

基于时频域瞬时特征的配电网弧光接地故障检测

张 华¹, 苏学能¹, 任 杰², 张真源²

(1. 国网四川省公司电力科学研究院, 四川 成都 610041; 2. 电子科技大学, 四川 成都 611731)

摘要:配电网弧光接地故障对电力系统安全和人身安全带来很大的威胁,快速准确的弧光检测是实现故障隔离与处置、预防电气安全风险的重要手段之一。为实现在不同电压等级和系统配置下均具有高水平检测速度和准确度的弧光检测,提出了一种基于时频域特征的弧光接地故障检测方法。首先,通过奇异值分解与变分模态分解将零序电流分解为不同频带的单分量子信号,得到的子信号有不同的频带与中心频率,且避免了模态混叠带来的误差,有利于对不同谐波分量进行细化分析;然后,利用希尔伯特变换获得子信号的瞬时幅值、相位与频率,并将瞬时特征作为检测的主要依据,为保证在线计算时对时序信号分类的准确性,设计了基于长短期记忆(LSTM)网络的故障分类器以区分弧光接地与其他情况;最后,通过不同系统配置的实际配电网弧光接地的故障数据验证了该方法的性能。

关键词:弧光接地; 瞬时特征; 希尔伯特变换; 长短期记忆(LSTM)

中图分类号:TM 734 文献标志码:A 文章编号:1003-6954(2024)05-0053-08

DOI:10.16527/j.issn.1003-6954.20240508

Arc Grounding Fault Detection in Distribution Network Based on Transient Features in Time-frequency Domain

ZHANG Hua¹, SU Xueneng¹, REN Jie², ZHANG Zhenyuan²

(1. State Grid Sichuan Electric Power Research Institute, Chengdu 610041, Sichuan, China; 2. University of Electronic Science and Technology of China, Chengdu 611731, Sichuan, China)

Abstract: Arc grounding faults in distribution network are a great threat to system safety and personal safety, and fast and accurate detection means are one of the important technologies to prevent the risk. In order to achieve a high level of detection speed and accuracy for different voltage levels and system configurations, an arc grounding fault detection method based on time-frequency domain characteristics is proposed. The zero-sequence current is decomposed into single component sub-signals of different frequency bands by singular value decomposition and variational mode decomposition, and the obtained sub-signals have different band and center frequency, and it avoids the errors caused by mode mixing, which ensures the refine analysis of different harmonic components. And then, the instantaneous amplitude, phase and frequency of sub-signals are obtained by using Hilbert transform, and the instantaneous characteristics are taken as the main basis for detection. In order to ensure the classification accuracy of sequence signals during online calculation, a fault classifier based on long short-term memory (LSTM) network is designed to distinguish arc grounding from other cases. Finally, the performance of the proposed method is verified by the fault data of arc grounding in an actual distribution network.

Key words: arc grounding; transient features; Hilbert transform; long short-term memory (LSTM)

0 引言

配电网作为电力系统的重要组成部分,其规模与智能化水平近年来得到了长足的发展。确保配

基金项目:国网四川省电力公司科技项目(52199722000B)

网的安全稳定运行变得越发重要^[1-2]。由于中国配电网系统多数采用中性点不直接接地的运行方式,在单相接地故障发生时,故障电流较主网更小,故障特征微弱。尤其在高阻接地时,过渡电阻进一步抑制了零序电流中的特征量,使得配电网单相接地故障检测面临着巨大的挑战。并且,弧光接地发生时,

电弧的随机性和非线性导致零序电流中存在大量的谐波分量^[3],使得故障信号暂态分量中的谐波成分与线性电阻接地时的理论谐波成分不一致,进一步降低了一些以暂态分量特征作为主要判据的故障检测方法的准确性。因此,快速准确的配电网弧光接地故障检测仍是亟待解决的工程难题。

通过建立配电网系统的零模等效方程,弧光接地故障检测可被简化为串联电弧故障,零模等效将具有复杂电路结构的耦合系统转化为具有明确参数且结构简单的电路。因此,一般对配电网弧光接地故障的研究重点在于对电弧故障发生时测量点的电气量特性。目前,许多学者在诸多方面对电弧进行了研究,包括基于信号处理的特征提取、基于电弧机理建模的电路状态辨识等。实际在大多数配电网中,能够直接得到的信号只有出线端的相电压和相电流采样值,而通过单端信号对系统状态进行精确的建模与估计是十分困难的。因此,利用信号处理方法来获取故障特征量成为了大多数研究中重要的步骤之一。文献[4]利用傅里叶变化(Fourier transform, FT)分析了电弧故障发生时的频率特性,并将一些低次谐波作为电弧故障检测的特征量。文献[5]利用 FT 对电弧电流与电压中的畸变程度进行了分析和计算,比较了电弧故障和其他故障时奇次谐波所占比例的差异,并作为电弧检测的依据。文献[6]对不同负载下不同类型的特征量进行了分析,包括时域中的均值、总变分、极值,以及频域中的直流量、三次谐波、五次谐波含量等,并在上述参数构成的特征空间中完成了故障分类。在文献[7]中,电弧故障的场景被分为了阻性、容-感性和开关性 3 种,在不同的类别下选择了更显著的谐波成分作为故障检测的指标。

上述的研究均在时域和频域中提取故障特征来实现电弧检测,需要至少采样一个周波的数据。不同场景下,时域特征的表现形式可能会存在很大差异。因此,需要针对故障场景特点设计合适的函数或数值计算方法,这无疑限制了检测方法的通用性。同时,基于 FT 的频域分析方法缺乏时间信息,单纯依赖频域特征的故障检测方法无法完全实现故障态表征,且容易被背景谐波干扰。

为解决上述问题,一些时频域分析方法被应用到电弧故障检测中。与频域分析不同的是,时频域分析兼顾了时间信息和频率信息,能够获得信号频

率、相位、幅值等参数随时间的变化趋势^[8],扩大了特征选择的范围。文献[9-12]通过小波变换算法获得了故障信号频率随时间的变化,并将小波系数作为故障检测指标。但基于小波变换的故障检测算法性能优劣取决于选择的基函数是否合适。文献[13-14]选择了维格纳维拉分布(Wigner-Viller distribution, WVD)来提取故障信号的时频域特征。虽然 WVD 具有很高的时频聚集性,且不需要选择基函数,但在分析电弧故障信号这类多分量非平稳信号时,会出现交叉项干扰。文献[7, 15-16]利用希尔伯特变换(Hilbert transform, HT)分析故障信号的时频特性。与小波变化、WVD 等积分变化方法相比,HT 提供了一种计算信号瞬时参数的新途径,不受测不准原理的制约;但应用于多分量信号的时频分析时,容易出现没有物理意义的负频率。因此,在应用 HT 之前,一般需要通过合适的信号分解技术将多分量信号分解为单分量信号。

许多文献也研究了弧光故障的检测策略。文献[17]提出了一种基于主成分分析和支持向量机的综合电弧检测方法,以解决电弧故障在多类型负载下的分类问题。文献[18]设计了一种基于随机森林与深度神经网络结合的串联电弧故障检测方法。文献[19]建立了用于快速电弧辨识的卷积神经网络模型,并在 IEC 62606 的支持下验证了方法的可行性。上述研究通过机器学习和人工智能来完成电弧故障检测,但采用的模型缺乏时序特征量变化趋势的捕捉能力,在处理强动态特性信号分类任务时,难以利用其演变规律。

为此,下面提出了一种基于时频域特征的电弧检测方法。为避免直接使用 HT 提取时频特征时可能出现的负频率,通过变分模态分解(variational mode decomposition, VMD)将多分量故障信号分解为具有不同频率中心的单量子信号,并利用奇异值分解(singular value decomposition, SVD)确定合适的分解层数,以获得故障场景适应能力和更好的分解性能。同时,分析了各个频带子信号的瞬时幅值、相位和频率,将瞬时参数作为电弧故障检测的指标。为兼顾特征量的幅值和相位变化特性,设计了基于长短期记忆单元(long short-term memory, LSTM)网络的故障分类器,以便更好地区分弧光接地故障和其他故障。通过实际配电网弧光接地故障数据,验证了所提方法的可行性。

1 电弧故障信号的时频特性

1.1 电弧故障信号时域-频域特性分析

电弧弧柱的等效电阻是时变的非线性电阻,在正弦电压激励下,故障信号为非平稳多分量信号。图1显示了实际配电网系统单相弧光接地的零序电压和零序电流,可见波形中存在周期性的畸变和随机跳变,且在电流过零点处尤为明显,被称为“零休”现象。




图1 弧光接地故障电压与电流波形

在现代信号处理技术中,周期信号 $x(t)$ 可表示为调幅-调频函数。

$$x(t) = a(t) \cdot \cos \varphi(t) \quad (1)$$

式中: $a(t)$ 为信号包络线; $\varphi(t)$ 为瞬时相位函数。当 $a(t)$ 为定值、 $\varphi(t)$ 为时间相关的一次函数时,信号 $x(t)$ 为平稳单分量余弦信号,其幅值、频率和相位均可通过 FT 得到。FT 的常见表达式为

$$F(\omega) = \int x(t) \cdot e^{-j\omega t} dt \quad (2)$$

由式(2)可见,FT 是将信号投射到以三角函数为基的线性空间中,并获得不同频率下的系数。一个周期的时间信号可由不同频率的三角函数叠加形成,且投影系数为常数而不是函数。因此,当 $a(t)$ 不为定值,或 $\varphi(t)$ 不为一次函数时,通过傅里叶变换无法得到信号幅值与相位的变化情况。

电弧故障电流和电压的频谱如图2所示,3~7次奇次谐波是故障信号中的主要成分,但谐波的时间信息,包括开始时间、结束时间和趋势,无法由 FT 获得。

1.2 希尔伯特变换

时频域分析同时具备时间与频率信息的获取能力,是分析非平稳信号的常用手段。其中,希尔伯特变换由于不受测不准原理的制约,相比于其他积分




图2 电弧故障电流与电压的频谱

变换型的时频分析方法,在某些场景下具备更优越的性能。

Gabor(伽柏)定义的解析信号由实部 $x(t)$ 与虚部 $\tilde{x}(t)$ 构成^[20],表示为

$$x_A(t) = x(t) + j\tilde{x}(t) \quad (3)$$

虚部 $\tilde{x}(t)$ 可通过原信号的 HT 来获得,其表达式为

$$\tilde{x}(t) = \frac{1}{\pi} \text{p.v.} \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (4)$$

式中:p.v.为柯西主值; τ 为时间变量。因此信号的瞬时幅值 $A(t)$ 、瞬时相位 $\varphi(t)$ 及瞬时频率 $f(t)$ 可表示为

$$\begin{cases} A(t) = \sqrt{x^2(t) + \tilde{x}^2(t)} \\ \varphi(t) = \arctan \frac{\tilde{x}(t)}{x(t)} \\ f(t) = \frac{\varphi'(t)}{2\pi} \end{cases} \quad (5)$$

式中, $\varphi'(t)$ 为瞬时相位导数。

显然,在分析故障电弧信号时,一些重要谐波成分的幅值、频率和相位等的变化趋势,可通过基于 HT 的时频域方法直接计算得出。

但是,HT 的应用存在一些限制,即待分析信号必须为幅度缓变的单分量信号,否则求出的瞬时频率会存在没有物理意义的负值。因此,在应用 HT 之前,一般会将信号分解为本征模函数(intrinsic mode function, IMF),即包络线频率低于载波频率的单分量信号。

1.3 VMD

VMD 是一种具备完备数学框架的信号分解方法。通过将信号分解任务转化为固定分解层数下的带宽和最小问题,构建了频域维纳滤波器。VMD 构建的最优化问题表示为

$$\min \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot x_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}$$

$$\text{s.t. } \sum_k x_k(t) = x(t) \quad (6)$$

式中: ∂_t 为时间的编导数; $x_k(t)$ 为分解信号; $\delta(t)$ 为狄拉克函数; k 为设置的分解层数; ω_k 为子信号中心频率。式(6)表示带约束条件的最小带宽和问题, 可通过拉格朗日方程转化为无约束最优化问题, 表示^[21]为

$$L = a \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot x_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| x(t) - \sum_k x_k(t) \right\|_2^2 + \left[\lambda(t), x(t) - \sum_k x_k(t) \right] \quad (7)$$

式中: a 为引入的松弛因子, 避免问题无法求解; $\lambda(t)$ 为拉格朗日乘子。该问题通过交替方向乘子法求解, 并得到在分解层数 k 下最优的子信号集。

显然, VMD 的优势在于在合适的参数下能够得到最优的分解结果, 相比于 EMD 及其衍生算法, 具有明确的物理意义和更低的模态混叠。但参数 k 的选择会严重地影响算法性能。

利用 SVD 确定合适的分解层数 k 。SVD 可获得非方阵的特征值, 从而得到在弗罗贝尼乌斯(Frobenius)规范下最接近目标矩阵的低维矩阵。其表达式为

$$\mathbf{A} = \mathbf{U}\mathbf{S}\mathbf{V}^T \quad (8)$$

式中, \mathbf{A} 为 $m \times n$ 维矩阵, 对于一维带噪声的信号 $a(q)$ ($q=0, 1, \dots, m+n-1$), 可将其构建为汉克尔矩阵, 如式(9)所示; \mathbf{U} 和 \mathbf{V} 为 $m \times m$ 和 $n \times n$ 维单位矩阵, 分别由 $\mathbf{A}\mathbf{A}^T$ 和 $\mathbf{A}^T\mathbf{A}$ 的特征向量构成; \mathbf{S} 为由矩阵 \mathbf{A} 的特征值构成的对角矩阵, 其对角元素为非增的。

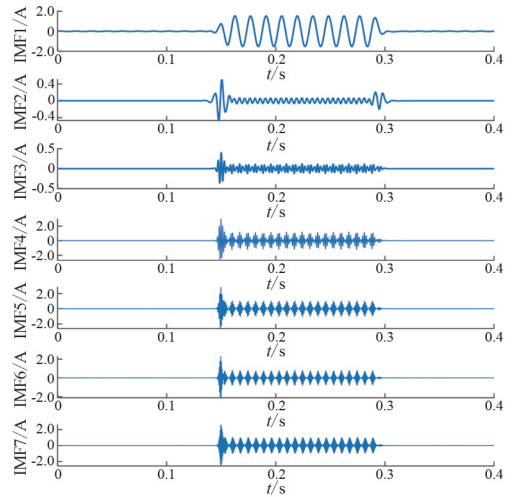
$$\mathbf{A} = \begin{bmatrix} a(0) & a(1) & \cdots & a(n-1) \\ a(1) & a(2) & \cdots & a(n) \\ \cdots & \cdots & 0 & \cdots \\ a(m-1) & a(m) & \cdots & a(m+n-1) \end{bmatrix} \quad (9)$$

特征值大小表示在原信号的重要程度, 因此可通过设置阈值选择前 k 个主要特征值, 实现信号去噪, 同时获得了适当的 k 值作为分解层数。


1.4 电弧故障信号的时频分析

为表明 SVD+VMD 分解的性能, 经 VMD 分解后以及相同数据的 EMD 分解结果如图 3 所示。可见, VMD 得到的 IMF 具有更小的带宽和模态混叠现象。

IMF1 至 IMF4 频谱如图 4 所示, 前 4 个 IMF 分



(a) VMD 得到的 IMF 的



(b) EMD 得到的 IMF 的

图 3 电弧故障电流的分解模态




图 4 IMF1 至 IMF4 频谱

别为以 50 Hz、150 Hz、350 Hz 和 450 Hz 为中心频率的调幅-调频信号。

通过希尔伯特变化, 获得前 4 个 IMF 的时频谱如图 5 所示。时频谱清晰地反映了电弧故障发生后, 幅值降低的整个过程。并且, 在故障发生和故障切除时, 其相位函数模式在故障时出现了明显切换。

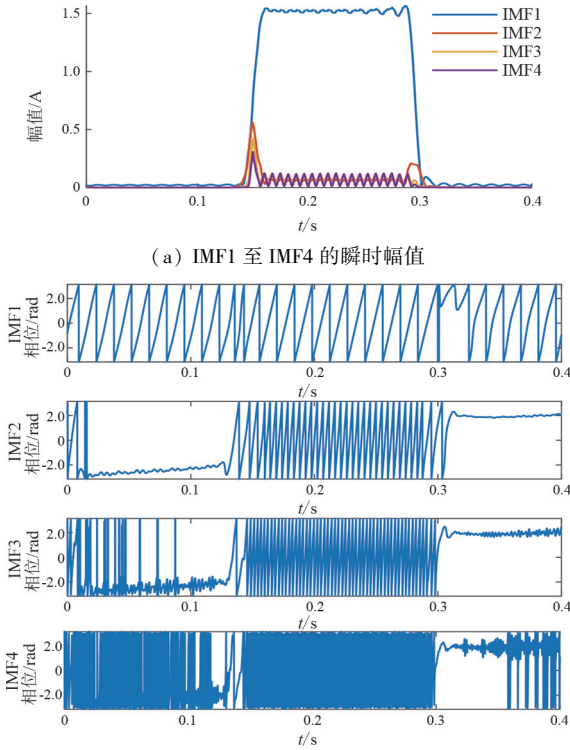


图 5 IMF1 至 IMF4 的相位函数

可见,在燃弧时零序电流中的主要谐波分量为 3~7 次谐波,且具有稳定的、不明显衰减的幅值,与故障暂态的谐波分量不同。另外,由于系统状态的切换,所有 IMF 的相位函数模式也同时发生了变化。这些时频域动态特性为电弧检测提供了依据。

1.5 方法的灵敏性分析

采用 SVD+VMD 对故障信号进行分解的目的在于获得故障信号中主要固有模态分量。电弧故障伴随着大量的且含量随频率增加而降低的奇次谐波, IMF1 至 IMF4 实际上主要表征的是故障信号中的工频以及 3、5、7 次谐波,但与傅里叶变换描述的平稳信号不同, IMF1 至 IMF4 表征的子信号是具有动态特性的非平稳信号。因此相较于傅里叶变换,对电弧故障信号而言,该方法具有更强的特征表征能力。

但在某些情况下,如燃弧间隙过小、空气电离程度高时,电弧阻值的非线性非常弱以至于故障信号畸变程度很低,故障信号中特征谐波含量随之变低,从而影响故障检测算法的精度。实际上,一些其他因素,如故障距离、接地电阻大小等对检测方法造成的影响最终也归结于对特征谐波造成的影响。对所提的方法而言,会影响 SVD 的特征值矩阵中表征主要谐波分量的特征值的大小,从而影响 VMD 对信号的分解准确性。通过 SVD 主要特征值和信号总

谐波失真(total harmonic distortion, THD)的关系来阐述该现象,仿真分析如图 6 所示。




图 6 IMF 特征值随 THD 的变化

图 6 中, IMF1 的特征值比例随 THD 的增加而减小,意味着在动态特性更强的电弧故障中,工频分量相对更小。相反, IMF2 至 IMF4 的特征值比例随 THD 的增加而增加,且 IMF2 的特征值上升得十分明显,其原因在于 IMF2 至 IMF4 对应的 3、5、7 次谐波是造成 THD 增加的主要因素。但在 THD 小于 0.1 时, IMF2 至 IMF4 的特征值同样小于 0.1,此时的电弧故障信号的特征是非常微弱的,仅依靠点值特征难以完成准确的故障检测。这种情况下,需要对信号中的时序特征进行挖掘。

2 电弧检测方法

2.1 LSTM

故障检测的准确率和速度不仅取决于特征集是否具有显著的特征表征能力,还取决于故障分类器的性能。经过上述分析,选择了第 1 至第 4 模态的瞬时参数作为特征,在实际应用中,作为与采样数据长度相同的时序数据。因此,选择了 LSTM 作为时序特征分类器,其基本原理表示为

$$\begin{cases} i_t = g(\mathbf{W}_i x_t + \mathbf{V}_i h_{t-1} + \mathbf{b}_i) \\ o_t = g(\mathbf{W}_o x_t + \mathbf{V}_o h_{t-1} + \mathbf{b}_o) \\ m_t = f_t m_{t-1} + i_t c_t \\ f_t = g(\mathbf{W}_f x_t + \mathbf{V}_f h_{t-1} + \mathbf{b}_f) \\ h_t = o_t \tanh m_t \\ c_t = \tanh(\mathbf{W}_c x_t + \mathbf{V}_c h_{t-1} + \mathbf{b}_c) \end{cases} \quad (10)$$

式中: i_t 为输入门; o_t 为输出门; m_t 为记忆单元; f_t 为遗忘门; h_t 为隐层的输出,且 h_t 会作为遗忘因子参与下一次 LSTM 单元的计算; x_t 为输入序列; \mathbf{W} 为权重向量; \mathbf{V} 为递归权重向量; \mathbf{b} 为偏移权重向量; C_t

为当前输入的单元状态。LSTM 的主要结构和 LSTM 网络如图 7 和图 8 所示。




图 7 LSTM 单元的主要结构

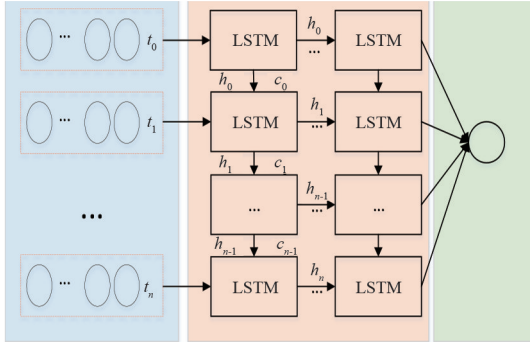


图 8 LSTM 网络

依靠独特的结构和遗忘因子, LSTM 能够捕获时序数据的前后关系, 相比于同样可以实现时序分类的循环神经网络, 降低了梯度消失的可能性。

2.2 算法设计

三相系统中不对称故障发生时, 零序分量为最能体现故障发生的模量, 因此将零序电流和零序电压作为原始数据。由于在弧光接地故障发生时, 零序分量为非平稳周期信号, 因此检测算法输入至少为一个工频周期的采样值。弧光接地检测流程如图 9 所示。

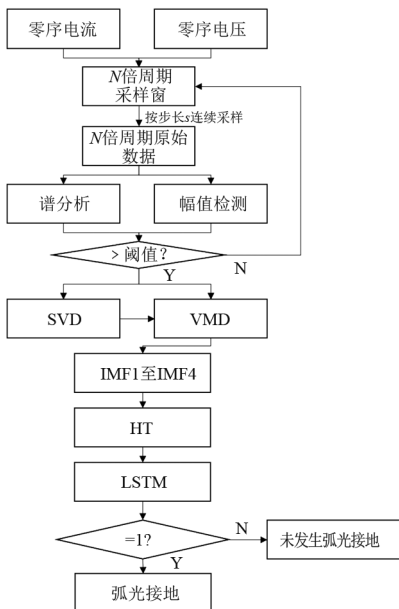


图 9 算法流程

首先, 缓存整数倍周期的采样数据并按固定步长递推, 以获得连续且长度相同的时间序列; 在进行 VMD 分解前通过频谱分析和幅值检测确定是否需要弧光接地检测, 从而避免传感器零漂、三相不平衡或漏电流带来的噪声; 当检测到非对称故障时, 则触发弧光检测算法开始对零序分量信号进行分析和分类; 通过 SVD 计算出故障信号的主要成分数量, 并作为 VMD 最佳分解层数; 随之通过 VMD 和 HT 得到的 IMF1 至 IMF4 的瞬时振幅、瞬时相位和瞬时频率, 并作为输入的时间序列信号输入 LSTM 网络。

3 算例

用实际 35 kV 配电网弧光接地故障的零序分量来验证所提方法的有效性, 具体配置如表 1 所示。

表 1 系统配置


电压等级/kV	数据源	中性点接地方式	故障类型
35	零序电流和零序电压	中性点不接地和中性点经消弧线圈接地	持续燃弧和间歇性燃弧

训练数据集被分为 3 个部分: 故障前数据、故障时数据以及故障后数据。其目的是通过对故障前后数据分别标签化, 使模型能够辨别三相不平衡、零漂或漏电流导致的零序信号噪声等情况与实际弧光故障的区别。同时, 分段标签化有助于识别故障起始的谐波跃升和相位突变, 提高检测速度。上述 3 种情况的分解子信号如图 10 所示。燃弧前零序电流的 IMF 与燃弧时的 IMF 存在明显的区别, 如故障前零序电流 IMF1 的幅值较低, IMF2 至 IMF4 的频率较高。同时, 燃弧期间电流的 IMF, 特别是 IMF1 和 IMF2 (工频分量和 3 次谐波分量) 有明显的上升。而随着接地故障的发展和稳定燃弧通道的形成, 3 次谐波的幅度在连续上升后逐渐稳定。


此外, LSTM 模型的配置为 100 个隐藏单元, 并采用自适应矩估计算法进行训练。基于 LSTM 的电弧检测方法的训练过程如图 11 所示。

模型训练完成后, 将 22 个中性点不接地系统和 32 个谐振接地系统的零序电流和电压数据作为测试数据集输入模型, 以检验模型的有效性。结果表明, 中性点不接地系统的故障电弧检测准确率为 95%, 谐振接地系统为 91%。中性点不接地系统的识别精度略高于谐振接地系统, 这是由于谐振接地系统故障发生后投入了随调试消弧线圈, 补偿了系


统中的电容电流,使得电弧特性变小导致模型无法识别。



(a) 故障前信号 IMFs



(b) 故障时信号的 IMFs



(c) 故障后信号 IMFs

图 10 故障零序电流的分解模式




图 11 模型训练时的正确率和损失

在相同的测试数据集下,将所提方法与常见的弧光检测算法,包括基于频域特征与支持向量机

(support vector machine, SVM) 的故障分类方法、基于卷积神经网络 (convolutional neural networks, CNN) 的故障信号特征提取与故障辨识方法等进行对比,其正确率如图 12 所示。

由于实际故障数据的强动态特性,频域特征无法完全描述其故障特性,特别是故障时的暂态分量和电弧的强随机性会影响频域特征提取和卷积层特征提取的准确性,因此基于频域特征的 SVM 方法与 CNN 在动态特性太强的情况下难以完成高精度检测任务。而所提方法融合 SVD 和 VMD 的优势,完成了信号去噪和对主要固有模态分量的提取,具有更强的抗噪能力和强动态情况下的准确性。




图 12 算法的正确率对比

4 结 论

上面提出了一种基于时频域瞬时特征的弧光接地故障检测新方法。针对电弧故障信号的非平稳性和多分量特性,结合 SVD 和 VMD 实现了故障信号的分解并获得了故障信号中的主要模态。同时,通过希尔伯特变换计算出瞬时振幅、频率和相位,并对其特性进行分析,得到电弧故障信号的瞬时特征。经过对瞬时参数的分析,选择反映工频以及 3、5、7 次谐波成分的调幅信号 IMF1 至 IMF4 作为主要特征。此外,还设计了基于 LSTM 的电弧检测算法,该算法可以捕获输入时间序列的趋势。最后,用实际配电系统的电弧故障数据验证了所提方法的有效性。

参考文献

[1] 邓丰,李鹏,曾祥君,等.基于 D-PMU 的配电网故障选线和定位方法[J].电力系统自动化,2020,44(19): 160-167.

[2] 李雅洁,孟晓丽,宋晓辉,等.基于最优 FIR 滤波器与层次聚类的配电网单相接地故障选线方法[J].电网技

- 术,2015,39(1):143-149.
- [3] 顾荣斌,蔡旭,陈海昆,等.非有效接地电网单相电弧接地故障的建模及仿真[J].电力系统自动化,2009,33(13):63-67.
- [4] ARTALE G, CATALIOTTI A, NUCCIO V C S, et al. A set of indicators for arc faults detection based on low frequency harmonic analysis[C]//2016 IEEE International Instrumentation and Measurement Technoloty Conference Proceedings, May 23 - 26, 2016, Taipet, China. IEEE, 2016:1183-1188.
- [5] ZENG K, XING L D, ZHANG Y J, et al. Characteristics analysis of AC arc fault in time and frequency domain[C]//2017 Prognostics and System Health Management Conference, July 9 - 12, 2017, Harbin, China. IEEE, 2017:1-5.
- [6] LI S N, YAN Y. Fault arc detection based on time and frequency domain analysis and radom forest [C] // 2021 International Conference on Computer Network, Electronic and Automation (ICCNEA), September 24-26, 2021, Xi'an, China. IEEE, 2021:248-252.
- [7] ZHANG Z Y, REN J, TANG X T, et al. Novel approach for arc fault identification with transient and steady state based time-frequency analysis [J]. IEEE Transactions on Industry Applications, 2022, 58(4):4359-4369.
- [8] WANG Y K, ZHANG F, ZHANG X H, et al. Series AC arc fault detection method based on hybrid time and frequency analysis and fully connected neural network [J]. IEEE Transactions on Industrial Informatics, 2019, 15(12):6210-6219.
- [9] LAI T M, SNIDER L A, LO E, et al. High-impedance fault detection using discrete wavelet transform and frequency range and RMS conversion [J]. IEEE Transactions on Power Delivery, 2005, 20(1):397-407.
- [10] YU Q F, HU Y Q, YANG Y. Identification method for series arc faults based on wavelet transform and deep neural network [J]. Energies, 2019, 13(1):142.
- [11] KIM Chul-Hwan, KIM Hyun, KO Young-Hun, et al. A novel fault-detection technique of high-impedance arcing faults in transmission lines using the wavelet transform [J]. IEEE Transactions on Power Delivery, 2002, 17(4):921-929.
- [12] ZHANG S, QU N, ZHENG T F, et al. Series arc fault detection based on wavelet compression reconstruction data enhancement and eep residual network [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71:3508409.
- [13] GUO F Y, GAO H X, WANG Z Y, et al. Detection and line selection of series arc fault in multi-load circuit [J]. IEEE Transactions on Plasma Science, 2019, 47(11):5089-5098.
- [14] LIU J T, ZHOU K F, HU Y. EMD-WVD method based high-frequency current analysis of low voltage arc [C] // 2018 Condition Monitoring and Diagnosis (CMD), September 23 - 26, 2018, Perth, WA, Australia. IEEE, 2018:1-5.
- [15] CHEN C K, GUO F Y, LIU Y L, et al. Recognition of series arc fault based on the Hilbert Huang transform [C] // 2015 IEEE 61st Holm Conference on Electrical Contacts (Holm), October 11 - 14, 2015, San Diego, CA, USA. IEEE, 2015:324-330.
- [16] LIU W J, ZHANG X B, DONG Y J, et al. Arc fault detection for AC SSPC based on Hilbert-Huang transform [C] // IECON 2017 - 43rd Annual Conference of the IEEE Industrial Electronics Society, October 29 - November 1, 2017, Beijing, China. IEEE, 2017:4104-4109.
- [17] JIANG J, WEN Z, ZHAO M X, et al. Series arc detection and complex load recognition based on principal component analysis and support vector machine [J]. IEEE Access, 2019, 7:47221-47229.
- [18] JIANG J, LI W, WEN Z, et al. Series arc fault detection based on random forest and deep neural network [J]. IEEE Sensors Journal, 2021, 21(15):17171-17179.
- [19] WANG Y, HOU L M, PAUL K C, et al. ArcNet: Series AC arc fault detection based on raw current and convolutional neural network [J]. IEEE Transactions on Industrial Informatics, 2022, 18(1):77-86.
- [20] WANG X Z, YAN Z. Multiple scale identification of power system oscillations using an improved Hilbert-Huang transform [C] // 2009 IEEE/PES Power Systems Conference and Exposition, March 15-18, 2009, Seattle, WA, USA. IEEE, 2009:1-6.
- [21] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3):531-544.

作者简介:

张 华(1985),男,硕士,高级工程师,研究方向为电力系统安全稳定分析与控制;

苏学能(1991),男,博士,工程师,研究方向为电力系统安全稳定分析与并行计算;

任 杰(1993),男,博士研究生,研究方向为配电网故障检测;

张真源(1986),男,博士,研究方向为电力系统分析。

(收稿日期:2024-05-18)