

柔性直流配电网中接地故障检测技术研究

郑峰¹, 吕佳雯¹, 林燕贞², 梁宁³

(1. 福州大学 电气工程与自动化学院, 福建 福州 350116; 2. 国网福建省电力有限公司, 福建 福州 350000;
3. 昆明理工大学 电力工程学院, 云南 昆明 650500)

摘要:针对柔性直流配电系统拓扑结构复杂、故障种类多、故障识别难度大等问题,提出一种基于相对熵(K-L)散度优化变分模态分解(VMD)与结合Inception的卷积神经网络(CNN)的故障检测方法,该方法首先对故障点的正极暂态电压时域波形采用K-L VMD方法提取特征分量,利用特征模态分量构造识别判据,接着对采样数据进行CNN训练,获取模型最优参数,最后利用仿真平台搭建了一个基于模块化多电平变换器(MMC)的10 kV两端直流配电网结构来验证所提方法的有效性,仿真实验表明利用K-L散度优化变分模态分解对仿真数据进行处理,具有良好的推广能力,且具备对噪声的抗干扰能力,所提出的故障检测方法有效,对于各种故障类型的识别具有较强的灵敏性,能准确识别故障类型。

关键词:柔性直流配电网;K-L散度优化;变分模态分解;卷积神经网络;故障检测;模块化多电平变换器

DOI:10.15938/j.emc.2025.04.006

中图分类号:TM77

文献标志码:A

文章编号:1007-449X(2025)04-0054-11

Research on fault detection technology of flexible DC distribution network

ZHENG Feng¹, LÜ Jiawen¹, LIN Yanzhen², LIANG Ning³

(1. School of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350116, China;

2. State Grid Fujian Electric Power Co., Ltd., Fuzhou 350000, China;

3. Faculty of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650500, China)

Abstract:To solve the problems of flexible DC power distribution system, including flexible operations, multiple fault types, and difficulty in fault identification, a fault detection method based on K-L divergence optimization variational mode decomposition (VMD) and convolution neural network (CNN) combined with Inception was proposed. Firstly, K-L VMD method was used to extract the feature component of the time-domain waveform of the positive transient voltage at the fault point, and the identification criterion was constructed using the feature modal component. Then, CNN training was performed on the sampled data to obtain the optimal parameters of the model. Finally, a 10 kV two-end DC distribution network structure based on modular multilevel converter (MMC) was built using the simulation platform to verify effectiveness of the proposed method. Simulation experiments show that K-L divergence optimization variational mode decomposition has good generalization ability and anti-interference ability to the simulation data. The proposed fault detection method is effective and has strong sensitivity to the identification of various fault types and can accurately identify the fault types.

收稿日期: 2024-05-13

基金项目: 国家自然科学基金(52167010)

作者简介: 郑峰(1983—),男,博士,副教授,研究方向为直流配电网系统保护与运行;

吕佳雯(2000—),女,硕士,研究方向为直流配电网故障检测;

林燕贞(1991—),女,硕士,研究方向为直流配电网系统保护与运行;

梁宁(1985—),男,博士,副教授,研究方向为电力系统运行与优化。

通信作者: 郑峰

Keywords: flexible DC distribution network; K-L divergence optimization; variational modal decomposition; convolutional neural network; fault detection; modular multilevel converter

0 引言

随着光伏和储能等分布式电源的快速发展,交流配电网正面临着供电走廊紧张、线路损耗大以及电能质量差等一系列问题。相较于交流配电网,柔性直流配电网具有分布式电源接入高效、线路损耗小、传输容量大且运行方式灵活等优点,在新型配电系统中具有广阔前景。但同交流配电网类似,由于运行环境复杂,柔性直流配电网也容易发生高阻接地故障^[1],由于故障特征与正常负荷投切和运行方式切换等正常工况类似,进一步加剧高阻故障识别的难度。此外,若不能及时检测高阻接地故障,长时间带故障运行会破坏导线绝缘,对人身安全造成极大的威胁^[2]。因此,准确的高阻接地故障检测对柔性直流配电网可靠运行具有重要意义。

目前高阻接地故障检测常采用信号处理方法,采集的信号通常包括电压、电流、磁场强度以及阻抗等,常用的信号分解方法有傅里叶变换(Fourier transform, FT),经验模态分解(empirical mode decomposition, EMD),小波分解(wavelet transform, WT)等。通过傅里叶变换可以将一个时域非周期的连续信号转化为在频域非周期的连续信号,但该方法只能提取信号在频率分量中的信息,且只适用于平稳信号^[3];EMD是一种时频的处理方法,能够反映出非平稳信号的局部特征,但存在模态混叠的现象^[4];集合经验模态分解是EMD的改进,但仍存在模态混叠和噪声的影响^[5];WT在处理非平稳信号中具有优势,但需要人为选择母小波^[6]。文献[7]利用广义S变换提取电压特征谐波,识别区内外故障;文献[8]利用短时傅里叶变换对瞬态条件下的高频元件进行了定量研究,能够区分短路故障和负载突然变化的暂态情况;文献[9]利用Minkowski距离测量法(闵科夫斯基距离测量法)测量波阻抗的相关性,构建故障检测方案;文献[10]利用自适应噪声完备集合经验模态对暂态零模电流进行分解构造高阻接地故障的启动判据;文献[11]通过计算电流波形的曲率与电流突变量结合构成保护判据;文献[12]利用小波变换分解电流,构造故障检测判据;文献[13]利用散度优化变分模态分解(variational mode decomposition, VMD)算法对故障电流做特征提取,将累积能量作为检测指标。虽然

上述信号处理方法能够提取相关的故障特征,但仍存在人工选择模态个数对精确度造成的影响,可靠性还需进一步提升。

随着电网数据规模骤升和计算能力大幅提升,人工神经网络智能算法显现出极大的优越性,能从复杂的外部与内部环境的影响下精确有效地自动提炼出对故障判别有用的信息,有效避免了人工构造检测判据的问题。例如,文献[14]利用小波变换提取故障特征信号,并利用人工神经网络(artificial neural network, ANN)对这些信号进行训练,完成检测和分类;文献[15]利用电流的均值、标准差、信息熵和峰度值做不同故障位置的检测,并用深度置信网络(deep belief network, DBN)进行训练,但该检测方法并未验证所提方法的抗噪声能力;文献[16]根据变压器有载分接开关振动信号的相空间分布和卷积神经网络来构建故障识别方法;文献[17]通过构建高维随机矩阵作为卷积神经网络(convolution neural network, CNN)的输入,实现配电网的故障识别;文献[18]利用EMD对暂态电流进行分解,然后用CNN模型对本征模态分量进行训练。但是,上述神经网络模型大都存在参数个数多,计算量大,抗噪声性能弱,以及随着网络深度和宽度的增多容易产生过拟合等问题。

针对上述问题,提出了一种改进VMD与CNN的故障识别算法,实现了对单极小电阻接地故障(small impedance fault, SIF)、单极中电阻接地故障(middle impedance fault, MIF)、单极高阻接地故障(high impedance fault, HIF)、极间短路故障(pole to pole fault, PPF)、负荷投切(load switch, LS)、交流侧对称故障(symmetrical fault, SF)、交流侧不对称故障(asymmetrical fault, ASF)等不同故障类型的准确辨识。主要贡献有以下几点:

1) 针对VMD中人为选择分解个数所引起的精确度不可靠问题,引入相对熵(Kullback-Leibler, K-L)散度对VMD进行自适应选择,提高特征提取的准确度。

2) 针对传统CNN网络引起的参数多、过拟合等问题,提出结合Inception的CNN故障检测方法,快速且准确地识别各种故障类型。

1 仿真建模

1.1 直流配电网建模

为验证所研究的内容,现采用直流电磁暂态计

算程序(PSCAD/EMTDC)平台搭建仿真模型,双端柔性直流配电网结构如图1所示,直流配电网的参数如表1所示。




图1 10 kV 柔性直流配网结构图

Fig.1 Structure of 10 kV flexible DC distribution network

表1 10 kV 直流配网参数

Table 1 Parameters of 10 kV DC distribution network

参数	数值
系统频率 f/Hz	50
额定交流电压 U_{ac}/kV	10
额定直流电压 U_{dc}/kV	± 10
直流线路电抗 L_{dc}/mH	0.5
MMC 桥臂电抗 L_{arm}/mH	10
桥臂子模块数量 N_{sm}	50
子模块电容 C_{sm}/mF	4.5
每个 MMC 的额定功率/MVA	25

交流侧变压器采用 Δ/Y_n 型经大电阻接地方式,系统中所有模块化多电平变流器(modular multi-level converter, MMC)具有相同数量的子模块(N_{sm})和相同的子模块电容(C_{sm}), L_{dc} 为平波电抗器,安装在输电线路的两端,通过 MMC 将电缆与交流电网相连,表1为各参数数值情况。

该系统为小电流接地系统,当直流线路发生单极接地故障时,故障电流没有对地回路,直流线路电流仍为额定值,系统零电位发生偏移,接地极线路电压下降至0,非接地极线路电压升高为原来的两倍,极间电压保持不变,发生单极接地故障后系统仍能运行两小时。

相较于单极接地故障,直流配网的极间短路故障更为严重,该故障会造成电流急剧上升,接地极正负极电压迅速降低为0,极间电压也降低为0。在换流器闭锁后,若无法及时切除故障,此后系统将继续维持在该状态,损害配网设备安全^[19]。

交流侧不对称故障中零序电压分量会引起直流侧正负极电压的工频共模波动^[20-21],其暂态特性与直流高阻接地故障时情况类似。

基于暂态分量的故障选线方法能克服稳态分量选线方法灵敏度低,间歇性接地故障时可靠性差的

缺点,针对暂态故障特征微弱、不稳定故障电弧存在、内外部随机因素等的影响,现代信号处理技术被广泛应用,利用信号处理技术可以提高对微弱特征的辨识与提取能力。

由于正负极电压变化过程相似,因此仅以接地极正极电压作为特征预处理量。

1.2 故障建模

获取每种故障类型 200 组数据,对于单极接地故障,设置 SIF、MIF、HIF 3 种故障类型,其中人为将 SIF 的阻值设置在 $0 \sim 100 \Omega$ 中变化;将 MIF 的阻值设置在 $100 \sim 1\,000 \Omega$ 中变化^[22];当发生 HIF 故障时,故障点会出现电弧的熄灭与重燃过程,电弧电流出现高频波动,同时接地线路极电压也出现高频振荡,无法通过单纯增加接地电阻阻值情况的方式来进行模拟该故障情况,伊曼纽尔模型是目前广泛使用的能够准确描述 HIF 电弧特性、反应 HIF 特征的模型^[23],因此采用伊曼纽尔电弧模型对 HIF 进行模拟,该模型具体模型结构如图2所示。




图2 伊曼纽尔电弧模型电路图

Fig.2 Emanuel arc model circuit diagram

该模型由 2 个直流电压源 V_m 、 V_n , 2 个二极管 D_m 、 D_n , 以及 2 个可变电阻 R_m 、 R_n 组成,通过该模型可以模拟高阻情况下电弧的特性,其中改变直流电压的数值可以调节电弧电压的零休时间,二极管用来反映不同周期波形的通断情况,可变电阻用来模拟故障下电流的不对称性。模型的参数设置为 V_m 在 $0.5 \sim 0.8 \text{ kV}$ 之间随机变化, V_n 在 $0.9 \sim 1.1 \text{ kV}$ 之间随机变化, R_m 与 R_n 在 $450 \sim 1\,000 \Omega$ 之间随机变化, R 在 $800 \sim 3\,000 \Omega$ 之间取值。

对于极间故障,设置其过渡电阻在 $0 \sim 5 \Omega$ 中变化;考虑到配网中会出现较大负荷扰动时的情况,需将负荷投切也作为其中一种工况,将 LS 的容量设置在 $0 \sim 10 \text{ MW}$ 变化;此外,还应考虑交流侧故障时对直流侧电压的影响,因此还需在交流侧设置对称及

不对称故障两种类型。

在所选时间窗下7种工况接地极正极电压故障波形如图3所示,故障在0时刻发生。




图3 各工况下接地线路正极电压波形

Fig 3 Positive voltage waveform of grounding line under different fault condition

当发生图3(a) SIF故障时,线路正极电压跌落至5.63 kV,此后缓慢下降;发生图3(b) MIF故障时,线路正极电压波动,波形中出现高频分量,此后电压值缓慢下降;发生图3(c) HIF故障时,突变相较于SIF、MIF而言表现没有那么剧烈,但在该故障下正极电压的震荡特性较为明显,且波动幅值小,变化随机;发生图3(d) PPF故障时,线路正极电压瞬时降至0,此后持续维持在0,此时换流器之间停止功率传输;发生图3(e) LS扰动时,电压值在故障时刻有一个突然的变化,此后呈现出稳态响应状态;发生交流不对称故障时,如图3(g)所示,此时换流器交流侧电压、电流将会出现负序分量,该分量会在直流侧引起偶数次非特征谐波,造成接地极电压的波动,仿真结果与理论分析保持一致。

2 算法分析

2.1 变分模态分解

VMD是一种时频分析算法,通过重新定义一个能够调整幅度与频率的信号,可将原始接地极正极电压信号拆解为一系列的本征模态信号(intrinsic mode function, IMF),构建并求解变分问题,提取频域中有用的成分,克服了模态混叠与端点效应,该算法具有一定的抗干扰能力,能够全面分解故障信号,获取信号中被隐藏的特征信息,获得变分问题的最优解^[24]。

VMD算法有2个约束条件:1)各模态之和与输入信号 f 相等;在该限制条件下,迭代搜寻该模型的最优解以此获得各个分解分量的中心频率和带宽。2)通过对变分问题的构建和求解,使得各本征模态函数 $u_k(t)$ 中心频率的估计带宽之和最小。计算步骤如下:

1)对于各接地极正极电压信号拆解得到后的本征模态分量,通过希尔伯特变换,计算 $u_k(t)$ 的解析信号为

$$M = [\delta(t) + \frac{j}{\pi t}] u_k(t)。 \quad (1)$$

2)通过预估各解析信号的中心频率 ω_k ,将式(1)得到的单边频谱乘以一个指数项信号,从而将各解析信号的频谱转化为基频带,即

$$e^{-j\omega_k t} M = \{ [\delta(t) + \frac{j}{\pi t}] u_k(t) \} e^{-j\omega_k t}。 \quad (2)$$

3) 通过高斯平滑对信号进行解调, 防止过拟合, 估计各模态函数的带宽, 最终约束变分问题可表示如下:

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum_k \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) \right\| e^{-j\omega_k t} \right\|_2^2 \right\}; \\ \text{s. t. } & \sum_k u_k = f_0. \end{aligned} \quad (3)$$

其中: $\{u_k\} = \{u_1, \dots, u_k\}$ 表示分解后的 k 个模态函数; $\{\omega_k\} = \{\omega_1, \dots, \omega_k\}$ 表示各 IMF 分量所对应的频率中心; f 表示未分解前的信号。

4) 要求解该约束变分问题需要引入二次惩罚项 α 和拉格朗日乘法算子 $\lambda(t)$, 将约束性问题转变为非约束性问题, 具体表达式为

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) \right\| e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \\ & \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle. \end{aligned} \quad (4)$$

需要将原始正极电压信号进行 VMD 分解, 但分解的精确度受到分解数 k 的影响, 因此选择 K-L 散度用于衡量信号分解精确度的指标, K-L 散度值越小, 分解的模态分量与原始分量的相似度越高, 据此可以确定 VMD 分解信号的最优 k 值。K-L 的原理如下:

设两信号分别为 $X = \{x_1, x_2, \dots, x_n\}$ 与 $Y = \{y_1, y_2, \dots, y_n\}$, 概率分布分别为 $P(x)$ 、 $Q(y)$, 核密度函数概率密度为 $\delta(P, Q)$, 求解信号的概率分布。

$$\delta(P, Q) = \sum_{i=1}^N P(x_i) \ln \frac{P(x_i)}{Q(x_i)}; \quad (5)$$

$$D(P, Q) = \delta(P, Q) + \delta(Q, P); \quad (6)$$

$$P(x) = \frac{1}{nh} \sum_{i=1}^n k\left(\frac{x_i - x}{h}\right), x \in \mathbf{R}; \quad (7)$$

$$k(u) = \frac{1}{\sqrt{2\pi}} e^{-u^2/2}. \quad (8)$$

其中: $P(x)$ 代表信号的核密度估计函数; $k(u)$ 表示核密度函数; h 一般为正数, 表示平滑函数; $D(P, Q)$ 为 K-L 散度值结果。K-L 散度值与相似度呈负相

关, 当经过 VMD 分解后的数据与实际故障信号越接近时, K-L 散度值也越小。K-L 散度优化 VMD 算法的流程图如图 4 所示。




图 4 K-L 散度优化 VMD 流程图

Fig. 4 K-L divergence optimization VMD flow chart

为了验证所提 KL-VMD 抗干扰能力强的优越性, 设置 EMD、VMD 与 K-L VMD 三组算法对信号进行重构, 并以均方根误差 (root mean squared error, RMSE) 作为评价指标, 结果如表 2 所示。

表 2 不同信噪比下算法重构对比分析

Table 2 Comparative analysis of algorithm reconstruction under different SNR

参数	RMSE/dB		
	10	20	40
EMD	0.234 1	0.136 2	0.087 2
VMD	0.105 7	0.093 8	0.052 2
K-L VMD	0.078 3	0.065 1	0.034 6

信噪比 (signal-to-noise ratio, SNR) 是一种衡量原始信号与噪声之间关系的指标, 与算法的重构性能呈正相关关系, 而均方根误差则表现为负相关, 以 HIF 故障为例, 利用 3 种算法对分解信号进行重构, 对比结果如图 5 所示。由该结果可得, 相比于 EMD 与 VMD 算法, 所提的 K-L VMD 的结果在信号处理方面具有更强的抗噪声能力以及更高的精确度。

采用 K-L VMD 算法对包括 LS 扰动情况下的 7 种故障信号做特征提取, 得到结果如图 6 所示。将这些分解后的信号用以构建检测判据, 作为 CNN 的输入样本数据。




图5 3种算法进行信号重构的情况对比结果(信噪比为20 dB)

Fig. 5 Comparison of the effect of three algorithms on signal reconstruction (SNR = 20 dB)

2.2 卷积神经网络

CNN 是一种有监督的机器学习,主要学习过程分为前向传播(forward propagation, FP)过程和反向参数更新(back propagation, BP),其中前向传播主要包括卷积层、池化层、全连接层,基本模型结构如图7所示,这一过程可以实现对预处理信号的提取并进行预分类,而反向参数更新可以将预分类的结果与预期对比,自动调整模型的可学习参数,实现故障类别的准确划分。

2.2.1 前向传播过程

卷积神经网络将前一层的输出作为下一层的输入,构建多个能够提取输入特征的滤波器,实现对隐藏数据的多敏感特征的提取,其本质是一种输入对

输出的映射关系,数学模型表达如下:

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} \omega_{ij}^l + b_j^l\right) \quad (9)$$




图6 经过 K-L VMD 分解后的 IMF1

Fig. 6 IMF1 after K-L VMD decomposition




图7 卷积神经网络的基本模型结构图

Fig.7 Basic model structure of CNN

其中： x_j^l 是第 l 层第 j 个神经元的输出； x_i^{l-1} 是第 $l-1$ 层第 i 个神经元的输入； M_j 是输入特征图； l 是第 l 层网络； ω 是权重矩阵； b_j^l 是第 l 层上第 j 个神经元的偏置； f 是激活函数，采用一种非线性函数—Relu作为激活函数，该函数的表达式为

$$f(x) = \max(0, x). \quad (10)$$

若输入大于0，直接返回输入值，若输出小于等于0，返回0。对比经常使用的Tanh和Sigmoid函数，Relu能够加快模型的训练速度，降低计算的难度，具有很强的鲁棒性，梯度消失问题得到了一定的解决。

池采样层对局部特征进行提取，能检测到不同位置下的相同特征，具有较好的空间和结构的不变性，常见的有最大值池化和平均池化两种采样方式，采用最大值池化。池采样层的数学模型为

$$x_j^l = f(\beta_j^l \text{down}(x_j^{l-1}) + b_j^l). \quad (11)$$

其中： $\text{down}()$ 是池采样函数； β 是网络乘性偏置，经过池采样后，采样层和卷积层所拥有的特征在数量上保持不变，但大小减小 n 倍。

经过多次的卷积池化后，采用全连接层对神经元权重进行连接，Softmax作为激活函数，将每个输出的概率置于 $[0, 1]$ 之中，从而对不同特征进行数据分类。

2.2.2 反向参数更新

对于分类问题来说，要最小化模型的损失函数，尽可能地提升模型的精确度，因此，损失函数的选择是十分重要的。常见的损失函数有均方根误差函数、平均绝对误差函数、交叉熵代价函数等，选用交叉熵函数作为损失函数，表达式为

$$E = -\frac{1}{n} \sum_{k=1}^n [y_k \ln t_k + (1 - y_k) \ln(1 - t_k)]. \quad (12)$$

其中： n 为输入数据的样本总数； t 为预测值； y 为实际值，在反向传播过程中，常用梯度下降法不断更新迭代过程，对式(8)求取一阶导数，使得网络可学习

参数得以调整，具体如下：

$$\left. \begin{aligned} \omega' &= \omega - \eta \frac{\partial E}{\partial \omega}; \\ b' &= b - \eta \frac{\partial E}{\partial b}. \end{aligned} \right\} \quad (13)$$

其中： ω' 是更新后的权重； b' 是更新后的偏置； ω 是未更新的权重； b 是未更新的偏置； η 是学习速率参数，用来控制权值更新的步长。

2.2.3 Inception 模块

网络深度或宽度的增加会使卷积网络带来2个问题：1)网络所需要训练的参数会在网络层数增加的过程中也不断增加，不可避免地会带来过拟合问题；2)随着所需训练参数的增加，模型训练速度也会降低，导致该卷积模型难以应用于实际的工程中。

据此，在卷积网络中引入Inception模块，将不同的卷积层通过并联的方式结合在一起，结构如图8所示。




图8 Inception 模型图

Fig.8 Inception model diagram

2.2.4 模型参数与指标

对不同故障类型对应标签的定义针对7种不同故障类型，设置不同故障对应的标签形式为 $[l_1, l_2, l_3, l_4, l_5, l_6, l_7]$ ，用于该网络的输出，具体标签分类如表3所示。

表3 不同故障对应的标签

Table 3 Labels corresponding to different faults

类型	标签
SIF	[1,0,0,0,0,0,0]
MIF	[0,1,0,0,0,0,0]
HIF	[0,0,1,0,0,0,0]
PPF	[0,0,0,1,0,0,0]
LS	[0,0,0,0,1,0,0]
SF	[0,0,0,0,0,1,0]
ASF	[0,0,0,0,0,0,1]
SIF	[1,0,0,0,0,0,0]

将训练集与测试集的比例设为3:7。故障时间设置为故障点前后的1 ms,时间窗的大小为2 ms,设定故障在2 s时发生,系统采样频率为20 kHz。对经K-L VMD分解后的特征模态分量进行数据归一化,采用Min - Max标准化的方法,将输入数据映射到[0,1]中。

$$x_{\text{normalization}} = \frac{x - \text{Min}}{\text{Max} - \text{Min}} \quad (14)$$

一维卷积神经网络结构包括1个输入层,5个卷积层,7个池化层,2个Inception层,2个Dense层,1个输出层,其中卷积的步长设置为2,训练次数为300次,卷积核大小为4,学习率为0.02。

为了更直观地表示故障分类结果,采用混淆矩阵作为可视化工具。该矩阵每一列表征不同故障的预测类别,每一行表征数据所代表的实际故障类别,具体结构如图9所示。

		预测值	
		Positive	Negative
真实值	Positive	True Positive	Flase Negative
	Negative	Flase Positive	True Negative

图9 混淆矩阵结构图

Fig.9 Confusion matrix structure diagram

在该结构中,True Positive(TP)和 False Negative(FN)表示模型判断正确,True Negative(TN)和 False Positive(FP)表示模型判断错误。

模型的总样本数量 = TP + FP + TN + FN,CNN模型辨识结果的正确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1 Score表示如下:

$$\left. \begin{aligned} \text{Accuracy} &= \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}; \\ \text{Precision} &= \frac{\text{TP}}{\text{TP} + \text{FP}}; \\ \text{Recall} &= \frac{\text{TP}}{\text{TP} + \text{FN}}; \\ \text{F1 Score} &= \frac{2PR}{P + R}. \end{aligned} \right\} \quad (15)$$

其中:P表示Precision;R表示Recall。

正确率可以直观地表示分类模型中所有判断正

确的结果所占的预测值的比重;精确率表示在模型预测是Positive的结果中正确数值的比重;召回率表示在实际值是Positive中模型预测是正确数值的比重,F1 Score指标综合考虑了精确度与召回率产生的结果,范围从0~1之间变化,越贴近1表示模型的输出越好。

3 仿真分析

搭建如图1所示的系统仿真。

3.1 CNN模型训练结果

将经过K-L VMD预处理的特征模态分量输入CNN网络,利用混淆矩阵对网络训练结果进行识别,图10为识别结果。由该混淆矩阵可知,CNN训练的模型正确率为100%,精确率为100%,召回率为100%,F1 Score为100%。不同故障下实际值与预测值完全保持一致,检测错误或遗漏的概率为0,利用所建立的模型训练,可以精确有效地识别各种故障类型。

实际值 \ 预测值	0	1	2	3	4	5	6
6	59	0	0	0	0	0	0
5	0	60	0	0	0	0	0
4	0	0	63	0	0	0	0
3	0	0	0	61	0	0	0
2	0	0	0	0	56	0	0
1	0	0	0	0	0	69	0
0	0	0	0	0	0	0	52

图10 CNN识别结果

Fig.10 CNN recognition results

4 不同应用场景

4.1 不同故障位置

为了测试在不同故障时所提出算法的适用性,现模拟在电缆线路6 km处发生不同故障的情况(图10为故障位置为10 km处的训练结果),在该故障位置下的训练结果如表4所示。

由表4可知,该训练模型在不同故障位置时的准确率为100%,由此可知提出的判别方法适用于不同故障位置下的不同故障类型的辨别。

表 4 6 km 处各故障的识别结果

Table 4 Identification results of each fault at 6 kilometers

类型	测试集数目	正确识别数目	准确率/%
SIF	64	64	100
MIF	60	60	100
HIF	56	56	100
PPF	58	58	100
LS	56	56	100
SF	65	65	100
ASF	61	61	100

4.2 添加强噪声

添加噪声后会造成波形一定程度上的波动,对模型的训练识别有一定的干扰。为了验证在强噪声情况下的适用性,对直流线路正极电压添加信噪比为 1 dB 的高斯白噪声。

将添加噪声过后的特征分量送入 CNN 进行识别,图 11 为识别结果,识别准确率为 99.76%,据此可知,在强噪声的干扰下,CNN 判别模型准确度仍旧可靠。




图 11 1 dB 噪声下识别准确率

Fig. 11 Recognition accuracy under 1 dB noise

4.3 改变时间窗

时间窗的设置直接影响到数据量的多少,数据的时间窗越多,所包含的测试样本数越多,基于系统的换流器闭锁时间考虑,现将所选时间窗改变为故障前后的 2 ms 进行测试,图 12 为所选时间窗下经过 VMD 分解后的结果。

将该结果送入 CNN 中进行训练,准确率为 100%,由此可知提出的判别方法适用于不同时间窗下的不同故障类型的辨别。




图 12 不同数据窗测试

Fig. 12 Different data window tests

4.4 与未改进的 CNN 对比

为验证所提 Inception-CNN 模型降低过拟合的能力,现将经过 K-L VMD 分解的模态分量 IMF1 分

别送入 CNN 模型与 Inception-CNN 模型并进行对比,如图 13 所示。




图 13 CNN 模型与 Inception-CNN 模型对比

Fig 13 Comparison of CNN model with Inception-CNN model

由图 13 (a) 可知,对比 CNN 模型而言,Inception-CNN 模型具有降低过拟合的能力,且训练集与验证集的准确率都得到了提升,此外,由图 13 (b) 可以知道,在迭代次数达到 300 时,模型训练效果最好。

5 结 论

本文提出一种基于 K-L VMD 和 Inception-CNN 的直流配网故障识别方案,并基于 PSCAD 平台进行仿真验证,得到以下结论:

1) 本文所提出的方案利用 K-L 散度优化变分模态分解的方法,对仿真数据进行处理,将处理后的特征模态分量作为训练模型的输入,有良好的推广能力,且具备对噪声的抗干扰能力,在不同应用场景下可靠性能优异。

2) 所提训练模型不仅能够识别单极、双极、交

流侧故障,同时对于单极故障下不同阻值变化的故障类型也能够进行有效判别,识别精确度高。

3) Inception-CNN 模型具有降低过拟合的能力,且识别故障准确度高。

参 考 文 献:

- [1] 王晓卫, 田书, 李玉东, 等. 基于 S 变换特征频率序列的小电流接地系统故障区段定位方法[J]. 电力系统保护与控制, 2012, 40(14): 109.
WANG Xiaowei, TIAN Shu, LI Yudong, et al. A novel fault section location method for small current neutral grounding system based on characteristic frequency sequence of S transform[J]. Power System Protection and Control, 2012, 40(14): 109.
- [2] 汪光远, 杨德先, 林湘宁, 等. 基于深度置信网络的柔性直流配电网高灵敏故障辨识策略[J]. 电力系统自动化, 2021, 45(17): 180.
WANG Guangyuan, YANG Dexian, LIN Xiangning, et al. High-sensitivity fault identification strategy for flexible DC distribution network based on deep belief networks[J]. Automation of Electric Power Systems, 2021, 45(17): 180.
- [3] 李恒, 张氢, 秦仙蓉, 等. 基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法[J]. 振动与冲击, 2018, 37(19): 124.
LI Heng, ZHANG Qing, QIN Xianrong, et al. Fault diagnosis method for rolling bearings based on short-time Fourier transform and convolution neural network[J]. Journal of Vibration and Shock, 2018, 37(19): 124.
- [4] 胡爱军, 孙敬敬, 向玲. 经验模态分解中的模态混叠问题[J]. 振动、测试与诊断, 2011, 31(4): 429.
HU Aijun, SUN Jingjing, XIANG Ling. Mode mixing in empirical mode decomposition[J]. Journal of Vibration, Measurement and Diagnosis, 2011, 31(4): 429.
- [5] 李晓莉, 李成伟. 改进的自适应噪声总体集合经验模态分解在光谱信号去噪中的应用[J]. 光学精密工程, 2016, 24(7): 1754.
LI Xiaoli, LI Chengwei. Application of improved complete ensemble empirical mode decomposition with adaptive noise in spectral signal denoising[J]. Optics and Precision Engineering, 2016, 24(7): 1754.
- [6] 张静远, 张冰, 蒋兴舟. 基于小波变换的特征提取方法分析[J]. 信号处理, 2000, 16(2): 156.
ZHANG Jingyuan, ZHANG Bing, JIANG Xingzhou. Analysis of feature extraction methods based on wavelet transform[J]. Signal Processing, 2000, 16(2): 156.
- [7] 张艳霞, 李多多, 张帅, 等. 基于广义 S 变换的高压直流输电线路边界保护[J]. 高电压技术, 2018, 44(10): 3197.
ZHANG Yanxia, LI Duoduo, ZHANG Shuai, et al. Boundary protection of HVDC transmission lines based on generalized S-transform[J]. High Voltage Engineering, 2018, 44(10): 3197.
- [8] SATPATHI K, YEAP M Y, UKIL A, et al. Short-time Fourier

- transform based transient analysis of VSC interfaced point-to-point DC system [J]. IEEE Transactions on Industrial Electronics, 2018, 65(5): 4080.
- [9] SONG Xinxin, WANG Shitao, DONG Xia. Research on fault detection scheme for hybrid LCC-MMC system[C]//2022 7th Asia Conference on Power and Electrical Engineering (ACPEE), April 15–17, 2022, Hangzhou, China. 2022: 1309–1313.
- [10] 王晓卫, 高杰, 吴磊, 等. 柔性直流配电网高阻接地故障检测方法[J]. 电工技术学报, 2019, 34(13): 2806.
- WANG Xiaowei, GAO Jie, WU Lei, et al. A high impedance fault detection method for flexible DC distribution network[J]. Transactions of China Electrotechnical Society, 2019, 34(13): 2806.
- [11] 王宾, 耿建昭, 董新洲. 配网高阻接地故障伏安特性分析及检测[J]. 中国电机工程学报, 2014, 34(22): 3815.
- WANG Bin, GENG Jianzhao, DONG Xinzhou. Analysis and detection of volt-ampere characteristics for high impedance faults in distribution systems[J]. Proceedings of the CSEE, 2014, 34(22): 3815.
- [12] 洪翠, 连淑婷, 黄晟, 等. 基于改进经验小波变换和改进多视角深度矩阵分解的直流配电网故障检测方案[J]. 电力自动化设备, 2022, 42(6): 8.
- HONG Cui, LIAN Shuting, HUANG Sheng, et al. Fault detection scheme based on IEWT and IMDMF for DC distribution network[J]. Electric Power Automation Equipment, 2022, 42(6): 8.
- [13] SHARMA N K, SAMANTARAY S R, BHENDE C N. VMD-enabled current-based fast fault detection scheme for DC microgrid[J]. IEEE Systems Journal, 2022, 16(1): 933.
- [14] CHOPDAR S M, KOSHTI A K. Fault detection and classification in power system using artificial neural network[C]//2022 2nd International Conference on Intelligent Technologies (CONIT), June 24–26, 2022, Hubli, India. 2022: 1–6.
- [15] ZHENG Yuyu, MAO Meiqin, CHANG Liuchen. DCSCF detection method of MMC-DC-grid based on statistical feature and DBN-SOFTMAX[C]//2021 IEEE 12th International Symposium on Power Electronics for Distributed Generation Systems (PEDG), June 28–July 1, 2021, Chicago, IL, USA. 2021: 1–6.
- [16] 曾全昊, 王丰华, 郑一鸣, 等. 基于卷积神经网络的变压器有载分接开关故障识别[J]. 电力系统自动化, 2020, 44(11): 144.
- ZENG Quanhao, WANG Fenghua, ZHENG Yiming, et al. Fault recognition of on-load tap-changer in power transformer based on convolutional neural network[J]. Automation of Electric Power Systems, 2020, 44(11): 144.
- [17] 魏文兵, 毛钧毅, 荣娜, 等. 采用随机矩阵与 CNN 的暂态电压稳定快速评估[J]. 电网与清洁能源, 2020, 36(11): 68.
- WEI Wenbing, MAO Junyi, RONG Na, et al. Fast evaluation of transient voltage stability using random matrix and convolutional neural network[J]. Power System and Clean Energy, 2020, 36(11): 68.
- [18] 韦延方, 吴郑磊, 王鹏, 等. 基于 CNN 与 DCGAN 的柔性直流配电网故障检测[J]. 煤炭学报, 2021, 46(S2): 1201.
- WEI Yanfang, WU Zhenglei, WANG Peng, et al. Fault detection of VSC based DC distribution network based on CNN and DCGAN[J]. Journal of China Coal Society, 2021, 46(S2): 1201.
- [19] 姜山, 范春菊, 黄宁, 等. 电力电子变压器直流端口极间短路故障特性分析[J]. 中国电机工程学报, 2018, 38(5): 1301.
- JIANG Shan, FAN Chunju, HUANG Ning, et al. Fault characteristic analysis of DC pole-to-pole fault in power electronic transformer[J]. Proceedings of the CSEE, 2018, 38(5): 1301.
- [20] 杨杰, 郑健超, 汤广福, 等. 电压源换相高压直流输电系统接地方式设计[J]. 中国电机工程学报, 2010, 30(19): 14.
- YANG Jie, ZHENG Jianchao, TANG Guangfu, et al. Grounding design analysis of VSC-HVDC system[J]. Proceedings of the CSEE, 2010, 30(19): 14.
- [21] 管敏渊, 徐政. 两电平 VSC-HVDC 系统直流侧接地方式选择[J]. 电力系统自动化, 2009, 33(5): 55.
- GUAN Minyuan, XU Zheng. DC side grounding methodology for a two-level VSC HVDC system[J]. Automation of Electric Power Systems, 2009, 33(5): 55.
- [22] 王晓卫, 高杰, 魏向向, 等. 基于小波包—贝叶斯的小电流接地系统故障选线方法[J]. 工矿自动化, 2014, 40(6): 54.
- WANG Xiaowei, GAO Jie, WEI Xiangxiang, et al. A fault line selection method of small current grounding system based on wavelet packet and Bayes theory[J]. Industry and Mine Automation, 2014, 40(6): 54.
- [23] 白浩, 李鹏, 袁智勇, 等. 人工智能在配电网高阻接地故障检测中的应用及展望[J]. 南方电网技术, 2019, 13(2): 34.
- BAI Hao, LI Peng, YUAN Zhiyong, et al. Application and prospect of artificial intelligence in high impedance fault detection of distribution network[J]. Southern Power System Technology, 2019, 13(2): 34.
- [24] 李浩, 张禄亮. 基于改进 VMD 和特征分布系数的配电网高阻接地故障检测方法[J]. 南方电网技术, 2022, 16(12): 109.
- LI Hao, ZHANG Luliang. High impedance grounding fault detection method for distribution network based on improved VMD and characteristic distribution coefficient[J]. Southern Power System Technology, 2022, 16(12): 109.

(编辑:刘琳琳)