

基于 ASFF-DC1D-CNN 的变电站典型复合故障 自动化辨识

王存超¹,戴威¹,徐滔¹,张强¹,黄建宏¹,陈金刚²

(1. 国网江苏省电力有限公司, 江苏 南京 210000;

2. 国网江苏省电力有限公司技能培训中心, 江苏 苏州 210023)

摘要: 变电站复合故障是影响电力系统稳定性的重要因素。为了自动化地识别变电站典型故障, 提出一种基于模拟量-开关量融合特征(ASFF)的双通道一维卷积神经网络(DC1D-CNN)模型。该模型由两个独立的特征处理模块和一个共享的决策模块组成, 可以充分利用不同类型数据特征的互补性。在传统的一维卷积神经网络(1D-CNN)模型上加入批量归一化(BN)和注意力机制(AM)结构。通过使用双通道结构, 录波信号的模拟特征和开关信号的数字特征可以被高效地融合, 从而提高模型的特征提取能力和学习能力。以典型的 220 kV 智能变电站为例, 进行建模和仿真, 并且将仿真得到的数据对模型进行训练和测试, 结果显示该模型对典型故障的识别准确率达 98.33%。相比于传统的单通道 CNN、反向传播神经网络(BPNN)、循环神经网络(RNN), 本模型的训练效率更高, 具有更强的泛化能力和鲁棒性, 在面对复杂数据时表现更好。

关键词: 变电站; 复合故障识别; 模拟量-开关量融合特征; 卷积神经网络

中图分类号: TP391 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqed26611

Automatic Identification of Typical Compound Faults in Substation Based on ASFF-DC1D-CNN

WANG Cunchao¹, DAI Wei¹, XU Tao¹, ZHANG Qiang¹, HUANG Jianhong¹, CHEN Jingang²

(1. State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210000, Jiangsu, China;

2. Skill Training Center of State Grid Jiangsu Electric Power Co., Ltd., Suzhou 210023, Jiangsu, China)

Abstract: The multi-faults of substation are of great significance for the stability of power system. In order to automatically identify the typical faults of substation, a dual-channel one-dimensional convolutional neural network (DC1D-CNN) model based on analog-switch fusion features (ASFF) was proposed. The model consists of two independent feature processing modules and a shared decision module, which could utilize the features of different types of data. Batch normalization layer (BN) and attention mechanism (AM) structure were added into the traditional one-dimensional convolutional neural network (1D-CNN) model. The analog features of the recording signal and the digital features of the switching signal could be efficiently fused by using dual-channel, which could enhance the ability of feature extraction and learning of the model. A typical 220 kV intelligent substation was modeled and simulated. The data obtained from the simulation were employed to train and test the model. The results indicated that the model achieved a recognition accuracy of 98.33% for typical faults. Compared with the traditional single-channel CNN, backpropagation neural network (BPNN), and recurrent neural network (RNN) algorithm, the proposed method has great efficiency and robustness. It performs better in the face of complex data.

Key words: substation; multi-fault identification; analog-switch fusion features (ASFF); convolutional neural network (CNN)

变电站故障会引发火灾、停电等事故, 对电力系统安全有重要影响。当前的变电站故障识

别主要依靠对故障录波数据和保护动作信息的人工排查。此种方法难以满足日益增长的用电

基金项目: 国网江苏省电力有限公司科技项目(J2023160)

作者简介: 王存超(1984—), 男, 硕士, 高级工程师, 主要研究方向为电力系统故障诊断, Email: spunish@163.com

需求^[1]。因此,采用智能化方法准确识别变电站典型故障非常重要。

变电站故障类型多样,不同故障之间具有耦合效应^[2]。传统电力系统故障分析理论在处理非线性数据时存在一定的局限性。例如,傅里叶变换在处理具有恒定频率成分的平稳信号时表现出色,但是无法有效捕捉非平稳信号的时间变化特性。小波变换(wavelet transform, WT)在处理突变信号时性能不佳。希尔伯特-黄变换(Hilbert-Huang transform, HHT)的自适应基函数能有效计算非平稳的信号,但在分解时存在模态混叠的问题。

人工智能技术具有强大的学习和决策性能。基于人工智能技术的识别方法在变电站故障识别领域应用广泛^[3]。目前主要有两个研究方向:一是将故障波形输入到人工智能网络中自动学习故障特征完成识别;二是先利用信号处理方法提取故障波形特征,再基于人工智能算法识别故障。录波信号特征参数包含了故障的信息,此种信息可作为智能算法的输入。例如,傅里叶变换^[4]、小波变换^[5]、S变换^[6]和希尔伯特-黄变换^[7]等。人工智能模型可以学习序列与标签间的映射关系,常用的模型有决策树^[8]、支持向量机^[9]和神经网络^[10]等。例如,文献[11]提出了一种基于改进的希尔伯特-黄变换用于电流波形相位的提取。文献[12]提出一种基于HHT的故障录波电流信号的频率特征方法,该方法可用于变电站故障定位。文献[13]将故障录波中的三相电压和电流信号转换为图像,基于CNN识别了故障类型。文献[14]将三相电压信号转换为时频谱图,这样信号的时频特征可以被成功分析。

在数据量不足的情况下,传统人工智能模型的性能表现不佳^[15]。如果输入通道多,在校准期间模型参数会冗余。其次,参数具有非唯一性,会导致效率降低^[16]。同时,一维到二维的转换会丢失如时频细节这样的关键信息。最后,当前的故障诊断模型往往忽略了继电保护开关信息^[17]。

为了准确识别变电站典型复合故障,本文提出一种基于模拟量-开关量融合特征(analog-switch fusion features, ASFF)的双通道一维卷积神经网络(dual-channel one-dimensional convolutional neural network, DC1D-CNN)的故障识别模型,定义了三个故障录波开关信号的时域参量。DC1D-CNN能融合故障录波开关量和模拟量信

息,从而可以精准地识别变电站典型故障。

1 复合特征提取

1.1 录波模拟特征

CEEMDAN利用白噪声辅助分解信号^[18-21]。首先,向原始信号中添加白噪声得到多个序列,使用经验模态分解(empirical mode decomposition, EMD)算法分解这些序列。然后,求出这些内在模态函数(intrinsic mode function, IMF)的均值。最后,向剩余信号中重新引入白噪声后迭代。因此,CEEMDAN可以减少噪声的影响。CEEMDAN的计算流程如图1所示。




图1 CEEMDAN分解流程图

Fig.1 CEEMDAN decomposition process

首先, $x(\tau)$ 被设为目标信号, 加入白噪声 $x(\tau) + \varepsilon_0 \omega^i(n)$ 。其中, $\omega^i(n)$ 为单位方差的零均值高斯白噪声, ε_0 为每个白噪声的权重。

1) 对 $x(\tau) + \varepsilon_0 \omega^i(n)$ 进行 N 轮 EMD 分解, 得到 IMF_1 :

$$IMF_1 = \frac{1}{N} \sum_{z=1}^N IMF_1^z(\tau) \quad (1)$$

2) 计算一阶残差 r_1 :

$$r_1(\tau) = x(\tau) - IMF_1(\tau) \quad (2)$$

3) 分解 $r_1(\tau) + \varepsilon_1 E_1[\omega^i(\tau)]$, 得到 IMF_2 :

$$IMF_2(t) = \frac{1}{N} \sum_{i=1}^N E_1 \{ r_1(\tau) + \varepsilon_1 E_1[\omega^i(\tau)] \} \quad (3)$$

式中: E_1 为 EMD 分解后的 IMF; $\varepsilon_1 E_1[\omega^i(\tau)]$ 为每个阶段高斯白噪声权重。

4) 计算第 u 个残差 r_u :

$$r_u(\tau) = r_{u-1}(\tau) - IMF_u(\tau) \quad (4)$$

式中: u 为 $IMF(\tau)$ 的总和; $r_u(\tau)$ 为第 u 个残差; $r_{u-1}(\tau)$ 为第 $u-1$ 个残差。

5) 分解 $r_u(\tau) + \varepsilon_u E_u[\omega^u(\tau)]$, 得到 $IMF_{u+1}(\tau)$:

$$IMF_{u+1}(\tau) = \frac{1}{N} \sum_{i=1}^N E_1 \{ r_u(\tau) + \varepsilon_u E_u[\omega^u(\tau)] \} \quad (5)$$

6)重复上述步骤直到无法进一步分解。最终残差 $R(\tau)$ 为

$$R(\tau) = x(\tau) - \sum_{u=1}^u IMF_u(\tau) \quad (6)$$

7)目标信号 $x(\tau)$ 为

$$x(\tau) = \sum_{u=1}^u IMF_u(\tau) + R(\tau) \quad (7)$$

对每个IMF分量 $c_m(t)$ 希尔伯特变换^[22],即

$$H[c_m(t)] = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{c_m(\tau)}{t - \tau} d\tau = c_m(t) \frac{1}{\pi t} \quad (8)$$

令 $H[c_m(t)] = y_m(t)$,则复解析信号 $z_m(t)$ 为

$$z_m(t) = c_m(t) + jy_m(t) = a_m(t)e^{j\phi_m(t)} \quad (9)$$

式中: $a_m(t)$, $\phi_m(t)$ 分别为IMF分量 $c_m(t)$ 的瞬时幅值和瞬时相位。

其中

$$\begin{cases} a_m(t) = \sqrt{c_m^2(t) + y_m^2(t)} \\ \phi_m(t) = \arctan\left[\frac{y_m(t)}{c_m(t)}\right] \end{cases} \quad (10)$$

$c_m(t)$ 的瞬时频率为

$$\omega_m(t) = \frac{d\phi_m(t)}{dt} \quad (11)$$

本研究提取信号的7个特征参数值,具体如表1所示。

表1 模拟量信号特征参数

Tab.1 Feature parameters of analog signals		
类别	参数名	表达式
信号统计特性参数	均值	$\frac{1}{N} \sum_{n=0}^{N-1} x[n]$
	方差	$\frac{1}{N} \sum_{n=0}^{N-1} (x[n] - \mu)^2$
	均方根	$\sqrt{\frac{1}{N} \sum_{n=0}^{N-1} (x[n] - \mu)^2}$
熵特征	信息熵	$-\sum_{i=1}^k P_i \log_2(P_i)$
信号时域无量纲特征值	峰值因子	$\frac{\max(x[n])}{\sqrt{\frac{1}{N} \sum_{n=0}^{N-1} x[n]^2}}$
	脉冲因子	$\frac{\max(x[n])}{\frac{1}{N} \sum_{n=0}^{N-1} x[n] }$
	裕度因子	$\frac{\max(x[n])}{(\frac{1}{N} \sum_{n=0}^{N-1} \sqrt{x[n]^2})^2}$

1.2 开关量保护动作特征

故障录波的开关信号可以体现变电站故障的保护动作信息。本研究定义三个特征量来描

述开关量动作的顺序和时长:上升顺序位置系数(rising sequential position coefficient, RSPC)、下降顺序位置系数(falling sequential position coefficient, FSPC)和动作时间比例系数(action time proportion coefficient, ATPC)。

各保护动作及开关量假定在一段时间内发生两次变位。所有开关量动作依次排列在时间轴上,如图2所示。




图2 开关量模型简化时间轴

Fig.2 Switching value model simplified timeline

图2中, t_{i1} 为第 i 个开关量上升沿的时间节点, t_{i2} 为其下降沿的时间节点, t_{b1} (t_{b2})为第一个上升沿(下降沿)的时间节点, t_{e1} (t_{e2})为最后一个上升沿(下降沿)的时间节点。对于第 i 个开关量 S_i , η_{i1} , η_{i2} 和 λ_i 分别为

$$\eta_{i1} = \frac{t_{i1} - t_{b1}}{t_{e1} - t_{b1}} \quad (12)$$

$$\eta_{i2} = \frac{t_{i2} - t_{b2}}{t_{e2} - t_{b2}} \quad (13)$$

$$\lambda_i = \frac{t_{i2} - t_{i1}}{t_{e2} - t_{b1}} \quad (14)$$

式中: η_{i1} 为RSPC; η_{i2} 为FSPC; λ_i 为ATPC。

由于某些开关量会有两阶段动作,因此需要计算两阶段RSPC,FSPC和ATPC。只动作一轮的开关量第二阶段RSPC,FSPC和ATPC设为0。

模拟量的特征参数与数字量的RSPC,FSPC和ATPC构成ASFF。ASFF结合了模拟量的连续性和数字量的瞬时性,从而能为故障模式的识别提供更为丰富的信息。

2 故障诊断模型

2.1 1D-CNN

1D-CNN的参数少,更适合于变电站故障录波一维数据^[7,23-24]。1D-CNN主要包括卷积层、池化层和全连接层。

1D-CNN通过一维卷积层(convolution layer)提取特征^[25]。卷积操作的过程为

$$y_i^{l+1}(j) = \text{ReLU}[K_i^l * x^l(j) + b_i^l] \quad (15)$$

式中:ReLU($\cdot$)为激活函数;*为卷积运算操作; $x^l(j)$ 为卷积层 l 中的第 j 个局部区域; K_i^l , b_i^l 分别为

第*i*个卷积核在第*l*层中的权重和偏置。

池化层(pooling layer)可以提取主要特征并降低维度^[26]来降低计算复杂度。

全连接层(full connection layer)将输入的特征拼接组合并通过激活函数输出分类结果^[27]。全连接层的操作为

$$z^{l+1}(j) = \text{ReLU} \left[\sum_{i=1}^m \sum_{t=1}^n W_{ij}^l a_i^l(t) + b_j^l \right] \quad (16)$$

式中: W_{ij}^l, b_j^l 分别为权重和偏置; $a_i^l(t)$ 为第*l*层中第*i*个特征的第*t*个神经元的值。

2.2 DC1D-CNN

本研究提出的DC1D-CNN结构如图3所示。在传统的1D-CNN中加入批量归一层(batch normalization layer, BN)和注意力机制(attention mechanism, AM)。




图3 DC1D-CNN模型结构图

Fig.3 DC1D-CNN model structure

本研究中提出的DC1D-CNN的结构如下:

1) ASFF模拟特征输入通道用于处理ASFF的模拟量特征。它接收经过主成分分析(principal component analysis, PCA)降维的特征向量,加入BN层以加快训练速度,添加一个AM层,用于关注特征的重要部分。加入20%随机丢弃率的丢弃层以减少过拟合。通过展平层将多维特征向量转换为一维向量。

2)相比模拟特征输入通道,ASFF开关量特征输入通道具有更少的卷积核。同样加入BN层和AM层。展平层将处理后的特征转换成一维向量,其输出与模拟量特征通道的输出融合。

3)两个模块的输出通过拼接层(Concatenate)合并。联合特征被输入进全连接层。再次加入20%随机丢弃率的丢弃层以减少过拟合。激活函数为Softmax,损失函数为稀疏分类交叉熵。通过学习率为0.001的Adam优化器训练模型。

2.3 故障诊断流程

ASFF两类数据在两个1D-CNN模型中分别训练。模型包含两个独立的特征处理模块和一

个共享决策模块。为提升模型分类的性能,对输入的两类数据分别进行PCA处理^[28]。在传统1D-CNN的卷积层和池化层之间加入BN层。在模型的池化层后添加注意力机制,从而增强模型的特征关注能力。模型采用丢弃层,从而有效地减少过拟合并提高模型的泛化能力^[29]。

3 实验

3.1 故障数据集

以华东某地市220 kV变电站典型接线方式为例。该变电站电气主接线如图4所示。




图4 变电站一次主接线图

Fig.4 Primary main wiring of substation

使用数字动态实时模拟器(digital dynamic real-time simulator, DDRTS)建立变电站一次仿真系统的拓扑结构并生成保护信息和故障录波。

除了常规的单相接地、两相相间、两相接地以及三相接地故障,本研究还采集了复合故障,例如,故障期间电流互感器(current transformer, CT)饱和或断线等。这可以丰富故障数据集并验证模型的泛化能力和鲁棒性。

正常情况下,CT一次侧电流和二次侧电流呈比例关系,当变电站线路发生故障时,故障电流迅速增加,电流互感器可能出现饱和的情况。此时二次侧电流不再和一次侧电流等比例转换,二次侧电流会发生畸变。CT饱和如图5所示, I_2 为二次侧电流, I_1 为一次侧电流按比例缩小的电流,可以看到二次侧电流有明显的畸变。在模拟实验中,在120 ms设置接地故障以获取较大的故障电流,并且设置CT为真实物理模型,读取一次侧电流和二次侧电流进行观察对比。




图5 一次侧电流和二次侧电流

Fig.5 Primary side current and secondary side current

当电流互感器输入侧的导线发生断裂或接触不良时,CT将无法正确采样实际电流,测量结果出现误差,进而导致保护装置接收到错误的电流信息,从而引起误动。以CT的A相断线为例,如图6所示,A相电流直接变为0,B,C两相电流迅速增大,这种异常电流会导致保护装置的误动。在模拟实验中,在120 ms断开CT的A相以模拟CT的单相断线。




图6 CT断线电流

Fig.6 CT disconnection current

数据集的故障样本分组如表2所示。共12类,按8:2划分训练集和测试集。

表2 故障样本分组

Tab.2 Fault sample grouping

故障	训练样本	测试样本	故障	训练样本	测试样本
A相接地	80	20	AB接地	80	20
B相接地	80	20	BC接地	80	20
C相接地	80	20	CA接地	80	20
AB相间	80	20	三相接地	80	20
BC相间	80	20	CT饱和	80	20
CA相间	80	20	CT断线	80	20

3.2 特征提取

以CT暂态饱和期间发生AB两相相间短路故障为例,三相线路电流如图7所示。




图7 CT饱和且发生两相相间短路故障的部分故障录波图

Fig.7 Partial fault oscillogram with CT saturation and two-phase short circuit fault

通过CEEMDAN分解A相电流。A相电流波形的重构信号与残余量曲线如图8所示。CEEMDAN的重构信号与原始信号高度重合,误差仅有 10^{-15} 的数量级。说明CEEMDAN可以精确地分解原始信号。

通过对A相线路电流CEEMDAN分解后的各IMF分量进行HT变换,并计算各分量的瞬时幅




图8 重构信号与残余量曲线

Fig.8 Reconstructed signal and residual curve

值,结果如图9所示。




图9 A相线路电流各IMF分量Hilbert变换后瞬时幅值

Fig.9 Instantaneous amplitude of IMF components of phase A current after Hilbert transformation

各开关量信号的RSPC,FSPC和ATPC的第一阶段如表3所示。由于各开关量仅动作一次,第二阶段的特征参数均为0。

表3 各开关量信号第一阶段的特征参数

Tab.3 Feature parameters of each switching value signal at the first stage

开关量通道	RSPC	FSPC	ATPC
保护启动	0	1	1
差动动作	0.615 4	0.186 4	0.573 3
A相跳闸	0.615 4	0.186 4	0.573 3
B相跳闸	0.615 4	0.186 4	0.573 3
C相跳闸	0.615 4	0.186 4	0.573 3
远传开入A	0.615 4	0.203 4	0.58
远传开入B	0.615 4	0.169 5	0.566 7
保护动作	0.615 4	0.186 4	0.573 3
快速距离	1	0.033 9	0.446 7
相间距离I段动作	0.961 5	0	0.44

3.3 消融实验

为了验证DC1D-CNN的有效性,进行对比实验。Model structure_1为传统CNN结构但同时接收模拟量和数字量输入。Model structure_2为传统CNN但只接收模拟量输入。Model structure_3

为双通道结构但不添加BN层和注意力机制。Model structure_4为双通道结构但只加入了BN层。Model structure_5为双通道结构只加入了注意力机制。各模型在同一数据集上的损失曲线、准确率曲线如图10所示。




图10 不同网络结构的训练集和测试集曲线

Fig.10 Training set and verification set curves of different structures

图10中表明,两个传统CNN的性能和Model structure_3在训练集上的表现几乎相同,但Model structure_3的性能在测试集上的表现明显更优。这说明传统CNN存在过拟合。相比Model structure_3,由于BN层的加入,Model structure_4的损失下降速度更快并且准确率更高。说明BN层可以加快模型收敛速度并提高模型泛化能力。由于注意力机制的加入,Model structure_5的训练损失更低并且准确率更高。表明注意力机制有效地增强了模型对特征的辨识能力。

为了进一步验证模型的性能,Precision(P), Recall(R), Accuracy(Acc)和F1-Score($F1$)被用来评估模型。每个模型在测试集上的各项评价指标平均值如表4所示。

对比表4中数据可知,在不改变输入数据结构的情况下加入开关量特征对各项指标的提升

表4 不同网络结构的各项评价指标平均值

Tab.4 Average values of various evaluation indicators of different structures

	$P/\%$	$R/\%$	$Acc/\%$	$F1/\%$
DC1D-CNN	99.42	98.68	98.33	98.26
structure_1	91.52	90.82	91.67	89.16
structure_2	92.02	89.48	89.58	87.87
structure_3	93.80	94.40	92.22	92.75
structure_4	95.37	95.38	95.00	94.90
structure_5	97.40	97.08	96.67	96.75

作用有限,仍保持在90%左右;但若给开关量数据设计独立的输入通道,模型在各项指标上展现出了显著的性能增益。通过引入BN层,模型的准确率和F1分数得到了显著提升。注意力机制的加入进一步提高了模型的性能。结合批量归一化和注意力机制的DC1D-CNN模型在所有评估指标上都达到了最佳性能,由此证明了两者的共同提升了模型的泛化能力和分类准确性。

DC1D-CNN在不同类型的数据集上都性能优异。这表明DC1D-CNN对数据的分布变化更稳定。通过融合模拟量与数字量DC1D-CNN可以获得更加全面的特征。DC1D-CNN特征学习能力显著增强并且对不同故障类型的识别效率显著提高。

3.4 模型对比

为了验证本文所提出模型的创新性和有效性,将本文所提出模型与其他较为常用和先进的模型进行对比。model_1和model_2分别为常规的BPNN和RNN两种神经网络模型,输入为本文提出的ASFF特征。model_3采用HHT提取故障录波数据中的三相电流信号的频率特征,并通过CNN模型进行故障诊断;model_4通过VMD分析电流瞬变信号的特征后,利用HHT提取内在模态函数的故障特征,将最终的故障特征向量作为CNN的输入;model_5对EMD分解后的固有模态函数IMF进行SVD操作,计算信号的谱能量和IMF的熵,并利用深度神经网络进行分类。

各模型训练集和测试集的损失曲线、准确率曲线在同一数据集上如图11所示。

如图11所示,BPNN收敛速度慢并且准确率低。RNN在处理离散的一维非时间序列上性能不佳且存在过拟合。model_3未解决HHT的模态混叠,容易受到噪声干扰。model_4和model_5未对模型进行改进,虽然准确率较高,但收敛速度较慢,且它们的准确率仍低于本研究提出的方法。




图11 不同算法模型的训练集和测试集曲线

Fig.11 Training set and verification set curves of different models

每个模型在测试集上的各项评价指标平均值如表5所示。如表5所示,本研究所提出的方法优化了特征提取和模型训练,在处理复杂的数据时更加稳定可靠。相较于其他的模型,本研究所提出的方法更快地完成训练过程并且性能更优。该模型的各项指标均高于98.2%并且平均准确率为98.33%,明显优于其他算法模型。

表5 不同算法结构的各项评价指标平均值

Tab.5 Average value of various evaluation indicators of different models

	$P/\%$	$R/\%$	$Acc/\%$	$F1/\%$
DC1D-CNN	99.42	98.68	98.33	98.26
model_1	91.26	89.77	89.58	89.11
model_2	82.86	81.59	79.72	79.14
model_3	85.54	85.57	84.58	84.45
model_4	94.75	94.48	93.89	93.50
model_5	92.58	91.73	91.67	91.03

3.5 抗噪声实验

为验证模型的抗噪声能力,在原数据集每类掺入信噪比为15 dB的噪声。使用含噪声数据集对模型进行训练与测试,结果如图12所示。由图12可知,模型在含噪声数据集上和正常数据集上表现都很好,说明即使存在一定噪声,但模型仍

能分辨出故障类型。




图12 DC1D-CNN在含噪声数据集上的性能

Fig.12 Performance of DC1D-CNN on data set containing noise

3.6 数据缺失实验

为验证模型在数据缺失情况下的性能,在原数据集上随机去除50%数据并进行训练和测试,其结果如图13所示。由图13可知,在缺失50%数据的情况下,模型的训练和测试准确率没有受到非常明显的影响,说明在面对较大的数据缺失时,模型仍能保持良好的性能。




图13 DC1D-CNN在数据缺失50%数据集上的性能

Fig.13 Performance of DC1D-CNN on data set with 50% missing data

在原数据集上随机去除 70% 数据并进行训练和测试,其结果如图 14 所示。在训练集上,模型表现没有呈现出差别,但在测试集上,模型性能出现了明显的下降。说明当数据缺失过大时,模型存在过拟合问题。




图 14 DC1D-CNN 在数据缺失 70% 数据集上的性能

Fig.14 Performance of DC1D-CNN on data set with 70% missing data

4 结论

为了自动化地辨识变电站典型复合故障,本研究提出 ASFF 和 DC1D-CNN 故障识别模型。它由两个独立的特征处理模块和一个共享决策模块组成,可以有效融合并处理 ASFF。首先,采用 CEEMDAN 提高 IMF 的质量,这样可以避免模态混叠。定义数字量的 3 个时间特性参数。将录波模拟特征和开关保护动作特征作为模型的输入,模拟-数字混合特征可以全面捕捉故障发生时的波形信息和动态行为。该模型可以执行精确的多类别分类任务。实验表明,DC1D-CNN 的双通道输入能充分利用数字量和模拟量的关键信息。此外,该模型应用了 PCA 和正则化技术并加入 BN 层和注意力机制,这提高了模型的性能及泛化能力。该模型性能明显优于传统 CNN, BPNN, RNN 等模型。在含噪声数据集上进行了测试,结果显示即使添加了 15 dB 信噪比的噪声在数据集中,模型仍能表现良好,验证了模型的抗干扰能力。

本模型属于轻量化模型,在 i5-7500 及以上性能的 CPU 上即可运行,无需 GPU 加速。训练结束后将模型保存在本地,随机在测试集中选取 10 个样本进行识别,平均每个样本的识别速度仅为 206 ms。在实际应用中,需将模型部署至 i5-7500 及以上性能的 CPU 的计算机。

参考文献

- [1] 洪嘉炜,杨剑友,奚洪磊,等. 基于移动互联的变电站故障录波及报文分析装置研究[J]. 电力系统保护与控制, 2020, 48(1): 157-163.
HONG Jiawei, YANG Jianyou, XI Honglei, et al. Research on fault recording and message analysis device based on mobile internet[J]. Power System Protection and Control, 2020, 48(1): 157-163.
- [2] DASHTI R, GHASEMI M, DAISY M. Fault location in power distribution network with presence of distributed generation resources using impedance based method and applying π line model[J]. Energy, 2018, 159: 344-360.
- [3] LIU J, KONG X, XIA F, et al. Artificial intelligence in the 21st century[J]. IEEE Access, 2018, 6: 34403-34421.
- [4] 张鸿博,熊军华,蔡晓峰. 基于高倍过采样与加窗插值 FFT 的电力谐波分析[J]. 电力系统保护与控制, 2024, 52(5): 105-115.
ZHANG Hongbo, XIONG Junhua, CAI Xiaofeng. Power harmonic analysis based on high-rate oversampling and windowed interpolation FFT[J]. Power System Protection and Control, 2024, 52(5): 105-115.
- [5] JAMES J Q, HOU Y, LAM A Y S, et al. Intelligent fault detection scheme for microgrids with wavelet-based deep neural networks[J]. IEEE Transactions on Smart Grid, 2017, 10(2): 1694-1703.
- [6] 高淑萍,李晓芳,宋国兵,等. 基于 Pearson 相关系数与广义 S 变换的低压直流微电网的故障选线方法[J]. 电力系统保护与控制, 2023, 51(15): 120-129.
GAO Shuping, LI Xiaofang, SONG Guobing, et al. Fault line selection method of a low-voltage DC microgrid based on the Pearson correlation coefficient generalized S-transform[J]. Power System Protection and Control, 2023, 51(15): 120-129.
- [7] AQAMOHAMMADI A R, NIKNAM T, SHOJAIEYAN S, et al. Deep neural network with Hilbert-Huang transform for smart fault detection in microgrid[J]. Electronics, 2023, 12(3): 499.
- [8] 李杰,孙鹤林,雷一鸣,等. 基于优化决策树算法的变电站故障诊断系统研究[J]. 自动化技术与应用, 2023, 42(6): 112-115, 154.
LI Jie, SUN Helin, LEI Yiming, et al. Research on substation fault diagnosis system based on optimized decision tree algorithm[J]. Techniques of Automation and Applications, 2023, 42(6): 112-115, 154.
- [9] SUN P, LIU X, LIN M, et al. Transmission line fault diagnosis

- method based on improved multiple SVM model[J]. IEEE Access, 2023, 11: 133825–133834.
- [10] 徐舒玮,邱才明,张东霞,等. 基于深度学习的输电线路故障类型辨识[J]. 中国电机工程学报, 2019, 39(1): 65–74, 321.
XU Shuwei, QIU Caiming, ZHANG Dongxia, et al. A deep learning approach for fault type identification of transmission line[J]. Proceedings of the CSEE, 2019, 39(1): 65–74, 321.
- [11] 秦榛,武长青,刘振华,等. 基于改进HHT的故障电流相位抗干扰提取[J]. 电力信息与通信技术, 2022, 20(2): 69–75.
QIN Zhen, WU Changqing, LIU Zhenhua, et al. Anti interference extraction of fault current phase based on improved Hilbert-Huang transform[J]. Electric Power Information and Communication Technology, 2022, 20(2): 69–75.
- [12] 张天忠,穆弘,贾健雄,等. 电力物联网背景下基于HHT-CNN的智能变电站故障诊断[J]. 安徽大学学报(自然科学版), 2022, 46(4): 50–57.
ZHANG Tianzhong, MU Hong, JIA Jianxiong, et al. Fault diagnosis of smart substation based on HHT-CNN under the background of power internet of things[J]. Journal of Anhui University (Natural Science Edition), 2022, 46(4): 50–57.
- [13] HONG J, KIM Y H, NHUNG-NGUYEN H, et al. Deep-learning based fault events analysis in power systems[J]. Energies, 2022, 15(15): 5539.
- [14] MIRSHEKALI H, KESHAVERZ A, DASHTI R, et al. Deep learning-based fault location framework in power distribution grids employing convolutional neural network based on capsule network[J]. Electric Power Systems Research, 2023, 223: 109529.
- [15] ZHANG Q, MA W, LI G. Fault diagnosis of power grid based on variational mode decomposition and convolutional neural network[J]. Electric Power Systems Research, 2022, 208: 107871.
- [16] FAN S, LI L, WANG S, et al. Application analysis and exploration of artificial intelligence technology in power grid dispatch and control[J]. Power System Technology, 2020, 44(2): 401–411.
- [17] ZHU S, ZECCHIN A C, MAIER H R. Use of exploratory fitness landscape metrics to better understand the impact of model structure on the difficulty of calibrating artificial neural network models[J]. Journal of Hydrology, 2022, 612: 128093.
- [18] 季宁,李世倩,任罡,等. 基于声发射乐谱化Frechet编码的变电站主变压器基底渗水损伤监测[J]. 中国测试, 2023, 49(2): 42–49.
JI Ning, LI Shiqian, REN Gang, et al. Water seepage damage monitoring of substation main transformer based on acoustic emission musicalized Frechet coding[J]. China Measurement & Test, 2023, 49(2): 42–49.
- [19] 江兵,李响,巢一帆,等. 基于KPCA-CGSSA-KELM的变压器故障识别方法[J]. 电子测量与仪器学报, 2024, 38(5): 139–147.
JIANG Bing, LI Xiang, CHAO Yifan, et al. Transformer fault recognition method based on KPCA-CGSSA-KELM[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(5): 139–147.
- [20] REN G, ZHA X, JIANG B, et al. Location of multiple types of faults in active distribution networks considering synchronization of power supply area data[J]. Applied Sciences, 2022, 12(19): 10024.
- [21] TAO K, CHEN G, WANG Q, et al. Ultrasonic curved coordinate transform-RAPID with Bayesian method for the damage localization of pipeline[J]. IEEE Transactions on Industrial Electronics, 2024, 71(11): 15066–15076.
- [22] TAO K, WANG Q, YUE D. Data compression and damage evaluation of underground pipeline with musicalized sonar GMM[J]. IEEE Transactions on Industrial Electronics, 2023, 71(3): 3093–3102.
- [23] NING J, XI C, XUE Q, et al. Transformer fault identification based on GWO-optimized Dual-channel M-A method[J]. PloS one, 2024, 19(10): e0312474.
- [24] XIONG J, QIAN W, CEN J, et al. A fault diagnosis method for building electrical systems based on the combination of variational modal decomposition and new mutual dimensionless[J]. Scientific Reports, 2023, 13(1): 4567.
- [25] TURIZO S, RAMOS G, CELEITA D. Voltage sags characterization using fault analysis and deep convolutional neural networks[J]. IEEE Transactions on Industry Applications, 2022, 58(3): 3333–3341.
- [26] ZHU S, ZECCHIN A C, MAIER H R. Use of exploratory fitness landscape metrics to better understand the impact of model structure on the difficulty of calibrating artificial neural network models[J]. Journal of Hydrology, 2022, 612: 128093.
- [27] CHEN X, JI N, QIN X, et al. Transformer fault diagnosis based on the improved sparrow search algorithm and random forest feature selection[C]//2024 3rd International Conference on Energy and Electrical Power Systems (ICEEPS), 2024: 1086–1091.
- [28] HONG J, KIM Y H, NHUNG-NGUYEN H, et al. Deep-learning based fault events analysis in power systems[J]. Energies, 2022, 15(15): 5539.
- [29] SIDDIQUE M N I, SHAFIULLAH M, MEKHILEF S, et al. Fault classification and location of a PMU-equipped active distribution network using deep convolution neural network (CNN)[J]. Electric Power Systems Research, 2024, 229: 110178.

收稿日期:2025-05-07

修改稿日期:2025-07-03