

基于知识蒸馏与注意力机制的电缆故障 可扩展化诊断研究

迟 鹏¹, 梁 睿²

(1. 青岛科技大学先进电工材料研究院, 青岛 266042; 2. 中国矿业大学电气工程学院, 徐州 221116)

摘要: 现有基于人工智能的电缆故障诊断方法缺乏处理故障动态差异化发展的能力, 其不能适应新的故障场景, 无法随着时间的推移增强诊断能力。鉴于此, 在深度卷积神经网络(deep convolutional neural network, DCNN)的基础上, 融合知识蒸馏与注意力机制提出一种电缆故障可扩展化诊断方法(DCNN with knowledge distillation and attention, DCNN-KD-A)。引入知识蒸馏思想, 保留 DCNN 模型对原有故障的诊断信息, 同时利用新增故障的分类损失对模型进行拓展修正, 使其具备故障可扩展化诊断的能力。为避免模型训练中的灾难性遗忘问题, 重新构建了相适应的故障分类器。为应对知识蒸馏中的信息损耗与改变, 利用注意力机制增强模型的特征凝练作用, 提升其可扩展化诊断精度。通过实测与仿真数据进行实验, 实验结果验证了所提方法的有效性和可行性。

关键词: 电缆故障; 可扩展化诊断; 知识蒸馏; 注意力机制; 深度卷积神经网络; 人工智能

Research on Scalable Diagnosis of Cable Faults Based on Knowledge Distillation and Attention Mechanism

CHI Peng¹, LIANG Rui²

(1. Institute of Advanced Electrical Materials Research, Qingdao University of Science and Technology, Qingdao 266042, China;

2. School of Electrical Engineering, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: Existing methods for artificial intelligence-based cable fault diagnosis lack the ability to handle the dynamic and differentiated development of faults, and they cannot adapt to new fault scenarios or enhance diagnostic capabilities over time. Therefore, this paper proposes a scalable diagnosis method for cable fault based on the deep convolutional neural network(DCNN), incorporating the idea of knowledge distillation and attention mechanism(DCNN with knowledge distillation and attention, DCNN-KD-A). The knowledge distillation is introduced to retain the diagnostic information of the original faults by the DCNN model; meanwhile the classification loss of the newly-added faults is used to expand and modify the model, enabling it to have the capability for extensible fault diagnosis. To avoid the catastrophic forgetting problem in model training, a suitable fault classifier has been reconstructed. To address the issues of information loss and changes in knowledge distillation, the attention mechanism is utilized to enhance the model's feature extraction capabilities, thereby improving its scalability in diagnostic accuracy. The experiments are conducted using actual measured data and simulation data, and the experimental results verify the effectiveness and feasibility of the method proposed in this paper.

Key words: cable fault; scalable diagnosis; knowledge distillation; attention mechanism; deep convolutional neural network; artificial intelligence

0 引言

电力电缆依靠其优越性能在现代电力系统中得到广泛应用。但随着电缆服役时间的增加, 电缆绝缘水平逐步下降, 加之外力的侵蚀与损害, 不可避免地会产生相应故障^[1-2]。做好电缆故障的精确诊

断工作对于故障排除、快速恢复供电和保证电力系统的供电可靠性有着极其重要的意义^[3]。目前针对电缆故障诊断的研究主要分为 3 类: 一是基于电流或电压信号的传统电气分析^[4-5], 即从电流或者电压信号中提取某些参量诊断电缆故障; 二是基于反射法, 包括时域反射法^[6]、频域反射法^[7]以及时频域反射法^[8], 从时域或频域对注入电缆信号的反射信号进行特性分析, 以此对故障进行诊断; 三是基于

人工智能技术, 依靠神经网络强大的非线性映射能力, 在大量数据样本和故障类型之间建立对应关系, 以此实现电缆故障诊断^[9-10]。

在传统电气分析的电缆故障诊断中, 以护层电流和相电流信号的分析使用为主, 电压信号的使用相对较少。文献[4]选取共模漏电流作为表征电缆状态的参量, 文献[11]将故障相电流中的直流衰减分量作为故障诊断依据, 而文献[12]以计算电压信号的起始角和谐波畸变率来判断电缆是否发生多周波早期故障。传统电气分析方法比较直接, 但以参量阈值来判断故障, 易受到外界扰动的影响, 无法保证故障诊断精度。相比于传统电气量分析, 基于反射法的故障诊断研究使用信号的频段更宽^[13], 信息更为丰富, 其诊断精度相应得到提高。该类方法中, 以频域反射法为代表的研究近年来受到更多关注, 其主要包括宽频阻抗谱^[14]与反射系数谱^[15]这2种思路。文献[16]以调频连续波的相位谱特征对高阻、低阻等故障进行识别, 而文献[15]利用反射系数谱构建的诊断函数极值峰辨识电缆缺陷。反射法本质上还是同传统电气分析方法类似, 即均基于某些特征阈值对故障予以判别, 所以依然不可避免地会受到扰动误差的影响。

与上述2类方法相比, 基于人工智能的电缆故障诊断方法能够依靠大量训练样本, 确保人工智能诊断模型对不同电缆状态(包括扰动状态)都可以呈现较高敏感性, 因而其更具鲁棒性与适应性。国内外学者已在基于人工智能的电缆故障诊断研究方面进行大量分析和讨论, 主要涉及两大类。一类是基于浅层特征, 即直接使用原始信号作为人工智能模型的输入, 利用构建的人工智能模型自身提炼特征实现电缆故障诊断。文献[9]将局部放电相位分布谱图作为多尺度卷积神经网络的输入进行电缆终端故障诊断; 文献[17]以半波三相电流及零序电流堆叠信号作为输入, 基于稀疏表示方法实现海底电缆短路故障分类; 文献[18]则是将局部放电信号输入卷积神经网络完成电缆局部放电模式的识别。另一类是基于统计特征, 在人为经验的加持下, 通过相关信号处理手段从原始信号中提炼出能更好展现电缆故障的特征, 再将其输入到人工智能诊断模型中。文献[19]利用S变换从电流信号中提炼了11个时频域特征量, 文献[20]则通过回归反射法从故障电压信号与反射信号中提取了时延、峰值电压和时频相位差3个特征量。除直接提炼数值类的特征量外,

提炼的统计特征也可以是将原始信号处理成图的形式。文献[21]基于离散小波变换与混沌理论构建局部放电信号的动态误差散点图, 而文献[22]采用小波变换处理放电脉冲信号, 得到能量归一化后的时频谱图。在获得这些统计特征后, 再将其输入到相适应的人工智能诊断模型, 如堆叠自编码器、回归神经网络、深度卷积神经网络(deep convolutional neural network, DCNN)就可完成电缆故障的精准诊断。相比浅层特征, 统计特征提炼过程相对复杂, 但其诊断精度也相应较高。

现有基于人工智能的电缆故障诊断方法展现出一定优势, 但其目前面临一个重要挑战: 模型缺乏动态扩展性。现有基于人工智能的电缆故障诊断模型是静态的, 其只能诊断训练过程中遇到的故障状态, 当面对因电缆运行时间增加和运行环境变化而新产生的不同特性故障时, 其无法做出精确诊断, 即现有基于人工智能的电缆故障诊断模型无法实现故障可扩展化诊断。现有基于人工智能的电缆故障诊断模型如果想诊断这些新场景的故障, 只能把当前训练好的模型舍弃, 然后将新的故障数据与原有故障数据合并, 重新训练。若计算机内存无限大且不考虑数据存储问题, 则可以按照上述操作进行新故障的诊断。但实际上计算机内存容量是有限的, 而且若完全舍弃之前耗费资源训练的模型, 也造成资源的浪费。基于此问题, 本文提出一种基于知识蒸馏与注意力机制的电缆故障可扩展化诊断方法, 解决有限内存下现有基于人工智能的电缆故障诊断模型动态扩展问题, 实现电缆故障的可扩展化诊断。

1 统计特征提炼与卷积神经网络构建

1.1 统计特征提炼

本文以10 kV单芯电缆作为故障诊断分析的对象, 所采用电缆的参数如表1所示。当电缆发生故障时, 将接地线电流故障信号进行4层小波分解重构, 得到5个不同频段的重构信号。从每个重构信号中提取9个波形特征, 再根据重构信号与故障信号间的能量关系得到9个能量特征, 这些特征的具体描述以及相应的计算方法被列于表2中。表2中变量 E 表示故障信号的总能量; E_{rdj} 为低频重构信号的能量; E_{rdj} 是高频重构信号的能量, 这些能量可由式(1)和式(2)计算得到。

$$E_i = \sum_{i=1}^N s_i^2 \quad (1)$$

$$E = E_{raj} + E_{rdj} + E_{rd(j-1)} + \dots + E_{rd1} \quad (2)$$

式中： E_r 表示单个重构信号的能量； N 是重构信号的长度； s_i 为重构信号中第*i*点的幅值； j 是故障信号的小波分解层数。第*j*层低频重构信号的能量表示为 E_{raj} ，而高频重构信号的能量表示为 E_{rdj} ， $E_{rd(j-1)}$ ， \dots ， E_{rd1} 。

1.2 深度卷积神经网络

根据 1.1 节中的特征提取方法，每个接地线电流故障信号可提取到 54 个特征，包括 45 个波形特征和 9 个能量特征，最终构造形成 1 个尺寸为 6×9 的诊断矩阵。诊断矩阵中的特征从低频到高频排列，矩阵前 5 行对应 5 个重构信号的波形特征，第 6 行为能量特征，诊断矩阵在局部存在较强相关性。为此，构建 1 个 7 层深度卷积神经网络 DCNN 来处理所构造的诊断矩阵，DCNN 的相关参数如表 3 所示。卷积 1 层使用 9 个尺寸为 2×2 的卷积核，池化 1 层采用最大池化方式，其滤波器尺寸为 2×2。卷积 2 层则使用 18 个尺寸为 1×2×9 的卷积核，池化 2 层依然采用最大池化方式，其滤波器尺寸为 2×1。池化 2 层的特征在平展拼接成 1 个向量后与全连接层进行全连接运算。输出层维度为 n ，对应故障种类数量。DCNN 网络中的激活函数为修正线性单元。

2 故障可扩展化诊断实现

第 1 章中的内容即为现有基于人工智能的电缆故障诊断方法的研究思路，先获取样本特征，再构建人工智能诊断模型，最后利用样本特征对构建的人工智能诊断模型进行训练。如引言部分所提到的，现有基于人工智能的故障诊断模型无法实现模型可扩展化的电缆故障诊断。为此，本文以第 1 章中构建的 DCNN 模型为例，在现有基于人工智能的电缆故障诊断方法的基础上，主要开展以下 4 部分工作，以实现有限内存下电缆故障的可扩展化诊断：一是重新设计适应于电缆故障可扩展化诊断的故障分类器；二是构建固定容量的联合特征集及其更新机制以对有限内存这一实际问题予以表征；三是通过知识蒸馏构造损失函数使现有基于人工智能的电缆故障诊断模型具备可扩展化诊断的能力；四是利用注意力机制增强特征的关注度以提升可扩展化诊断的精度。本章具体工作如下。

2.1 分类器的设计

将故障样本 x 输入 DCNN 模型后，DCNN 的全连接层特征可用 $\varphi(x)$ 表示，将 $\varphi(x)$ 称作故障样本 x 的

表 1 10 kV 单芯电缆参数

符号	符号意义	数值
r_c	线芯内径	9.15 mm
r_{in}	绝缘内径	15.65 mm
r_s	屏蔽层内径	17.65 mm
ρ	电阻率	$1.72 \times 10^{-8} \Omega \cdot m$
ϵ	绝缘相对介电常数	2.3

表 2 能量特征与波形特征

特征名称	计算式	特征名称	计算式
单层信号能量比	$\frac{E_{raj}}{E}$ 或 $\frac{E_{rdj}}{E}$	相邻信号能量比	$\frac{E_{raj}}{E_{rdj}}$ 或 $\frac{E_{rdj}}{E_{rd(j-1)}}$
波峰因子	$\sqrt{N} \frac{\max(s_i)}{\sqrt{\sum_{i=1}^N s_i^2}}$	脉冲因子	$N \frac{\max(s_i)}{\sum_{i=1}^N s_i }$
清除因子	$N^2 \frac{\max(s_i)}{(\sum_{i=1}^N s_i)^2}$	形状因子	$\frac{\sqrt{N \sum_{i=1}^N s_i^2}}{\sum_{i=1}^N s_i }$
均方根植	$(\frac{1}{N} \sum_{i=1}^N \sqrt{ s_i })^2$	算术均值	$\frac{1}{N} \sum_{i=1}^N s_i $
峰度	$\frac{1}{N} \sum_{i=1}^N s_i^4$	方差	$\frac{1}{N} \sum_{i=1}^N s_i^2$
偏斜度	$\frac{1}{N} \sum_{i=1}^N s_i^3$		

表 3 深度卷积神经网络参数

网络层	层尺寸	网络层	层尺寸
输入层	6×9	池化 2 层	2×3×18
卷积 1 层	5×8×9	全连接层	108
池化 1 层	3×4×9	输出层	n
卷积 2 层	3×3×18		

类特征，其中 $\varphi(\cdot)$ 可理解为 DCNN 模型的非线性映射函数。DCNN 输出层的结果 $a(x)$ 可由式(3)表示。

$$a(x) = \mathbf{w}^T \varphi(x) \quad (3)$$

式中： \mathbf{w} 是全连接层和输出层间的权重向量。

如式(4)所示，故障样本 x 的分布概率 $g(x)$ 可通过 sigmoid 函数与 $a(x)$ 来计算。

$$g(x) = \frac{1}{1 + e^{-a(x)}} \quad (4)$$

传统深度学习模型一般是在输出层应用 softmax 或 sigmoid 分类器，然后计算该样本属于某一类别的概率，将样本划归到对应最高概率的类别，

分类器表达式为:

$$y^* = \arg \max g(x) \quad (5)$$

式中: y^* 为分类结果。

由式(5)可知, 该分类机制使用的信息是非线性映射 φ 和权重向量 w 。就分类结果而言, φ 和 w 之间存在相关性。这意味着当 φ 在 DCNN 模型扩展化诊断过程中发生变化时, w 必须更新, 否则, 模型的输出将不受控制的变化, 导致灾难性遗忘问题的出现^[23], 这将不利于模型可扩展化诊断的实现。

为避免上述问题, 本文采用最近分类中心思想来构建故障分类器。假设当前已有故障样本的集合为 $X = \{X_1, X_2, \dots, X_k\}$, 其中 $X_k = \{x_k^1, x_k^2, \dots, x_k^n\}$ 表示第 k 类故障的样本集, n 是第 k 类故障的样本数量。 X_k 的类中心即第 k 类故障所有样本的中心 μ_k 可由式(6)表示。

$$\mu_k = \frac{1}{n} \sum_{x \in X_k} \varphi(x) \quad (6)$$

同理, X 中所有故障的类中心可表示为 $\mu = \{\mu_1, \mu_2, \dots, \mu_k\}$ 。

在获得故障样本类特征和故障类中心后, 基于最近分类中心的故障分类器可由式(7)表示。它是将故障样本的类特征分别与每类故障的类中心做差, 对应差向量长度最小的类别即为故障样本所属的故障类型 y^* 。

$$y^* = \arg \min_{y=1, \dots, k} \|\varphi(x) - \mu_y\| \quad (7)$$

对于本文所构建的故障分类器而言, 其与权重向量 w 不存在耦合关系, 且在模型可扩展化诊断中, 类中心 μ 会随着模型非线性映射 φ 的变化而自动变化, 因而构建的分类器具有较强鲁棒性。

2.2 联合特征集的构建与更新

2.2.1 联合特征集的构建

电力系统中硬件设备的内存是有限的, 本文通过构造 1 个具有固定容量的联合特征集来表征这一实际问题。联合特征集 P 是对已完成训练的旧故障类别样本的筛选, 其包含的样本更能反映所属故障类别的特性。假设联合特征集 $P = \{P_1, P_2, \dots, P_k\}$ 的容量为 N_U , 则需要从每个故障类别的样本集 X_k 中选择 $m = N_U/k$ 个样本。 P_k 表示第 k 类故障的特征样本集, 其包含的样本称为特征样本, 特征样本的选择可按式(8)进行。

$$p_k^i = \arg \min_{x_k^n \in X_k} \left\| \mu_k - \frac{1}{i} \left(\varphi(x_k^n) + \sum_{j=1}^{i-1} \varphi(p_k^j) \right) \right\| \quad (8)$$

式中: $p_k^i \in P_k = \{p_k^1, p_k^2, \dots, p_k^m\}$, $P_k \subseteq X_k$ 和 $i=1, 2, \dots, m$ 。

对于 p_k^1 的选择: 分别将样本集 X_k 中每个样本的类特征与类中心 μ_k 做差, 然后比较这些差向量的长度, 把对应最小长度的样本选择为特征样本集 P_k 的第 1 个样本, 表示为 p_k^1 。

对于 p_k^2 的选择: 将 p_k^1 去掉, 然后将 X_k 其余样本的类特征分别与第 1 个特征样本 p_k^1 的类特征取平均, 再将得到的平均向量与类中心 μ_k 做差, 选择差向量长度最小的样本作为第 2 个特征样本, 表示为 p_k^2 。

对于剩下的特征样本选择: 移除已经被选择的特征样本, 然后以选择 p_k^2 的方法依次从 X_k 中选取剩余的 $m-2$ 个特征样本。

选取的 m 个特征样本形成第 k 类故障的特征样本集 P_k 。同理, 通过上述方法可得到每一类故障对应的特征样本集。将这些特征样本集组合起来即可构造获得联合特征集 P 。

2.2.2 联合特征集的更新

若有包含 t 个新故障类别的样本集 S_t 被添加到模型训练, 在模型训练结束, 学习到新故障类别的特征后, 这 t 个新故障类别对于模型而言就变成旧故障类别。因而, 此时需要从新样本集 S_t 中选择特征样本, 将其添加到联合特征集中。但如上面所提到的, 联合特征集的容量是固定的, 为给新故障类别的样本腾出空间, 则需要减少联合特征集中旧故障类别的特征样本数量, 从而实现联合特征集的更新。联合特征集的更新规则如下所述。

添加 t 个新故障类别后, 故障类别总数变为 $k+t$ 。此时, 联合特征集中每个故障类别的特征样本数量 m' 应按等式(9)计算, 即:

$$m' = N_U / (k+t) \quad (9)$$

联合特征集中特征样本的选择是通过样本的类特征与类中心之间的距离来实现的, 这意味着特征样本在 P_k 中的顺序越靠前, 特征样本就越具有代表性。因此, 对于 k 个旧故障类别, 只需要去除各自特征样本集中最后的 $m-m'$ 个特征样本即可。而对于 t 个新故障类别, 则可以根据等式(8)中的选择方法获得特征样本, 进而获得对应特征样本集。通过上述两步操作后, 更新后的联合特征集可以表示为 $P = \{P'_1, P'_2, \dots, P'_k, P'_{k+1}, \dots, P'_{k+t}\}$ 。

2.3 损失函数构造

基于 DCNN 的电缆故障可扩展化诊断即要求 DCNN 诊断模型在不忘记旧故障诊断信息的情况下又能学习到新故障的诊断信息,从而实现对新旧故障的准确诊断。为实现这一目标,本文引入知识蒸馏思想^[24]。对于神经网络来说,知识是输入到输出的映射,包括网络结构和参数。蒸馏是一种将从复杂神经网络学习到的知识应用于简单神经网络的模型压缩方法,它确保简单神经网络能够获得复杂神经网络的功能。根据知识蒸馏这一思路,在电缆故障可扩展化诊断中,可以将旧故障的诊断模型视为复杂网络,将新故障的诊断模型对应为简单网络。将旧故障诊断模型中获得的知识转移到新故障诊断模型中,从而使得新故障诊断模型可以获得对旧故障进行诊断的能力,这也就意味着基于 DCNN 的电缆故障诊断模型具备可扩展化诊断的能力。

知识蒸馏中简单模型的最终损失函数由蒸馏损失和学习损失组成。蒸馏损失是对复杂模型知识的继承,而学习损失是对简单模型知识的修正。据此,本文可扩展化诊断模型的损失函数也包括两部分,即旧故障的蒸馏损失和新故障的分类损失,分类损失对应于知识蒸馏中的学习损失。为便于区分,将引入知识蒸馏的可扩展化诊断模型用 DCNN-KD(DCNN with knowledge distillation)表示。

在电缆故障的可扩展化诊断训练过程中,诊断模型 DCNN-KD 使用扩展训练集(extended training set, ETS),它是由联合特征集 P 和新故障样本集 S_i 组合而成。在 2.2.1 节中提到,联合特征集中的特征样本是训练过的旧故障样本,用 $g_y(x)$ 表示其在旧故障诊断模型中的分布概率。 $g_y(x)$ 可以被认为是从旧故障诊断模型中蒸馏得到的知识,称之为软标签。则当联合特征集中的特征样本被输入到可扩展化诊断模型 DCNN-KD 训练时,它的蒸馏损失 L_1 可以如式(10)所示。

$$L_1(\theta) = -\sum_{y=1}^k \left(q_i^y \ln a_y(x_i) + (1 - q_i^y) \ln(1 - a_y(x_i)) \right) \quad (10)$$

式中: $q_i^y = g_y(x_i)$; $a_y(x_i)$ 是特征样本输入到 DCNN-KD 模型的输出值; θ 是 DCNN-KD 模型的参数; $i=1, 2, \dots, m$ 。

新故障样本集 S_i 中样本的分类损失 L_2 如式(11)所示。

$$L_2(\theta) = -\sum_{y=k+1}^{k+t} \left(\delta_{y=y_i} \ln a_y(x_i) + \delta_{y \neq y_i} \ln(1 - a_y(x_i)) \right) \quad (11)$$

式中: δ 是样本的标签,称为硬标签。

为防止 DCNN-KD 模型过拟合,使用如式(12)所示的 L_2' 正则化项对其进行限制。

$$L_2' = \frac{\lambda_w}{2n_w} \sum_{i=1}^{n_w} w_i^2 \quad (12)$$

式中: w_i 是模型的权重参数; n_w 是权重参数的数量; λ_w 是权重乘罚因子,取值为 1×10^{-5} 。

因而,由旧类故障样本的蒸馏损失、新故障样本的分类损失和 L_2' 正则化项 3 部分构建形成电缆故障可扩展化诊断模型 DCNN-KD 的总损失函数 $L_T(\theta)$, 即:

$$L_T(\theta) = \sum (L_1 + L_2) + L_2' \quad (13)$$

2.4 注意力机制

知识蒸馏能够保留先前模型对旧故障样本的诊断信息,但在知识蒸馏的过程中,不可避免地会造成相关信息的损耗或改变。为应对这些损耗或改变,保证故障可扩展化诊断的精度,在 DCNN-KD 的基础上,加入通道注意力机制,旨在增强特征的凝练作用,得到基于知识蒸馏与注意力机制的 DCNN 诊断模型(DCNN with knowledge distillation and attention, DCNN-KD-A)。通道注意力机制如图 1 所示。

设经过池化 1 层处理后的特征为 F_{p1} , 其维度为 $H \times W \times C$, 其中 H 为二维矩阵高度, W 为二维矩阵宽度, C 为通道数,即二维矩阵的个数。

对 F_{p1} 分别做全局最大池化和全局平均池化,得到 2 个维度为 $1 \times 1 \times C$ 的特征 $G_{pm}(F_{p1})$ 与 $G_{pa}(F_{p1})$, G_{pm} 与 G_{pa} 分别为全局最大池化与全局平均池化操作。

将 $G_{pm}(F_{p1})$ 与 $G_{pa}(F_{p1})$ 分别输入 1 个共享权值的 2 层全连接层中,得到 2 个新的维度为 $1 \times 1 \times C$ 的特征,其中全连接第 1 层神经元个数为 K , 第 2 层神经元个数为 C (与 F_{p1} 通道数相同)。

对上述 2 个 $1 \times 1 \times C$ 的特征做加和处理,再经过 Sigmoid 函数得到通道注意力权重矩阵 W_c 。

将特征 F_{p1} 与 W_c 做乘积得到新维度为 $H \times W \times C$




图 1 通道注意力机制

Fig.1 Channel attention mechanism

的特征, 此特征即可作为卷积 2 层输入。

本文 H 、 W 、 C 和 K 的值分别为 3、4、9 和 3。

2.5 所提方法的实现流程

将知识蒸馏与注意力机制同 DCNN 相结合的电缆故障可扩展化诊断实现方法如图 2 所示。该方法实现的最初两个步骤与现有基于 DCNN 的电缆故障诊断过程一致, 随后的步骤旨在通过知识蒸馏与最近分类中心故障分类器赋予 DCNN 可扩展化的故障诊断能力, 方法步骤如下所述。

步骤 1: 利用 1.1 节的特征提取方法, 从电缆接地线电流故障信号中提取波形特征与能量特征, 构建现有 k 类电缆故障的样本集 X 。

步骤 2: 根据 1.2 节, 构建 1 个 7 层 DCNN 模型, 并在模型的池化 1 层之后加入 2.4 节的通道注意力机制模块。使用步骤 1 中的样本集 X 对模型进行训练, 得到能够诊断当前 k 类电缆故障的 DCNN 诊断模型。

步骤 3: 利用步骤 2 中的模型获得所有 k 类样本的类特征 $\varphi(x)$, 使用式(3)和式(4)得到所有 k 类样本的分布概率 $g(x)$, 使用等式(6)计算每个故障类别的类中心 μ_k 。

步骤 4: 使用步骤 3 中的 $\varphi(x)$ 与 μ_k 通过等式(8)构建当前 k 类故障的联合特征集 P 。

步骤 5: 当有 t 类新电缆故障发生后, 将这些新故障的样本集 S_t 与联合特征集 P 相结合形成扩展训练集 E_{Ts} 。然后, 使用 E_{Ts} 和总损失函数 $L_T(\theta)$ 继续训练步骤 2 中的 DCNN 模型。训练结束后, 保留网络参数, 得到能够诊断 $k+t$ 类电缆故障的新模型

DCNN-KD-A。

步骤 6: 应用步骤 3 和 4 中的方法, 结合步骤 5 中的模型, 获得 t 类新故障样本的类特征 $\varphi(x)$ 和类中心 μ_{k+t} 。步骤 5 结束后, t 类新故障对于诊断模型而言, t 类新故障就变成旧故障, 此时, 按照 2.2.2 节中联合特征集 P 的更新规则对 P 进行更新。更新后的联合特征集 P 包含 $k+t$ 类电缆故障样本。

步骤 7: 当继续有 l 类新电缆故障发生后, 重复步骤 5 和 6, 获得能够诊断 $k+t+l$ 类故障的新模型和包含 $k+t+l$ 类故障样本的联合特征集 P 。

步骤 8: 故障诊断。将需要诊断故障的样本输入步骤 7 中的模型, 得到该样本的类特征, 使用构建的故障分类器和类特征确定该样本的电缆故障类别。至此, 电缆故障可扩展化诊断的整个流程完成。

3 诊断实验与结果分析讨论

3.1 数据集的获取与构建

本文共研究 8 种电缆状态, 包括 3 种干扰和 5 种故障。扰动包括静态负荷突变、动态负荷突变和电容器投切; 故障包括间歇性电弧故障、永久性故障和 3 类弱故障。这 8 种状态涉及电缆故障发展的不同阶段以及可能遭受的扰动。

在数据获取上, 课题组分别在江苏某 10 kV 开闭所和江苏某 10 kV 真型实验平台上进行电缆运行数据测量和故障测试。通过这些量测与实验, 得到静态负荷突变、间歇性电弧故障和永久性故障 3 种电缆状态数据, 这 3 种状态数据的数量分别为 238、146 和 255。然而, 这些实测数据的数量不足以支持

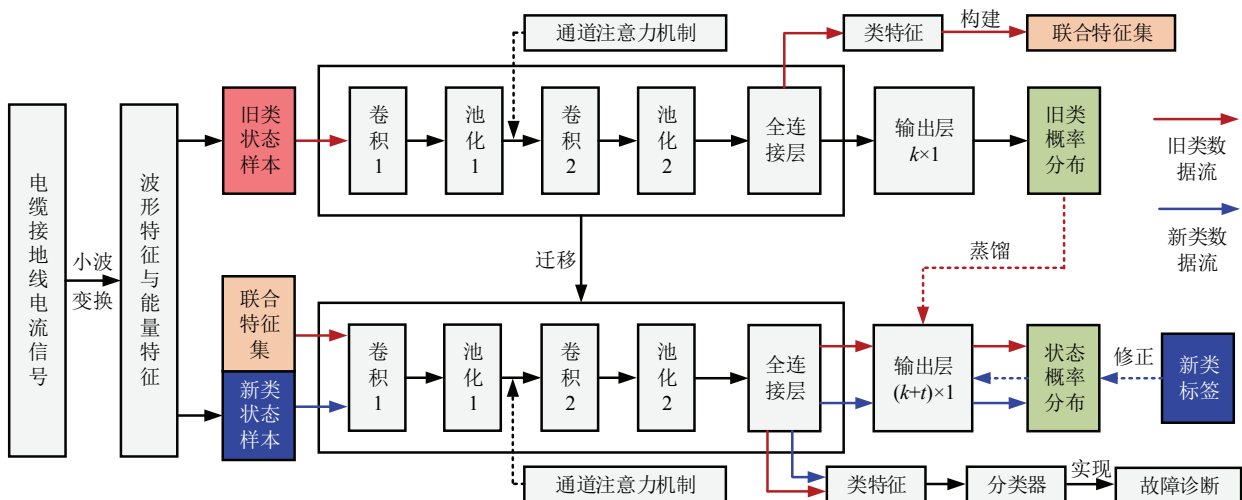


图 2 基于知识蒸馏与注意力机制的电缆故障可扩展化诊断实现示意图

Fig.2 Implementation diagram of scalable diagnosis for cable faults based on knowledge distillation and attention mechanism

基于人工智能的电缆故障诊断研究。为解决这一问题，本文采用少量实测数据与仿真数据相结合的方式，创建一个用于电缆故障可扩展化诊断的复合数据集。

对于仿真数据的生成，本文采用 Mayr 电弧模型模拟间歇性电弧故障，采用 10 kV 鼠笼式异步电动机模型模拟动态负荷突变，采用线路末端并联电容器组模拟电容器投切。对于永久性故障，采用金属性接地和经过渡电阻接地 2 种模型进行仿真。而对于弱故障，采用文献[25-26]中的 3 个模型进行仿真：1) 电缆外绝缘因机械应力或化学腐蚀引起破损导致金属护套在损坏点接地；2) 电缆线芯与金属护套之间的绝缘劣化导致高阻故障；3) 金属护层接地后因腐蚀或水分进入等引起的电缆某点绝缘下降故障。为简化对弱故障模型的描述，这 3 个模型分别被简称为弱故障 1、弱故障 2 和弱故障 3。

如图 3 所示，使用 PSCAD 仿真软件搭建 10 kV 三出线电缆网络，其主要参数被列于表 4。在三出线电缆网络的不同位置应用 8 个不同的电缆状态模型，并在线路首端测量接地线电流。

利用 1.1 节中的特征提取方法对复合数据集中的实测数据和仿真数据进行处理，共计获得电缆 8 种状态的 11 943 个样本。将这些样本随机打乱顺序，以其中 85%作为训练样本，15%作为测试样本。为降低因使用单个样本数据集而产生的诊断偶然性，本文将整个数据集随机打乱 2 次，产生 2 个不同的数据集 A 和 B，用于交叉验证。数据集 A 和 B 的样本分布如表 5 所示，其中加粗标记部分为实测数据数量。与间歇性电弧故障和永久性故障相比，表 5 中弱故障样本较多。这种数据分布是有意的，意在反映电缆状态在现实中的衍变特点。电缆状态的衍变发展不是一蹴而就的，而是一个渐进的过程，其早期故障的频率应较高，而故障中后期的样本数量相比较少，随着时间的推移，中后期故障样本才会逐步增多。

3.2 诊断实验结果

按照 2.5 节中的方法步骤，将样本集 A 和 B 中的前 4 类电缆状态样本分别放入 DCNN-KD-A 模型中进行训练，然后按照每次增加 1 类电缆状态的频率，依次将第 5 类到第 8 类状态样本加入到模型中进行可扩展化诊断训练。每完成 1 次可扩展化诊断，则利用样本集 A 和 B 中相应的测试样本对可扩展化诊断训练后的模型进行评估。于是，得到如图 4 和

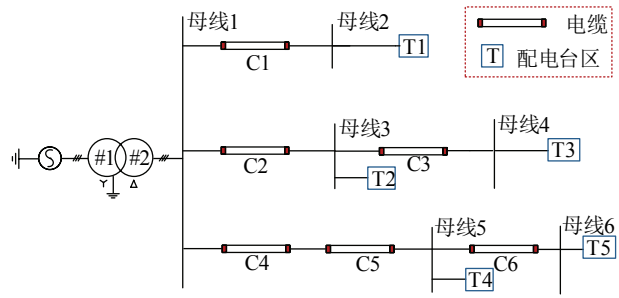


图 3 10 kV 三出线电缆网络

Fig.3 10 kV three-feeder network

表 4 10 kV 三出线电缆网络参数

Table 4 Parameters of 10 kV three-feeder cable network

电缆	长度/km	配电台区	容量/MVA	cos(φ)
C1	6	T1	2	0.90
C2	4	T2	1	0.90
C3	3	T3	1	0.88
C4, C5	3, 5	T4	2	0.87
C6	2	T5	1	0.86

表 5 样本分布

Table 5 Distribution of sample data

状态类型	训练样本		测试样本		总计	状态标签
	A	B	A	B		
弱故障 1	1 955	1 945	349	359	2 304	0
弱故障 2	1 979	1 973	325	331	2 304	1
弱故障 3	1 933	1 962	371	342	2 304	2
静态负荷突变	1 215 (199)	1 205 (205)	216 (39)	226 (33)	1 431 (238)	3
间歇性电弧故障	853 (129)	876 (126)	155 (17)	132 (20)	1 008 (146)	4
动态负荷突变	804	832	156	128	960	5
永久性故障	737 (221)	717 (207)	127 (34)	147 (48)	864 (255)	6
电容器投切	675	641	93	127	768	7

图 5 所示的 DCNN-KD-A 模型分别在 5 类状态、6 类状态、7 类状态和 8 类状态时的可扩展化诊断混淆矩阵。样本集 A 和 B 的可扩展化诊断结果如表 6 所示。根据经验和相关计算，DCNN-KD-A 模型的可扩展化诊断训练所使用的参数设置如下：联合特征集的容量 N_U 为 4 000，学习率为 0.1，训练批次的大小为 64，训练的轮次为 100，优化器采用自适应矩估计算法(adaptive moment estimation, Adam)。

从表 6 中可以看到，随着电缆状态数量的增加，可扩展化诊断的精度有下降趋势，但诊断精度可以保持在 88%以上。结合图 4 和图 5 的混淆矩阵，可

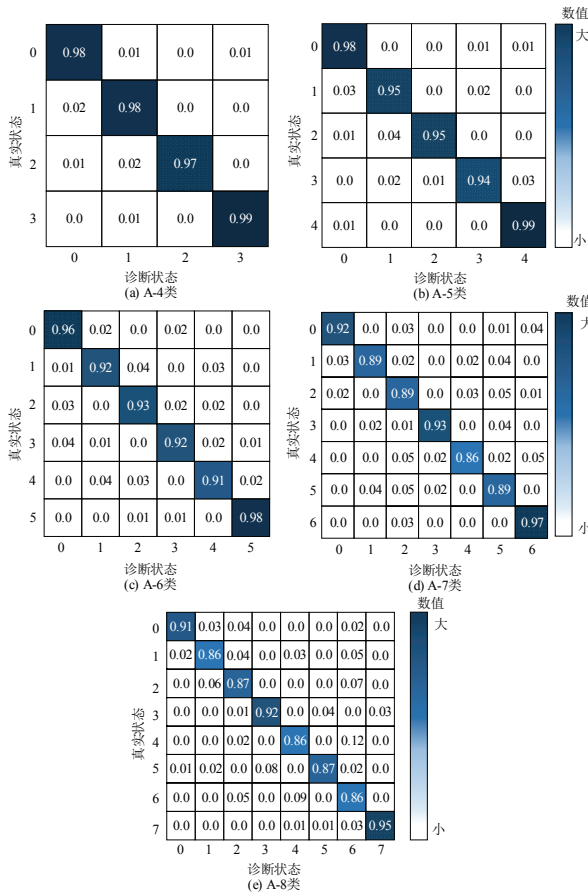


图 4 A 样本集的可扩展化诊断混淆矩阵

Fig.4 Confusion matrix of incremental diagnosis of set A

表 6 样本集 A 和 B 的可扩展化诊断结果

Table 6 Incremental diagnosis result of set A and B

样本集	诊断精度/%				
	4 类	5 类	6 类	7 类	8 类
A	97.94	95.97	94.27	90.70	88.45
B	97.14	95.68	92.88	90.27	88.73

以发现可扩展化诊断精度下降的原因在于旧类状态诊断精度的降低。出现此问题的原因主要为两方面，一是本文使用固定容量的联合特征集对设备有限内存这一实际问题进行表征，在固定容量这一条件下，随着电缆状态数量的增加，旧类状态特征样本的数量相应减少，可能会导致无法学到某些样本的特征；二是尽管有注意力机制的引入，其对特征凝练有较好的作用，但依然无法避免蒸馏过程中一些信息的损耗或改变，这可能会削弱模型诊断旧类状态的准确性。

相较于旧类状态，在每次可扩展化诊断中，新增的状态均会具有较高诊断精度。这是因为新状态样本的分类损失采用硬标签，模型在学习新状态特

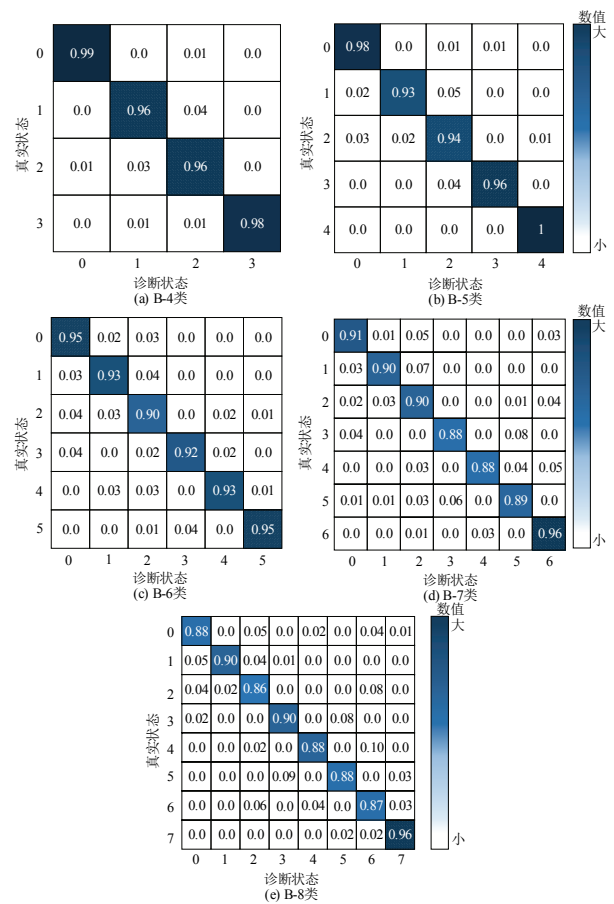
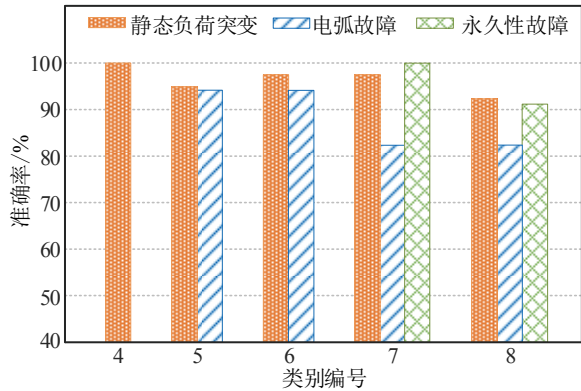


图 5 B 样本集的可扩展化诊断混淆矩阵


Fig.5 Confusion matrix of incremental diagnosis of set B

征时能够得到不断的修正，从而保证较高的诊断准确率。

本文所使用的复合数据集包含少量实测数据，样本集 A 的测试集中有 39 个静态负荷突变的实测样本、17 个间歇性电弧故障样本和 34 个永久性故障样本，而在样本集 B 的测试集中，这 3 种状态的实测样本数量分别为 33、20 和 48。为展示本文所提方法对实测数据的效果，分别将 A 和 B 2 个测试集的实测数据在可扩展化诊断中的诊断精度进行整理，得到结果如图 6 所示。从图 6 中可以看到，对于 2 个测试集中的静态负荷突变和永久性故障，它们的诊断精度均可保持在 90% 以上。与这 2 种状态相比，间歇性电弧故障的诊断精度略低，但也超过 80%。间歇性电弧故障诊断精度低的原因在于其实测数据量最少，即使少量样本的误判也会导致其诊断精度的较大幅度降低。此外，间歇性电弧故障的故障特征也是这 3 种状态中最复杂的，这也会在一定程度上为其精确诊断造成困难。尽管这 3 种状态实测数据的诊断精度有所差异，但结果依然表明，本



(a) A样本集中实测数据的诊断精度



(b) B样本集中实测数据的诊断精度

图6 测试集中测量数据的诊断精度

Fig.6 Diagnosis accuracy for field data in testing set

文所提方法对实测数据有较好的效果。

3.3 不同容量联合特征集的对比

理论上,训练样本数量越多,DCNN-KD-A模型的泛化能力越强,其诊断效果也会越好。但实际上,计算机内存是有限的,训练样本不可能无限多,因而本文通过1个固定容量的联合特征集来表征这一问题。为探究不同联合特征集容量对DCNN-KD-A模型诊断结果的影响,本节以数据集A为分析和讨论对象(后续其他讨论也是以此数据集为例),改变联合特征集容量 N_U ,对每个容量进行5次诊断实验,得到如表7所示的8种电缆状态在不同容量下的可扩展化诊断结果。结果表明,当 $N_U=4\ 000$ 时,DCNN-KD-A模型的平均诊断精度最高。当 N_U 小于4 000时,模型的平均诊断精度会随着 N_U 的增加而提升。然而,当 N_U 增加到5 000时,平均诊断精度会降低。

由于使用固定容量的联合特征集,每类电缆状态样本的数量会随着状态类别的增加而减少。当联合特征集容量过小时,用于训练的每类状态样本数量都会很少,这将导致特征学习不足,诊断精度必

表7 不同容量联合特征集的诊断结果

Table 7 Diagnostic results with different united feature set

N_U	诊断精度/%					平均诊断精度/%
	实验 1	实验 2	实验 3	实验 4	实验 5	
2 000	86.39	86.83	86.72	86.39	86.05	86.48
3 000	87.28	87.11	88.17	87.67	87.33	87.51
4 000	88.45	88.73	89.12	88.84	88.50	88.73
5 000	87.28	86.83	87.22	87.67	86.72	87.14

然较低。而联合特征集容量过大时,由于本文使用的是分布不平衡的数据集样本,样本数量的不平衡将导致一些状态过拟合,而另一些状态则欠拟合,这也会降低诊断精度。因此,在有限内存下对电缆故障状态进行可扩展化诊断时,需要考虑新旧状态样本数量之间的平衡问题。

3.4 不同输入特征的对比

引言部分提到,基于人工智能的电缆故障诊断方法主要分为两大类,一是基于浅层特征,二是基于统计特征。为探究浅层特征与统计特征在电缆故障可扩展化诊断中的差异性,本节使用浅层特征同本文方法使用的统计特征进行电缆故障可扩展化诊断的对比实验,浅层特征使用的是文献[25]中护层电流和三相电流的时间序列数据,每一特征类型做5次诊断实验,实验结果如表8所示。使用DCNN-KD-A模型诊断4种电缆状态时,统计特征的平均诊断精度为97.64%,其比浅层特征的平均诊断精度高3.95%。在使用DCNN-KD-A模型完成6种电缆状态的可扩展化诊断后,统计特征与浅层特征的平均诊断精度差值为4.58%。而当可扩展化诊断8种电缆状态时,两者之间的差值上升到5.03%。这一趋势表明,在可扩展化诊断中,随着电缆状态数量的增加,统计特征和浅层特征间的诊断精度差值也会扩大。因此,与浅层特征相比,统计特征在可扩展化诊断中更稳定,优势更为明显。

3.5 不同网络模型的对比

在现有基于人工智能的电缆故障诊断方法中,每一个诊断任务,例如诊断4类电缆故障或5类电缆故障,都是1个独立的诊断模型,每个诊断任务的模型参数是不同的,且各任务间不存在关联性。现有基于人工智能的电缆故障诊断方法可被视为单任务解决方案。与其不同的是,本文中提出的DCNN-KD-A模型,其通过一种增量学习的方式促进任务间的连接,允许新诊断任务能够从之前的诊

表 8 不同输入特征的诊断结果

特征类型	诊断精度/%					平均诊断精度/%
	实验 1	实验 2	实验 3	实验 4	实验 5	
统计特征(4)	97.94	97.46	97.30	97.46	98.02	97.64
浅层特征(4)	93.97	93.66	93.58	93.74	93.50	93.69
统计特征(6)	94.27	94.53	94.02	93.89	94.27	94.20
浅层特征(6)	89.44	89.69	89.63	89.69	89.63	89.62
统计特征(8)	88.45	88.73	89.12	88.84	88.50	88.73
浅层特征(8)	84.04	83.54	84.43	83.76	83.71	83.70

断任务中继承相关信息,使 DCNN-KD-A 能够在原有诊断任务的基础上实现动态扩展,实现电缆故障的可扩展化诊断。为更好地说明现有基于人工智能的电缆故障诊断方法和本文所提方法之间的差异,本节使用 DCNN、DCNN-KD 和 DCNN-KD-A 模型分别从状态增量下的诊断精度和总诊断时间 2 个方面进行对比实验,对比结果如表 9 和表 10 所示。

通过表 9 可以看到,随着电缆状态种类的增加,DCNN、DCNN-KD 和 DCNN-KD-A 的诊断准确率都呈现下降趋势。传统 DCNN 的诊断准确率要优于 DCNN-KD,从 4 类状态到 8 类状态,两者的诊断精度差值分别为 0.09%、0.44%、0.02%、0.11%和 0.51%。相较于 DCNN-KD,在加入注意力机制后的 DCNN-KD-A 的诊断准确率有较为明显提升,其诊断精度要高于 DCNN。从 4 类状态到 8 类状态,DCNN-KD-A 的诊断精度分别超出 DCNN 0.57%、0.14%、1.13%、0.86%和 0.45%。

状态增量下不同网络模型的诊断时间对比结果如表 10 所示。从诊断 4 类状态到 8 类状态,DCNN 与 DCNN-KD-A 的诊断时间总消耗差值分别为 -21.29、-26.82、0.39、28.88、33.7 s,而 DCNN-KD 与 DCNN-KD-A 的诊断时间总消耗差值分别为 -10.35、-12.39、-13.66、-15.95、-14.96 s。相比于 DCNN-KD 和 DCNN-KD-A 2 种模型,DCNN 结构简单,参数较少,因而在故障可扩展化诊断的初期,即诊断 4 类和 5 类状态时,其诊断时间总消耗要少于 DCNN-KD 与 DCNN-KD-A。但由于 DCNN 缺乏可扩展化诊断机制,其无法利用先前诊断任务的信息,面对每项诊断任务,都需要重新训练。因此,在诊断 5 类状态以后,随着电缆状态种类的增加,DCNN 的诊断时间总消耗要逐步多于 DCNN-KD 和 DCNN-KD-A,且新增状态越多,时间消耗的差异愈加明显。相较于 DCNN-KD,

表 9 状态增量下不同网络模型的诊断精度

Table 9 Diagnostic accuracy among different models with the number of fault types increasing

故障诊断模型	不同状态类型的诊断精度/%				
	4 类	5 类	6 类	7 类	8 类
DCNN	97.07	95.69	93.07	89.73	88.28
DCNN-KD	96.98	95.25	93.05	89.62	87.77
DCNN-KD-A	97.64	95.83	94.20	90.59	88.73

表 10 状态增量下不同网络模型的诊断时间对比

Table 10 Comparison of diagnostic time among different models with the number of fault types increasing

故障诊断模型	状态增量下的总诊断时间/s				
	4 类	4、5 类	4—6 类	4—7 类	4—8 类
DCNN	246.37	498.37	757.12	1 018.23	1 283.30
DCNN-KD	257.31	512.80	743.07	973.40	1 234.64
DCNN-KD-A	267.66	525.19	756.73	989.35	1 249.60

DCNN-KD-A 增加了注意力机制模块,其模型复杂度提高,模型参数数量增加,诊断时间的消耗不可避免的增多。但随着电缆状态种类的增加,DCNN-KD 与 DCNN-KD-A 之间的诊断时间差仅有少量增加,DCNN-KD 的诊断时间优势并不能随着电缆状态种类的增加而明显扩大。

因而,从诊断精度与诊断时间消耗 2 个方面综合评判,本文所提出的 DCNN-KD-A 模型的性能要优于现有 DCNN 模型。而在 DCNN-KD 基础上引入注意力机制模块,仅需增加少量计算资源,就可实现电缆故障可扩展化诊断精度的提升。

4 结论

1) 在有限内存这一条件下,本文所提方法的诊断准确率会随着电缆状态种类的增加而呈现下降趋势,但它依然能够保持接近 90%的诊断精度。相关实验结果也表明,该方法对实测数据的诊断也具有较好效果。

2) 在实际应用中,电缆状态样本的分布规律是旧状态样本多于新状态样本。因此,在确定联合特征集的容量时,有必要考虑新旧样本之间的数量平衡。避免容量过大或过小,可以保证可扩展化诊断模型的诊断精度。

3) 与浅层特征相比,基于统计特征的电缆故障诊断精度更高。而在电缆故障的可扩展化诊断中,

随着电缆状态种类的增加,这一优势更为明显。

4) 与现有基于深度卷积神经网络的诊断方法相比,在电缆故障可扩展化诊断中,本文所提方法不仅能够提升诊断的准确率,还可以减少诊断时间的总消耗,节约计算资源。

在电缆故障可扩展化诊断中,旧类故障的诊断精度始终低于新增加故障类型的诊断精度,这影响了可扩展化诊断的整体精度。因而在后续研究中,我们一方面将在注意力机制的基础上,研究相关方法进一步增强深度神经网络的特征凝练作用,减小知识蒸馏的信息损耗与改变;另一方面将在联合特征集的构建和更新规则上做改进研究,以保证旧类故障样本的多样性和特征学习的全面性。通过这些研究提升对旧类故障的诊断精度,从而确保可扩展化诊断的整体精度也得以提高。

参考文献 References

- [1] 于志鹏, 许永鹏, 钱庆林, 等. 潮湿环境中中压电缆接头早期故障的演变规律及特性[J]. 高电压技术, 2024, 50(3): 1311-1321.
YU Zhipeng, XU Yongpeng, QIAN Qinglin, et al. Evolution process and characteristics of medium voltage cable joints' incipient faults in humid environment[J]. High Voltage Engineering, 2024, 50(3): 1311-1321.
- [2] 张浩然, 高建, 武康宁, 等. 基于温度测量和气体分析的高压电缆缓冲层烧蚀故障检测技术[J]. 高电压技术, 2023, 49(12): 4929-4937.
ZHANG Haoran, GAO Jian, WU Kangning, et al. Detection technology of buffer layer ablation failure in high voltage cables based on temperature measurement and gases analysis[J]. High Voltage Engineering, 2023, 49(12): 4929-4937.
- [3] 揭青松, 杨庆, 崔浩楠, 等. 基于暂态电压传递特性的电缆接头绝缘状态检测方法[J]. 高电压技术, 2022, 48(3): 1124-1132.
JIE Qingsong, YANG Qing, CUI Haonan, et al. Insulation state detection method of cable joint based on transient voltage transfer characteristics[J]. High Voltage Engineering, 2022, 48(3): 1124-1132.
- [4] 吴阳, 张品佳. 基于漏电流测量的配电网电缆高精度状态感知技术研究[J]. 中国电机工程学报, 2022, 42(8): 2929-2939.
WU Yang, ZHANG Pinjia. High-accuracy condition sensing for power cables in distribution grids based on leakage current measurement approach: an overview[J]. Proceedings of the CSEE, 2022, 42(8): 2929-2939.
- [5] 瞿科, 张文海, 肖先勇, 等. 基于波形衰减因子的电缆接头绝缘早期故障状态监测[J]. 高电压技术, 2022, 48(1): 318-327.
QU Ke, ZHANG Wenhai, XIAO Xianyong, et al. Condition monitoring for incipient faults of cable joint insulation based on waveform attenuation factor[J]. High Voltage Engineering, 2022, 48(1): 318-327.
- [6] GAO C, WANG L, MAO J M, et al. Non-intrusive cable fault diagnosis based on inductive directional coupling[J]. IEEE Transactions on Power Delivery, 2019, 34(4): 1684-1694.
- [7] 赵洪山, 孙京杰, 许向东. 基于反射系数谱积分的电缆缺陷诊断方法[J]. 电网技术, 2022, 46(11): 4548-4556.
ZHAO Hongshan, SUN Jingjie, XU Xiangdong. Diagnosis of local defects in cables based on integral reflection coefficient spectrum[J]. Power System Technology, 2022, 46(11): 4548-4556.
- [8] 王子健, 周凯, 朱光亚, 等. 基于时频域转换法的配网电缆冷缩中间接头受潮诊断[J]. 高电压技术, 2022, 48(6): 2178-2186.
WANG Zijian, ZHOU Kai, ZHU Guangya, et al. Moisture diagnosis method for cold-shrinkable intermediate joints of distribution cables based on time-frequency domain conversion[J]. High Voltage Engineering, 2022, 48(6): 2178-2186.
- [9] 郭蕾, 曹伟东, 白龙雷, 等. 融合注意力机制与多尺度网络的EPR电缆终端故障诊断方法[J]. 高电压技术, 2021, 47(11): 3872-3880.
GUO Lei, CAO Weidong, BAI Longlei, et al. Fault diagnosis method for EPR cable terminals based on attention mechanism and multiscale network[J]. High Voltage Engineering, 2021, 47(11): 3872-3880.
- [10] 聂永杰, 王威望, 李欣原, 等. 基于电流积分电荷技术的神经网络-模糊聚类电缆绝缘热老化状态评估模型[J]. 高电压技术, 2022, 48(12): 4760-4769.
NIE Yongjie, WANG Weiwang, LI Xinyuan, et al. Evaluation model for thermal aging state of cable insulation using the current integral charge measurement technique with the neural network-fuzzy clustering method[J]. High Voltage Engineering, 2022, 48(12): 4760-4769.
- [11] ZHU K, PONG P W T. Fault classification of power distribution cables by detecting decaying DC components with magnetic sensing[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(5): 2016-2027.
- [12] ZHANG W H, XIAO X Y, ZHOU K, et al. Multicycle incipient fault detection and location for medium voltage underground cable[J]. IEEE Transactions on Power Delivery, 2017, 32(3): 1450-1459.
- [13] 李蓉, 周凯, 万航, 等. 基于输入阻抗谱的电力电缆本体局部缺陷类型识别及定位[J]. 电工技术学报, 2021, 36(8): 1743-1751.
LI Rong, ZHOU Kai, WAN Hang, et al. Identification and location of local defects in power cable body based on input impedance spectroscopy[J]. Transactions of China Electrotechnical Society, 2021, 36(8): 1743-1751.
- [14] 张海月, 王守明, 刘骥, 等. 基于PT-PFM激励阻抗谱数字重构的电缆故障诊断定位[J]. 中国电机工程学报, 2024, 44(2): 805-816.
ZHANG Haiyue, WANG Shouming, LIU Ji, et al. Cable fault diagnosis and location based on digital reconstruction of PT-PFM excitation impedance spectrum[J]. Proceedings of the CSEE, 2024, 44(2): 805-816.
- [15] 饶显杰, 徐忠林, 刘翔宇, 等. 基于反射系数与核函数构建的新型电缆缺陷诊断方法[J]. 电工技术学报, 2024, 39(7): 2184-2192, 2213.
RAO Xianjie, XU Zhonglin, LIU Xiangyu, et al. A new cable defect diagnosis method based on reflection coefficient and kernel function construction[J]. Transactions of China Electrotechnical Society, 2024, 39(7): 2184-2192, 2213.
- [16] 赵书静, 龚梁涛, 詹博博, 等. 基于FMCW的10 kV配电网电缆故障定位及类型识别方法[J]. 中国电机工程学报, 2023, 43(11): 4452-4462.
ZHAO Shujing, GONG Liangtao, ZHAN Bobo, et al. 10 kV cable fault location and type identification method based on FMCW[J]. Proceedings of the CSEE, 2023, 43(11): 4452-4462.
- [17] 唐文虎, 梁启恒, 赵柏宁, 等. 基于改进稀疏表示的海上风电场交流海底电缆短路故障分类方法[J]. 中国电机工程学报, 2023, 43(6): 2212-2221.
TANG Wenhui, LIANG Qiheng, ZHAO Baining, et al. Short-circuit fault classification method for AC submarine cables in offshore wind farms based on improved sparse representation[J]. Proceedings of the CSEE, 2023, 43(6): 2212-2221.

- [18] 朱煜峰, 许永鹏, 陈孝信, 等. 基于卷积神经网络的直流 XLPE 电缆局部放电模式识别技术[J]. 电工技术学报, 2020, 35(3): 659-668. ZHU Yufeng, XU Yongpeng, CHEN Xiaoxin, et al. Pattern recognition of partial discharges in DC XLPE cables based on convolutional neural network[J]. Transactions of China Electrotechnical Society, 2020, 35(3): 659-668.
- [19] 汪 颖, 卢 宏, 杨晓梅, 等. 堆叠自动编码器与 S 变换相结合的电缆早期故障识别方法[J]. 电力自动化设备, 2018, 38(8): 117-124. WANG Ying, LU Hong, YANG Xiaomei, et al. Cable incipient fault identification based on stacked autoencoder and S-transform[J]. Electric Power Automation Equipment, 2018, 38(8): 117-124.
- [20] KWON G Y, LEE C K, SHIN Y J. Diagnosis of shielded cable faults via regression-based reflectometry[J]. IEEE Transactions on Industrial Electronics, 2019, 66(3): 2122-2131.
- [21] WANG M H, LU S D, LIAO R M. Fault diagnosis for power cables based on convolutional neural network with chaotic system and discrete wavelet transform[J]. IEEE Transactions on Power Delivery, 2022, 37(1): 582-590.
- [22] 傅 尧, 周 凯, 朱光亚, 等. 一种基于改进的 WGAN 模型的电缆终端局部放电识别准确率提升方法[J]. 电网技术, 2022, 46(5): 2000-2008. FU Yao, ZHOU Kai, ZHU Guangya, et al. Accuracy improvement of cable termination partial discharging recognition based on improved WGAN algorithm[J]. Power System Technology, 2022, 46(5): 2000-2008.
- [23] REBUFFI S A, KOLESNIKOV A, SPERL G, et al. iCaRL: incremental classifier and representation learning[C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017: 5533-5542.
- [24] HINTON G, VINYALS O, DEAN J, et al. Distilling the knowledge in a neural network[J]. arXiv: 1503.02531, 2015.

- [25] CHI P, ZHANG Z, LIANG R, et al. A fault diagnosis method of double-layer LSTM for 10 kV single-core cable based on multiple observable electrical quantities[J]. Electrical Engineering, 2022, 104(2): 603-614.
- [26] ALOUI T, AMAR F B, ABDALLAH H H. Fault prelocalization of underground single-phase cables: modeling and simulation[J]. International Journal of Electrical Power & Energy Systems, 2013, 44(1): 514-519.



CHI Peng
Ph.D.

Associate professor
Corresponding author



LIANG Rui
Ph.D., Professor

迟 鹏(通信作者)

1990—, 男, 博士, 副教授, 硕导
主要从事电气设备故障诊断与状态评估、人工智能在电力系统中应用方面的研究工作
E-mail: chipeng@qust.edu.cn

梁 睿

1981—, 男, 博士, 教授, 博导
主要从事电气安全、综合能源、设备状态评估方面的研究工作
E-mail: liangrui@cumt.edu.cn

收稿日期 2024-10-28 修回日期 2025-06-09 编辑 曾文君