

基于 MTF 和 CNN 融合注意力机制的过电压故障识别研究

郝葆亮¹, 刘翰林², 张明轩³, 郑世超^{1,*}, 孙荣荣¹

(1. 青岛理工大学 信息与控制工程学院, 青岛 266525; 2. 国网山东省电力公司莱阳市供电公司, 烟台 265200;
3. 国网淄博供电公司, 淄博 255022)

摘要:在“双碳”目标背景下, 电力行业得到了高速发展, 各行各业对电能质量与数量的需求急剧增加, 为电力系统的安全稳定运行带来了极大挑战。为了提高电力系统过电压故障识别的准确度, 本文提出了一种基于马尔可夫转移场(Markov Transition Field, MTF)与卷积神经网络(Convolutional Neural Network, CNN)融合注意力机制(Attention Mechanism, AM)的过电压故障识别模型(MTF-CNN-Attention)。利用 MTF 技术将一维时序数据转化为二维平面特征图形, 从而提高卷积神经网络与注意力机制的特征提取能力和学习效率。然后将 MTF-CNN-Attention 模型与现有的 GoogleNet、AlexNet、ResNet-50、VGG 模型进行对比分析。结果显示, 相较于上述 4 种模型, MTF-CNN-Attention 模型的识别准确度分别提升了 5.36%、7.26%、3.74%、4.85%, 有着更好的识别精度。

关键词:马尔可夫转移场; 卷积神经网络; 注意力机制; 过电压故障识别

中图分类号: TM7 **文献标志码:** A **文章编号:** 1673-4602(2026)01-0097-08

DOI: 10.3969/j.issn.1673-4602.2026.01.013

Research on overvoltage fault identification based on MTF and CNN fusion attention mechanism

HAO Baoliang¹, LIU Hanlin², ZHANG Mingxuan³, ZHENG Shichao^{1,*}, SUN Rongrong¹

(1. School of Information and Control Engineering, Qingdao University of Technology, Qingdao 266525, China;
2. Laiyang City Power Supply Company of State Grid Shandong Electric Power, Yantai 265200, China;
3. State Grid Zibo Power Supply Company, Zibo 255022, China)

Abstract: Under the background of “dual carbon” target, the power industry has been developed rapidly. The demand for power quality and quantity in all trades and professions has increased sharply, which has brought great challenges to the safe and stable operation of the power system. In order to improve the overvoltage fault identification accuracy of power system, an overvoltage fault identification model based on Markov transition field (MTF) and convolutional neural network (CNN) fusion attention mechanism (AM) is proposed. MTF technology is used to transform one-dimensional time series data into two-dimensional planar feature graphics, which improves the feature extraction ability and learning efficiency of the

收稿日期: 2024-06-07

基金项目: 山东省自然科学基金青年项目(ZR2023QF034)

作者简介: 郝葆亮(2002—), 男, 山东潍坊人。学士, 研究方向为数智电网故障诊断、深度学习在电网中的应用。

E-mail: 2463851972@qq.com。

* 通信作者: 郑世超(1989—), 男, 山东青岛人。博士, 讲师, 主要从事高电压与绝缘技术以及人工智能在电网中的应用等方面的研究。E-mail: zsc13792889163@163.com。

convolutional neural network and the attention mechanism. Then the MTF-CNN-Attention model is compared with the existing GoogleNet, AlexNet, ResNet-50 and VGG models. The results show that compared with the above four models, the recognition accuracy of MTF-CNN-Attention model is improved by 5.36%, 7.26%, 3.74% and 4.85% respectively, exhibiting better recognition accuracy.

Key words: Markov transition field; convolutional neural network; attention mechanism; overvoltage fault identification

在“双碳”目标下,光伏、风能等新能源发电设备并网比例越来越高,电动汽车、电气化铁路等非线性负荷接入电网的规模也在不断扩大^[1],伴随着电力系统的快速发展,对电网的智能化需求也在不断提高。现如今我国已将智能电网的发展提升至国家级的战略高度。在此背景下,国家电网公司积极响应并提出了构建以特高压电网为基石,促进各级电网之间和谐共进的“坚强智能电网”规划。过电压故障不仅会损坏电力设备、影响电力系统的安全可靠运行,还可能对人民生命财产安全构成威胁。因此,研究过电压故障识别技术具有重要的现实意义和应用价值。

过电压故障的诊断方式经历了多次迭代更新^[2],从传统的人工检测、按经验巡检到早期的计算机检测,均离不开人力的参与。随着电力电子技术、传感器技术等新兴技术的发展,已有多个研究团队将研究方向放在了基于人工智能、深度学习的新型电力网络检测领域^[3-9],从经典的 Fourier Transform 技术、Prony 方法到 dq 变换、小波变换、稀疏分解算法等信号处理方法,甚至是规则推理、模糊神经网络、蚁群算法、粒子群算法等群体优化技术都是当今过电压故障识别的发展方向。

本文所提出的马尔可夫转移场与卷积神经网络融合注意力机制(MTF-CNN-Attention)模型便是以深度学习为基础。其创新点主要在于使用马尔可夫转移场将故障数据由一维时序数据转换为二维平面特征图形,可以直观地反映数据中的潜在特征与性质,再配合使用卷积神经网络这种在图像识别领域已经被证实非常有效的图像识别处理方法,最后融入注意力机制,以图像的形式捕捉时间序列中的时间依赖性和动态变化。

1 深度学习模型的建立

1.1 马尔可夫转移场(MTF)模型

马尔可夫转移场(Markov transition field, MTF)是一种将时序数据转化为空间图像数据的方法^[10],是计算机视觉和图像处理中用于表示和分析视频序列中时空模式的一种技术。它基于马尔可夫链的概念,以二维平面图形来表现事件序列中状态间的概率转移。MTF 扩展了马尔可夫状态转移矩阵,该方法通过顺序表达状态转移矩阵实现了对离散化时域动态信息的保留,最终通过模糊内核聚合生成二维图像。

MTF 方法首先根据时序信号的幅值大小将信号划分为 Z 个区间(bin),这些区间分别用 $q_1, q_2, q_3, \dots, q_i$ 来表示。对于每一个采样信号 x_i ,都会根据其幅值大小被映射到相应的区间 q_i 中。随后,MTF 模型会计算 x_{i-1} 与 x_i 由区间 q_i 转移到区间 q_j 的概率 P ,从而将之作为元素 w_{ij} 用于构建一个 $Z \times Z$ 维度的反映时序信号中采样信号在不同区间之间转移概率的 MTF 矩阵 \mathbf{W} ,其结构如式(1)所示。

$$\mathbf{W} = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1Z} \\ w_{21} & w_{22} & \cdots & w_{2Z} \\ \vdots & \vdots & \ddots & \vdots \\ w_{Z1} & w_{Z2} & \cdots & w_{ZZ} \end{bmatrix} = \begin{bmatrix} P(x_i \in q_1 | x_{i-1} \in q_1) & P(x_i \in q_1 | x_{i-1} \in q_2) & \cdots & P(x_i \in q_1 | x_{i-1} \in q_n) \\ P(x_i \in q_2 | x_{i-1} \in q_1) & P(x_i \in q_2 | x_{i-1} \in q_2) & \cdots & P(x_i \in q_2 | x_{i-1} \in q_n) \\ \vdots & \vdots & \ddots & \vdots \\ P(x_i \in q_n | x_{i-1} \in q_1) & P(x_i \in q_n | x_{i-1} \in q_2) & \cdots & P(x_i \in q_n | x_{i-1} \in q_n) \end{bmatrix} \quad (1)$$

通过式(1)可以发现,MTF 忽略了时序数据的动态概率转移。为了实现时间尺度的跨越,这里利用 MTF 矩阵生成了如式(2)所示的动态概率转移矩阵 \mathbf{M} 。

$$\mathbf{M} = \begin{bmatrix} m_{11} & m_{12} & \cdots & m_{1n} \\ m_{21} & m_{22} & \cdots & m_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ m_{n1} & m_{n2} & \cdots & m_{nn} \end{bmatrix} = \begin{bmatrix} w_{ij} | x_1 \in q_i, x_1 \in q_j & w_{ij} | x_1 \in q_i, x_2 \in q_j & \cdots & w_{ij} | x_1 \in q_i, x_n \in q_j \\ w_{ij} | x_2 \in q_i, x_1 \in q_j & w_{ij} | x_2 \in q_i, x_2 \in q_j & \cdots & w_{ij} | x_2 \in q_i, x_n \in q_j \\ \vdots & \vdots & \ddots & \vdots \\ w_{ij} | x_n \in q_i, x_1 \in q_j & w_{ij} | x_n \in q_i, x_2 \in q_j & \cdots & w_{ij} | x_n \in q_i, x_n \in q_j \end{bmatrix} \quad (2)$$

关于 MTF 的计算步骤,首先需要根据式(1)中的矩阵 \mathbf{W} 确定 x_1, \dots, x_n 之间的过渡概率,随后将这些转移概率 w_{ij} 作为 MTF 矩阵的元素进行填充,最终得到一个 $n \times n$ 维度的 MTF 矩阵。MTF 矩阵的每个元素 w_{ij} 表示 2 个时间间隔为 $|i-j|$ 的状态之间的转移概率,特别地, w_{ij} 在 $|i-j|=1$ 时表示沿时间轴的单一间隔转移;而当时间间隔为 0,即 $i=j$ 时, w_{ii} 代表每个状态转移到其自身的概率,也就是自转移概率。

以表 1 中 a、b 所示数据为例,经 MTF 转换后的示意图如图 1 所示。

表 1 特征数据带标签

图片	特征 1	特征 2	特征 3	特征 4	特征 5	特征 6	特征 7	特征 8	标签
a	0.000 209 0	327.092 242 6	187.488 699 5	514.580 942 1	0.000 209 0	31.012 473 6	255.538 549 5	286.551 023 1	1
b	0.001 219 0	254.860 789 1	790.754 119 7	535.893 330 6	0.001 209 0	117.870 903 3	322.237 365 9	204.366 462 6	2




图 1 数据经 MTF 转换结果示意

1.2 卷积神经网络(CNN)模型

卷积神经网络(Convolutional Neural Network, CNN)是一种包含卷积计算且具有深度结构的前馈神经网络。近年来, CNN 表现出的优异特征提取性能使其广泛应用于图像识别、自然语言处理等领域。卷积神经网络的基本结构由多个关键组件构成,分别是负责数据输入的输入层、负责特征提取的卷积层、减少数据维度的降采样层(也称为池化层)、负责信息整合的全连接层以及最终的输出层。这些层级通过连续的卷积和池化操作逐步从输入的图片中抓取并提炼出关键特征,最终用于图像的准确识别和分类。卷积神经网络流程如图 2 所示。




图 2 卷积神经网络流程示意

在过电压故障识别中,CNN能够通过模拟人脑神经元的连接方式构建出多层的网络结构,自动学习图像中的故障特征,避免了传统方法中手动标注特征标签等繁琐的步骤。此外 CNN 能够通过多层的卷积和池化操作提取图像中的深层次特征,进而提高故障识别的准确性和鲁棒性。

CNN 在图像处理方面的优势非常广泛,一方面体现在其优秀的泛化性能,另一方面则是其层次化的特征提取方式。通过在大规模数据集上进行预训练,CNN 模型可以学习到丰富的图像知识并在新的任务上进行迁移学习,这种能力使得卷积神经网络能够快速地适应不同的图像识别任务,提高其实用性和灵活性。

1.3 注意力机制(AM)

注意力机制(Attention Mechanism, AM)是一种通过权重分配使包含重要信息的特征不会随着步长的增加而消失,从而突出重点信息的影响,提高模型特征提取能力的资源分配机制^[11]。其核心概念在于,通过赋予输入数据不同的重要性权重,使得模型能够聚焦于关键信息,从而提高处理效率和准确性,因此在故障识别领域,尤其是过电压故障识别中,AM 的应用尤为重要。

常见的 AM 主要包括点积注意力机制、加性注意力机制以及自注意力机制,由于本次设计涉及大量序列数据,因此本文主要采用自注意力机制来将所有时间步的信息进行整合和交互。其原理是根据查询(Query)、键(Key)和值(Value)之间的关系计算出注意力权重,然后将权重与值相乘,得到每个时间步的加权和,从而得到最终的输出结果。假设有一个序列 $\mathbf{X}=[x_1, x_2, \dots, x_n]$,其中 x_i 表示序列的第 i 个元素。对每个元素 x_i ,分别计算其查询(Q)、键(K)和值(V):

$$\begin{aligned} \mathbf{Q} &= \mathbf{W}^Q \times x_i \\ \mathbf{K} &= \mathbf{W}^K \times x_i \\ \mathbf{V} &= \mathbf{W}^V \times x_i \end{aligned} \quad (3)$$

式中: \mathbf{W}^Q 为对 Query 进行线性变换的权重矩阵; \mathbf{W}^K 为对 Key 进行线性变换的权重矩阵; \mathbf{W}^V 为对 Value 进行线性变换的权重矩阵;它们的维度分别为 $d_Q \times d_X$ 、 $d_K \times d_X$ 和 $d_V \times d_X$,其中 d_X 为输入序列的维度, d_Q 、 d_K 、 d_V 分别为查询、键和值的维度。

计算注意力权重,即将 Query 和 Key 进行点积操作,然后除以一个归一化因子,最后通过 softmax 函数进行归一化:

$$a = \text{softmax}(\mathbf{Q} \times \mathbf{K}^T / \sqrt{d_K}) \quad (4)$$

式中:softmax() 为 softmax 函数; \mathbf{K}^T 为矩阵转置; d_K 为键向量的维度。

在 softmax 函数中,点积操作的结果除以 $\sqrt{d_K}$ 是为了缩放点积的结果,避免注意力权重过小或过大,影响模型的效果。

计算加权和,即将注意力权重与值进行加权求和,得到每个时间步的加权和:

$$o_i = \text{sum}(a_i \times V_j), j=1, 2, \dots, n \quad (5)$$

式中: o_i 为输出序列的第 i 个元素; $\text{sum}()$ 为求和函数; a_i 为第 i 个元素的注意力权重; V_j 为值序列的第 j 个元素。

AM 的本质思想如图 3 所示:在处理序列数据或类似的数据结构时,将一系列由 $\langle K, V \rangle$ 对组成的元素集合作为输入的源数据 Source,当面对目标数据中的某个 Q 时,AM 通过计算这个查询元素与源数据中每个 K 的相似性或相关性来确定对应值的权重系数,随后根据这些权重系数对 V 进行加权求和,得到最终的 AM 数值。

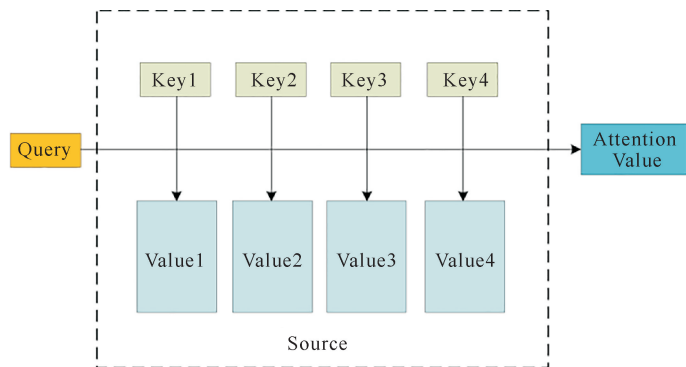


图3 AM 的本质思想

$$A(Q, S) = \sum_{i=1}^L S(Q_i, K_i) \times V_i \quad (6)$$

式中: Q 为查询向量; S 为源数据或上下文; Q_i 为第 i 个查询向量; K_i 为第 i 个键向量; V_i 为第 i 个值向量; $S(\cdot)$ 为查询向量和第 i 个键向量的相似度函数; L 为键值对的数量。

1.4 基于 MTF 与 CNN 融合 AM 的深度学习模型

在构建基于马尔可夫转移场与卷积神经网络融合注意力机制的过电压故障识别模型时,首先需要明确框架方法与流程设计。本文采用了一种混合模型——马尔可夫转移场与卷积神经网络融合注意力机制模型(MTF-CNN-Attention),该模型结合了 MTF 在图像处理中的优势以及 CNN 在特征提取和分类方面的强大能力,并通过引入 AM 来进一步提升模型的识别精度和鲁棒性。

在数据预处理阶段,第一步对所获取的过电压故障数据集进行处理,包括特征值的标定、无关项的去除等,便于后续的数图转换。第二步,利用 MTF 理论将输入的时序电压数据转化为相应的二维平面图像。第三步,借助 Matlab 程序对上一步所得二维图像进行规范化处理,统一其像素大小并进行归一化处理,以提高图像质量和减少计算复杂度。

在特征提取阶段,利用 CNN 的多层卷积和池化操作,从预处理后的图像中提取了丰富的特征。这些特征不仅包括了图像的局部信息,还涵盖了全局的上下文信息,通过逐层卷积和池化逐步抽取和提炼了图像中的关键信息,为后续的分类任务提供了有力的特征表示。

在故障识别与结果分析阶段,本设计将数据集随机打乱并按 70% 的比例划分训练集,30% 的比例划分测试集,利用训练好的模型对测试集进行了故障识别,并对识别结果进行详细分析。

本次设计期望通过有机结合 MTF、CNN 和 AM 的优势,实现对过电压故障的高精度识别。这一研究不仅可以为电力系统的故障识别提供新的思路和方法,也可以为其他领域的图像处理和模式识别提供有益借鉴。

2 仿真数据及参数设置

2.1 仿真数据集的制作

为了更好地训练本次的 MTF-CNN-Attention 模型,利用 Simulink 平台搭建 2 套简易的电力系统网络,即 0.4 kV 电力网络和 1 kV 电力网络。

对于 0.4 kV 电力网络,本次设计采用三相电源模块 Three-Phase Source 代替发电机组为电力网络提供三相电,其具体参数为:星型连接中性点接地,线电压有效值为 0.4 kV, A 相初始相角为 0,电源频率为 50 Hz,电源在额定电压下的短路容量为 1000 kVA,额定线电压有效值为 0.4 kV,电抗与电阻之比为 7。负载部分使用了三相并联 RLC 负载来模拟,采用星型接地,标称相对电压为 0.4 kV,标称频率为 50 Hz,有功功率设置为 10 kW,感性无功功率为 100 var,容性无功功率为 0 var。为比较有雷击过电压故障与没有雷击过电压故障的差异,本设计搭建了 2 个同样的 0.4 kV 电力系统,并在其中 1 个上加入 Lightning Block 模块来模拟线路受到雷击后造成的雷击过电压故障。该模块可以模拟 IEEE 1159.1 标准定义的 1.2/50 μ s 脉冲瞬态电压,该电压由 $V=A \times \exp(\alpha \times |t-t_1|) \times u(t)$ 计算得到,其中 V 为瞬态电压, A 为脉冲幅度, α 为衰减系数, t_1 为脉冲启动时间, $u(t)$ 为单位阶跃函数。这里设置脉冲幅度为 1 kV,脉冲启动时间为 0.01 s,耦合电阻为 1 Ω ,耦合电感为 10^{-6} H。具体 Simulink 电路如图 4(a)所示。

经过仿真运行,可以得到如图 4(b)(c)所示的 0.4 kV 电力网络受雷击过电压影响电压波形与正常运行时的电压波形。从图中可以明显看到,当时间来到 0.01 s 时 Lightning Block 模块启动发出 1 kV 的高电压作用于 A、B、C 三相电路上,使得在 0.01 s 时的电压发生显著跃变。

1 kV 的电力网络结构参数与 0.4 kV 网络相似,这里不再赘述。仿真完成后,将仿真所得到的 0.4 kV 正常运行时的 A、B、C 三相电压数据,0.4 kV 受雷击导致雷击过电压时的 A、B、C 三相电压数据结合仿真时序信息,以 0.000 01 s 为时间间隔逐一抽取,最终获得了 4000 行该类型电力系统的过电压故障数据集。

2.2 仿真参数设置

本次设计的所有实验都基于 Intel core i7-10875H CPU @2.30 GHz 16 GB RAM 的 64 位 win11 系统。在参数设置方面,本次设计根据过往研究经验与实验数据精心调整了学习率、批处理大小、迭代次数等关键参数。学习率的选择对于模型的收敛速度和性能至关重要,本次设计采用了自适应学习率算法,即 Adam 算法以动态调整学习率,避免模型在训练过程中陷入局部最优解。定义电力网络受雷击影响产生雷击过电压作为类别 1,电力网络正常运行作为类别 2,经过调试发现当初始学习率为 0.0012,最大训练迭代次数为 10,每个迭代的迷你批次大小为 5 时,可以取得相对理想的预测精度。

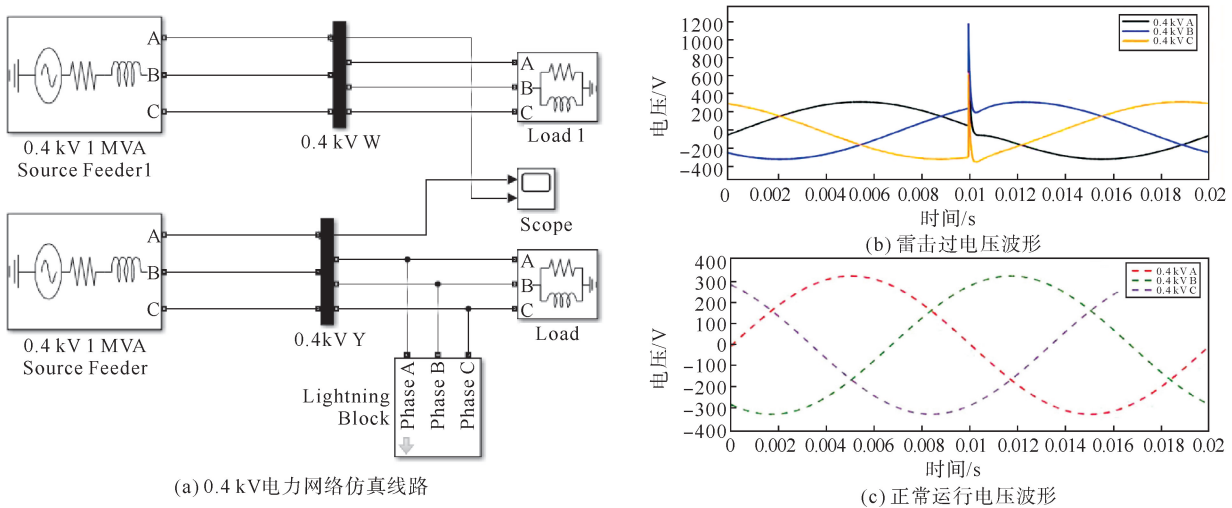


图 4 0.4 kV 电力网络仿真线路与电压波形

3 模型训练结果分析

3.1 仿真结果分析

本次设计利用 GPU 进行 10 轮每轮 560 次共 5600 次的迭代训练,具体训练过程如图 5 所示。从图中可以看到,随着训练次数和迭代次数的不断增加,MTF-CNN-Attention 模型对于过电压故障数据特征的识别准确度虽有小幅度波动,但整体上仍在不断提高,同时模型的损失值也在波动中不断下降,使得识别准确度最终稳定在较高水平:训练集准确率最高达到 97.8571%,测试集最高准确率达到 98%。




图 5 MTF-CNN-Attention 模型的训练曲线

经过一系列仿真运行,最终得到以下训练数据结果,如图 6、图 7 所示。包括 1 个训练集混淆矩阵,1 个测试集混淆矩阵,1 个训练预测精度散点图以及 1 个测试预测精度散点图。

混淆矩阵是用于展示分类模型性能的一种可视化工具,它通过将真实类别与预测类别进行对比,可以直观地了解模型在各个类别上的表现。训练集的混淆矩阵如图 6(a)所示,从矩阵中可以明确看到在模型训练过程中,有 56 个真实类别为类别 2 的数据被错误识别为类别 1,占总体样本的 2%,有 4 个真实类别

为类别 1 的数据被错误地识别为类别 2,占总体样本的 0.1%。测试集的混淆矩阵如图 6(b)所示,从矩阵中可以明确地看到有 23 个真实类别为类别 2 的数据被错误地识别为类别 1,占总体样本的 1.9%,有 1 个真实类别为类别 1 的数据被错误地识别为类别 2,占总体样本的 0.1%。




图 6 训练集与测试集的混淆矩阵

图 7 分别为训练集的预测精度散点图和测试集的预测精度散点图。从图中可以清晰地看到无论是训练还是测试,绝大多数预测值的“★”形图标都与实际标签的“.”图标相重合,这也充分体现出了本次训练的 MTF-CNN-Attention 模型具有较高的识别准确度和特征识别稳定性。

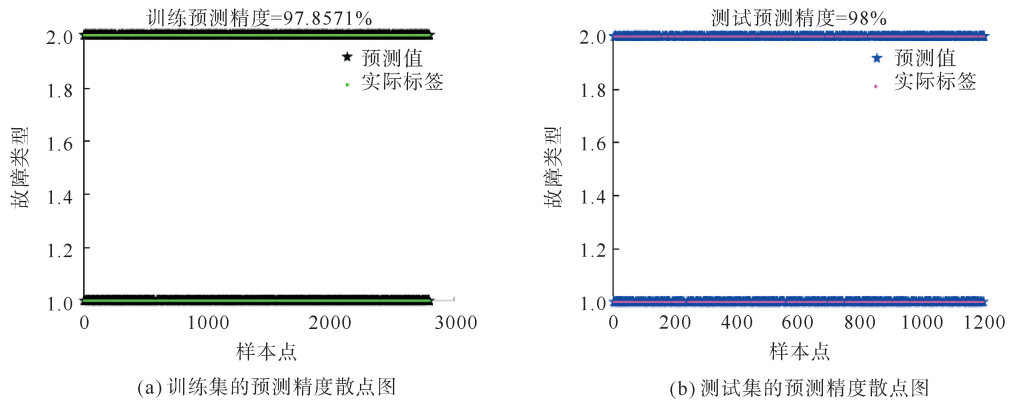


图 7 训练集与测试集的预测精度散点图

3.2 与其他模型仿真结果对比

为了进一步体现基于 MTF-CNN-Attention 模型的过电压故障识别方法的优秀性能与高效的识别能力,本文参照了文献[12-14]的仿真结果以及 GoogleNet、AlexNet、ResNet-50、VGG 4 种较为常用的模型训练结果,制作了如表 2 所示的仿真结果对比。

由表 2 可知,无论是测试集的准确率、训练时间还是所需的模型训练参数都会由于模型的不同而存在显著差异^[15]。虽然 GoogleNet、AlexNet、ResNet-50、VGG 等模型能够达到 94%左右的高准确率,但相

表 2 不同网络模型仿真结果对比

模型	测试集准确率/%	训练时间/min	模型训练参数/10 ⁶
文献[12]	92.45	—	—
文献[13]	92.50	—	—
文献[14]	94.30	—	—
GoogleNet	92.64	28.21	8.64
AlexNet	90.74	19.65	62.70
ResNet-50	94.26	46.76	28.55
VGG-16	93.97	63.77	146.32
VGG-19	93.15	68.65	155.26
MTF-CNN-Attention	98	6.03	2.47

对于本设计所训练的 MTF-CNN-Attention 模型高达 98% 的测试集准确率而言还是有所不足,而且在训练时间上,由于本次设计的训练参数较少,不仅会大大缩短训练时间,而且还可以大幅减少模型训练对于算力的需求,减少模型训练的时间成本与算力成本。由此可见,本文所设计的 MTF-CNN-Attention 过电压故障识别模型相较于现有的传统过电压故障识别方法,有着更高的识别精度、更高的识别效率以及更低的训练成本。

4 结论

本研究通过深度结合马尔可夫转移场(MTF)、卷积神经网络(CNN)以及注意力机制(AM)等技术的优势,最终实现了 MTF-CNN-Attention 模型的搭建与测试。通过与 GoogleNet、AlexNet、ResNet-50、VGG 模型进行对比,得到以下结论:

1) MTF-CNN-Attention 的过电压故障识别方法拥有高达 98% 的故障识别准确率,相较于上述 4 种模型分别提升了 5.36%、7.26%、3.74%、4.85%,因此该模型能够更好地应用于各类系统的故障识别。

2) 在训练时间与训练参数方面,得益于 MTF 与 CNN 的优势互补以及 AM 的加入,本次设计的训练参数远远低于上述 4 种模型,训练时间也依次比上述模型缩短了 22.18、13.62、40.73、62.62 min,本次设计的 MTF-CNN-Attention 模型拥有更高的训练效率以及更低的训练成本。

3) MTF-CNN-Attention 模型不仅适用于过电压故障识别,也为其他领域的分类识别研究提供了新的思路和方法,仅需更换数据集和少数仿真参数即可应用于其他领域的类型识别。

综上所述,随着机器学习等新兴技术的不断发展和相关故障识别研究的不断深入,本文所设计的 MTF-CNN-Attention 过电压故障识别模型在电压故障检测领域具有潜在的发展空间与应用价值。

参考文献(References):

- [1] 黄雨涵,丁涛,李雨婷,等. 碳中和背景下能源低碳化技术综述及对新型电力系统发展的启示[J]. 中国电机工程学报,2021,41(S1):28-51.
HUANG Yuhan,DING Tao,LI Yuting,et al. Decarbonization technologies and inspirations for the development of novel power systems in the context of carbon neutrality[J]. Proceedings of the CSEE,2021,41(S1):28-51.
- [2] 王荆. 电力系统过电压识别方法及混合过电压分解方法研究[D]. 重庆:重庆大学,2011.
WANG Jing. Research on the identification of over-voltage and the decomposition of mixed over-voltage[D]. Chongqing:Chongqing University,2011.
- [3] 孙雅明,王俊丰. 基于分形理论的输电线路故障类型识别新方法[J]. 电力系统自动化,2005(12):23-28.
SUN Yaming,WANG Junfeng. New approach of fault type recognition of transmission lines based on fractal theory[J]. Automation of Electric Power Systems,2005(12):23-28.
- [4] 赵军,吕艳萍,王汉广. 基于多尺度形态分解的特高压线路雷击干扰识别新方法[J]. 高电压技术,2009,35(5):994-998.
ZHAO Jun,LY Yanping,WANG Hanguang. New scheme to identify lightning disturbance for the UHV transmission lines based on multi-scale morphology decomposition[J]. High Voltage Engineering,2009,35(5):994-998.
- [5] 杨晓辉,蔡旭. 分形理论在中压电网故障辨识中的应用[J]. 电力系统自动化,2006(4):59-64.
YANG Xiaohui,CAI Xu. Application of fractal theory in the fault classification for distribution systems[J]. Automation of Electric Power Systems,2006(4):59-64.
- [6] 肖先勇,李逢,邓武军. 雷击与短路故障的 S 变换特征量识别方法[J]. 高电压技术,2009,35(4):817-822.
XIAO Xianyong,LI Feng,DENG Wujun. Identification method of lightning stroke and short-circuit faults using S-transformed characteristics[J]. High Voltage Engineering,2009,35(4):817-822.
- [7] 操丰梅,苏沛浦. 小波变换在配电自动化接地故障检测中的应用研究[J]. 电力系统自动化,1999(13):33-36.
CAO Fengmei,SU Peipu. Study on the application of wavelet transform to detect earth-fault in distribution automation system[J]. Automation of Electric Power Systems,1999(13):33-36.
- [8] GEEV M,PIERLUIGI S,ANTONIO P. Identification of ferroresonance based on S-transform and support vector machine[J]. Simulation Modelling Practice and Theory,2010,18(9):1412-1424.
- [9] ZHU T X. Detection and characterization of oscillatory transients using matching pursuits with a damped sinusoidal dictionary[J]. IEEE Transactions on Power Delivery,2007,22(2):1093-1099.