

DOI: 10.19783/j.cnki.pspc.240502

基于深度自适应 K-means++ 算法的电抗器声纹聚类方法

闵永智¹, 郝大宇¹, 王果¹, 何怡刚², 贺建山¹

(1. 兰州交通大学自动化与电气工程学院, 甘肃 兰州 730070; 2. 武汉大学电气与自动化学院, 湖北 武汉 430072)

摘要: 在高压并联电抗器声纹信号监测系统中, 长时海量无标签声纹的高维非平稳性导致特征提取困难、无监督聚类适应性差。由此提出了一种基于深度自适应 K-means++ 算法(deep adaptive K-means++ clustering algorithm, DAKCA)的 750 kV 电抗器声纹聚类方法。首先通过采用两阶段无监督策略微调的改进堆叠稀疏自编码器(stacked sparse autoencoder, SSAE), 对快速傅里叶变换后的归一化频域数据提取电抗器原始声纹 32 维深度特征。进一步提出了依据最近邻聚类有效性指标(clustering validation index based on nearest neighbors, CVNN)的自适应 K-means++ 聚类算法, 构建了能自适应确定最优聚类个数的电抗器声纹聚类模型。最后通过西北地区某 750 kV 电抗器实测声纹数据集进行了验证。结果表明, DAKCA 算法对无标签声纹数据在不同样本均衡程度下能够稳定提取 32 维深度特征, 并实现最优聚类, 为直接高效利用电抗器无标签声纹数据提供了参考。

关键词: 750 kV 电抗器; 声纹聚类; 自适应聚类算法; 稀疏自编码器; 深度自适应 K-means++ 算法

Reactor voiceprint clustering method based on deep adaptive K-means++ algorithm

MIN Yongzhi¹, HAO Dayu¹, WANG Guo¹, HE Yigang², HE Jianshan¹

(1. School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China;

2. School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China)

Abstract: In high-voltage shunt reactor voiceprint signal monitoring systems, the high-dimensional non-stationarity of long-term, large-scale unlabeled voiceprint data make feature extraction difficult and reduce the adaptability of unsupervised clustering. To address this, a 750 kV reactor voiceprint clustering method based on deep adaptive K-means++ clustering algorithm (DAKCA) is proposed. First, the improved stacked sparse autoencoder (SSAE), fine-tuned using a two-stage unsupervised strategy, is used to extract the 32-dimensional depth features from the normalized frequency domain data obtained via fast Fourier transform. Then, an adaptive K-means++ clustering algorithm is developed using clustering validation index based on the nearest neighbor (CVNN), and a reactor voiceprint clustering model which can adaptively determine the optimal number of clusters is constructed. Finally, the method is validated using real measured voiceprint data from a 750 kV reactor in Northwest China. The results demonstrate that the DAKCA algorithm can stably extract 32-dimensional depth features from unlabeled voiceprint data under varying sample balance conditions and achieve optimal clustering, providing a reference for the direct and efficient use of unlabeled reactor voiceprint data.

This work is supported by the National Natural Science Foundation of China (No. 62066024).

Key words: 750 kV reactor; voiceprint clustering; adaptive clustering algorithm; sparse autoencoder; DAKCA

0 引言

在高电压远距离输电系统中, 高压并联电抗器作为关键设备, 对于调控输电线路的无功功率、限

制短路电流及保持电压稳定起到了至关重要的作用^[1-2]。在高压并联电抗器运行过程中, 由铁芯与绕组振动产生的声纹信号包含丰富的运行状态信息, 通过分析声纹信号可以实现对电抗器的状态监测^[3-4]。由于在实际变电站中获取大量标注的声纹数据既耗时又昂贵, 且声纹信号具有高维非平稳的特性, 导致特征提取困难以及模式识别适应性差。因此, 针

基金项目: 国家自然科学基金项目资助(62066024); 甘肃省联合基金项目资助(24JRR852)

对无标签电抗器声纹数据，研究电抗器声纹判别方法，对实现电抗器声学状态监测具有重要意义。

针对电抗器或变压器等电力设备声纹识别问题，国内外研究学者已开展大量理论及应用研究工作。一些研究人员基于传统机器学习理论研究声纹识别方法。文献[5]中提出使用梅尔频率倒谱系数(Mel-frequency cepstral coefficients, MFCC)进行变压器声纹特征提取，并基于快速增量式支持向量数据描述以及门控循环单元对其进行识别；文献[6]提取 MFCC 特征向量并提出使用单类支持向量机(one-class support vector machine, one-class SVM)进行新奇检测，随后使用 C 参数支持向量机(C-parameterized support vector machine, C-SVM)进行电气设备声纹识别。然而传统机器学习方法存在提取特征能力有限、辨识准确率低等问题，在深度学习不断发展的背景下，研究人员探索了深度学习网络的声纹识别方法。文献[7]结合优化的高斯窗 S 变换和深度残差收缩网络，提出了一种新的饱和电抗器铁心松动程度声纹识别模型，优于传统深度学习方法，为在线监测提供了有力支持。尽管上述方法均取得了优异的成绩，但它们普遍依赖于大量标注数据。然而，在实际变电站中，获取大量标注声纹数据既耗时又耗力，这极大地限制了有监督深度声纹识别算法的应用范围和实用性。此外，当有监督^[8]深度声纹识别算法面对未知或新出现的故障类型时，往往难以有效识别，这进一步加大了电力设备监测和诊断的难度。

相比之下，无监督学习^[9]算法直接从无标签数据中提取特征，无需手动选择和先验信号处理技术^[10]，不依赖数据标注，为识别新型或未知故障提供了可能。然而，在高压并联电抗器声纹识别领域，关于无监督学习方法的研究相对较少，仍存在较大研究空白^[11]。自编码器(autoencoder, AE)作为最常用的无监督学习算法之一^[12]，具有纯无监督性质，可以提取低维代表特征。文献[13]通过搭建卷积自编码器对变压器声纹数据的多粒度知识(multi-granularity knowledge, MGK)特征进行降维处理，最终实现变压器机械故障的精准辨识。文献[14]提出了一种一维残差收缩自编码器，以无监督的方式直接从振动信号中提取特征。文献[15]提取了基于度分布的变压器振动信号特征并据此构建了基于栈式自编码器(stacked autoencoder, Stacked AE)的变压器机械故障诊断模型。Stackd AE 是一个由多个 AE 叠加而成的深度神经网络，可以有效地拟合复杂数据并表征非线性特征，但其训练占据大量时间及计算资源且易

过拟合。文献[16]提出了一种综合阻带滤波器和稀疏自动编码器(sparse autoencoder, Sparse AE)的特高压变压器本体噪声提取方法，对比分析了特高压变压器噪声信号分离前后的频谱瀑布图。稀疏自编码器通过引入稀疏性惩罚减少过拟合的风险。鉴于自编码器在电气和机械设备等振动信号处理中已经取得了一定的成果^[17]，本研究尝试将自编码器引入电抗器声纹特征提取中，以研究无监督电抗器声纹聚类方法。尽管传统聚类算法^[18-20]应用广泛，但面对电抗器声纹数据的复杂性，其聚类效果并不理想。特别是，传统的 K-means 算法在初始聚类中心选择上存在随机性^[21]，易受噪声影响，并且簇数 k 的选择由实际情况所决定^[22]，导致聚类效果不稳定。

为此，本文提出一种基于深度自适应 K-means++ 算法的 750 kV 电抗器声纹聚类方法以解决无标签电抗器声纹聚类问题。首先，利用堆叠稀疏自编码器(stacked sparse autoencoder, SSAE)提取声纹信号的深度特征，降低数据维度同时保留核心信息；其次，结合最近邻聚类有效性指标(clustering validation index based on nearest neighbors, CVNN)提出改进 K-means++ 算法进行聚类并以此构建电抗器声纹聚类模型，自适应确定聚类数量，提高聚类适应性和准确性。

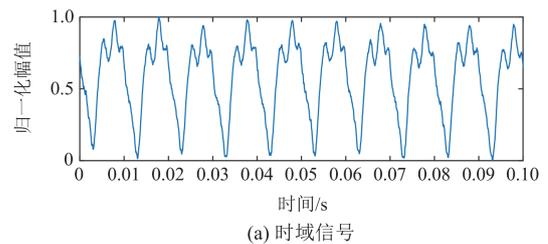
1 基于 SSAE 的 750 kV 电抗器声纹特征提取

由于高压并联电抗器的复杂结构以及发声机理的非线性，其声纹信号呈现出显著的时变性和非平稳性。因此，选取该电抗器在正常和异常运行状态下的典型声纹进行分析，并在此基础上提取电抗器声纹的深度特征。

1.1 750 kV 电抗器声纹时域与频域特性分析

图 1 为某 750 kV 电抗器在正常运行状态下声纹的时域信号及其频域分布。

当某 750 kV 电抗器发生异常，声纹信号的时域波形幅度及频率成分将发生明显变化。附录 A 图 A1 展示了该电抗器异常状态下实测声纹的时域和频域图，异常状态包括直流偏磁、组件松动、局部放电、外壳松动和重过载，这些异常会改变声纹的时域波形与频谱分布。与时域信息相比，频域信息



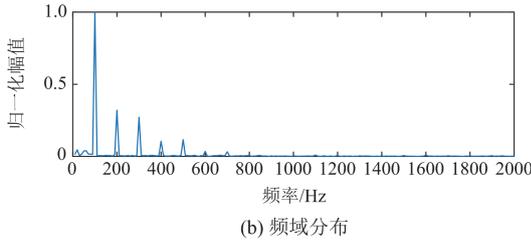


图 1 电抗器正常运行期间的声纹时域信号及频域分布图
Fig. 1 Time domain signal and frequency domain distribution of the voiceprint during the normal operation of the reactor

不仅可以更有效地进行信号压缩, 还能更清晰地展示声纹特征的频谱差异。

因此, 本文主要分析电抗器声纹的频域特征, 通过快速傅里叶变换将原始声纹数据转为归一化频域数据, 为后文特征提取和聚类分析提供基础。

但直接使用频域特征可能面临维度高、冗余多、噪声干扰等问题。堆叠稀疏自编码器能自动学习无标签数据的特征表示, 通过高级表示学习提取出有代表性和区分度的特征, 降低维度, 提高聚类准确性和泛化能力。因此, 本文采用堆叠稀疏自编码器提取电抗器声纹深度特征。

1.2 SSAE 提取电抗器声纹深度特征

稀疏自编码器是一种无监督学习算法, 作为自编码器的衍生形式, 由编码器和解码器组成, 以重构输出逼近原始输入为目的。为提取电抗器声纹深度特征, 采用 SSAE, 它是由多个稀疏自编码器堆叠而成的深度神经网络。SSAE 结合了稀疏性和深度结构的优点, 即使网络包含大量隐藏神经元, 也能保持稀疏性并揭示输入数据的结构。这种深层结构有助于提升特征提取的质量和训练效果, 如图 2 所示。

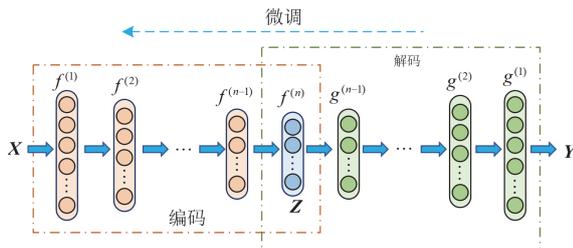


图 2 堆叠稀疏自编码器结构图

Fig. 2 Diagram of stacked sparse autoencoder structure

输入数据是经过快速傅里叶变换并归一化处理的 d 维电抗器原始声纹数据, 记为 $X \in \mathbb{R}_{N \times d}$, 该数据通过非线性激活函数 $f(\cdot)$ 输入至含有 N 个神经元的编码层, 此处选用 softplus 激活函数, 如式(1)所示, 得到 $Z \in \mathbb{R}_{N \times n}$ 的结果如式(2)所示。

$$\text{softplus}(x) = \log(1 + e^x) \quad (1)$$

$$Z = f(W_1 X + b_1) \quad (2)$$

式中: W_1 为权值矩阵, $W_1 \in \mathbb{R}_{d \times n}$; b_1 为编码层偏置向量, $b_1 \in \mathbb{R}_{N \times 1}$ 。然后, 将 Z 输入解码层 Y , 如式(3)所示。

$$Y = g(W_2 Z + b_2) \quad (3)$$

为了减少需要训练的参数数量, 一般 $W_2 = W_1^T$, $b_2 \in \mathbb{R}_{n \times 1}$ 为解码层偏置向量。通过训练调整权值矩阵 W_1 和偏置向量 b_1 、 b_2 , 使损失函数式(4)最小。

$$J(W, b) = \frac{1}{N} \sum_{i=1}^N \left(\frac{1}{2} \|x^i - y^i\|^2 \right) + \frac{\lambda}{2} \sum_{i=1}^d \sum_{j=1}^n (w_{ij}^2) \quad (4)$$

式中: 第一项是输入输出数据之间的总平方误差; 第二项是用于避免 AE 过拟合的权值衰减项; $J(W, b)$ 是损失函数, 用于衡量自编码器的重构误差和权值正则化项的总和; N 是样本数量; x^i 是第 i 个输入样本; y^i 是第 i 个输出样本(重构后的样本); λ 是权值衰减项的系数, 用于防止过拟合; d 是输入样本的维度; n 是隐藏层神经元的数量; w_{ij} 是权值矩阵中的一个元素, 表示输入层的第 i 个输入与隐藏层的第 j 个神经元之间的连接权重。训练完成后, 隐含层的输出是输入数据的有效降维特征表示。

稀疏自编码器是在自编码器的基础上加入稀疏约束得到的, 隐藏层神经元 j 的平均激活 $\hat{\rho}_j$ 为

$$\hat{\rho}_j = \frac{1}{n} \sum_{i=1}^n [a_j(x^{(i)})] \quad (5)$$

式中, $a_j(x^{(i)})$ 表示隐藏层神经元 j 在给定输入 $x^{(i)}$ 下的激活程度。为了实现稀疏性, 将在损失函数中增加一个额外的惩罚项, 一般采用 KL 散度, 见式(6)。

$$\text{KL}(\rho \parallel \hat{\rho}_j) = \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (6)$$

式中, ρ 为稀疏参数, 表示隐藏层神经元的目标平均激活值。

此时稀疏自编码器的损失函数 $J_{\text{sparse}}(W, b)$ 如式(7)所示。

$$J_{\text{sparse}}(W, b) = J(W, b) + \beta \sum_{j=1}^n \text{KL}(\rho \parallel \hat{\rho}_j) \quad (7)$$

式中, β 为稀疏惩罚项的权值。

使用反向传播算法迭代更新网络参数, 优化损失函数式(7), 直到式(7)收敛到期望的局部最小值, 从而实现稀疏自编码器的无监督特征学习。

SSAE 通过逐层无监督预训练, 逐步堆叠稀疏自编码器构建深度神经网络, 以监督微调优化参数。由于电抗器声纹数据缺乏标签, 无法使用传统监督微调方法, 因此进行如式(8)所示的调整。

$$J_{SSAE}(\mathbf{W}, \mathbf{b}) = \frac{1}{N} \sum_{i=1}^N \left(\frac{1}{2} \|x^i - y^i\|^2 \right) + \beta \sum_{j=1}^n \text{KL}(\rho \| \hat{\rho}_j) \quad (8)$$

通过最小化最后一个稀疏自编码器隐藏层输出的 KL 散度，提取电抗器声纹的深度特征。完成训练后，即可得到参数优化的 SSAE。

2 基于 DAKCA 算法的 750 kV 电抗器声纹聚类模型

依据上述理论无监督提取 750 kV 电抗器的声纹深度特征，针对特征进行聚类分析，以更加准确地区分电抗器不同状态的声纹特征。传统 K-means 聚类方法在处理球形或椭球形信号时计算效率高^[21]，但难以捕捉具有非线性非平稳特性的电抗器声纹数据真实结构，尤其是在数据分布不均或形状复杂时。为此，结合最近邻聚类有效性指标 CVNN 提出自适应 K-means++ 算法并以此构建基于深度自适应 K-means++ 算法的 750 kV 电抗器声纹聚类模型，在不预先设定聚类个数的情况下对所提特征自适应地确定最优聚类结果。

2.1 自适应 K-means++ 聚类算法

SSAE 提取的电抗器声纹特征形成含 N 个样本的集合 $\mathbf{H} = \{h_1, h_2, h_3, \dots, h_N\}$ ，以此作为 K-means++ 聚类算法的输入。通常情况下，聚类数 K 需根据实际情况确定。然而，由于高压电抗器声纹数据往往无标签，难以预先判断设备健康状态，因此聚类分析时无法预设聚类数。为解决此问题，引入基于最近邻聚类有效性指标 CVNN 来选择最佳簇数。设聚类数的范围^[23]是 $[2, \sqrt{N}]$ ，提出改进 K-means++ 聚类算法，该算法能在不预先设定聚类数的情况下，自适应地确定最符合电抗器实际健康状况的聚类个数。

最近邻聚类有效性指标 CVNN 是一种内部度量指标，能够弥补现有聚类度量指标在处理任意形状簇数据时的不足。它通过动态选择多个对象作为各簇代表，综合最近邻一致性、动态多重代表、簇间分离度和簇内紧密度 4 个特点，有效应对不同形状和大小的簇，对噪声和异常值也有较强鲁棒性，且计算高效，适用于电抗器声纹特征聚类。通过优化参数 k ，可提升簇间分离度的计算精度，综合考虑数据全局和局部特征，从而提高聚类结果的准确性和可靠性。

定义 CVNN 指标 $C_{\text{VNN}}(K, k)$ 如式(9)所示。

$$C_{\text{VNN}}(K, k) = S_{\text{ep_norm}}(K, k) + C_{\text{om_norm}}(K) = \frac{S_{\text{ep}}(K, k)}{\max_{K_{\min} \leq K \leq K_{\max}} S_{\text{ep}}(K, k)} + \frac{C_{\text{om}}(K)}{\max_{K_{\min} \leq K \leq K_{\max}} C_{\text{om}}(K)} \quad (9)$$

式中： $S_{\text{ep}}(K, k)$ 代表簇间分离度； $S_{\text{ep_norm}}(K, k)$ 代表归一化后簇间分离度； K 代表聚类数； k 为聚类过程中考虑的邻近点的数量； $C_{\text{om_norm}}(K)$ 代表归一化后簇内紧凑度； $C_{\text{om}}(K)$ 代表簇内紧凑度； K_{\min} 和 K_{\max} 分别为最小及最大聚类数。

$$S_{\text{ep}}(K, k) = \max_{i=1,2,\dots,K} \left(\frac{1}{n_i} \sum_{j=1,2,\dots,n_i} \frac{q_j}{k} \right) \quad (10)$$

式中： n_i 为第 i 个簇中的样本数； q_j 为第 i 个簇中的第 j 个样本的 k 个最近邻中不属于第 i 个簇的样本数。 S_{ep} 值越小表示簇间分离度越高，可有效衡量聚类簇的分散程度。

$$C_{\text{om}}(K) = \sum_{i=1}^K \left(\frac{2}{n_i \cdot (n_i - 1)} \sum_{x,y \in C_i, x \neq y} d(x, y) \right) \quad (11)$$

式中： C_i 是第 i 个簇； x 和 y 是第 i 个簇 C_i 中的任意两个不同的样本； $d(x, y)$ 是样本 x 和 y 之间的距离。 C_{om} 值小表示簇内样本距离近，簇内紧密度高，可有效衡量聚类结果中簇的紧密程度。

在 CVNN 中，参数 k 代表每个对象的最近邻数量，对簇间分离度、敏感性、计算复杂度、最优聚类数和数据特性适应性均产生影响。通常，可以通过观察不同 k 值下聚类结果的稳定性，根据经验来选择合适的 k 值，此处选择 $k = 10$ 。

CVNN 指标为归一化聚类间分离度和聚类内紧凑度之和，较低值表示较好的聚类结果。因此，选择 CVNN 指标最小值对应的聚类数确定最佳聚类个数。

自适应 K-means++ 聚类算法的步骤如下所述。

步骤 1：初始化算法参数。将聚类数 K 设置为 $[2, \sqrt{N}]$ ， $\varepsilon = 1 \times 10^{-4}$ ， $k = 10$ 。在极限理论中， ε 代表一个大于 0 的任意小正数，用于衡量数列或函数值与极限值的接近程度。例如，在 ε - N 或 ε - δ 定义中， ε 表示允许的最大误差范围，通过调整参数(如 N 或 δ)确保结果满足精度要求。

步骤 2：初始分配。通过将每个样本特征分配到最近的中心点来进行初始分配，从而形成数据的初始划分。

步骤 3：更新中心点。根据步骤 2 的结果计算各个簇的中心点，确保中心点是簇内点的均值向量。

步骤 4：收敛检验。判断聚类中心的变化是否小于 ε ，若是，则执行步骤 6；否则，继续执行步骤 5。

步骤 5： $K = K + 1$ ，如果 K 小于或等于 \sqrt{N} (预定的最大簇数)，则重复执行步骤 2；如果 K 超过 \sqrt{N} ，则计算 CVNN 值，选择 CVNN 最小值对应的 K 作为最优聚类数。

步骤 6: 输出 CVNN 最小值及对应的最优聚类数 K 。

在电抗器声纹数据的聚类分析中, 传统 K-means++算法需预先设定聚类数, 而引入 CVNN 指标后, 算法能自适应地确定最佳聚类数。CVNN 通过优化聚类间分离度和聚类内紧凑度提升聚类质量, 有效区分远距离特征和细微声学差异, 该指标对非球形或不规则聚类及含噪声、异常值的非线性非平稳声纹数据更具适应性。

自适应 K-means++算法作为无监督学习方法, 能处理无标签数据, 揭示潜在故障模式, 减少对数据标签的依赖, 提高声纹聚类的效率和准确性, 其算法流程图见图 3。

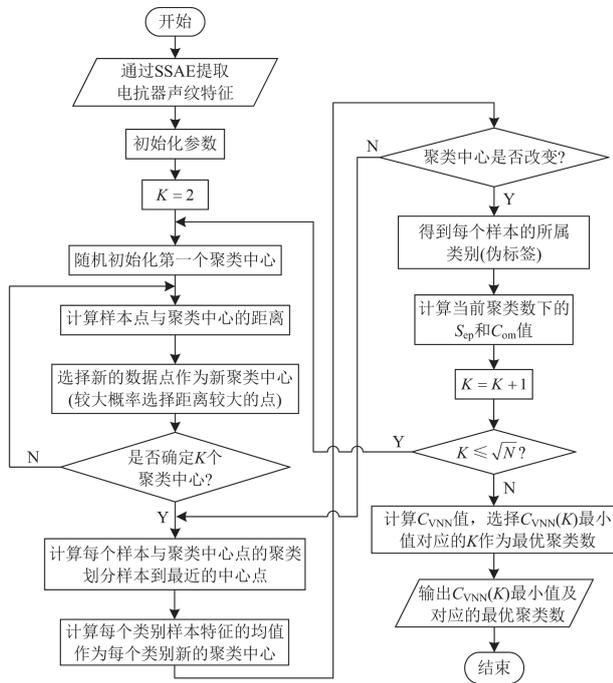


图 3 自适应 K-means++算法流程图

Fig. 3 Flow chart of adaptive K-means++ algorithm

2.2 基于 DAKCA 算法的电抗器声纹聚类流程

两阶段深度自适应 K-means++聚类算法(deep adaptive K-means++ clustering algorithm, DAKCA)结合了 SSAE 和自适应 K-means++算法, 其网络结构如图 4 所示。在第一阶段, SSAE 从电抗器声纹信号中逐层提取深层特征, 有效表征样本并减少噪声干扰; 在第二阶段, 将第一阶段提取的特征输入到自适应 K-means++中聚类, 实现电抗器声纹数据的无监督自适应聚类。

图 4 展示了 SSAE 在 DAKCA 的两个阶段中的微调过程。在第一阶段, SSAE 直接利用式(8)进行微调; 在第二阶段, 获得聚类个数 K 对应的 CVNN

值后, 对 SSAE 进行进一步微调。随后, 将微调后的隐藏层输出作为改进的 K-means++聚类算法的输入, 再次聚类并重新计算 CVNN 值。若 CVNN 值减小, 则重复上述操作, 直至 CVNN 值稳定。此过程确保得到当前聚类数 K 下的最优聚类结果。

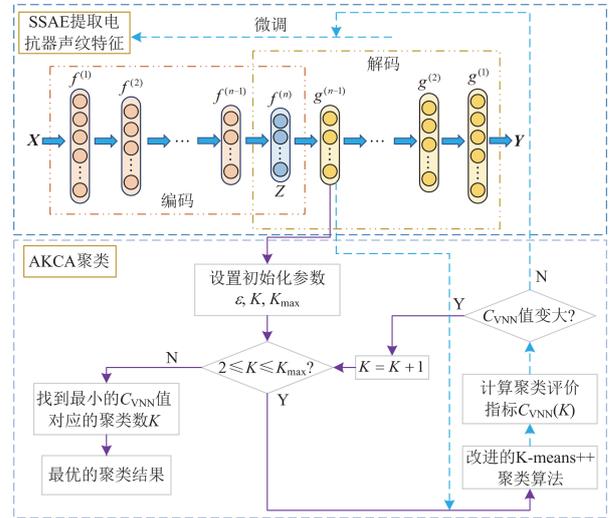


图 4 DAKCA 算法网络结构图

Fig. 4 Diagram of DAKCA algorithm network structure

由于电抗器声纹数据无标签, 第一阶段的微调可能无法获得最具代表性的特征, 但第二阶段的微调有效弥补了这一不足。通过 SSAE 的两阶段微调策略, SSAE 与 K-means++紧密结合, 提高了聚类的准确性。

完成整个 DAKCA 模型训练后, 获得最优聚类结果, 实现无监督聚类。最终, 声纹诊断人员将依据此结果判断电抗器声纹类型。

基于 DAKCA 算法的电抗器声纹聚类方法的具体步骤如下所述。

步骤 1: 在待分析的原始无标签数据集中, 从每个数据文件抽取约 0.1 s 的数据, 选取的数据构成后续分析的样本集。

步骤 2: 根据样本集的采样频率进行数据分段, 随后对其进行快速傅里叶变换, 从而获得频域数据, 并进行归一化处理。

步骤 3: 将归一化的频域数据送入 DAKCA 网络进行训练, 按照前文描述的训练过程获取最优聚类结果。

步骤 4: 从最佳聚类结果的各个类别中选取若干数据文件, 交给电力设备声纹识别专家, 通过其专业经验分析数据, 最终评估电抗器的健康状态。

通过上述步骤, 实现了利用无标签振动数据进行无监督的电抗器声纹聚类, 仅在最终阶段依赖专

家知识, 显著节省了时间和人力资源。

3 实验与结果分析

3.1 750 kV 电抗器声纹数据集

为验证所提方法在电抗器声纹信号聚类的有效性, 实验选取西北某变电站的 750 kV B 相电抗器声纹数据。电抗器正常运行时的现场声纹采集图见图 5。实验依据 GB/T 3785.1-2023 标准, 利用自主开发的声纹采集系统收集声纹数据。该系统的前端配置了 CHZ-213+YG-201 型声压传感器, 此传感器的灵敏度标为 50 mV/Pa, 可覆盖 20 Hz 至 20 kHz 的频率范围。数据采集模块采用 PCI8862 型采集卡, 支持最多 8 通道输入, 最高可达 102.4 kHz 的采样率。根据采样定理及实际经验, 各通道的采样率设为 48 kHz。根据 GB/T 1094.10-2003 标准, 对传感器阵列进行布置, 声压传感器布置于电抗器规定轮廓线上(电抗器规定轮廓线距电抗器基准发射面 1 m), 高度为 1.5 m, 同侧传感器之间距离大于 1 m, 所有传感器电容式极头正对电抗器, 声压传感器布置示意图如图 6 所示, 8 通道传感器依次为 M_1 — M_8 。



图 5 电抗器声纹现场实测图

Fig. 5 On-site measurement diagram of the voiceprint of the reactor

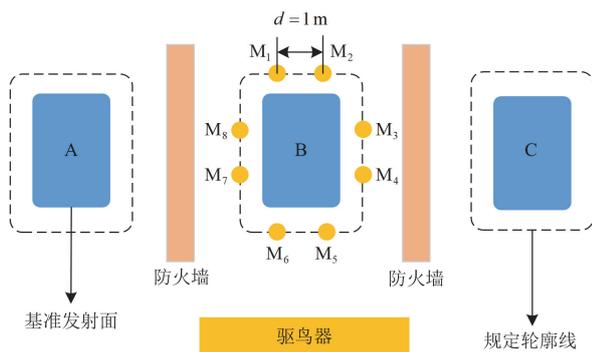


图 6 声阵列布置示意图

Fig. 6 Diagram of sound array layout

研究依托现场采集和历史积累的数据样本, 构建了一个包含 6 种电抗器故障类型的声纹数据集。正常运行状态下的电抗器声纹样本是通过自主开发的声纹采集系统, 在西北某变电站内对 750 kV 电抗

器进行采集而获得的, 而不同类型的故障样本则来自于与课题组合作的中国电力科学研究院有限公司在电抗器实际运行中积累收集的历史故障数据。数据集涵盖的正常与故障状态分别为: 正常运行(标签 0)、局部放电(标签 1)、直流偏磁(标签 2)、组件松动(标签 3)、铁芯松动(标签 4)和重过载(标签 5)。数据集共 3358 条音频切片样本, 每个音频切片长 0.1 s, 含 4800 个采样点, 采样率均为 48 kHz。由于实际中故障的电抗器较少, 故障样本不足, 使用 SMOTE 算法对故障数据进行扩充, 从 439 组增至 2500 组, 缓解了数据不平衡的问题^[24]。

为全面评估模型的有效性与鲁棒性, 设置均衡数据集(D1、D2、D3)与非均衡数据集(D4、D5)两种数据集。如表 1 所示, 均衡数据集中正常样本和各类故障样本(局部放电、直流偏磁、组件松动、铁芯松动以及重过载, 下同)的比例为 1:1:1:1:1:1, 这有助于防止模型偏向于某个特定类别, 从而更准确地反映模型的真实性能; 在非均衡数据集中, 正负样本比例不同, 其中, D4 数据集中正常样本和各类故障样本的比例为 3:1:1:1:1:1, D5 数据集中正常样本和各类故障样本的比例为 4:1:1:1:1:1, 可以评估模型在处理不平衡数据时的鲁棒性和有效性, 更符合实际应用场景。

表 1 电抗器声纹样本数据集划分

Table 1 Data set division of reactor voiceprint sample

数据集	正常类数量	非正常类数量(5类)	总样本数量
D1	200	1000	1200
D2	300	1500	1800
D3	500	2500	3000
D4	300	500	800
D5	400	500	900

3.2 特征提取结果分析

为验证 SSAE 的特征提取能力, 将 SSAE 与主成分分析(principal component analysis, PCA)、Stacked AE 和 Sparse AE 算法进行效果对比。

首先, 应用快速傅里叶变换(fast Fourier transform, FFT)将电抗器声纹的时域数据转换为频域数据, 然后将频域数据的幅值归一化至[0,1], 作为特征提取算法的输入。SSAE 特征的二维 t-SNE 分布点图如图 7 所示, 图 8 显示出了原始数据与不同对比算法所提取特征的二维 t-SNE 分布点图。

图 7 和图 8 表明 SSAE 在声纹数据中具有最好的特征提取能力, 完全分离了各种健康状况; 其他算法的特征提取效果较差, 并且某些健康状况之间出现了一定程度的重叠。结果表明选用 SSAE 作为无监督特征提取算法是有效的。

为了进一步证明上述结论, 使用模式识别和聚类分析中最常用的准则函数 S_b/S_w 指数来评估不同方法提取的特征的可分离性^[25], 如式(12)所示。

$$\frac{S_b}{S_w} = \frac{\sum_{i=1}^C m_i \|\mu_i - \mu_f\|^2}{\sum_{i=1}^C \sum_{f \in C_i} \|f - \mu_i\|^2} \quad (12)$$

式中: C 为类别数; m_i 为第 i 类样本的个数; μ_i 为第 i 类样本的平均特征向量; μ_f 为所有类样本的总平均特征向量, $\mu_f = \sum_{i=1}^C \mu_i / C$; f 为样本向量; C_i 为第 i 类样本的集合。

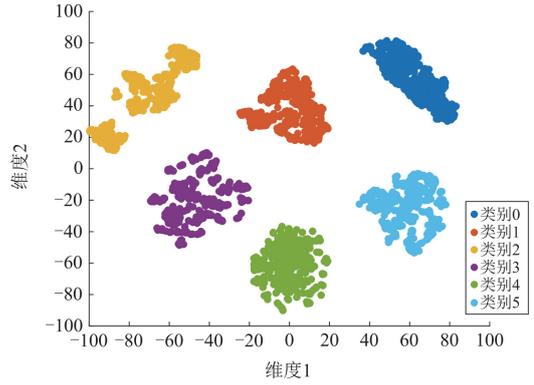


图 7 SSAE 特征提取结果

Fig. 7 Result of SSAE feature extraction

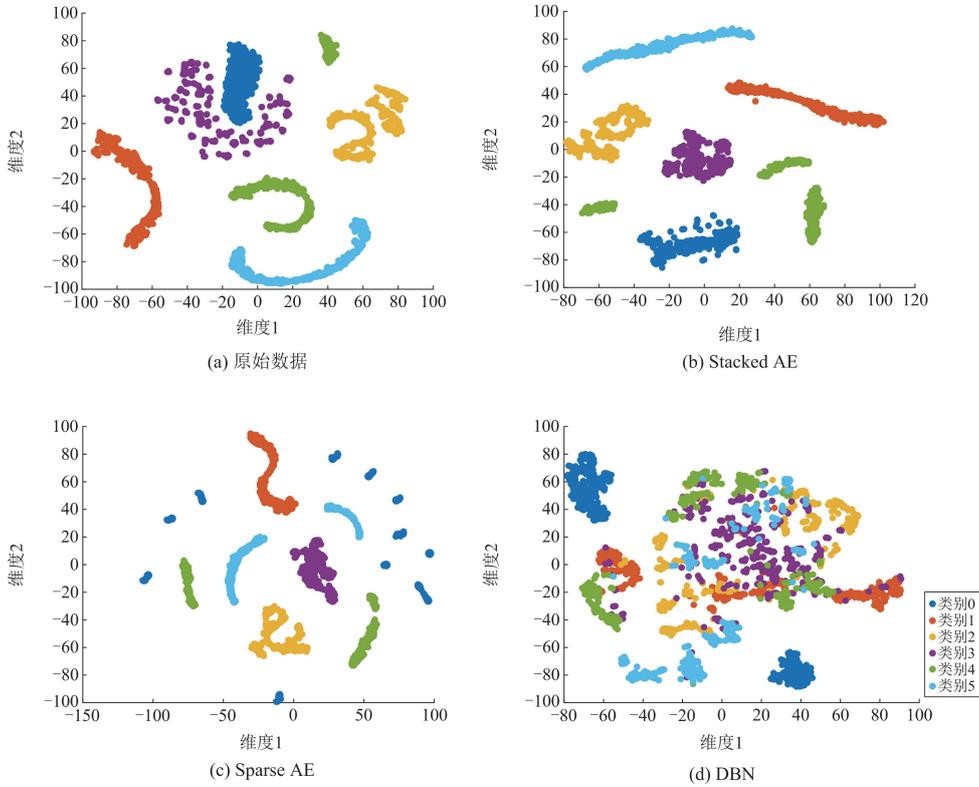


图 8 不同方法特征提取结果对比

Fig. 8 Comparison of feature extraction results of different methods

图 9 结果显示, 在 D1—D5 不同样本情况下, SSAE 的 S_b/S_w 指数均优于其他对比算法, 表明 SSAE 提取的特征具有最好的可分离性。

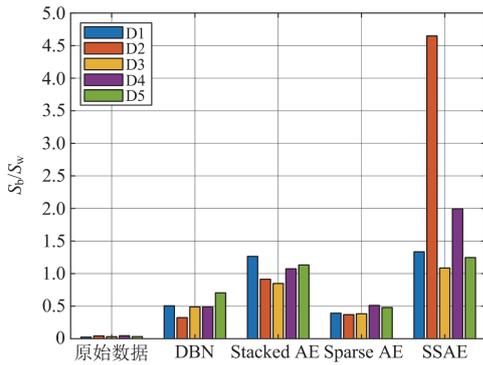
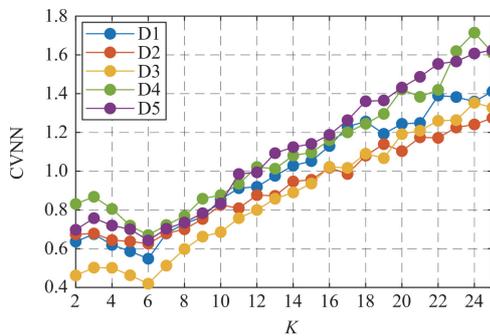
综上, 由图 8、图 9 及分析可知, 与其他算法相比, SSAE 提取的特征具有最好的可分离性, 充分证明了 SSAE 作为特征提取算法的有效性。

3.3 声纹聚类结果分析

利用所提 DAKCA 算法在电抗器声纹数据 D1—D5 上进行实验, 比较不同聚类评价指标对聚类结果的影响。实验中 DAKCA 相关网络参数设置如下:

SSAE 有 4 个隐藏层, 对应各层的网络节点为 4800-512-256-32, 稀疏率 $\beta = 0.1$, 批尺寸(batch size)为 256, 迭代次数(epoch)为 100, 聚类样本数据的簇数范围设置: $K_{\min} = 2$, $K_{\max} = 25$, 聚类评价指标随聚类数 K 的变化如图 10 所示(重复 10 次实验取平均值)。

如图 10 所示, 当结合 CVNN 指标时, K-means++ 算法在最小 CVNN 值的情况下确定了最佳簇数为 6, 这与电抗器实际声纹状态的数量相吻合。CVNN 值随着 K 值的的增长呈 U 形变化, 且在 K 等于 6 时达

图9 不同算法的 S_b/S_w 指标值Fig. 9 S_b/S_w index values of different algorithms图10 CVNN 指标随聚类数 K 的变化Fig. 10 Change of CVNN index with the number of clusters K

到最低点。在数据集 D1—D5 中, CVNN 值在 $K=6$ 附近均出现了明显的最低点, 随后便呈现上升趋势。CVNN 的最小值准确地反映了最佳聚类数, 即相应的 K 值, 从而确保了聚类的清晰区分。

为了进一步验证 CVNN 指标的有效性, 分别将 K-means++ 算法与附录 A 表 A1 所示传统 11 个聚类评价指标^[26]相结合进行聚类。

不同的聚类指标在聚类过程中使用相同的策略来微调 SSAE, 每个实验重复 10 次, 各聚类指标结果取 10 次实验平均值, 如附录 A 图 A2 所示。

在分析 11 种传统聚类评价指标确定电抗器声纹的最佳聚类数时, 这些指标的表现可以归类为 3 种主要趋势:

- 1) 随聚类数 K 增加而单调变化的指标;
- 2) 随聚类数 K 增加而显示不一致或波动的趋势;
- 3) 随聚类数 K 增加而表现出极值, 但趋势不稳定或准确性有限。

随着聚类数 K 的增加, 一些指标出现单调变化, 如 R 平方 (R_s) 和修改后的 Hubert Γ 统计量 (Γ) 逐渐增大, 而均方根标准差 (R_{MSSTD}) 和 S_{Dbw} 有效性指数 (S_{Dbw}) 逐渐减小。然而, 由于簇大小不均衡和噪声等因素, 这些指标在评估聚类质量时可能存在局

限性, 并且电抗器声纹数据具有非线性特征和复杂分布, 导致聚类质量与 K 值的关系复杂, 可能出现多个局部最优解。因此, 仅依赖单一指标可能无法全面准确地评估最优的聚类结果。

随着聚类数 K 的增加, Calinski-Harabasz 指数 (C_H)、I 指数 (I)、Dunn 指数 (D)、Xie-Beni 指数 (X_B) 等指标表现不一致和波动。 C_H 指标在初期上升, 但 $K > 1$ 后增速减缓或下降, 对噪声和异常值敏感, 簇形态不规则时准确性降低。 I 指标随 K 的增加, 最大值簇数不一致, 受簇内外差异和数据特性影响, 有效性受限; D 指标显示, 最大 D 值簇数随 K 增加波动, 受噪声和簇大小不均影响; X_B 指标波动显著, 最低值通常出现在 $K=4$ 或 5 , 与预期 $K=6$ 不符, 可能不稳定或不准确。

随着聚类数 K 的增加, 轮廓系数 (S)、Davies-Bouldin 指数 (D_B) 和 SD 有效性指数 (S_D) 表现出极值点且不稳定。这些指标在确定电抗器声纹的最佳聚类簇数时存在准确性和稳定性问题, 特别是对形状不规则的簇容易失效, 高维、非线性和复杂分布的电抗器声纹数据使得基于距离的聚类指标难以准确捕捉其结构。

与传统的 11 种聚类评价指标相比, CVNN 通过引入最近邻关系, 克服了传统指标如 R_{MSSTD} 和 R_s 等在簇间分离度或簇大小不均时的局限, 为簇内紧密度和簇间分离度提供了全面而准确的评价。在电抗器声纹数据聚类中, CVNN 能准确判断并优化聚类算法, 选择最佳聚类数, 优于其他对比指标。

综上, DAKCA 充分考虑初始聚类中心的选择以及各种样本对聚类结果的影响, 并利用 CVNN 指标来获得最佳聚类结果。DAKCA 是一种有效的无监督聚类方法, 完全使用无标签数据。

4 结论

1) 提出了一种基于深度自适应 K-means++ 的 750 kV 电抗器声纹聚类算法, 该算法能够提取无标签声纹数据的深层特征, 并且与传统的 K-means 算法相比, 该算法无需预先设定聚类数量, 即可自适应地确定最优聚类数。

2) 实测结果表明, DAKCA 算法能够在不同样本均衡程度下稳定提取 750 kV 电抗器声纹深度特征, 且特征可视化差异显著; 同时, 该算法能够对无标签电抗器声纹特征精确聚类。与多个传统聚类评价指标相比, CVNN 指标获得的最佳聚类数与真实类别数完全一致, 证明了该指标的有效性和适用性。

3) 该方法可有效提升无标签声纹数据的利用效率, 显著节省时间和人力成本。对于聚类结果的

解释, 将在后续工作中依托诊断专家的领域知识和
附录 A

深入分析来进一步判定故障类型。

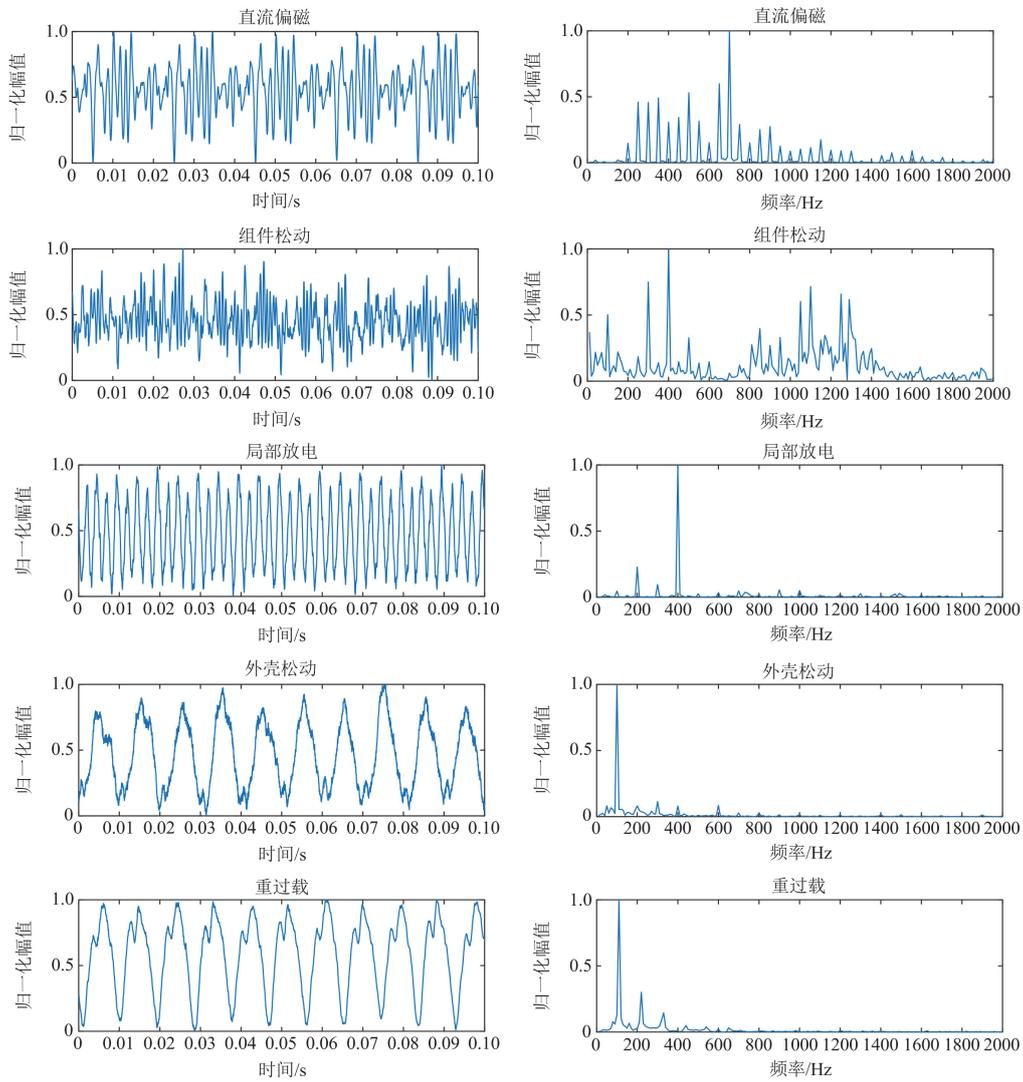
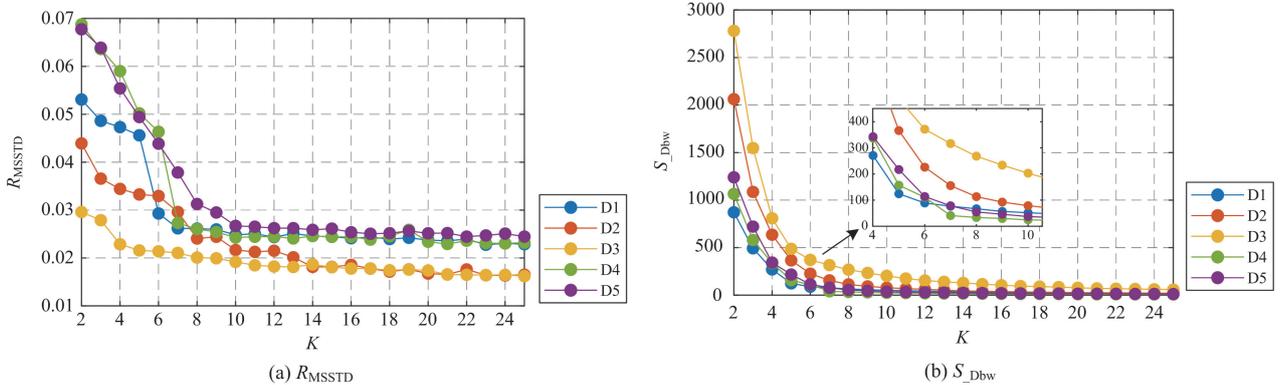


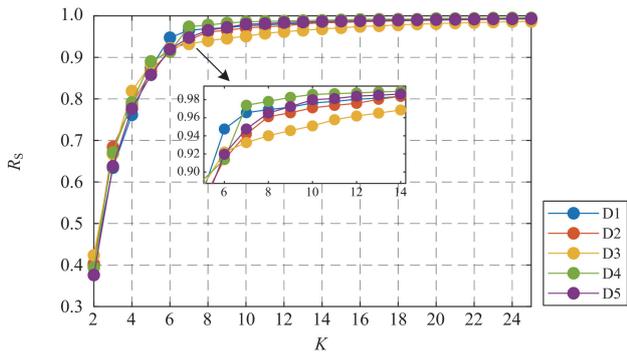
图 A1 电抗器异常运行期间的声纹时域信号及频域分布图

Fig. A1 Time domain signal and frequency domain distribution of the voiceprint in the abnormal operation state of the reactor

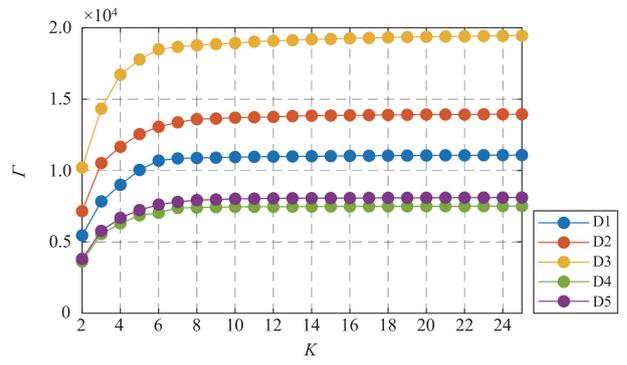


(a) R_{MSSTD}

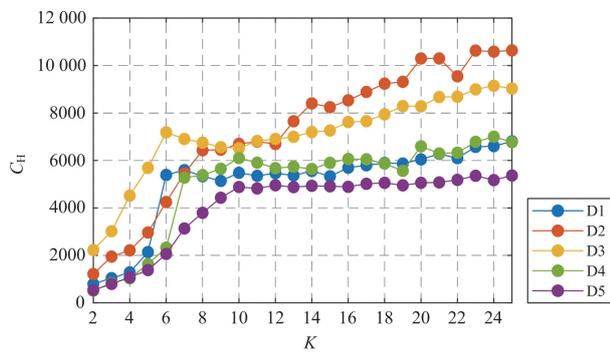
(b) S_{Dbw}



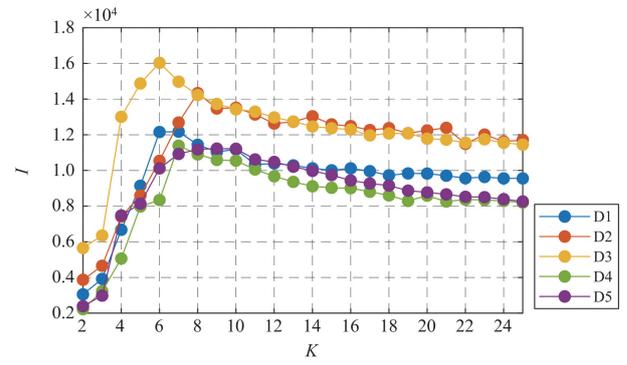
(c) R_S



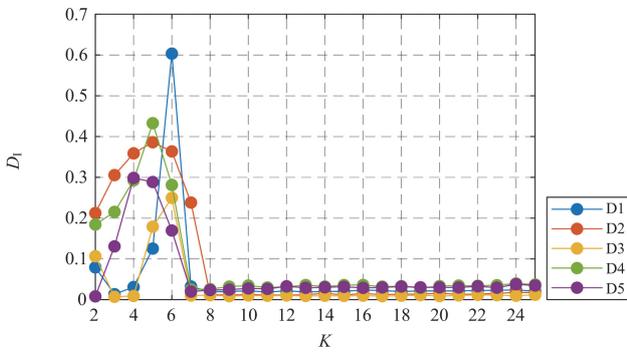
(d) Γ



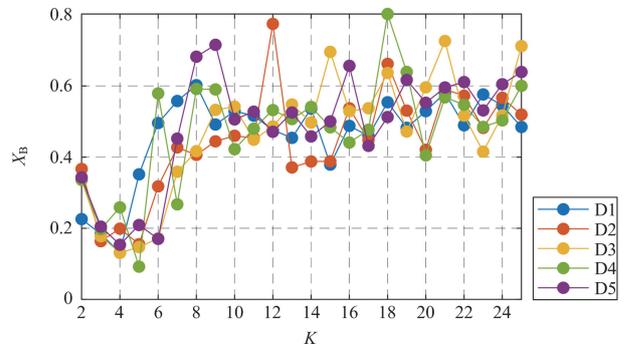
(e) C_H



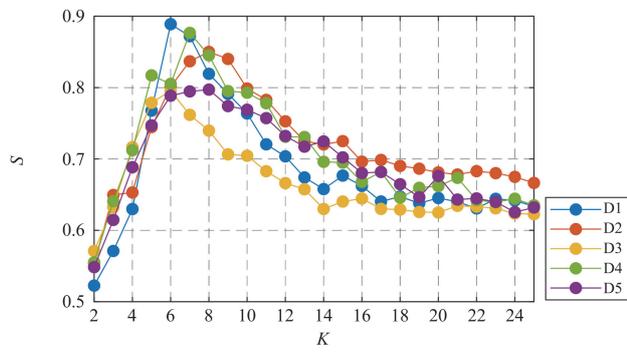
(f) I



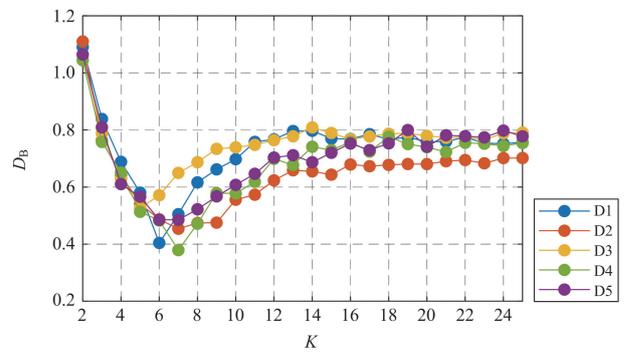
(g) D_I



(h) X_B



(i) S



(j) D_B

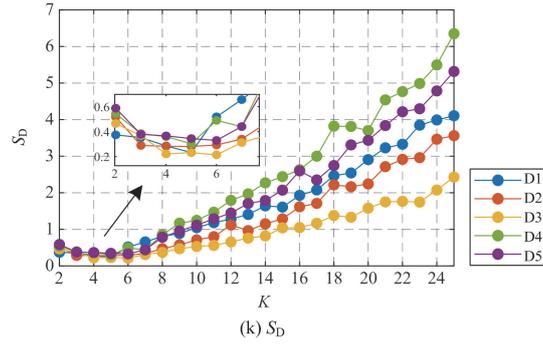

 图 A2 对比指标随聚类数 K 的变化

 Fig. A2 Change of comparison index with the number of clusters K

表 A1 11 个传统聚类评价指标

Table A1 11 traditional clustering evaluation indexes

聚类评价指标	计算表达式	特点	备注
均方根标准差(Root-mean-square std dev, R_{MSSTD})	$R_{MSSTD} = \sqrt{\frac{\sum_{i=1}^K \sum_{x \in C_i} \ x - c_i\ ^2}{ P (n_i - 1)}}$	基于方差衡量簇内紧密程度	对非球形簇效果不佳
S_Dbw 有效性指数 (S_Dbw validity index, $S_{D_{bw}}$)	$S_{D_{bw}} = S_{cat}(K) + D_{ens_bw}(K)$	基于密度评价簇间分离和簇内紧密度	计算成本高, 参数选择敏感
R 平方(R-squared, R_s)	$R_s = \frac{\left(\sum_{i=1}^K \sum_{x \in C_i} \ x - c\ ^2 \right) - \left(\sum_{i=1}^K n_i \ c_i - c\ ^2 \right)}{\sum_{i=1}^K \sum_{x \in C_i} \ x - c\ ^2}$	考虑簇内聚合度与整体聚合度	鲁棒性较差, 依赖数据分布
修改后的 Hubert Γ 统计量 (Modified Hubert Γ statistic, Γ)	$\Gamma = \frac{2}{n(n-1)} \sum_{x \in D} \sum_{y \in D} d(x, y) d_{x \in C_i, y \in C_j}(c_i, c_j)$	衡量聚类结构一致性	对数据集结构敏感
Calinski-Harabasz 指数 (Calinski-Harabasz index, C_{H_i})	$C_{H_i} = \frac{\sum_{i=1}^K n_i d^2(c_i, c) / (K-1)}{\sum_{i=1}^K \sum_{x \in C_i} d^2(x, c_i) / (n-K)}$	通过对比簇间与簇内距离评价聚类质量	对球形簇表现良好, 对噪声和非球形簇效果不佳
I 指数(I index, I)	$I = \left(\frac{1}{K} \cdot \frac{\sum_{x \in D} d(x, c)}{\sum_{i=1}^K \sum_{x \in C_i} d(x, c_i)} \cdot \max_{i,j} d(c_i, c_j) \right)^p$	通过簇间最大距离与簇内距离和的比值衡量聚类效果	尤其适用于球形簇, 对噪声敏感
Dunn 指数(Dunn's indices, D_1)	$D_1 = \min_{1 \leq k \leq K} \left\{ \min_{1 \leq j \leq K, j \neq k} \left\{ \frac{\min_{x \in C_i, y \in C_j} d(x, y)}{\max_{1 \leq k \leq K} \max_{x, y \in C_k} d(x, y)} \right\} \right\}$	基于簇间最小距离与簇内最大直径之比	适用紧密且分离的簇, 易受噪声干扰
Xie-Beni 指数 (Xie-Beni index, X_B)	$X_B = \frac{\sum_{i=1}^K \sum_{x \in C_i} d^2(x, c_i)}{n \times \min_{i,j} d^2(c_i, c_j)}$	综合考虑簇间分离与簇内紧密度	适用于分离度好的簇, 处理重叠簇效果有限
轮廓系数(Silhouette index, S)	$S = \frac{1}{K} \sum_{i=1}^K \frac{1}{n_i} \sum_{x \in C_i} \frac{b(x) - a(x)}{\max\{a(x), b(x)\}}$	通过簇间与簇内距离差来评价聚类效果	计算复杂, 成本较高
Davies-Bouldin 指数 (Davies-Bouldin index, D_B)	$D_B = \frac{1}{K} \sum_{i=1}^K \max_{j \neq i} \left(\frac{\sum_{x \in C_i} d(x, c_i) + \sum_{x \in C_j} d(x, c_j)}{n_i + n_j} \right)$	计算簇间最大相似度的平均值来评价聚类质量	易受噪声干扰
SD 有效性指数 (SD validity index, S_D)	$S_D = D_{is}(K_{max}) S_{cat}(K) + D_B(K)$	综合考虑簇内方差与簇间中心距离来评价聚类效果	处理复杂或差异大的簇可能不准确

注: D 为数据集; n 为数据集 D 中的样本数量; c 为数据集 D 的中心; P 为数据集 D 的特征数量; K 为簇的数量; C_i 为第 i 个簇; n_i 为第 i 个簇中的样本数量; c_i 为第 i 个簇的中心; $\sigma(C_i)$ 为第 i 个簇的方差向量; $d(x, y)$ 为 x 和 y 之间的距离; $\|X_i\| = \sqrt{X_i^T \cdot X_i}$ 为 X_i 的欧几里得范数;

$$S_{cat}(K) = \frac{1}{K} \sum_{i=1}^K \|\sigma(C_i)\| / \|\sigma(D)\|; \quad D_{is}(K) = \frac{\max_{i,j} d(c_i, c_j)}{\min_{i,j} d(c_i, c_j)} \sum_{i=1}^K \left(\sum_{j \neq i} d(c_i, c_j) \right)^{-1}; \quad D_{ens_bw}(K) = \frac{1}{K(K-1)} \sum_{i=1}^K \left[\frac{\sum_{x \in C_i \cup C_j} f(x, u_{ij})}{\max_{j \neq i} \left\{ \sum_{x \in C_i} f(x, c_i), \sum_{x \in C_j} f(x, c_j) \right\}} \right]$$

参考文献

- [1] 郭冰, 祝磊, 陈一惊, 等. 适用于带中段并联电抗器的电缆线路的参数识别纵联保护新原理[J]. 电力系统保护与控制, 2021, 49(6): 124-130.
GUO Bing, ZHU Lei, CHEN Yicong, et al. Novel pilot protection principle based on parameter identification for a transmission line with a shunt reactor in the middle[J]. Power System Protection and Control, 2021, 49(6): 124-130.
- [2] 胡晓静, 徐鹏, 王海亮, 等. 一起 500 kV 油浸式电抗器故障调查及防范措施分析[J]. 电力系统保护与控制, 2021, 49(2): 173-178.
HU Xiaojing, XU Peng, WANG Hailiang, et al. Fault analysis and preventive measures for a 500 kV oil-immersed reactor[J]. Power System Protection and Control, 2021, 49(2): 173-178.
- [3] 王果, 雷武, 闵永智, 等. 改进 EEMD 算法在高压并联电抗器声信号去噪中的应用[J]. 电力系统保护与控制, 2023, 51(24): 164-174.
WANG Guo, LEI Wu, MIN Yongzhi, et al. Application of an improved EEMD algorithm in high voltage shunt reactor sound signal denoising[J]. Power System Protection and Control, 2023, 51(24): 164-174.
- [4] 顾仲翔, 马宏忠, 张勇, 等. 基于 VMD 与优化 SVM 的变压器绕组松动缺陷振动信号诊断方法[J]. 高压电器, 2023, 59(1): 117-125.
GU Zhongxiang, MA Hongzhong, ZHANG Yong, et al. Vibration signal diagnosis method of transformer winding looseness defect based on VMD and optimized SVM[J]. High Voltage Apparatus, 2023, 59(1): 117-125.
- [5] 王荣昊, 李喆, 孙正, 等. 基于 FISVDD 与 GRU 的变压器声纹识别技术[J]. 高电压技术, 2022, 48(11): 4546-4556.
WANG Ronghao, LI Zhe, SUN Zheng, et al. Transformer voice-print recognition technology based on FISVDD and GRU[J]. High Voltage Engineering, 2022, 48(11): 4546-4556.
- [6] 孙汉文, 李喆, 林睿, 等. 基于新奇检测的两级电气故障声纹识别算法[J]. 电网技术, 2021, 45(7): 2888-2895.
SUN Hanwen, LI Zhe, LIN Rui, et al. Two-stage voiceprint recognition algorithm of electrical faults based on novelty detection[J]. Power System Technology, 2021, 45(7): 2888-2895.
- [7] 刘云鹏, 来庭煜, 刘嘉硕, 等. 特高压直流换流阀饱和和电抗器振动声纹特性与松动程度声纹检测方法[J]. 电工技术学报, 2023, 38(5): 1375-1389.
LIU Yunpeng, LAI Tingyu, LIU Jiashuo, et al. Vibration voice-print characteristics and looseness detection method of UHVDC converter valve saturable reactor[J]. Transactions of China Electrotechnical Society, 2023, 38(5): 1375-1389.
- [8] 游文霞, 申坤, 杨楠, 等. 基于 AdaBoost 集成学习的窃电检测研究[J]. 电力系统保护与控制, 2020, 48(19): 151-159.
YOU Wenxia, SHEN Kun, YANG Nan, et al. Research on electricity theft detection based on AdaBoost ensemble learning[J]. Power System Protection and Control, 2020, 48(19): 151-159.
- [9] 刘钊瑞, 高云鹏, 郭建波, 等. 基于深度自编码器高斯混合模型的窃电行为检测[J]. 电力系统保护与控制, 2022, 50(18): 92-102.
LIU Zhaorui, GAO Yunpeng, GUO Jianbo, et al. Abnormal detection of electricity theft using a deep auto-encoder Gaussian mixture model[J]. Power System Protection and Control, 2022, 50(18): 92-102.
- [10] CHEN L, XU G, WANG Y, et al. Detection of weak transient signals based on unsupervised learning for bearing fault diagnosis[J]. Neurocomputing, 2018, 314: 445-457.
- [11] 王嘉宁. 基于无监督学习的电力变压器声纹异常诊断方法研究[D]. 北京: 华北电力大学, 2023.
WANG Jianing. Research on unsupervised learning based power transformer voiceprint anomaly diagnosis method[D]. Beijing: North China Electric Power University, 2023.
- [12] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning internal representations by error propagation, parallel distributed processing, explorations in the microstructure of cognition[J]. Biometrika, 1986, 71: 599-607.
- [13] 齐子豪, 仝杰, 张中浩, 等. 基于多粒度知识特征和 Transformer 网络的电力变压器故障声纹辨识方法[J/OL]. 中国电机工程学报: 1-13[2024-03-25]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20231204.1422.004.html>.
QI Zihao, TONG Jie, ZHANG Zhonghao, et al. A voiceprint classification method for power transformer fault identification based on multi-granularity knowledge features and transformer network[J/OL]. Proceedings of the CSEE: 1-13[2024-03-25]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20231204.1422.004.html>.
- [14] YU J, ZHOU X. One-dimensional residual convolutional auto-encoder based feature learning for gearbox fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16(10): 6347-6358.
- [15] 解颖, 王丰华, 傅正财. 基于栈式自编码器的变压器机械故障诊断[J]. 高压电器, 2020, 56(9): 46-53.
XIE Ying, WANG Fenghua, FU Zhengcai. Mechanical fault

- diagnosis of power transformer based on stacked auto encoder[J]. High Voltage Apparatus, 2020, 56(9): 46-53.
- [16] 田昊洋, 马文嘉, 王丰华, 等. 基于稀疏自动编码器的特高压变压器可听噪声分析[J]. 高压电器, 2020, 56(9): 67-73.
TIAN Haoyang, MA Wenjia, WANG Fenghua, et al. Research on audible noise of UHV power transformer based on sparse auto-encoder[J]. High Voltage Apparatus, 2020, 56(9): 67-73.
- [17] MAO W, CHEN J, LIANG X, et al. A new online detection approach for rolling bearing incipient fault via self-adaptive deep feature matching[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 69(2): 443-456.
- [18] 余洋, 陆文韬, 陈东阳, 等. 光伏波动平抑下改进 K-means 的电池储能动态分组控制策略[J]. 电力系统保护与控制, 2024, 52(7): 1-11.
YU Yang, LU Wentao, CHEN Dongyang, et al. Dynamic grouping control strategy for battery energy storage based on improved K-means under photovoltaic fluctuation suppression[J]. Power System Protection and Control, 2024, 52(7): 1-11.
- [19] 邹阳, 林锦茹, 李安娜, 等. 基于灰色关联分析和聚类云模型的变压器油纸绝缘状态评估[J]. 电力系统保护与控制, 2023, 51(21): 35-43.
ZOU Yang, LIN Jinjia, LI Anna, et al. Evaluation of transformer oil-paper insulation status based on grey relational analysis and a cluster cloud model[J]. Power System Protection and Control, 2023, 51(21): 35-43.
- [20] 杜耀文, 谢静, 刘志坚, 等. 基于深度学习的高压隔离开关分合状态检测算法研究[J]. 电力系统保护与控制, 2023, 51(19): 114-123.
DU Yaowen, XIE Jing, LIU Zhijian, et al. A detection algorithm for opening and closing states of high-voltage isolation switches based on deep learning[J]. Power System Protection and Control, 2023, 51(19): 114-123.
- [21] 侯鹏飞, 马宏忠, 吴金利, 等. 基于混沌理论与蝗虫优化 K-means 聚类算法的电抗器铁芯和绕组松动状态监测[J]. 电力自动化设备, 2020, 40(11): 181-187.
HOU Pengfei, MA Hongzhong, WU Jinli, et al. Looseness status monitoring of reactor core and winding based on chaos theory and K-means clustering algorithm optimized by grasshopper algorithm[J]. Electric Power Automation Equipment, 2020, 40(11): 181-187.
- [22] 官松泽, 唐钰本, 蔡争, 等. 基于 Kmeans++-Bi-LSTM 的太阳辐照度超短期预测[J]. 太阳能学报, 2023, 44(12): 170-174.
GUAN Songze, TANG Yuben, CAI Zheng, et al. Ultra-short-term forecast of solar irradiance based on KMEANS++-BI-LSTM[J]. Acta Energiæ Solaris Sinica, 2023, 44(12): 170-174.
- [23] LEI Y, HE Z, ZI Y, et al. New clustering algorithm-based fault diagnosis using compensation distance evaluation technique[J]. Mechanical Systems and Signal Processing, 2008, 22(2): 419-435.
- [24] 刘云鹏, 和家慧, 许自强, 等. 基于 SVM SMOTE 的电力变压器故障样本均衡化方法[J]. 高电压技术, 2020, 46(7): 2522-2529.
LIU Yunpeng, HE Jiahui, XU Ziqiang, et al. Equalization method of power transformer fault sample based on SVM SMOTE[J]. High Voltage Engineering, 2020, 46(7): 2522-2529.
- [25] DING X, HE Q, LUO N. A fusion feature and its improvement based on locality preserving projections for rolling element bearing fault classification[J]. Journal of Sound and Vibration, 2015, 335: 367-383.
- [26] LIU Y, LI Z, XIONG H, et al. Understanding and enhancement of internal clustering validation measures[J]. IEEE Transactions on Cybernetics, 2013, 43(3): 982-994.

收稿日期: 2024-04-20; 修回日期: 2024-06-04

作者简介:

闵永智(1975—), 男, 通信作者, 博士, 教授, 研究方向为人工智能测试、图像识别和电气化铁路多源接入; E-mail: minyongzhi@mail.lzjtu.cn

郝大宇(1999—), 男, 硕士研究生, 研究方向为电力设备声纹监测与诊断技术。E-mail: 12221562@stu.lzjtu.edu.cn

(编辑 魏小丽)