

# 基于 VMD-LSTM 的小电流接地系统故障选线方法

翟二杰, 舒征宇, 汪俊, 黄志鹏

(三峡大学电气与新能源学院, 湖北 宜昌 443000)

**摘要:**提出一种基于 VMD-LSTM 的故障选线方法。首先通过 VMD 算法将各出线零序电流分解为表征其特性的高、中、低频分量,分时段计算各分量能量值,并依次输入到 LSTM 神经网络中,通过建立各分量能量随时序变化特征与故障线路的联系,从而实现故障选线。仿真结果表明,该方法不受故障初始相角、接地电阻以及故障距离等因素影响,且在噪声干扰、异步采样和采样频率较低时依然可以取得良好的选线效果。

**关键词:**小电流接地系统;故障选线;变分模态分解;长短期记忆神经网络

**DOI:** 10.12067/ATEEE2006007

**文章编号:** 1003-3076(2021)01-0070-11

**中图分类号:** TP277

## 1 引言

我国中压配电网普遍采用小电流接地的方式运行,其发生单相接地故障的几率高达 80%<sup>[1]</sup>。但由于发生单相接地故障时故障电流幅值较小,暂态过程持续时间短,容易受故障初始相角、接地电阻以及采样频率等因素影响,致使小电流接地系统故障选线问题成为配网自动化过程中的难题<sup>[2-4]</sup>。

近年来,以神经网络、支持向量机(Support Vector Machine, SVM)等为代表的基于人工智能的故障选线方法由于具有较高的选线精度和较好的鲁棒性,被广泛应用于配电网单相接地故障选线中。比如文献[5]根据故障初相角的不同,通过建立两类 SVM 分类器来解决接地电阻较大造成的配电网单相接地故障选线难的问题。文献[6]将蚁群算法优化后的 BP 神经网络应用于配电网故障选线,提高网络训练速度的同时,有效降低了选线误判率;文献[7,8]利用 ADABOOST 算法将多个分类方法级联,从而提高对复杂分类样本的处理能力,实现综合选线。上述各基于人工智能的方法在故障选线问题上取得了一定的成效,但都忽略了单相接地故障的零序电流是随时间变化的量,而 BP 神经网络和 SVM 分类器均属于浅层神经网络,它们与 ADABOOST 算法一样,在处理有延续性的时间序列方面存在不足,

使得在某些极端情况下以及采样频率较低时容易造成误判。

长短期记忆神经网络(Long Short-Term Memory Neural Network, LSTM)作为一种具有记忆能力的递归型神经网络,其在处理有关时间序列的问题上具有显著优势,近年来在各个领域开始受到广泛关注。鉴于此,本文将 LSTM 神经网络应用于故障选线,提出一种基于 VMD-LSTM 的小电流接地系统故障选线新方法。通过变分模态分解(Variational Mode Decomposition, VMD)算法将各出线零序电流分解成能直观体现零序电流基本组成的本征模态分量(IMF),将不同分量的能量值按时段代入到训练完成的 LSTM 网络中,实现故障选线。其实质是建立模态分量的能量随时序变化特征与故障线路之间的联系,从而实现不同场景下的故障线路快速辨识。

## 2 故障零序电流特性与组成

小电流接地系统可以分为中性点不接地系统和中性点经消弧线圈接地系统。本文以中性点经消弧线圈接地系统为例分析配电网系统发生单相接地故障后的零序电流特性及组成(中性点不接地系统可以看做是消弧线圈接地系统中电阻值无限大的一种特殊情况),假设  $C$  为消弧线圈接地系统的所有相对地电容,  $L_0$  为等效电感,  $R_0$  为零序回路中的等效

**收稿日期:** 2020-06-04

**基金项目:** 国家自然科学基金资助项目(61876097)

**作者简介:** 翟二杰(1997-),男,山西籍,硕士研究生,研究方向为电力系统运行与控制;

舒征宇(1983-),男,湖北籍,高级工程师,博士,研究方向为电力系统运行与控制。

电阻,  $r_L$ 、 $L$  分别为有功损耗电阻和电感,  $u_0$  为等效零序电源电压。等效电路如图 1 所示。




图 1 单相接地故障零序等效电路图

Fig.1 Single-phase ground fault zero sequence equivalent circuit diagram

由图 1 可知,故障零序电流  $i_d$  由故障电容电流  $i_C$  和流经消弧线圈的电感电流  $i_L$  组成,其计算如式(1)所示:

$$\begin{aligned} i_d &= i_C + i_L \\ &= (I_{Cm} - I_{Lm}) \cos(\omega t + \varphi) + \\ &\quad I_{Cm} \left( \frac{\omega_f}{\omega} \sin \varphi \sin \omega t - \cos \varphi \cos \omega_f t \right) e^{-\delta t} + \\ &\quad I_{Lm} \cos \varphi e^{-\frac{t}{L}} \end{aligned} \quad (1)$$

式中,  $I_{Cm}$ 、 $I_{Lm}$  分别为电容电流和电感电流的极值;  $\omega$  为系统角频率;  $\omega_f$  为暂态自由振荡分量的角频率;  $\delta$  为自由振荡分量的衰减系数;  $\varphi$  为故障发生时刻的相角。

由式(1)可知,故障零序电流  $i_d$  由稳态分量和暂态分量构成,其中稳态分量为稳态电容电流和稳态电感电流的幅值之和,其变化频率与工频相近;暂态分量则由电容电流的暂态自由振荡分量与电感电流的暂态直流分量构成,前者振荡频率高,衰减快,后者几乎无振荡,衰减较慢甚至无衰减。由此可见,故障零序电流亦可看作是工频交流分量、高频振荡分量和衰减直流分量三部分叠加而成。

为此,本文采用 VMD 算法对各出线零序电流进行分解,提取高、中、低频分量,计算故障线路与非故障线路不同分量在不同时间段内的能量值,利用 LSTM 网络处理时间序列的显著优势实现故障选线。

### 3 基于 VMD 的零序电流分解

#### 3.1 VMD 分解原理及步骤

变分模态分解(VMD)是一种自适应、完全非递归的模态变分和信号处理的方法<sup>[9]</sup>。其基本原理是确定时间序列的模态分解个数后,可以自适应地匹配每种模态的最佳中心频率和估计带宽,有效分

离本征模态分量(IMF)、划分信号频域,从而得到给定信号的有效分解成分,最终获得变分问题的最优解<sup>[10]</sup>,有效弥补了 EMD 算法<sup>[11]</sup>分解不直观、模态混叠较严重的缺陷。VMD 算法具体分解步骤如下:

(1)构造变分。其基本原则是寻求  $K$  个模态分量  $u_k(t)$ ,在保证各个模态分量之和等于原始信号  $f$  的前提下,使模态分量估计带宽相加最小。对应的约束变分模型公式为:

$$\begin{cases} \min_{\{u_k\}, \{w_k\}} \left\{ \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} \\ \text{s.t.} \sum_{k=1}^K u_k = f \end{cases} \quad (2)$$

式中,  $\{u_k\} = \{u_1, u_2, \dots, u_k\}$  为各模态分量;  $\{w_k\} = \{w_1, w_2, \dots, w_k\}$  为各模态分量中心频率;  $\delta(t)$  为冲激函数。

(2)求解变分。为求得该约束变分问题的最优解,引入拉格朗日乘子  $\lambda(t)$  和二次惩罚因子  $\alpha$ ,将约束变分问题转变为非约束变分问题,得到增广拉格朗日表达式为:

$$\begin{aligned} L(\{u_k\}, \{w_k\}, \lambda) &= \\ &\alpha \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-jw_k t} \right\|_2^2 + \\ &\left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (3)$$

式中,  $\alpha$  可保证信号重构精度;  $\lambda(t)$  增强了约束的严格性。

经过上述变换,子模态的带宽估计问题就被巧妙地转变成寻求增广拉格朗日公式鞍点问题。采用乘法算子交替方向法(Alternate Direction Method of Multipliers, ADMM)结合傅里叶变换解决上述变分问题,通过式(4)~式(6)迭代优化  $u_k^{n+1}$ ,  $w_k^{n+1}$  及  $\lambda^{n+1}$ ,最终求得增广拉格朗日表达式的“鞍点”。

$$\hat{u}_k^{n+1}(w) = \frac{\hat{f}(w) - \sum_{i \neq k} \hat{u}_i(w) + \hat{\lambda}(w)/2}{1 + 2\alpha(w - w_k)^2} \quad (4)$$

$$\hat{w}_k^{n+1} = \frac{\int_0^\infty w |\hat{u}_k(w)|^2 dw}{\int_0^\infty |\hat{u}_k(w)|^2 dw} \quad (5)$$

$$\hat{\lambda}^{n+1}(w) = \hat{\lambda}^n(w) + \tau [\hat{f}(w) - \sum_k \hat{u}_k^{n+1}(w)] \quad (6)$$

式中,  $n$  为当前迭代次数;  $\tau$  为拉格朗日乘子更新参数;  $\hat{u}_k^{n+1}(w)$ ,  $\hat{f}(w)$  以及  $\hat{\lambda}^{n+1}(w)$  分别为  $u_k^{n+1}(t)$ ,  $f(t)$  以及  $\lambda^{n+1}(t)$  所对应的傅里叶变换。

经过上述分析, VMD 的主要迭代求解步骤可表示如下:

步骤 1: 初始化  $\{u_k^1\}$ ,  $\{w_k^1\}$ ,  $\lambda^1$  和最大迭代次数  $N$ , 令  $n=0$ ;

步骤 2: 根据式(4)和式(5)更新  $u_k, w_k$ ;

步骤 3: 根据式(6)更新  $\lambda, n=n+1$ ;

步骤 4: 根据式(7)分析收敛性(本文  $\varepsilon$  设定为  $1.0 \times 10^{-6}$ ), 若不满足式(7)或  $n < N$ , 返回步骤 2; 否则完成迭代, 输出最终的  $u_k$  和  $w_k$ 。

$$\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (7)$$

### 3.2 基于 VMD 分解的能量计算

由第 2 节分析可知, 故障零序电流主要由工频交流分量、高频振荡分量和衰减直流分量组成。故本文设置 VMD 分解的分量个数  $K=3$ , 从而将故障零序电流的三种分量进行有效分离。此处以第 5.1 节场景 1 为例来说明 VMD 分解的有效性, 其故障线路零序电流 VMD 分解结果如图 2 所示。




图 2 故障线路零序电流 VMD 分解结果图

Fig.2 VMD decomposition results of fault line zero sequence current

从图 2 中不难看出, 通过 VMD 分解后得到的三个本征模态分量与故障线路零序电流的三个组成分量特性一致, 可以说明, 经过 VMD 算法的 3 层分解

后, 直流分量、工频交流分量以及高频振荡分量被有效且直观地分离出来。

对比图 2 中的 VMD 分解结果可以发现, 在相同时间段内三个模态分量的能量存在差异, 且同一分量在不同的时间段内衰减速度也有所不同。

考虑到 LSTM 神经网络处理时间序列的显著优势, 本文将采集到的零序电流信号进行 VMD 分解后, 分别计算不同时段下各个分量的能量值, 将其代入到 LSTM 网络中进行故障选线。能量计算步骤如下:

步骤 1: 将零序电流信号平均划分为  $M$  个时间段, 记为  $[T_1, T_2, \dots, T_i, \dots, T_M]$ , 其中,  $i$  为时间段编号。由于单相接地故障暂态过程持续时间较短, 常在 1~3 个工频周期内结束<sup>[12]</sup>, 故本文选取故障发生后的 2 个工频周波进行时段划分。本文  $M$  取 8, 此时网络训练时间最短, 准确率也较高。

步骤 2: VMD 分解的第  $k$  个分量  $IMF_k$  在  $T_i$  时间段的能量  $E_{k,ij}$  为:

$$E_{k,ij} = \int_{T_{i,\min}}^{T_{i,\max}} |IMF_{k,ij}| dt \quad k=1, 2, \dots, K \quad (8)$$

式中,  $j$  为线路编号;  $T_{i,\max}$  和  $T_{i,\min}$  分别对应  $T_i$  时间段的时间上限和时间下限;  $K$  为零序电流 VMD 分量个数, 本文  $K$  取 3。

在实际场景中, 当出现故障初始相角较小、接地电阻较大、采样频率较低等极端情况时, 采集到的各出线零序电流幅值较小, 使得 VMD 分解后的各分量幅值和能量值也较小。为增强 VMD 分解后的各分量信号, 本文对故障发生后的所有零序电流进行 VMD 分解, 得到各线路的高、中、低频模态分量后, 根据式(9)对其进行归一化处理, 再进行能量计算。

$$IMF_{kg,j} = \frac{IMF_{k,j}}{IMF_{k\max,j}} \quad (9)$$

式中,  $IMF_{kg,j}$  表示第  $k$  个模态分量的归一化幅值;  $IMF_{k,j}$  表示第  $k$  个模态分量的实际幅值;  $IMF_{k\max,j}$  表示第  $k$  个模态分量中的幅值最大值。表 1 所示为 5.1 节场景 1 中各线路零序电流 VMD 分量归一化前能量值  $E_{k,j}$  和归一化后能量值  $E_{kg,j}$  的对比结果。

由表 1 可知, 归一化处理后, 各健康线路零序电流 VMD 分量能量值相较于故障线路的同一分量能量值均有不同程度的增大, 相当于变相增强了各线路的零序电流幅值。

表 1 归一化前后各线路零序电流 VMD 分量的能量值

Tab.1 Energy value of VMD component of zero-sequence current of each line before and after normalization

线路 编号	VMD 分量	各分量对应能量值		$E_{k,j}/E_{k,5}$	$E_{kg,j}/E_{kg,5}$
		$E_{k,j}$	$E_{kg,j}$		
L1	$IMF_1$	0.000 4	0.004 6	0.012 8	1.569 5
	$IMF_2$	0.008 1	0.025 4	0.050 1	1.518 3
	$IMF_3$	0.000 9	0.002 2	0.034 9	1.331 2
L2	$IMF_1$	0.005 3	0.004 6	0.176 0	1.578 2
	$IMF_2$	0.081 4	0.024 1	0.504 0	1.440 4
	$IMF_3$	0.000 7	0.001 0	0.025 3	0.617 8
L3	$IMF_1$	0.012 2	0.006 5	0.403 8	2.233 5
	$IMF_2$	0.132 2	0.024 8	0.818 5	1.477 9
	$IMF_3$	0.009 5	0.002 5	0.360 9	1.534 3
L4	$IMF_1$	0.010 0	0.004 6	0.330 7	1.566 7
	$IMF_2$	0.153 6	0.024 2	0.951 1	1.443 4
	$IMF_3$	0.000 7	0.001 2	0.027 6	0.749 9
L5	$IMF_1$	0.030 3	0.002 9	1.000 0	1.000 0
	$IMF_2$	0.161 5	0.016 8	1.000 0	1.000 0
	$IMF_3$	0.0264	0.001 6	1.0000	1.000 0

## 4 基于 VMD-LSTM 的故障选线

### 4.1 LSTM 算法简介

LSTM(长短期记忆神经网络)是一种具有长短期记忆功能的深度神经网络,可以很好地处理时间序列数据的预测和分类问题,目前已广泛应用于语音识别、自然语言处理等领域中<sup>[13-15]</sup>。

图 3 所示为 LSTM 的结构图,其主要由三个门(即图 3 中的虚线框图,从左往右依次为遗忘门、输入门、输出门)组成,通过三个门的相互配合,LSTM 能更加有效地决定哪些历史信息被遗忘,哪些输入信息被保留,哪些信息可以被输出,从而更加高效地处理时间序列。

图 3 中, $\mathbf{x}(t_i)$  为 LSTM 神经网络  $t_i$  时刻的网络输入,本文中  $\mathbf{x}(t_i) = [E_{1,ij}, E_{2,ij}, E_{3,ij}]$ ;  $\mathbf{h}(t_i)$  为  $t_i$  时刻的网络输出; $\mathbf{C}(t_i)$  为  $t_i$  时刻网络的单元状态输出; $\mathbf{f}(t_i)$ ,  $\mathbf{i}(t_i)$ ,  $\mathbf{o}(t_i)$ ,  $\mathbf{C}'(t_i)$  分别表示遗忘门输出,输入门输出,输出门输出和当前输入单元状态; $\sigma$  和  $\tanh$  均为激活函数,其中  $\sigma$  为 sigmoid 函数,  $\tanh$  为双曲正切函数。

在 LSTM 模型训练过程中,首先根据初始设定的参数按照式(10)运算更新 LSTM 模型中各门参数,并进一步根据式(11)运算得到网络的输出结果:




图 3 LSTM 结构图

Fig.3 LSTM structure diagram

$$\begin{cases} \mathbf{f}(t_i) = \sigma(\mathbf{W}_f \cdot [\mathbf{h}(t_{i-1}), \mathbf{x}(t_i)] + \mathbf{b}_f) \\ \mathbf{i}(t_i) = \sigma(\mathbf{W}_i \cdot [\mathbf{h}(t_{i-1}), \mathbf{x}(t_i)] + \mathbf{b}_i) \\ \mathbf{C}'(t_i) = \tanh(\mathbf{W}_c \cdot [\mathbf{h}(t_{i-1}), \mathbf{x}(t_i)] + \mathbf{b}_c) \\ \mathbf{o}(t_i) = \sigma(\mathbf{W}_o \cdot [\mathbf{h}(t_{i-1}), \mathbf{x}(t_i)] + \mathbf{b}_o) \end{cases} \quad (10)$$

$$\begin{cases} \mathbf{C}(t_i) = \mathbf{f}(t_i) \otimes \mathbf{C}(t_{i-1}) + \mathbf{i}(t_i) \otimes \mathbf{C}'(t_i) \\ \mathbf{h}(t_i) = \mathbf{o}(t_i) \otimes \tanh(\mathbf{C}(t_i)) \end{cases} \quad (11)$$

式中, $\mathbf{W}_f$ 、 $\mathbf{W}_i$ 、 $\mathbf{W}_c$ 、 $\mathbf{W}_o$  分别代表遗忘门、输入门、当前输入单元状态和输出门的权重矩阵; $\mathbf{b}_f$ 、 $\mathbf{b}_i$ 、 $\mathbf{b}_c$ 、 $\mathbf{b}_o$  则表示遗忘门、输入门、当前输入单元状态和输出门的偏置矩阵;此 8 个参数矩阵为待求的参数矩阵,在模型的训练过程中逐步优化和更新。

按照式(11)计算出网络的输出值后,根据式(12)计算输出值与实际值之间的误差  $\mathbf{C}$ ,将误差反向传播,并按式(13)更新网络权重和偏置:

$$\mathbf{C} = |\mathbf{h}'(t_i) - \mathbf{h}(t_i)| \quad (12)$$

$$\begin{cases} \mathbf{W}' = \mathbf{W} - \alpha \cdot 2[\mathbf{h}'(t_i) - \mathbf{h}(t_i)] \\ \mathbf{b}' = \mathbf{b} - \alpha \cdot 2[\mathbf{h}'(t_i) - \mathbf{h}(t_i)] \end{cases} \quad (13)$$

式中, $\mathbf{h}'(t_i)$  表示 LSTM 网络实际值,本文取值 0 或 1,其中 0 代表健康线路,1 代表故障线路; $\mathbf{h}(t_i)$  表示 LSTM 网络输出值; $\alpha$  表示学习率; $\mathbf{W}$  和  $\mathbf{b}$  代表更新前的权重和偏置; $\mathbf{W}'$  和  $\mathbf{b}'$  代表更新后的权重和偏置。

### 4.2 基于 VMD-LSTM 的故障选线流程

由前文分析可知,故障零序电流的直流分量、工频交流分量以及高频振荡分量可以通过 VMD 算法



有效且直观地分离出来。不同的 VMD 分量在同一时间段内的能量大小不同,且各分量在不同时间段的能量值(即能量衰减速度)也有差异,其中,高频振荡分量衰减最快,直流分量衰减较为缓慢,工频交流分量几乎不衰减。

为此,本文借助 LSTM 网络处理时间序列的显著优势,依据故障线路与非故障线路零序电流各分量能量随时间变化特征的不同实现故障选线。

基于 VMD-LSTM 的小电流接地系统单相接地故障选线流程图如图 4 所示,步骤如下:

步骤 1:采集各线路零序电流  $I_j$ 。其中  $j$  为线路编号。

步骤 2:VMD 分解。确定预分解分量的个数  $K$ ,根据式(2)~式(7)对  $I_j$  进行 VMD 分解,构建并求解变分。本文设置  $K=3$ ,得到第  $j$  条线路零序电流的三个模态分量  $[IMF_{1,j}, IMF_{2,j}, IMF_{3,j}]$ 。

步骤 3:归一化处理。根据式(9)将  $IMF_{k,j}$  进行归一化处理,所得分量记为  $IMF_{kg,j}$ 。

步骤 4:时段划分。将采集到的零序电流数据

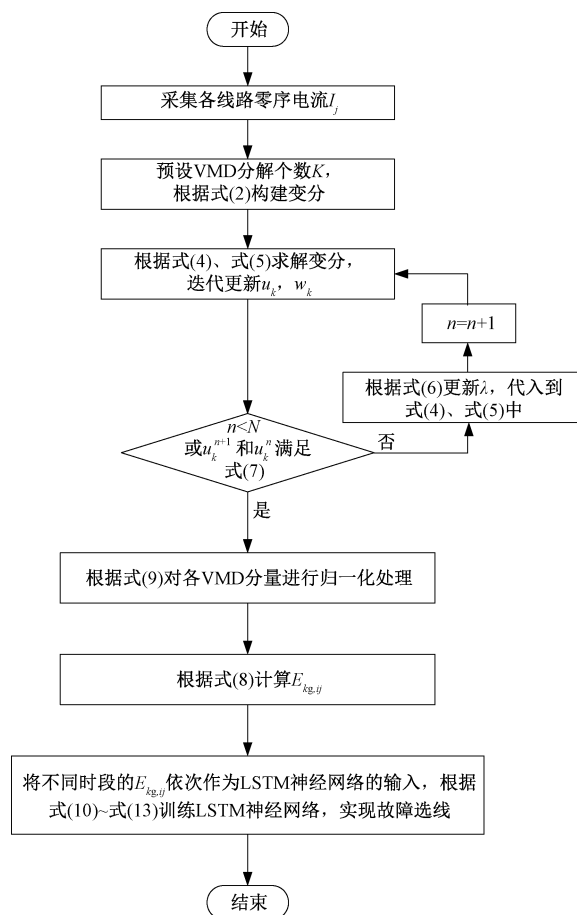


图 4 基于 VMD-LSTM 的故障选线流程图

Fig.4 Flow chart of fault line selection based on VMD-LSTM

序列按采集时间划分为  $M$  个时段  $[T_1, T_2, \dots, T_M]$ 。根据式(8)计算  $IMF_{kg,j}$  在  $T_i$  时段下的能量值  $E_{kg,ij}$ , 其中  $i$  表示时间段编号,  $M$  取 8。

步骤 5:将各分量能量值  $E_{kg,ij}$  按时段输入到 LSTM 神经网络,训练 LSTM 神经网络,建立不同分量的能量值随时间变化特征与故障线路的多层级映射关系,实现故障选线。

## 5 仿真案例分析

本文以 10 kV 中性点经消弧线圈接地系统为研究对象,利用 MATLAB/Simulink 软件搭建仿真模型,如图 5 所示。

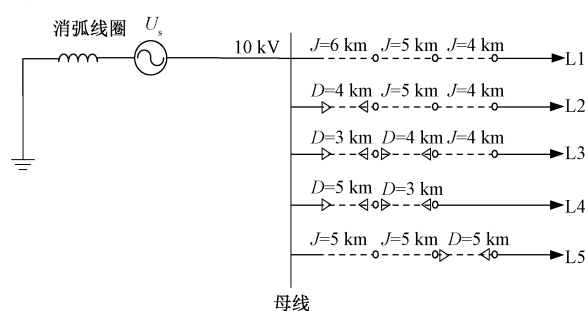


图 5 中性点经消弧线圈接地系统示意图

Fig.5 Schematic diagram of neutral point grounding system through arc suppression coil

图 5 中共包含五条出线,其中“J”表示架空线路,“D”表示电缆线路。消弧线圈采用 5% 的过补偿方式,其余线路参数如表 2 所示。假设 0.02 s 时系统发生单相接地故障,持续时间为 0.08 s,选择算法为 0de23tb, relative tolerance 为 1e-3,其他参数为默认值。

表 2 各线路电气参数

Tab.2 Electrical parameters of each line

线路类型	相序	$R$ /( $\Omega/\text{km}$ )	$L$ /( H/km )	$C$ /( F/km )
架空线路	正序	0.012 7	9.34E-04	1.27E-08
	零序	0.386 0	4.13E-03	7.75E-09
电缆线路	正序	0.270 0	2.55E-04	3.39E-07
	零序	2.700 0	1.02E-03	2.80E-07

### 5.1 基于 VMD-LSTM 故障选线结果分析

如表 3 所示,本文通过改变仿真模型中的故障初始相角、故障点接地电阻、故障点距母线距离来模拟不同场景下的系统单相接地故障,并使用“To Workspace”模块对仿真波形进行采样,采样频率为 400 次/周波。

表 3 典型接地故障的样本集合

Tab.3 Sample collection of typical ground faults

参数名称	样本集合
$\varphi/(^{\circ})$	{0,20,45,90}
$R_f/\Omega$	[5,1 000]
$d_f/\text{km}$	[1,15]
故障线路	{L1,L2,L3,L4,L5,母线}

表 3 中, $\varphi$  为故障初始相角, $R_f$  为故障点的接地电阻, $d_f$  为故障点到母线的距离。实验共采集到 750 组非故障样本,150 组故障样本,总计 900 组样本。将故障样本与非故障样本进行混合后,随机选择 800 组样本来进行 VMD-LSTM 模型的训练,剩余 100 组作为测试样本来检验故障选线的准确率,其中 LSTM 网络输出值接近于 1 的判断为故障线路,接近于 0 的判断为非故障线路。

表 4 所示为测试样本中三种典型的单相接地故障,本文将以此来说明所提方法的有效性。

表 4 三种典型的故障场景

Tab.4 Three typical failure scenarios

编号	$\varphi/(^{\circ})$	$R_f/\Omega$	$d_f/\text{km}$	故障线路
场景 1	90	5	5	L5
场景 2	45	50	6	L5
场景 3	20	1 000	10	L5




图 6 场景 1 至场景 3 故障线路零序电流对比

Fig.6 Comparison of zero-sequence currents of fault lines in scenarios 1 to 3

由图 6 可知,发生单相接地故障后,故障线路零序电流的幅值会受到故障初始相角、接地电阻以及故障距离的影响而呈现出明显的差异。为此本文分别将三种场景下采集到的各出线零序电流进行 VMD 分解和分量归一化处理,按时间段计算各分量能量值。图 7 所示即为各线路 VMD 分量能量随时间变化曲线。

从图 7 中可以看出,在上述三种场景中,故障线路与非故障线路的 VMD 分量能量值随时间变化曲线存在明显的差别,故利用可以处理时间序列的 LSTM 神经网络来进行故障选线具有很大的优势。鉴于此,本文将各分量的能量值按时段依次输入到训练完成的 LSTM 神经网络中,所得选线结果如表 5 所示。

表 5 VMD-LSTM 故障选线结果


Tab.5 VMD-LSTM fault line selection results

场景编号	分量编号	LSTM 网络输出值	选线结果
场景 1	L1	0.022 1	L5
	L2	0.015 3	
	L3	0.015 8	
	L4	0.016 7	
	L5	1.000 3	
场景 2	L1	0.001 2	L5
	L2	0.021 5	
	L3	0.014 6	
	L4	0.012 4	
	L5	1.109 1	
场景 3	L1	0.021 6	L5
	L2	0.021 4	
	L3	0.019 4	
	L4	0.017 9	
	L5	1.003 4	


由表 5 可知,基于 VMD-LSTM 的故障选线方法可以取得良好的选线效果。此外,对 100 组测试样本利用 VMD-LSTM 方法进行故障选线,选线准确率高达 94.63%。

5.2 噪声干扰对方法选线结果准确率的影响


近年来,大量的电力电子设备被广泛应用于电力系统中,这些装置会产生大量的噪声数据,并严重影响故障线路与健康线路的零序电流分布,增加选线难度。为此,本文通过在采集到的各线路零序电流波形上叠加信噪比为 10 dB 的高斯白噪声来检验噪声干扰情况下 VMD-LSTM 选线方法的有效性。



(a) 场景1各线路VMD分量能量随时间变化图



(b) 场景2各线路VMD分量能量随时间变化图



(c) 场景3各线路VMD分量能量随时间变化图

图7 各场景VMD分量能量随时间变化图

Fig.7 Variation of energy of VMD components of each scene with time

图8所示即为上述3个场景添加高斯白噪声后的故障线路零序电流。




图8 噪声信号对零序电流信号的影响

Fig.8 Effect of noise signal on zero-sequence current signal

从图8中不难看出,添加高斯白噪声后,场景1和场景2故障线路零序电流受噪声影响较小,而场景3故障线路零序电流变化较为明显。受篇幅所限,以下将主要以场景3为例来说明噪声干扰情况下VMD-LSTM方法的选线效果。噪声干扰时场景3中的VMD分量能量随时间变化曲线如图9所示。




图9 噪声干扰时场景3VMD分量能量随时间变化曲线

Fig.9 Variation curve of energy of VMD component of scene 3 with time under noise interference

如图 9 所示,加入噪声干扰后,故障线路与非故障线路的 VMD 分量能量值随时间变化曲线依然存在差别,将各 VMD 分量能量按时段依次输入到 LSTM 神经网络后依然可以实现正确选线。此外,本文将添加高斯白噪声后的 100 组测试样本,分别采用 VMD-LSTM 选线法、文献[5]中的 SVM 分类器(EEMD-SVM)、文献[6]中的蚁群算法优化后的 BP 神经网络(BP)以及文献[7]中的 ADABOOST 算法进行对比,所得结果如表 6 所示。

表 6 噪声干扰下的故障选线结果

Tab.6 Results of fault line selection under noise interference

选线方法	选线准确率(%)
EEMD-SVM	90.61
BP	82.36
ADABOOST	92.32
VMD-LSTM	91.84

由表 6 可知,在有噪声干扰的情况下,经过蚁群算法优化后的 BP 神经网络选线准确率较低,这是因为当出现类似于场景 3 的高阻接地故障时,其本身故障特征较弱,且 BP 神经网络结构简单,抗干扰能力差,因而在加入高斯白噪声后其选线误判率较高。

5.3 异步采样对方法选线结果准确率的影响

工程应用中,各信号采样不同步的问题往往难以避免。为此,本文在 100 组测试样本中将故障线路的采样滞后健康线路 0.002 s,如图 10 所示。




图 10 采样不同步时的各线路零序电流信号

Fig.10 Zero sequence current signal of each line with unsynchronized sampling

图 11 所示为采样不同步时场景 3 中各线路 VMD 分量能量随时间变化曲线。

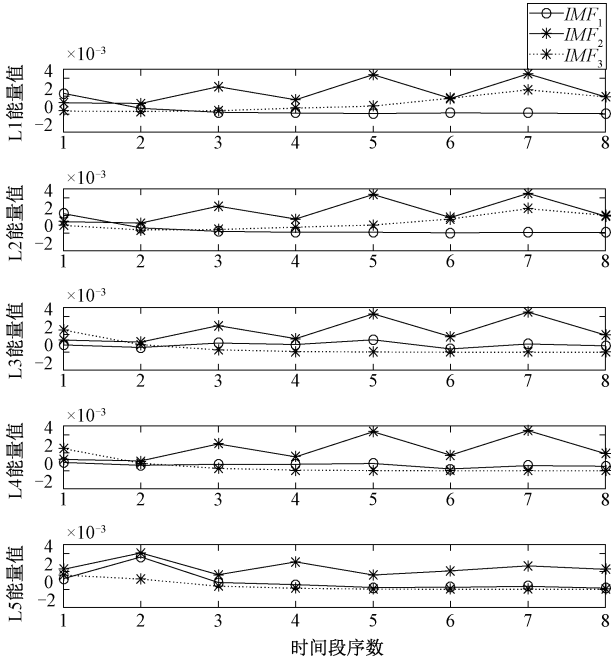


图 11 采样不同步场景 3 VMD 分量能量随时间变化图

Fig.11 Variation of energy of VMD components in scene 3 with time with unsynchronized sampling

对比图 7 和图 11 中场景 3 的 VMD 分量能量值随时间变化曲线,可以发现,采样不同步时,故障线路的 VMD 分量能量峰值出现了后移。在 100 组测试样本中采用前文所述的 4 种方法进行对比,所得结果如表 7 所示。

表 7 采样不同步时的故障选线结果

Tab.7 Fault line selection results with unsynchronized sampling

选线方法	选线准确率(%)
EEMD-SVM	87.36
BP	85.66
ADABOOST	82.69
VMD-LSTM	91.28

由表 7 可知,当发生采样不同步时,相比于本文所提的 VMD-LSTM 方法,其余方法选线准确率均有所下降。这是因为发生采样不同步时,各线路零序电流发生序错位,使得故障线路与健康线路同一时刻的极性、幅值差异规律被打乱,依靠一个或多个时间点对应的线路幅值和极性差异来进行故障选线的方法误判率较高。而本文通过计算多个连续时间段的能量,尽量减小点错位带来的选线误差,又借助 LSTM 神经网络的“记忆”特性,基于较长时间尺度



的能量变化曲线来实现故障选线,因而受采样不同步的影响较小。

#### 5.4 采样频率对方法选线结果准确率的影响

实际采样的零序电流信号由于采样频率的限制,有些故障信息可能丢失,致使故障线路的特征不明显,造成“误选”或“漏选”<sup>[16,17]</sup>。为验证本文所提方法在采样频率较低时的有效性,本文以 5.1 节场景 1 为基础,将故障线路替换为线路 4,分别以每个周波 10、40、100、400 次的频率对故障线路零序电流进行采样,所得图形如图 12 所示。




图 12 不同采样频率对零序电流信号的影响

Fig.12 Effect of different sampling frequencies on zero-sequence current signal

由图 12 可知,当以每个周波 10 次、40 次的频率进行采样时,其零序电流在故障初期幅值较小,存在较大的能量损失,影响故障选线的准确率。

考虑到实际工程应用的技术限制,本文在上述场景的基础上,以 40 次/周波的频率对线路 4 零序电流信号进行采样,并在此基础上进行故障选线,图 13 所示为低频采样时各线路 VMD 分量能量随时间变化曲线。

如图 13 所示,低频采样情况下,各线路的 VMD 分量能量值随时间变化曲线相较于其他故障类型变化较为明显,但故障线路与健康线路差别仍较大。在 100 组测试样本中采用前文所述的 4 种方法进行对比,所得结果如表 8 所示。

由表 8 可知,当采样频率较低时,采样得到的零序电流信号会产生能量损失。此外,当暂态过程持续时间较短,而采样频率较低时,采集到的零序电流




图 13 低频采样时 VMD 分量能量随时间变化图

Fig.13 Time-dependent graph of VMD component energy of scene 1 during low-frequency sampling

表 8 低频率采样时的故障选线结果

Tab.8 Fault line selection results at low frequency sampling

选线方法	选线准确率(%)
EEMD-SVM	82.21
BP	79.36
ADABOOST	80.31
VMD-LSTM	90.26

信号相较于原始信号会丢失一个或多个波峰、波谷信息,依靠极性、幅值、初始相角进行故障选线的 EEMD-SVM、BP、ADABOOST 等方法发生选线错误。而本文所提方法在 VMD 分解后采用归一化处理,变相对对 VMD 分量信号进行了增强,且本文基于长时间尺度的能量变化规律进行故障选线,因此,即便在采样频率较低、信号存在能量损失的情况下,依然可以保障故障选线结果的准确率。

## 6 结论

本文提出一种基于 VMD-LSTM 的小电流接地系统单相接地故障选线方法。本文首先对系统中各线路的零序电流进行 VMD 分解和归一化处理,进而得到不同频段零序电流的增强分量;考虑到长短期记忆神经网络在处理时间序列方面的显著优势,本文将增强后的各零序电流分量进行时段划分,并计算各时段能量,将其作为神经网络的输入,进而实

现故障选线。仿真结果表明,本文所提方法在有噪声干扰、异步采样、低采样频率、接地电阻较大等故障特征较弱的场景下具有较高的选线准确率。

## 参考文献 (References):

- [1] 张国军, 韩静静, 任荣, 等 (Zhang Guojun, Han Jingjing, Ren Rong, et al.). 多判据融合小电流单相接地故障选线方法研究与实验 (Research and experiment for fault line detection in non-solidly grounded system using multi-criteria combination) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2015, 34 (4): 56-61.
- [2] 余修勇, 肖立业 (Yu Xiuyong, Xiao Liye). 直流配电网故障识别和定位技术研究综述 (An overview of fault identification and location technology for DC distribution networks) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2019, 38 (7): 56-66.
- [3] 许晔, 郭谋发, 杨耿杰, 等 (Xu Ye, Guo Moufa, Yang Gengjie, et al.). 采用仿射不变矩的谐振接地系统故障选线方法研究 (New approach to detect fault line in resonant earthed system using affine moment invariants) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2015, 34 (7): 37-44.
- [4] 图尔荪·依明, 吴俊勇, 陈占锋, 等 (Tuersun · Yiming, Wu Junyong, Chen Zhanfeng, et al.). 配电网单相接地故障的负序电流纵联差动选线方法 (Fault line selection of single-phase to ground based on negative sequence current pilot differential in distribution network) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2015, 34 (6): 38-44.
- [5] 王晓卫, 魏向向, 高杰, 等 (Wang Xiaowei, Wei Xiangxiang, Gao Jie, et al.). 基于EEMD与SVM的配电网故障选线方法 (A novel fault line selection method based on EEMD-Hilbert and SVM for distribution network) [J]. 电力系统及其自动化学报 (Proceedings of the CSU-EPSCA), 2014, 26 (12): 55-61.
- [6] 庞清乐, 孙同景, 孙波, 等 (Pang Qingle, Sun Tongjing, Sun Bo, et al.). 基于蚁群算法的神经网络配电网故障选线方法 (Ant colony algorithm and neural network based fault line detection method for distribution network) [J]. 继电器 (Relay), 2007, (16): 1-6.
- [7] 陈奎, 韦晓广, 陈景波, 等 (Chen Kui, Wei Xiaoguang, Chen Jingbo, et al.). 基于样本数据处理和ADABOOST的小电流接地故障选线 (Fault line detection using sampled data processing and ADABOOST for small current grounding system) [J]. 中国电机工程学报 (Proceedings of the CSEE), 2014, 34 (34): 6228-6237.
- [8] 曾晓丹, 陈永往, 郭谋发, 等 (Zeng Xiaodan, Chen Yongwang, Guo Moufa, et al.). 基于Adaboost的配电网单相接地故障选线 (Adaboost-based single-phase-to-ground fault detection in distribution systems) [J]. 电气技术 (Electrical Engineering), 2018, 19 (3): 70-75.
- [9] Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62: 531-544.
- [10] 赵寿生, 汪卫国, 王丰华, 等 (Zhao Shousheng, Wang Weiguo, Wang Fenghua, et al.). 基于统计特征与EMD算法的有载分接开关振动信号去噪 (Denoising method of vibration signal of on-load tap changer based on statistical feature and EMD algorithm) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2020, 39 (1): 51-58.
- [11] 李文武, 石强, 王凯, 等 (Li Wenwu, Shi Qiang, Wang Kai, et al.). 基于变分模态分解和深度门控网络的径流预测 (Runoff prediction based on variational mode decomposition and deep gated network) [J]. 水力发电学报 (Journal of Hydroelectric Engineering), 2020, 39 (3): 34-44.
- [12] 卫永琴, 鞠凯, 王潇龙, 等 (Wei Yongqin, Ju Kai, Wang Xiaolong, et al.). 变分模态分解在小电流接地系统故障选线中的应用 (Application of variational mode decomposition in fault line selection for small-current grounding system) [J]. 电力系统及其自动化学报 (Proceedings of the CSU-EPSCA), 2019, 31 (11): 31-38.
- [13] 陆继翔, 张琪培, 杨志宏, 等 (Lu Jixiang, Zhang Qi-pei, Yang Zhihong, et al.). 基于CNN-LSTM混合神经网络模型的短期负荷预测方法 (Short-term load forecasting method based on CNN-LSTM hybrid neural network model) [J]. 电力系统自动化 (Automation of Electric Power Systems), 2019, 43 (8): 131-137.
- [14] 张宇帆, 艾芊, 林琳, 等 (Zhang Yufan, Ai Qian, Lin Lin, et al.). 基于深度长短期记忆网络的区域级超短期负荷预测方法 (A very short-term load forecasting method based on deep LSTM RNN at zone level) [J]. 电网技术 (Power System Technology), 2019, 43 (6): 1884-1892.
- [15] 朱乔木, 李弘毅, 王子琪, 等 (Zhu Qiaomu, Li Hongyi, Wang Ziqi, et al.). 基于长短期记忆网络的风电场发电功率超短期预测 (Short-term wind power forecasting based on LSTM) [J]. 电网技术 (Power System Technology), 2017, 41 (12): 3797-3802.

- [16] 雷杰宇 (Lei Jieyu). 基于判据重要度的小电流接地系统单相接地故障选线方法 (Single-phase grounding fault line selection method for small current grounding system based on multi-criteria importance) [D]. 成都: 西南交通大学 (Chengdu: Southwest Jiaotong University), 2019.
- [17] 庞清乐, 孙同景, 钟麦英, 等 (Pang Qingle, Sun Tongjing, Zhong Maiying, et al.). 基于粗集理论的小电流接地系统故障选线 (Fault line detection based on rough set theory in indirectly grounding power system) [J]. 中国电机工程学报 (Proceedings of the CSEE), 2007, 27 (4): 60-64.

## Fault line selection method of small current grounding system based on VMD-LSTM

ZHAI Er-jie, SHU Zheng-yu, WANG Jun, HUANG Zhi-peng

(College of Electrical Engineering and New Energy, China Three Gorges University,  
Yichang 443000, China)

**Abstract:** The paper proposes a fault line selection method based on VMD-LSTM. In this paper, the zero-sequence current of each line is decomposed into high, medium and low frequency components characterizing its characteristics by VMD algorithm, the energy value of each component is calculated by time, and then input into the LSTM neural network in turn by establishing the relationship between the characteristics of the energy changes of each component and the fault line to realize fault line selection. The simulation results show that the method is not affected by factors such as the initial phase angle, the grounding resistance and the distance of the fault, and it can still achieve good line selection effect when there is noise interference, asynchronous sampling and low sampling frequency.

**Key words:** small current grounding system; fault line selection; variational modal decomposition; long short-term memory neural network