

基于深度学习的矿井漏电故障分类算法研究

李一凡, 杨 静, 李 乐

(辽宁何氏医学院 a. 人工智能与大数据学院; b. 眼科智能器械应用实验室, 辽宁 沈阳 110170)

摘要: 漏电保护是确保矿井安全的关键措施之一。为实时监测矿井线路中的漏电故障, 文章构建了一个用于模拟矿井生产环境的 MATLAB 模型, 并采用瞬时对称分量法进行暂态故障分析。通过对仿真故障波形与正常波形的对比, 采取集合变换进行面向暂态波形图的数据集扩展。最终, 基于经典深度学习模型, 包括 VGGNet、ResNet 等, 构建了不同结构的深度学习模型, 用于进行暂态波形图的分类识别。研究结果表明: 1) 本文提出的深度学习方法可以有效地进行漏电故障的分类识别; 2) 通过模型对未见数据的测试, 计算了准确度 T_{Acc} 、精确度 T_{Pre} 、召回率 T_{Rec} 和 T_{F-1} 评分, 分别达到 0.983 0、0.986 7、0.983 3、0.983 3, 较高的评价指标证明了模型的分类能力。

关键词: 矿井电网; 瞬时对称分量法; 计算机仿真; 注意力机制

中图分类号: TD611

文献标志码: A

文章编号: 1673-8993(2025)06-0039-08

doi: 10.13402/j.gcs.2025.06.073

Research on mine leakage fault classification algorithm based on deep learning

LI Yifan, YANG Jing, LI Le

(He University; a. College of Artificial Intelligence and Big Data Shenyang; b. Laboratory for Application of Ophthalmic Smart Instruments, Shenyang 110170, Liaoning, China)

Abstract: Leakage protection is one of the critical measures to ensure mine safety. This study aims to achieve real-time monitoring of leakage faults in mine power circuits. To this end, a MATLAB simulation model replicating the mine production environment is developed, incorporating the instantaneous symmetrical component method for transient fault analysis. By comparing the simulated fault waveforms with normal waveforms, set transformation is applied to expand the dataset focused on transient waveform images. Subsequently, based on classic deep learning models such as VGGNet and ResNet, various structured deep learning models are constructed for the classification and recognition of transient waveform images. Experimental results demonstrate that: 1) The proposed deep learning framework effectively distinguishes leakage fault patterns with high reliability; 2) Evaluation metrics on unseen test data—accuracy (T_{Acc}), precision (T_{Pre}), recall (T_{Rec}), and T_{F-1} score, reached 0.983 0, 0.986 7, 0.983 3, and 0.983 3 respectively, validating the model's robust classification capability.

Key words: mine power grid; instantaneous symmetrical component method; computer simulation; attention mechanism

井下漏电故障对井下供电系统及工作人员构成巨大威胁, 长期存在的漏电故障可能会导致短路、人体触电甚至会引发煤矿粉尘爆炸。在煤矿

井下低压电网的电气故障中, 漏电故障占大多数, 约占其总故障的 70% 左右, 其中单相接地故障最为常见, 而三相接地故障则最为严重^[1-2]。作为

收稿日期: 2025-02-17

基金项目: 辽宁省教育厅基本科研项目(JYTMS20231472)

作者简介: 李一凡(1996—), 男, 助教, 从事深度学习、行为感知、智能医学等方面的研究。

全球煤炭生产大国,我国的煤炭开采大部分是在井下进行,因此对井下工作环境的安全要求更高。为此,必须在线路中安装可靠的漏电检测装置,以便在漏电故障发生时,能迅速切断漏电故障支路,确保供电系统的安全性,从而保护生命财产安全,减少经济损失,并保证井下的安全生产^[3-4]。

随着我国供电水平的不断提高,对漏电保护装置的重视程度也在日益增加。1955年,我国引进 PYB 漏电保护装置,并广泛应用到煤炭作业中。自 1960 年起,我国自主研发了大量漏电保护装置,如 JJKB30 型和 JL82 型。然而,随着供电系统的不断升级,原有的漏电保护设备已无法满足井下安全生产所需的高标准。近年来,随着计算机技术在各领域的广泛应用,基于计算机辅助系统的漏电保护设备得到了快速发展。例如将特制传感器与漏电故障相结合,或者利用计算机技术实时监控线路状态,能够检测漏电故障并及时发出预警^[5-7]。

基于前人研究,本文使用 MATLAB 进行了漏电特征的仿真分析,获得单相接地故障、三相接地故障及其正常波形图,作为原始暂态漏电故障波形图数据集。通过对漏电故障波形特征的分析后,采用数据平移、数据镜像等几何变换方法进行数据集扩展,以提高模型泛化能力。基于深度学习构建多种结构的神经网络模型,并使用一组真实数据集进行模型性能评判,以期及时发现故障并进行预警检修。

1 研发背景

1.1 附加直流源系统漏电

矿井电网通常采用全电缆电路,但在实际的矿井供电系统中,要考虑对地电容、对地电阻绝缘值以及线路电抗等。然而,矿井系统通常使用较短的供电线路,电抗和电感效应的影响可以忽略不计。因此,在本文搭建的短线路矿井供电系统图中忽略这两种因素,构建了 3 条低压矿井供电系统网络模型的矿井系统供电网络。在第一条支路中设置单相以及三相接地故障,其余支路为非故障支路,矿井供电系统如图 1 所示。

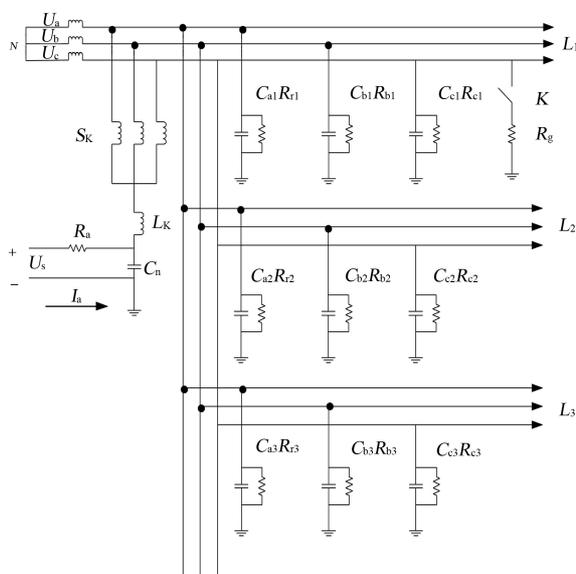


图 1 附加直流矿井供电系统

图 1 中: L_k 为零序电抗器; U_s 为附加的直流电压源; R_a 为限流电阻; C_n 为隔直电容; S_k 为三相电抗器; R 和 C 分别为系统对地绝缘电阻值 (Ω) 和对地电容值 (F)。为了进一步简化系统模型,假设系统中各相对地绝缘电阻相等,各相对地电容也分别相等。

1.2 交直流下的漏电故障电流

1.2.1 交流作用下漏电故障电流

对于单相接地暂态故障,选用瞬时对称分量法进行处理,以探索系统在交流作用下的瞬间暂态故障电路网络。图中隔直电容 C_n 起到隔离直流的作用。为了更简便地分析单相漏电故障电路,给其一个较大值,要求该值远大于对地电容,在本系统中可以忽略其影响。模型简化如图 2 所示。

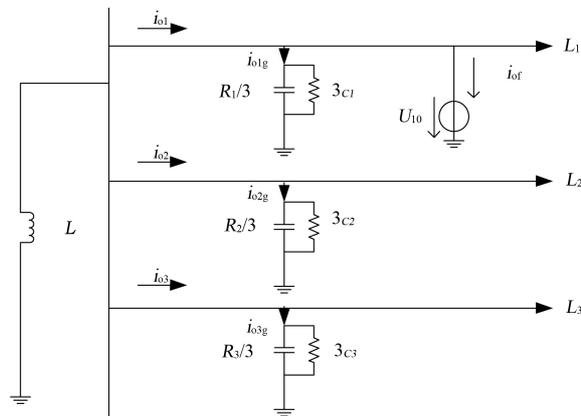


图 2 交流系统下零序网络

如图 2 所示,在交流系统作用下,正常支路的绝缘电阻和对地电容产生的零序电流最终流入

大地,即正常的对地零序电流,表达式为

$$i_{\text{opg}} = 3 \frac{u_{10}}{R_p} + 3C_p \frac{du_{10}}{dt} \quad (1)$$

式中: i_{opg} 为正常支路 p 在交流作用下的零序电流值, A; u_{10} 为零序电压, V; R_p 和 C_p 分别为正常支路下第 p 条支路的绝缘电阻(Ω)与对地电容值(F)。

正常支路稳态值为

$$I_{\text{opg}} = 3 \frac{\dot{U}_{10}}{R_p} + 3j\omega C_p \dot{U}_{10} \quad (2)$$

式中: ω 为角频率, (rad/s)。

根据式(1)可推出暂态分量 i_{opt} 为

$$i_{\text{opt}} = 3U_{100} \left(\frac{1}{R_p} - \frac{C_p}{\tau} \right) e^{-t/\tau} \quad (3)$$

式中: τ 为时间常数, (rad/s), t 为单位时间, s。

正常支路在交流作用下零序电流为

$$i_{\text{opt}} = i_{\text{opg}} + i_{\text{opt}} = 3U_{1(0)m} \sqrt{1/R_p^2 + \omega^2 C_p^2} \sin(\omega t + \beta) + 3U_{100} \left(\frac{1}{R_p} - \frac{C_p}{\tau} \right) e^{-t/\tau} \quad (4)$$

系统电网发生故障时在交流作用下零序电流分别为流过零序电抗器的零序电流 i_{L0} 与正常运行支路的零序电流和, 其值为

$$i_{L0} = \frac{U_{10}}{\omega L} [\sin(\varphi) e^{-\frac{t}{\tau}} - \sin(\omega t + \varphi)] \quad (5)$$

式中: φ 为相位角相关量, rad。

1.2.2 附加直流作用下漏电故障电流

在附加直流源机理下, 对图1建立其瞬时序网络模型, 如图3所示。

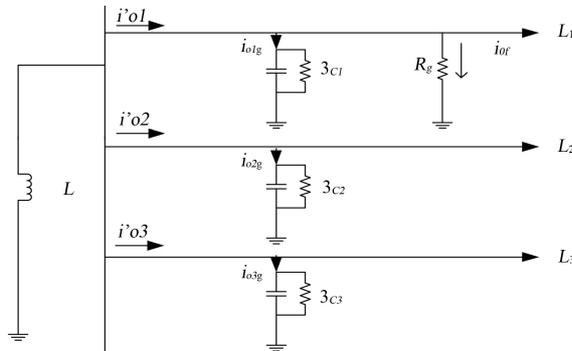


图3 直流机理下零序网络

根据图3可以推出, 在供电系统无论处于正常运行还是发生故障时, 附加直流系统始终存在。因此, 当出现单相接地故障时, 附加直流系统中的直流电流不能通过隔直电容与对地电容, 而只

能流经对地电阻, 并电感 L 对直流电流没有影响。

假设第一条支路发生故障, 则根据图3可知, 漏电阻阻值与第一支路的对地绝缘电阻并联, 可计算得出第一支路的漏电阻 R_1 为

$$R_1 = \frac{R_g r_1}{3R_g + r_1} \quad (6)$$

式中: r_1 为第一条支路的对地绝缘电阻, Ω 。

而非故障支路的电阻未发生变化, 第二支路电阻仍为 $R2/3$; 第三条支路电阻仍为 $R3/3$ 。

根据图3可知, 直流源为上负下正, 因此在直流系统作用下的零序暂态瞬时结构图中可以推断, 在直流机理作用下, 故障时各个支路的零序电流分别为

$$i'_{o1} = - \frac{(3R_g + r_1) u_s}{R_g r_1} \quad (7)$$

$$i'_{o2} = - \frac{3U_s}{r_2} \quad (8)$$

$$i'_{o3} = - \frac{3U_s}{r_3} \quad (9)$$

其中式(7)即为故障支路直流量的表达式, 且漏电阻远小于各个支路的对地绝缘电阻值, 即 $R_g \ll r_1/3$, 故式(7)可为

$$i'_{o1} = - \frac{U_s}{r_1} \quad (10)$$

1.2.3 附加直流作用下的三相接地故障

在矿井中性点不接地系统中, 三相接地故障作为其中所有漏电故障最为严重的一种, 虽然发生的概率比较小, 但也不容忽视, 一旦发生就会引发极其严重的后果, 设置附加直流源 L_1 发生三相接地漏电情况, 其余支路为正常。

三相接地示意图如图4所示。

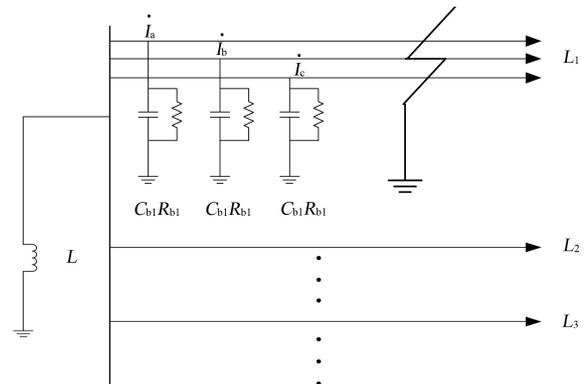


图4 三相接地示意图

由图可知,当发生三相接地故障的边界条件为

$$\dot{I}_a + \dot{I}_b + \dot{I}_c = 0 \quad \dot{U}_a = \dot{U}_b = \dot{U}_c \quad (11)$$

在利用瞬时对称法进行分析,可推出其零序

电流 \dot{I}_0 为

$$\dot{I}_0 = (\dot{I}_a + \dot{I}_b + \dot{I}_c)/3 = 0 \quad (12)$$

综上,可知在三相接地系统中无零序电流,其向量图如图 5 所示。

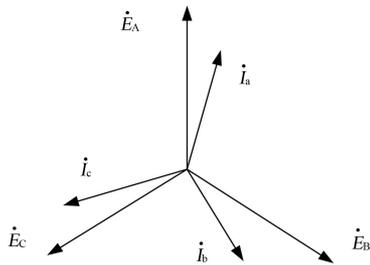


图 5 三相接地系统中无零序电流向量图

由以上分析可以得出:三相接地时故障相电压降低,故障相有短路电流,系统无零序电流和零序电压。

2 基于 MATLAB 的漏电特征仿真分析

针对矿井电网发生单相接地故障时的零序电流动态变化,本文在直流作用下给出了故障与正常支路的零序电流数值。针对包含 380 V 附加直流源^[3]的矿井低压供电系统进行了单相及三相接

地故障的仿真,利用 MATLAB 搭建了一个包含 3 回出线的附加直流矿井供电模型,并通过设置单相及三相接地情况,仿真出了单相、三相接地故障波形与正常波形。

当供电网络出现漏电接地故障时,系统中各条支路的特征值容易受到如漏电电阻、补偿状态、故障初相角等变量的影响。其中,故障初相角是一个影响较大的因素。因此,本文对图 4 中的 MATLAB 模型进行了不同故障初相角的仿真处理。

设置 L_1 支路发生单相及三相接地漏电故障,接地电阻 R_g 分别为固定值 200 欧,变化故障初相角为 0 度、45 度和 90 度。

在不同的初相角下,仿真得出正常与故障的零序电流波形如表 1 所示。

3 数据与方法

本文的实验数据通过 MATLAB 仿真获得,包括在交直流作用下的单相接地故障、三相接地故障及正常状态下的暂态波形图。原始数据集包含 3 种类别,共 1 313 张暂态波形图,本文实验数据概况如表 2 所示。

3.1 数据预处理

深度学习(deep learning, DL)模型通常需要在海量数据集中学习数据特征,而本文的数据量相

表 1 不同初相角故障与正常波形

初相角	三相接地故障波形图	单相接地故障波形图	正常波形图
0°			
45°			
90°			

表 2 本文实验数据概况

项目	正常波形图	单相接地故障	三相接地故障
原始	410	498	405
扩展后	1 230	1 494	1 215

对较小。为了避免人工采集数据的不便, 本文提出了一种面向暂态波形图的数据预处理方法, 主要包括数据集扩展和数据归一化。

3.1.1 数据集扩展

暂态波形图中的波形信息包含着该类的特征信息, 正常波形的对称性通常强于故障波形的对称性, 且正常波形图的波形曲线较为光滑, 本文考虑到实验数据的真实性, 针对暂态波形数据增强操作主要包括数据平移和数据镜像。

数据平移是一种在像素级别上对波形图进行特定范围(α)内的平移, 其中 α 的取值被限定在 5 到 30 之间。这种操作通过沿某一方向移动数据点的位置, 实现了对数据特征信息的平移处理。重要的是, 该处理方法并未改变数据特征, 反而有效地扩展了数据集的多样性。

假设二维空间中某一坐标(x_0, y_0)沿 X 轴、Y 轴分别平移 t_x 单位、 t_y 单位, 最后得到平移后坐标($x+t_x, y+t_y$)。如式(13)所示。

$$[x_1, y_1, 1] = [x_0, y_0, 1] \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ t_x & t_y & 1 \end{bmatrix} \quad (13)$$

式中: (x_0, y_0)为原始图片像素值, (x_1, y_1)为平移后像素值。

数据镜像是一种基于波形图对称性特点的数据增强技术, 它通过对原波形图数据进行镜像处理, 在像素级别上实现了数据的变换, 同时保留了数据的关键特征信息。本文采用了随机水平和垂直镜像两种方法, 具体见公式(14)。

$$\begin{bmatrix} x_o \\ y_o \\ 1 \end{bmatrix} = \begin{bmatrix} -1 & 0 & w \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_i \\ y_i \\ 1 \end{bmatrix} \quad (14)$$

式中: w 为原图像数据的宽度; 图片原点为 (x_i, y_i); (x_o, y_o)为镜像后的像素值。

3.1.2 数据归一化

由于暂态波形图数据为图像数据集, 其像素值范围为 $[0, 255]$, 为了优化模型的训练, 加速

模型的收敛并保持数据特征信息, 有必要对于波形图数据集实施归一化处理。本文处理方法旨在将任意给定的像素值线性映射至 $[0, 1]$ 区间, 让模型更快达到最优解, 如式(15)所示。

$$R_{\text{Nor}} = \frac{x_i}{\text{Max}R - \text{Min}R} \quad (15)$$

式中: R_{Nor} 为归一化以后的波形图矩阵; x_i 为像素值; $\text{Max}R$ 和 $\text{Min}R$ 分别代表波形图矩阵 R 中的最大值和最小值。

4 基于深度学习的分类器

深度学习源于神经网络算法, 作为计算机视觉领域的重要分支, 深度学习模型在图像分割、目标检测、姿态估计等领域发挥了重要作用^[8]。卷积神经网络(convolutional neural networks, CNN)作为深度学习中的重要方法之一, 依靠其隐藏层内的卷积核权值共享、具有稳定的性能且无需额外的工程开销, 在各类工程项目中表现出强大的竞争力。针对传统机器学习方法在精确度和效率方面的不足, 最终选用 VGG-Net 和 ResNet 作为基础模型, 并引入注意力机制, 构建面向暂态波形图可靠分类的深度分类器。

4.1 基于 VGG 的分类器

作为经典的卷积神经网络, VGG 在图像分类领域有着广泛的应用价值^[9]。由模型层数的不同, VGGNet 又可分为经典 VGG-11、VGG-16、VGG-19 等。考虑到实验数据量较小, 为了减小随着模型加深而产生的性能退化, 本文参考经典 VGGNet 构建浅层 VGG-7, 进行暂态波形图数据集的分类。

VGG-7 由 5 层卷积核为 3×3 的卷积层、2 层池化窗口为 2×2 的池化层和 2 层全连接层组成。通过卷积层和池化层对暂态波形图的交替作用进行有效特征的提取, 再由 2 层全连接层对特征数据进行整合进行整合并映射到输出结果。VGG-7 模型结构如图 6 所示。

图 6 中: Image 为图像; Convolution 为卷积层, Relu 为激活函数, Maxpooling 为最大池化层, Fully Connected 为全连接层。

4.2 基于 ResNet 的分类器

传统序列化神经网络随着模型层数的加深, 在

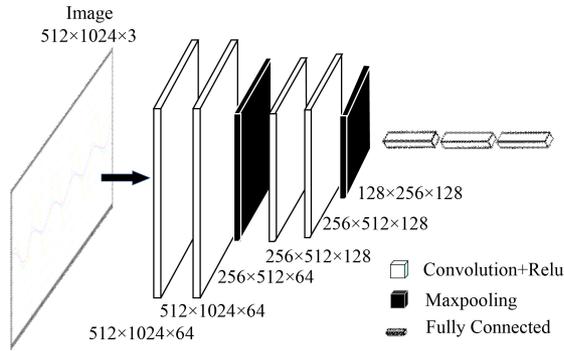


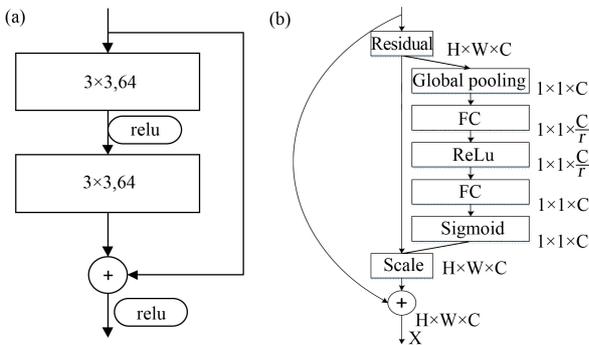
图 6 VGG-7Net 模型结构

不同层传递时会发生信息丢失，导致梯度弥散等问题，从而使模型性能退化。考虑到暂态波形数据的不可变性，本文引入了 ResNet 模型^[10-11]，ResNet 由 HE 等人于 2015 年提出，针对模型性能退化现象，ResNet 引入了残差连接。通过模型中的残差运算，能够较好地引入前层信息，进一步将残差模块串联起来，可有效解决随着模型加深产生的模型性能退化问题。由残差连接的不同，通常有经典的 ResNet34、ResNet50、ResNet101 等。

本文基于经典的 ResNet18、ResNet34、ResNet50，研究暂态波形图的特征分类。

4.3 注意力机制

随着神经网络的发展，注意力机制 (attention mechanism)^[13-14] 在神经网络中得到了广泛的应用。注意力模型通过计算注意力权值，对特征进行加权，强化有效信息，抑制无效信息，使得模型更具泛化能力，提高模型的鲁棒性。本文基于 ResNet 模型，在其残差模块结构中引入通道注意力机制，通过全局平均池化对通道进行压缩，与输入通道相乘，得到加权后的权重，并对特征进行加权。其模型结构如图 7 所示。



(a) Residual 模块；(b) 加入注意力机制的 Residual 模块

图 7 基于注意力机制残差模块

图 7 中：Residual 为残差；Global pooling 为全局池化；Relu、Sigmoid 为激活函数；Scale 为缩放；FC 为全连接层。

5 实验与评价

5.1 实验设计

应用表 2 中扩展的暂态波形数据集，邀请具有相关知识的人员进行数据标记，构建面向暂态波形图的深度分类器，并使用表 3 的评判指标进行实验评估。本文为 3 分类实验，当一类视为 P 类时，其他类视为 N 类。

表 3 混淆矩阵

项目	预测值 P	预测值 N
真实值 X _{TP}	True Positive X _{TP}	False Negative X _{FN}
真实值 N	False Positive X _{FP}	True Negative X _{TN}

其中：X_{TP}代表标记为 P 类的数据被正确归至 P 类；X_{FP}代表实际为 N 类的数据被模型错误归类为 P 类；X_{TN}代表标记为 N 类的数据被模型正确归类至 N 类；X_{FN}意为实际为 P 类的数据被模型错误归类为 N 类数据。

根据混淆矩阵可以计算如下 4 种评价指标参数，包括准确度 T_{Acc}、精确度 T_{Pre}、召回率 T_{Rec}、T_{F-1 Score}。

$$T_{Rec} = \frac{X_{TP}}{X_{TP} + X_{FN}} \tag{16}$$

$$T_{Acc} = \frac{X_{TP} + X_{TN}}{X_{TP} + X_{FP} + X_{TN} + X_{FN}} \tag{17}$$

$$T_{Pre} = \frac{X_{TP}}{X_{TP} + X_{FP}} \tag{18}$$

$$T_{F-1} = \frac{2 \times T_{Pre} \times T_{Rec}}{T_{Pre} + T_{Rec}} \tag{19}$$

其中：T_{Rec}为正样本中被正确识别的比例；T_{Acc}为总样本中被正确分类的样本所占的比率；T_{Pre}为在识别正确的样本中，X_{TP}所占的比率；T_{F-1 Score}为综合评价指标，旨在平衡召回率和精确率的重要性。

为体现模型性能，本文模型最终评价指标为每类各评价指标的均值。

$$T_{Pre} = \frac{T_{Pre1} + T_{Pre2} + T_{Pre3}}{3} \tag{20}$$

$$T_{Rec} = \frac{T_{Rec1} + T_{Rec2} + T_{Rec3}}{3} \tag{21}$$

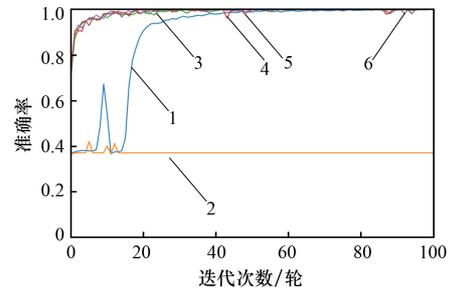
$$T_{F-1} = \frac{T_{F-1-1} + T_{F-1-2} + T_{F-1-3}}{3} \quad (22)$$

其中: T_{Pre1} 、 T_{Pre2} 、 T_{Pre3} 为每类的 T_{Pre} 值, T_{reC} 、 T_{F-1} 同理。

对扩展后的数据集,采取3:7的比例划分方法,其中训练集为随机选用的70%的数据,其余30%作为测试集。实验环境为GeForceRTX2080×4 GPU,内存125 G,操作系统为Ubuntu 16.04。合理的网络参数设置能够提高模型的分类能力并降低过拟合的风险,优化器设置为ADAM来自动对学习率进行调整,并将初识学习率设为0.001。同时,为了解决防止模型随着训练的深入而陷入局部最优的困境,每训练10轮将学习率阈值减少50%来帮助模型更好的寻优。为了更高效地利用计算资源并加速训练过程,将Batchsize设为32、训练周期Epoch设为100。为了确保实验结果的准确性和可靠性,在保证实验数据和网络参数不变的情况下,实验共进行了10次,并计算10次实验结果的均值为最终结果。

5.2 实验结果

实验面向扩展后的波形图数据集,进行深度学习模型训练。表4展示了扩展数据集在不同分类器上的性能,图8为扩展数据集在不同分类器上的训练过程图,图9为扩展数据集在部分分类



1—VGG7Net; 2—VGG11Net; 3—ResNet18;
4—ResNet34; 5—ResNet18 + AM; 6—ResNet50。

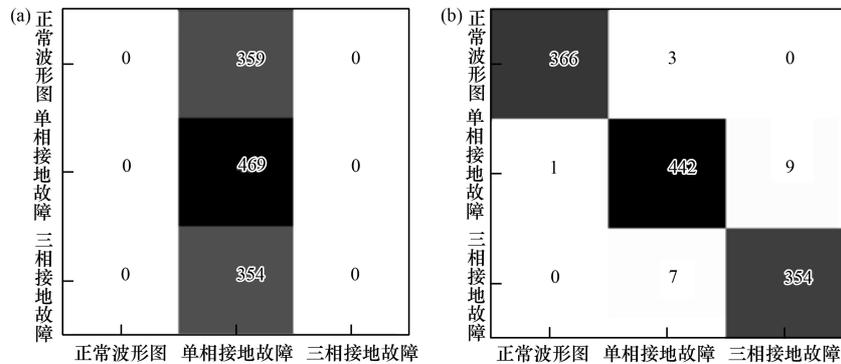
图8 扩展暂态波形图数据集在不同分类器上的训练过程图

器上的混淆矩阵。由表4和图8可以看出,在面向扩展后的暂态波形图数据集上,深度学习方法在识别暂态波形图类别方面有着较好的效果。

由表4中VGGNet试验结果可以看出,在序列化模型中,小数据量在较为浅层的模型上表现更好,VGG7Net的准确率达到0.9712,而VGG11Net的准确率仅为0.3967。从图9中的混淆矩阵可知,VGG11Net将3类归误判为一类,这是因为数据量较少,而网络深度较深发生了梯度弥散。通过对各个模型的实验结果综合对比分析可知,ResNet模型的残差模块能较好地抑制梯度弥散,随着模型层数的加深,模型性能并未降低,尤其当ResNet34模型

表4 扩展暂态波形图数据集在不同分类器上的性能

评价指标	模型					
	VGG7Net	VGG11Net	ResNet18	ResNet34	ResNet34 + Attention	ResNet50
T_{Acc}	0.971 2	0.396 7	0.979 6	0.967 8	0.983 0	0.967 9
T_{Pre}	0.970 0	0.133 3	0.983 3	0.973 3	0.986 7	0.982 4
T_{Rec}	0.973 3	0.333 0	0.983 3	0.966 7	0.983 3	0.951 8
T_{F-1}	0.973 3	0.570 0	0.983 3	0.970 0	0.983 3	0.966 9



(a) VGG11Net 混淆矩阵; (b) ResNet34 + Attention 混淆矩阵

图9 混淆矩阵

引入注意力机制模块时, T_{ACC} 、 T_{Pre} 、 T_{Rec} 、 T_{F-1} 分别达到 0.983 0、0.986 7、0.983 3、0.983 3, 这是因为相比于传统的 ResNet 模型, 通道注意力机制模块对波形图类别的有效特征进行了有效强化, 提高了模型对波形图类别特征信息的关注度, 进而提升了模型性能。且由图 7 可以得出, 串联结构的残差模块的训练曲线较为光滑, 模型更加容易收敛。

综上所述, 本文构建的 ResNet34 结合注意力机制模型在面向暂态波形图数据识别中有着可靠的性能, 具有一定的可行性和可信性, 可用于矿井漏电故障分类识别, 也为下一步工作奠定了基础。

6 结 论

本文针对矿井漏电的故障分类方法进行研究, 首先搭建了模拟矿井生产环境 MATLAB 模型, 并仿真得到正常及两类故障的波形图。然后, 提出了面向暂态波形图的数据增强方法。最后, 构建了面向暂态波形图的卷积神经网络分类器, 包括 VGGNet、ResNet 以及引入注意力机制的 ResNet, 并应用一组数据集进行测试, 验证了本文构建的分类模型的性能。其中, 引入了注意力机制的 ResNet34 模型在各项评价指标中获得了最好的结果, T_{Acc} 为 0.983 0、 T_{Pre} 为 0.986 7、 T_{Rec} 为 0.983 3、 T_{F-1} 值为 0.983 3。

未来将会在以下几方面对本文进行深化扩展:

1) 收集更多暂态波形数据集、稳态波形数据集, 验证本文数据增强的可靠性; 2) 选用更多深度学习模型进行测试, 验证本文实验的可扩展性; 3) 开发用于矿水漏电保护系统, 在真实环境中发现问题并进行完善。

参 考 文 献:

[1] 赵建文, 侯媛彬, 尹顶根. 矿井电网单相漏电瞬时序

网络模型[J]. 电网技术, 2011, 35(3): 119 - 123.

- [2] 余文连. 基于 Fuzzy - ISM 的装配式建筑施工安全风险关系研究[J]. 工程建设, 2023, 55(5): 43 - 48.
- [3] 孙尚斌. 基于模型参数辨识的矿井电网漏电保护[D]. 西安: 西安科技大学, 2012.
- [4] 唐世强. 基于故障特征值的煤矿井下漏电保护研究[D]. 淮南: 安徽理工大学, 2019.
- [5] 王子良, 金洪德, 李同同. 基于 CNN 的矿井供电漏电保护研究[J]. 煤炭技术, 2021, 40(2): 154 - 158.
- [6] 秦冲. 矿井电力系统漏电保护分析研究[J]. 煤炭技术. 2017, 36(10): 239 - 241.
- [7] 郭河志. 井下供电系统选择性漏电保护的研究[D]. 淮南: 安徽理工大学, 2015.
- [8] 赵雄鹰, 任宜春. 基于压缩感知和深度学习的结构损伤识别[J]. 工程建设, 2024, 56(8): 7 - 14.
- [9] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). New York: IEEE, 2016: 770 - 778.
- [10] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. nature, 2015, 521(7553): 436 - 444.
- [11] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional networks for large-scale Image recognition [J/OL]. 2014. <https://arxiv.org/abs/1409.1556>.
- [12] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2016: 770 - 778.
- [13] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 42(8): 2011 - 2023.
- [14] USAMA M A, SONG B, et al. Attention-based sentiment analysis using convolutional and recurrent neural network [J]. Future Generation Computer Systems, 2020, 113(10): 571 - 578.