}^{L}}{w} & 0<L\leqslant 1\end{cases} \tag{3}$$

式中:U_d 代表二次设备插件两端输出的电压数值,I_b 代表放电过程电流产生的变化情况,U_c 代表电感续流产生的电压数值,w 代表插件开断参数。

同时利用灰度-梯度信息矩阵对视觉传感器采集到红外图像纹理信息进行归一化处理[7],其数学表达式为:

$$\begin{cases}G(m,n)=\dfrac{g(m,n)}{g_{\max}}N_g+1\\ H(m,n)=\dfrac{h(m,n)}{h_{\max}}N_h+1\end{cases} \tag{4}$$

式中:$g_{\max}$代表最大梯度值,$h_{\max}$代表最大灰度值,N_g代表归一化处理后的梯度级最大值,N_h 代表归一化后的灰度级最大值,(m,n)代表像素点,$g(m,n)$代表该像素点的梯度值,$h(m,n)$代表该像素点的灰度值

将故障特征参数整理成结构化的数据形式,从而构建成变电站二次设备插件故障特征数据库,为之后的故障识别提供基础。

1.2 利用 Sigmoid 函数进行故障特征匹配

在池化层上,去除传感器实时数据冗余特征,得

到最大池化计算特征图，其计算公式如下所示：

$$y_j^l=f\left(\sum_{i\in M_j}^{+\infty}\alpha x_i^{l-1}+b_j^l\right) \tag{5}$$

式中：α 代表最大池化系数，y_j^l 代表最大池化特征图，b_j^l 代表偏置参数，l 代表滤波器序号，j 代表卷积层序号，f 代表激活函数，x_i^{l-1} 代表该滤波器第 i 个输入值。

计算特征图与 1.1 节构建的故障特征数据库中数据的余弦相似度[8]，计算公式如下所示：

$$\delta=\cos(A,B)=\frac{\sum_{i=1}^{n}A_i\cdot B_i}{\sqrt{\sum_{i=1}^{n}A_i^2}\cdot\sqrt{\sum_{i=1}^{n}B_i^2}} \tag{6}$$

式中：A_i 代表实时数据的第 i 个分量，B_i 代表故障特征向量的第 i 个分量，n 代表向量的维度，δ 代表余弦相似度。

通过上式计算得出实时数据与故障特征向量的余弦相似度，再将上式计算结果代入 Sigmoid 函数，其计算公式如下所示：

$$\sigma(\delta)=\frac{1}{1+e^{-\delta}} \tag{7}$$

式中：$\sigma(\delta)$ 代表针对相应相似度的 Sigmoid 函数数值。

将相似度值输入到 Sigmoid 函数中进行映射，得到[0,1]的数值，表示匹配概率[9]，如图 1 所示。

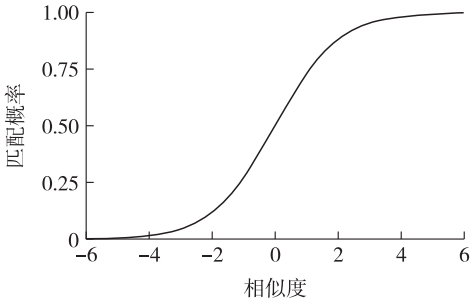

图 1　Sigmoid 函数图像

由图 1 可知实时数据与每个模板的 Sigmoid 函数数值，从而判断其匹配概率。根据故障特征匹配概率，判断该插件是否发生故障，以此改进神经网络模型结构，如图 2 所示。

如图 2 所示，改进神经网络模型结构包括输入层、卷积层、池化层、全连接层和输出层。输入层负责接收实时数据或故障特征数据库中的结构化数据，输入维度取决于故障特征参数的数量。输入的特征参数包括电流数值（如双极电流、放电电流）和红外图像纹理信息（归一化后的灰度-梯度矩阵）。卷积层用于局部特征提取，采用多层级卷积。具体地，设置

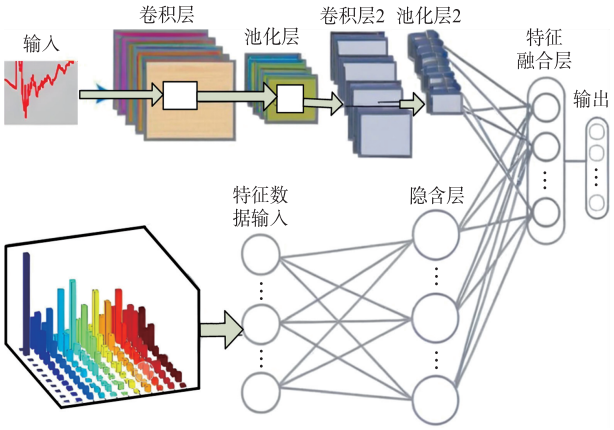

图 2　改进神经网络模型结构

两层卷积层，每层包含 32 个滤波器，滤波器大小设为 3×3，步长为 1，以捕捉故障波形的细微变化。故障特征涉及时间序列电流和空间纹理，小尺寸滤波器能更好保留局部特征。池化层采用最大池化操作去除冗余特征。池化窗口大小设为 2×2，步长为 2，最大池化系数 α 取值为 1.0（标准值），以降低特征图尺寸而不丢失关键信息。全连接层将池化层输出展平后连接至隐藏层。输出层输出判定为故障的结果。

1.3　设计变电站二次设备插件故障判定函数

计算高压侧三相电流数值[10]，将 Sigmoid 函数数值与高压侧三相电流数值进行比较，其计算公式如下所示：

$$\begin{cases}I_a=\dfrac{I_{1k}^T+I_{2k}^T+I_{3k}^T+I_{4k}^T}{4}\\ I_b=\dfrac{I_{1k}^T+2t_1I_{2k}^T+I_{3k}^T+I_{4k}^T}{4}\\ I_c=\dfrac{I_{1k}^T+I_{2k}^T+3t_1I_{3k}^T+I_{4k}^T}{4}\end{cases} \tag{8}$$

式中：I_a、I_b、I_c 代表 a、b、c 三相电流的数值，I_k^T 代表某时刻测得的四个电阻上的电流数值，T 代表测量时刻，t_1 代表高压侧平衡系数。

将 1.2 中计算所得 Sigmoid 函数数值与上式中高压侧三相电流数值进行比较，得到插件出现故障时，经过该插件的电流变化情况[11]，该情况电流变化如图 3 所示。

根据特征差异，以及图 3 电流变化图像，综合线路出口处电流幅值及其突变时刻检测 220 kV 智能变电站二次设备插件是否发生故障及短路类型，构建相应故障判定函数，该函数如下所示：

$$\begin{cases}N_{I>I_{set}}>1\\ t_m-t_n>t_{set}\end{cases} \tag{9}$$

式中：$N_{I>I_{set}}$ 代表出现短路特征的线路数目，I 代表各

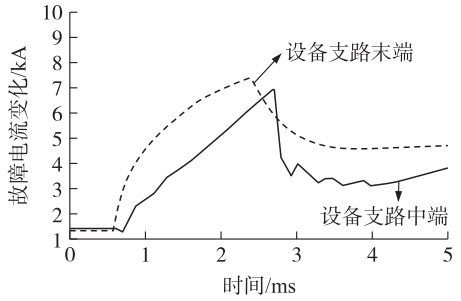

图 3 插件故障状态电流变化情况

开关处的电流幅值，I_{set}代表 FTU 定值，t 代表该线路出现电流突变的时刻，m、n 代表线路名称，t_{set}代表线路电流突变时刻的间隔定值。

通过过程判断所识别插件是否出现故障。

1.4 应用判定函数识别变电站二次设备插件故障

计算故障插件的温度概率密度，其计算公式如下所示：

$$h(x)=\frac{H_j}{H_{sum}},j\in(\theta_{min},\theta_{max}) \tag{10}$$

式中：$h(x)$代表温度概率密度，H_j 代表变电站二次设备插件红外图像中的数据点总数，H_{sum}代表对应样本数量，j 代表设定温度，θ_{min}代表红外图像最小温度数值，θ_{max}代表红外图像最大温度数值。

将 fail 数据作为输入值，代入到 1.3 判定函数中，得到相应结果，将该结果数值关系处理为伯努利分布[12]，从而进行故障特征的自动匹配，其计算公式如下所示：

$$P(t|w)=\frac{\prod_{i=t}^{N}\sigma[y(w)]}{1-N(\alpha_i)} \tag{11}$$

式中：$P(t|w)$代表构建的数值分布，$N(\alpha_i)$代表支持向量机的后验函数，σ 代表权重参数。

对过程进行不断迭代，从而得到最终故障识别结果，实现对变电站二次设备插件故障的识别工作。

2 实验

实验通过 Simulink 软件建立 220 kV 智能变电站二次设备仿真模型，针对插件故障类型进行仿真实验，其仿真实验结构如 4 所示。

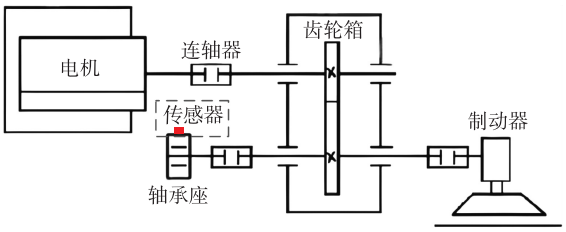

图 4 仿真模型结构图

仿真模型中相关参数设置如表 1 所示。

表 1 实验工具型号表

参数	数值
容量	3 MVA
变比	10 kV/0.4 kV
联结组	Dyn11
空载损耗	1.8×10^{-3} p.u.
铜耗	1.6×10^{-2} p.u.
励磁电流	3%

通过应用三种故障识别方法对 30 个变电站二次设备插件进行识别，并利用传感器对相关数值进行采集，经过三种故障识别方法后计算相关参数，将其与实际剩余寿命做差，将所得数据记录在坐标轴上。

改进神经网络模型关键参数直接影响模型性能和故障识别精度，设置如下：池化操作的缩放因子 α 取值设为 1.0，以保持特征幅值不变，避免引入额外偏差。在卷积和全连接层中的偏置参数初始化为 0，并通过训练优化。激活函数：输出层使用 Sigmoid，隐藏层使用 ReLU 函数，其参数斜率设为 1.0。ReLU 能缓解梯度消失问题，适合处理文档中所述的复杂故障数据。余弦相似度阈值 δ 最小值=0.7。温度概率密度参数 θ 最小值=20 ℃，最大值=100 ℃。

变量取值需结合实际情况设定：输入变量即为滤波器输入值，取值归一化到[0,1]区间。电流数值 I 通过 min-max 缩放，图像灰度值 $h(m,n)$归一化到[0,255]。故障特征向量维度取值为 128。128 维能有效编码多模态信息而不致过拟合。故障概率取值通过训练优化，但初始权重随机设置，方差为 0.01。

实验指标如下：

①引入剩余寿命使用参数作为实验指标，剩余寿命使用参数计算公式如下所示：

$$R=\frac{R'}{1-k^{\frac{\tau}{T}}} \tag{12}$$

式中：τ 代表理想退化参数数值，R 代表剩余寿命使用参数，T 代表退化周期长度，R'代表失效参数数值。

②对三种故障识别方法，结合 20 个存在不同故障类型的插件样本进行识别，并通过与实际值进行对比，计算相应 F1 分数，通过 F1 分数判断三种识别方法是否可以准确识别插件故障。

③对三种故障识别方法识别的样本进行聚类分析，根据聚类结果判断三种故障识别方法是否可以对不同故障类别进行精准分类。

本实验将理想退化模型的迭代周期设置为 9，在迭代过程中，利用式(12)计算每次迭代的剩余寿命参数，并与实际剩余寿命参数数值进行做差处理，通过对比各方法在迭代周期中剩余寿命参数数值与实际剩余寿命参数数值的差值，判断故障识别方法是否准确，其实验结果如图 5 所示。

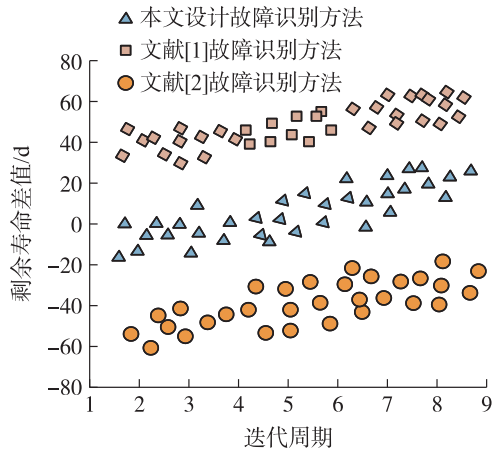

图 5　剩余寿命参数差值

由图 5 可知，剩余寿命参数的预测依赖于故障识别模型的精确度。如果故障识别模型能够准确识别插件的故障模式，那么基于这些故障模式的剩余寿命预测将更为准确。

本文设计方法利用 Sigmoid 函数作为故障特征匹配的激活函数，在神经网络中利用其较高的非线性映射能力，处理复杂的二次设备插件故障数据，以能够更准确地捕捉故障特征，提高识别的准确性。利用三种故障识别方法对二次设备插件进行故障识别，得到对应剩余寿命参数数值。由图 5 可知，文献[2]方法测得剩余寿命参数数值与实际值相差的平均值为−40，最大差值达到 60 天。文献[1]测得剩余寿命参数数值与实际值相差的平均值为 50 天，最大差值达到 65 天。而本文方法测得剩余寿命参数数值与实际值相差的平均值为 10 天，最大差值为 20 天，最小差值为 0。该实验结果表明，本文设计故障识别方法的剩余寿命参数数值与实际值相差最小，其识别精确度最高。

对 20 个实验样本用三种故障识别方法进行故障识别，对比三种识别方法的识别 F1 值，在此基础上对其增加噪声影响，从而观察识别方法是否可以抵抗噪声影响，以验证三种识别方法是否可以准确识别变电站二次设备插件故障。

由图 6 可知，故障判定函数从大量数据中判定不同故障模式的深层次特征，能够在面对数据波动、噪声干扰等复杂情况时，保持稳定的故障识别性能，具有更高的 F1 数值。F1 数值综合考虑了故障识别方法的精确度与识别速度，该数值越高，则表明故障识别方法越能准确地将所有故障插件和正常插件进行区分。由图 6 可知，当增加噪声影响后会对识别结果产生一定的影响，但本文设计故障识别方法 F1 值受噪声影响非常小，前后 F1 值均在 0.9 以上，文献[1]方法 F1 数值受噪声影响较少，前后数值均在 0.5～0.75 之间变化，文献[2]方法受噪声影响较大，在受噪声影响之前 F1 数值在 0.55～0.80 之间变化，在受噪声影响之后，其数值降低了 0.2。通过对比可知，本文识别方法的 F1 值最接近 1，这表明本文识别方法可以准确且稳定地识别故障插件。

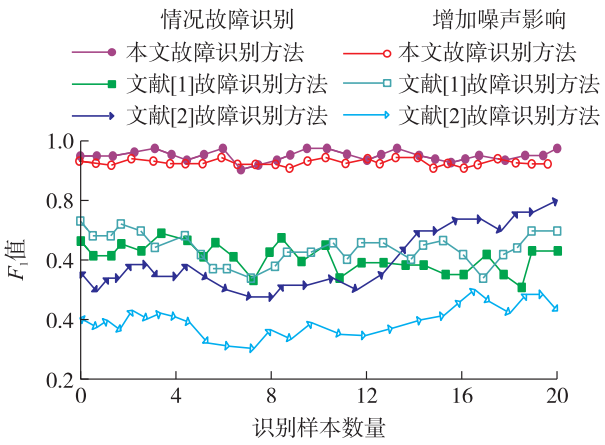

图 6　故障类型识别检测结果

以存在不同故障模式的插件作为实验样本，并分为实验组和对照组，实验组用本文方法进行故障识别，对照组用文献[1]和文献[2]方法。在实验对比中保证客观公正性，三种对比方法的实验条件与数据相同，对上述相同实验样本在时域和频域特征上进行特征提取，形成对应高维特征矩阵。将该矩阵作为降维模型在聚类分析软件中输入，三种方法实验结果如图 7 所示。

由图 8 可知，文献[1]故障识别方法可以对高维特征矩阵进行降维，但针对不同故障特征分类不明显，不同的类别出现混杂现象，难以对故障特征进行分类，出现较严重的聚类错误。文献[2]方法针对故障特征进行了较为明显的分类，但不同故障样本之间距离过近，且少部分故障样本仍存在混杂状态。由图 7 中数据可知，本文故障识别方法成功将不同故障类别进行区分，可以实现对不同故障类别进行精准分类。

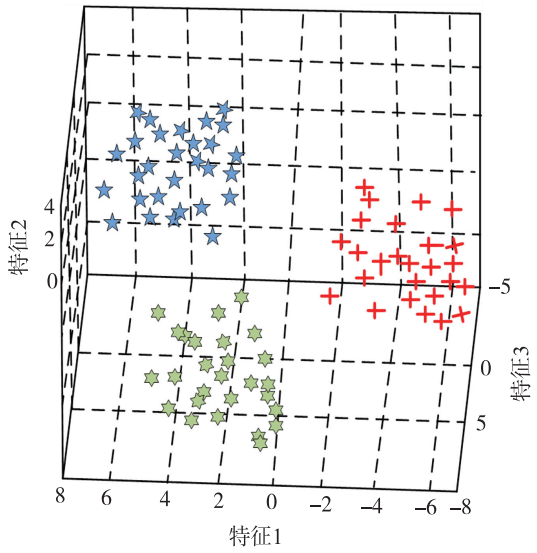

图 7 本文故障识别方法样本识别降维聚类结果

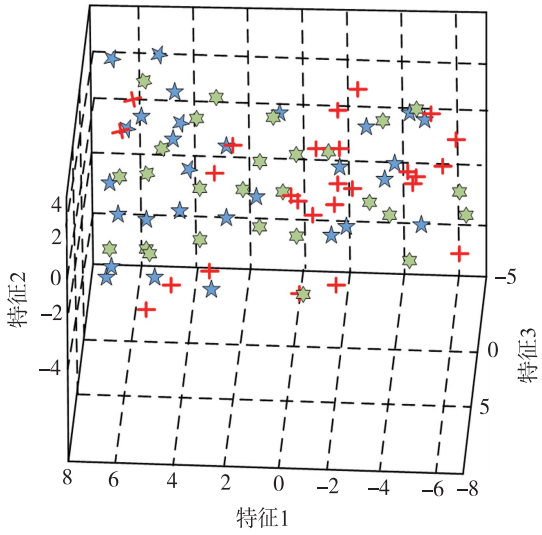

(a) 文献[1]方法降维聚类结果

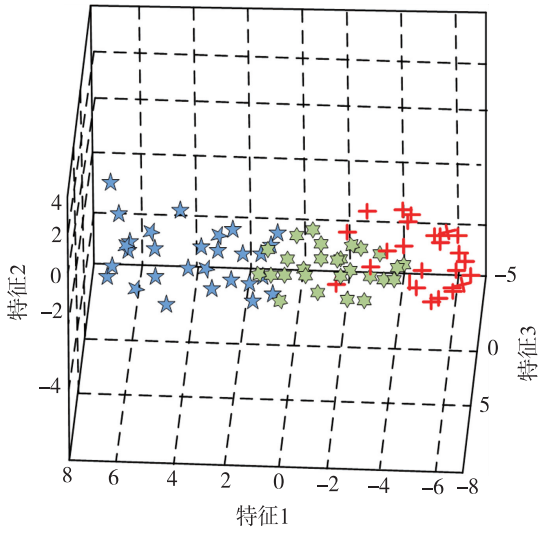

(b) 文献[2]方法降维聚类结果

图 8 对照组故障识别方法样本识别降维聚类结果

3 结束语

针对 220 kV 智能变电站二次设备插件故障，采用 Sigmoid 识别方法进行研究，利用 Sigmoid 方法对故障特征信息的分类能力，准确判断故障类型和位置，提高了故障识别的准确性和效率，从而提升电力系统稳定性和可靠性，为后续的故障排除提供了有力的支持。

但由于智能变电站二次设备插件故障涉及多个方面，因此在实际应用中，需要结合具体故障现象和诊断经验。因此在未来对 Sigmoid 识别方法进行研究中，应不断优化和完善故障识别技术，使其为电力系统的安全运行提供更加坚实的支撑。

参考文献：

[1] 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.

[2] 常仲学，李欢，张志华，等. 基于重合相有功功率的配电网永久性故障识别方法[J]. 电力系统自动化，2024，48(15)：151-159.

[3] 闵伟菘，张文海，王杨，等. 基于 RKELM 的中压电缆早期故障识别与定位方法研究[J]. 供用电，2024，41(10)：3-11.

[4] 许守东，欧阳金鑫，陈宇捷，等. 基于模型识别的有源配电网单相接地故障定位方法[J]. 电力系统保护与控制，2024，52(5)：51-60.

[5] 刘婷，罗皓鹏，王斌，等. 多能互补发电系统故障识别与测距方法[J]. 科学技术与工程，2024，24(6)：2405-2413.

[6] 翁东雷，王露民，莫建国，等. 基于云计算关联分析的电力设备故障识别模型[J]. 电网与清洁能源，2023，39(10)：38-44.

[7] 郑文杰，杨祎，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.

[8] 庞清乐，郑杨，马兆兴，等. 基于 Sigmoid 函数的改进功率预测变步长光伏 MPPT 算法[J]. 电源技术，2023，47(4)：523-527.

[9] 赵张睿，王尧尧，段雅琦，等. 面向飞行机械臂的实时目标检测与定位算法[J]. 南京航空航天大学学报，2022，54(1)：27-33.

[10] 庄文睿，郭谋发. 基于时频谱图的配电网高阻接地故障智能识别方法[J]. 福州大学学报(自然科学版)，2024，52(1)：53-60.

[11] 裴东锋，刘勇，闫柯柯，等. 一种基于 CNN 与 FFT-ELM 的输电线路故障识别与定位方法[J]. 电力科学与技

术学报,2024,39(1):164-170.
[12] 李文博,汤晓君,张泽宇,等. 基于虚拟功率比的柔性直流输电系统短路故障检测方法[J]. 高电压技术,2024,50(10):4703-4712.

耿　波(1976—),男,汉族,山东滨州人,硕士(电气工程),高级工程师,主要研究方向:继电保护技术,电力系统自动化,yue005526@163.com;

褚安琪(1995—),男,汉族,山东滨州人,本科(电气工程及其自动化),工程师,主要研究方向:继电保护技术,电力系统自动化;

牟　哲(1988—),男,汉族,山东滨州人,硕士(电气工程),高级工程师,主要研究方向:继电保护技术,电力系统自动化。

李　巍(1974—),男,汉族,山东滨州人,本科(计算机原理与应用),高级工程师,主要研究方向:计算机技术;

牛健飞(1983—),男,汉族,山东滨州人,本科(电气工程及其自动化),高级工程师,主要研究方向:继电保护技术,电力系统自动化;