

基于改进堆叠去噪自编码的接地故障选线方法

常宛露¹ 许刚¹ 张丙旭¹ 郑伟彦² 俞腾飞²

¹(华北电力大学电气与电子工程学院 北京 102206)

²(国网浙江省电力公司杭州供电公司 浙江 杭州 310000)

摘要 针对小电流接地系统单相接地故障时受噪声干扰、故障类型和数据样本数量等影响造成选线精度低的问题,提出一种基于改进堆叠去噪自编码的选线方法。根据故障零序电流分布特征,提出信号-图像转换的预处理方法以在无须预定义参数的情况下提取原始故障信号的二维特征;通过常数项惩罚样本之间度量距离并作为正则化项限制目标函数的方法改进堆叠去噪自编码网络,提高模型特征学习性能并减少模型训练所需样本数量;通过改进模型实现故障特征自动提取与选线。仿真实验验证了该方法在不同单相接地故障条件下的有效性,并且选线精度高于传统的深度学习方法。

关键词 单相接地故障 信号-图像转换 度量距离 堆叠去噪自编码

中图分类号 TP301.6 **文献标志码** A **DOI**:10.3969/j.issn.1000-386x.2020.07.008

PHASE-TO-GROUND FAULT LINE SELECTION METHOD BASED ON IMPROVED STACKED DENOISING AUTOMATIC ENCODER

Chang Wanlu¹ Xu Gang¹ Zhang Bingxu¹ Zheng Weiyan² Yu Tengfei²

¹(School of Electrical and Electronic Engineering, North China Electric Power University, Beijing 102206, China)

²(State Grid Zhejiang Electric Power Company Hangzhou Power Supply Company, Hangzhou 310000, Zhejiang, China)

Abstract Aiming at the problem of low accuracy of line detection caused by noise interference, fault type and data sample number when single-phase-to-ground fault occurs in small current grounding system, we propose a method of line selection based on improved stacked denoising automatic encoder. According to the characteristics of zero-sequence current distribution, a signal-image conversion pretreatment method was proposed to extract the two-dimensional characteristics of the original fault signal without predefined parameters; we improved the stacked denoising automatic encoder network by using the constant term to punish the metric distance between samples and as a regularization term to limit the objective function, which improved the learning performance of model features and reduced the number of samples required for model training; the improved model was used to realize automatic fault feature extraction and line selection. The simulation results verify the effectiveness of our method under different single-phase-to-ground fault conditions, and the accuracy of line detection is higher than that of the traditional deep learning method.

Keywords Single-phase-to-ground fault Signal-image conversion Metric distance Stacked denoising automatic encoder

0 引言

基于新一代配电自动化系统的单相接地故障智能

选线、定位和快速隔离是实现配电网可靠运行的关键技术,也是目前广大学者的研究热点。单相接地故障作为配电网发生频率最高的故障之一,选线准确性和可靠性在很大程度上影响了配电网的供电恢复能力。

目前,我国中低压配电网主要采用小电流接地系统,该系统单相接地故障选线主要包括基于稳态分量^[1]、基于暂态分量^[2-4]和基于信息融合^[5-6]的方法。随着智能故障诊断技术的深入研究,基于信息融合以及数据驱动的电网故障智能诊断方法,例如 SVM^[5]、ANN 和 Adaboost^[6]等逐渐得到了广大研究者的青睐。小电流接地系统单相接地故障选线主要包括故障特征提取和选线两个步骤,目前研究的主要方向是利用小波变换、HHT、时频波形分析和稀疏表示等信号处理技术提取特征,再通过合适的分类器进行选线^[5-7]。虽然传统的智能方法已经被研究用于小电流接地系统故障选线,但存在许多缺点:选线性能往往取决于提取的特征,而人为提取特征主要依靠专家经验;信息融合方法需要大量的样本进行前期训练,但样本数据的大量获取比较困难;选线方法无法适应不同的中性点接地系统,且选线结果容易受到外界的干扰,鲁棒性不高。

随着机器学习的发展,深度学习以其独特的优势克服了传统算法的不足,可以自动从原始数据学习深层特征,而不依赖于信号处理技术。目前,深度学习算法已经在涉及大规模数据的问题中获得了较好的结果,例如变压器故障诊断和风电功率预测等。常用的深度网络包括深度置信网络(DBN)、去噪自动编码网络(DAE)和卷积神经网络(CNN)等。DAE是一种经典的无监督特征学习模型,所需训练样本数量较少并能够处理受损数据,在解决 VSC-HVDC 故障定位^[8]、电力设备检测^[9]和配电过电压特征提取^[10]等问题方面均体现出较好学习能力,因此本文基于基础 DAE 模型解决小样本情况下单相接地故障选线问题。

基于上述深度学习方法,提出一种基于改进堆叠去噪自编码(SDAE)识别故障线路的方法。针对样本数据处理,提出零序电流转换为二维图像的预处理方法,即在无预定义参数的情况下提取原始数据二维特征;针对单相接地故障样本量的问题,提出度量距离限制目标函数的方法改进 SDAE,借助 Softmax 实现接地故障选线。仿真实验表明,本文方法具有较好的适用性和较高的选线精度,尤其适用于不同中性点接地系统、高阻接地故障和间歇性电弧接地故障等。

1 故障信号预处理及选线判据

1.1 单相接地故障零序电流

当小电流接地系统发生单相接地故障时,无论是

中性点不接地系统还是经消弧线圈接地系统,各馈线均会产生零序电流:非故障线路零序电流大小等于线路三相对地电容电流之和,方向由母线流向线路;而故障线路零序电流则与中性点接地方式相关。中性点不接地方式的零序电流分布情况参考文献[11],本文以谐振接地系统为例,图1为单相接地故障简化图,其中 L_n 为消弧线圈, $C_{0i}(i=1,2,\dots,N)$ 为线路对地电容, R_f 为故障电阻, u_f 为故障处等效电压。

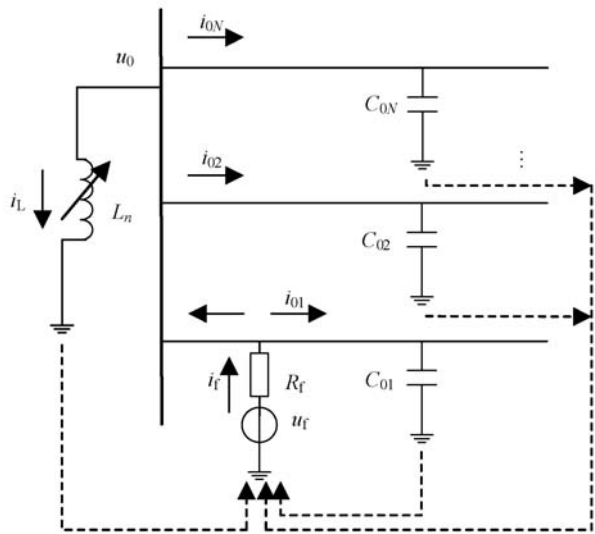


图1 单相接地故障简化图

假设第1条线路的A相发生单相接地故障,暂态接地电流^[12]由暂态电容电流 i_c 和暂态电感电流 i_L 组成,分别表示为:

$$i_c = I_C [(\omega_f / \omega \sin \varphi \sin \omega_f t - \cos \varphi \cos \omega_f t) e^{-\frac{t}{\tau_C}} + \cos(\omega t + \varphi)] \quad (1)$$

$$i_L = I_L [\cos \varphi e^{-\frac{t}{\tau_L}} - \cos(\omega t + \varphi)] \quad (2)$$

式中: I_C 和 I_L 为暂态电容和电感电流幅值; ω 和 ω_f 为工频和自由振荡角频率; φ 为相电压初始相位。

图2和图3分别为高阻故障和间歇性电弧故障条件下零序电流波形,假设共5条出线,线路故障时设为馈线1故障,并且设置A相发生接地故障,中性点为经消弧线圈接地和不接地方式。由图可知:高阻故障时,零序电流幅值比传统接地故障时小得多,这增加了选线难度;间歇电弧接地时波形会呈现周期性和休零点。零序电流的暂态分量较稳态分量大多,但持续时间较短。因此,小电流接地系统中接地故障时故障信号含有丰富的暂态信息,零序暂态分量不仅大于稳态分量,而且故障线路与非故障线路在故障后1/2到1个周期内幅值相差较大,且方向相反。因此,本文基于接地故障零序电流的原始故障信息实现选线。




图 2 高阻接地故障, $\theta = 30^\circ$, $R_f = 1\ 000\ \Omega$, 不接地系统




图 3 间歇性电弧故障, $\theta = 90^\circ$, $R_f = 5\ \Omega$, 谐振接地系统

1.2 零序电流预处理

假设配电网存在 m 条出线, 对各馈线故障后 $1/4$ 周期零序电流进行采样, 采样点数为 n 。如图 4 所示, 将时域原始信号各点采样值按顺序作为图像的像素值, 采用式(3)对像素矩阵进行归一化:

$$P(i, j) = \frac{A(i, j) - \min(A)}{\max(A) - \min(A)} \times 255 \quad (3)$$

式中: $A(i, j)$ 代表第 i 条馈线第 j 个采样点, i 的取值范围为 $i = 1, 2, \dots, m$, j 的取值范围为 $j = 1, 2, \dots, n$ 。

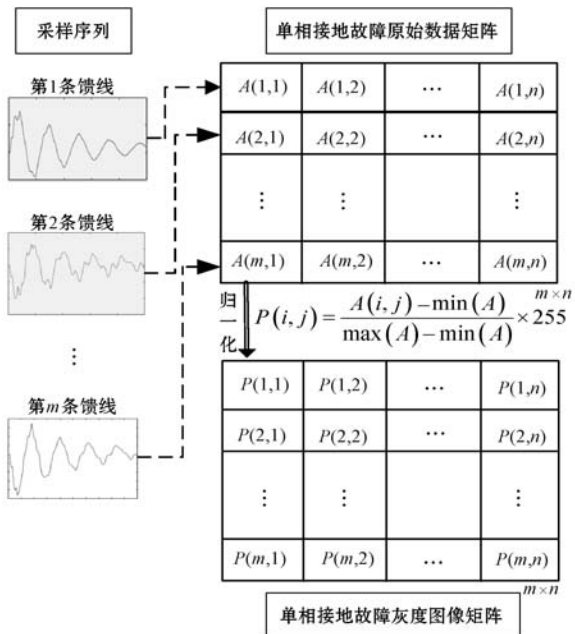


图 4 各馈线时域零序信号与图像表示的转换方法

1.3 选线判据

以图 2 高阻接地故障为例, 表 1 给出采用上述零序电流预处理方法将故障时各馈线时域原始信号转换为图像。由于该方法利用归一化将不同配电网电压等级下、不同中性点接地方式以及不同接地电阻的单相接地故障零序电流幅值等效为 $0 \sim 255$ 之间, 不仅避免了不同故障条件下零序电流幅值的差异, 还扩大了本文选线方法的适用范围。

表 1 不同馈线故障的图像表示

故障线路	类别	图像表示
母线	0	
Line 1	1	
Line 2	2	
Line 3	3	
Line 4	4	
Line 5	5	

2 改进堆叠去噪自编码

2.1 堆叠去噪自编码

自编码网络(AE)是一种无监督学习算法, 例如正则化自编码、收缩自编码和 DAE。DAE 的功能是学习叠加噪声的数据以实现对原始数据的预测, 学习的特征较 AE 更具鲁棒性。DAE 重构误差为 $L(x, g(f(\tilde{x})))$, 其中 \tilde{x} 为受损数据样本, 并通过条件分布 $C(\tilde{x} | x)$ 实现。由于 DAE 属于浅层结构, 仅通过一层隐藏层学习含噪声样本故障特征存在一定困难, 因此堆叠构建多层 DAE 网络, 即 SDAE 网络, 如图 5 所示。




图 5 SDAE 网络

虽然传统 SDAE 可用于提取深层特征,但用于单相接地故障选线问题仍存在许多难点:

(1) 小电流接地系统单相接地故障类型多种多样,存在金属接地故障、间歇性电弧接地故障、高阻接地故障等,中性点接地也存在多种方式,所以单相接地故障样本之间存在类内多样性和类间相似性问题,造成传统 SDAE 网络故障选线精度不高;

(2) 目前用于单相接地故障选线的数据样本并不像 MNIST 和 CIFAR-10 等数据集存在大量训练样本,传统 SDAE 网络在训练样本不足时学习表现不理想。

2.2 基于度量距离改进堆叠去噪自编码

针对上述问题,通过度量学习限制目标函数的方法改进 SDAE 网络,即利用常数项惩罚数据样本对之间的度量距离,并将其作为正则化项限制目标函数以克服故障样本多样性的难点,同时提高接地故障选线精度以及模型收敛速度,使其适用于小样本情况。

度量学习是在保持期望距离结构的数据对之间找到适当的相似性度量,其中度量学习包括对比嵌入^[13]和三元组嵌入,样本表示之间可用欧几里得距离来测量。其中,对于任意样本 x_i 和 x_j ,平方欧式距离可以表示为:

$$d^2(x_i, x_j) = \|f(x_i) - f(x_j)\|_2^2 \quad (4)$$

式中: $f(x)$ 为样本 x 提取特征; $\|\cdot\|_2$ 为 L_2 范数。

针对训练数据样本对 (x_i, x_j) ,对比嵌入的目标函数为:

$$J = \sum_{i,j} \zeta_{ij} d^2(x_i, x_j) + (1 - \zeta_{ij}) h(\delta - d(x_i, x_j))^2 \quad (5)$$

式中: ζ_{ij} 代表样本对 (x_i, x_j) 是否属于同一类别的样本,并且 $\zeta_{ij} \in \{0, 1\}$; $h(x) = \max(0, x)$ 为交叉损失函数; δ 为常数,用于惩罚功能。

设 $X = \{x_i \mid i = 1, 2, \dots, N\}$ 为一组训练样本集, N 为样本总数, $H_m(x_i)$ 为第 i 个训练样本通过第 m 个 AE 特征映射的输出, $I_m(x_i)$ 为对应的输入且 $I_m(x_i) = H_{m-1}(x_i)$, $I_m(x_i)$ 重构后可表示为 $R_m(x_i)$, $H_m(x_i)$ 和 $R_m(x_i)$ 可表示为:

$$H_m(x_i) = S_f(W_m H_{m-1}(x_i) + B_m) \quad (6)$$

$$R_m(x_i) = S_g(W'_m H_m(x_i) + B'_m) \quad (7)$$

式中: $\theta = \{W_m, B_m, W'_m, B'_m\}$ 为神经网络结构参数, $S_f(\cdot)$ 和 $S_g(\cdot)$ 为激活函数。

定义 SDAE 模型的目标函数包括重构误差项和度量距离正则化项:

$$J = \min(J_1 + \lambda J_2) \quad (8)$$

式(8)的第一项为重构误差项,旨在最小化输入数据与重建数据之间的误差,其中 J_1 为:

$$J_1 = \sum_{i=1}^N \|I_m(x_i) - R_m(x_i)\|_2^2 = \sum_{i=1}^N \|I_m(x_i) - S_g(S_f(I_m(x_i)))\|_2^2 \quad (9)$$

式(8)的第二项为度量距离限制目标函数的正则化项,旨在限制类内及类间距离。参考文献[13-14],定义正则化项 J_2 为:

$$J_2 = \sum_{i=1}^N \sum_{j=1}^N (\tau_1 + \tau_2 \|\tilde{H}_m(x_i) - \tilde{H}_m(x_j)\|_2^2) \quad (10)$$

$$\tilde{H}_m(x_i) = \frac{S_f(W_m I_m(x_i) + B_m)}{\|S_f(W_m I_m(x_i) + B_m)\|_2} \quad (11)$$

$$\tau_1 = \begin{cases} 0 & y_i = y_j \\ \alpha & y_i \neq y_j \end{cases} \quad (12)$$

$$\tau_2 = \begin{cases} 1 & y_i = y_j \\ -1 & y_i \neq y_j \end{cases} \quad (13)$$

式中:参数 τ_1, τ_2 用于度量距离限制; α 为大于零的常数; y_i 和 y_j 分别为样本 x_i 和 x_j 的标签。

深层网络比较复杂,与浅层机器学习算法相比更容易产生过拟合。从单相接地故障样本数据方面分析:故障信号并非纯净数据,存在各种干扰和噪声,而过拟合则是将异常数据当成正常数据学习的结果。因此,采用 Dropout 技术降低异常数据学习特征的机会,提高模型泛化能力,同时采用 Adam 算法最小化目标函数以更新权值。改进 SDAE 网络结构如图 6 所示。

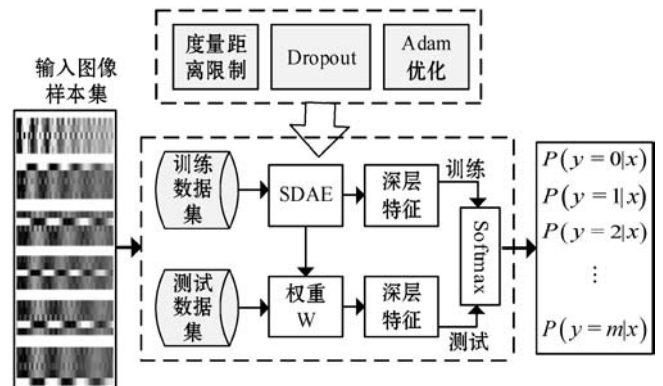


图6 基于度量距离限制的 SDAE 网络结构

3 基于改进 SDAE 的故障选线模型

基于改进 SDAE 网络的故障选线方法如图 7 所示。

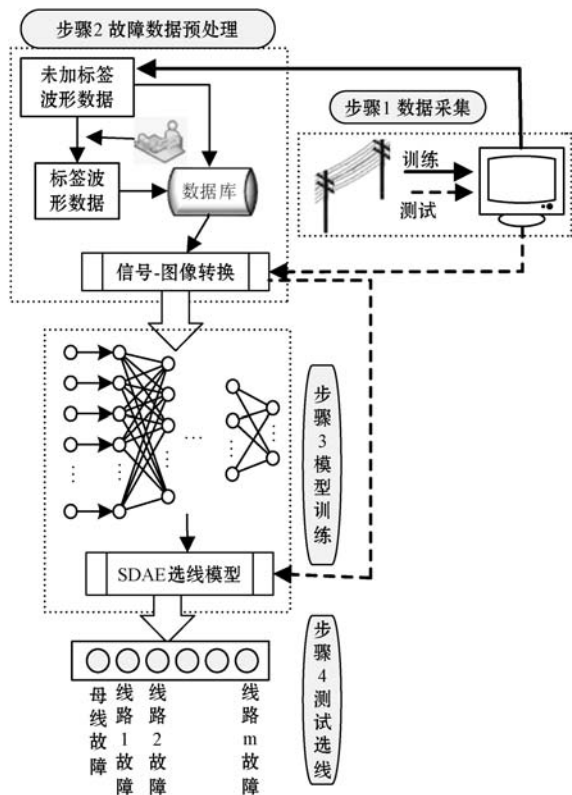


图7 基于改进 SDAE 网络的单相接地故障选线模型具体实现步骤如下:

步骤1 数据采集。建立单相接地故障仿真模型,通过修改参数采集到不同情况下单相接地故障零序电流,如故障电阻、初始相位角、接地方式、故障类型等参数。

步骤2 数据预处理。对采集的数据集利用 1.2 节的方法进行预处理,将各馈线零序电流的时域原始信号转换为灰度图像。

步骤3 模型训练。将预处理后的数据集按比例随机划分为训练样本集和测试样本集;设置改进 SDAE 网络的隐藏层神经元个数、隐藏层数和激活函数等相关超参数;添加度量距离限制的正则化项约束目标函数以提高 SDAE 网络特征学习能力,同时引入 Dropout、Adam 优化算法训练和微调选线模型。

步骤4 模型测试。将测试样本集输入至训练好的改进 SDAE 模型提取深层特征,并通过 Softmax 实现小电流接地系统单相接地故障选线,其中分类器的神经元个数为单相接地故障线路类别数,本文所有仿真均设置 5 条出线,共分为 6 类,即母线故障、线路 1~线路 5 故障。

4 仿真验证及适应性分析

4.1 单相接地故障仿真模型

图 8 为基于 MATLAB 建立的 66/10 kV 小电流接

地系统接地故障模型示意图,以架空线路为例,负载采用三相串联 RLC 负载,通过开关设置多种中性点接地方式:开关断开时为不接地方式,开关闭合时为经消弧线圈接地方式,补偿方式设为过补偿,补偿度取 8%。




图8 系统简化模型

4.2 构建接地故障样本集及评估指标

利用仿真模型构建小电流接地系统单相接地故障数据集,如表 2 所示。通过修改接地电阻、初始相位角、中性点接地方式等方式得到不同故障条件下的故障类型样本,并改变不同线路故障以确保数据样本的平衡性,其中故障位置分别设在线路总长的 10%、30%、50%、80% 处。由表可知:数据集包含 1 500 个样本集,每个样本集包含 1 个故障馈线样本和 4 个健全馈线样本。 L_0 代表母线故障; θ 代表故障初始相位角,分别取 0° 、 30° 、 60° 和 90° ; R_f 代表接地电阻;故障相为 A。由于单相接地故障持续时间一般为 0.2 s 左右,频率可达 300~3 000 Hz,因此仿真时间设置为 0.2 s,样本采样频率为 10 kHz,并将样本集按比例 0.8:0.2 随机划分为训练集和测试集。

表 2 单相接地故障样本集

数据集	故障线路	R_f/Ω	样本集	样本数
不同接地方式	0-5	5~1 000	300	1 500
传统低阻故障	0-5	5~100	300	1 500
高阻故障	0-5	500~5 000	300	1 500
间歇电弧故障	0-5	5~1 000	300	1 500
噪声干扰故障	0-5	5~1 000	300	1 500
总数			1 500	7 500

为验证所提选线方法的精确度,定义平均选线准确率和混淆矩阵作为选线评估方法。混淆矩阵主要用于分析不同类别之间的分类错误和混淆的信息表,是通过计算测试图像的每一类正确和不正确的分类并将结果累积在表中来获得的。平均选线准确率可定义为:

$$\bar{P} = \frac{1}{L+1} \sum_{i=0}^L \frac{M_i}{N_i} \quad (14)$$

式中: $i=0,1,\dots,L$ 代表不同线路, N_i 和 M_i 分别代表第 i 条线路故障时的测试样本数和正确识别处该线路故障的样本数。

4.3 实验参数设置

实验使用机器学习的 TensorFlow 框架,选择 Python3 作为编程语言,硬件实验环境是具有 Inter Core i7-7700 四核处理器的个人计算机。

改进 SDAE 算法的参数配置对于单相接地故障选线精度有很大的影响,包括学习率、各层神经单元数、激活函数等参数。由于输入图像大小为 5×100 ,类别为 6,故输入输出分别设置为 500 和 6,而隐藏层层数及各层单元数的确定参考 BP 神经网络的节点数设置的经验公式,具体参数及训练超参数设置如表 3 所示,其中度量距离限制的正则化参数 λ 设为 0.01, α 设为 1。此外,为了提高模型的泛化性能,采用 DAE 隐藏层代替原模型中的 F_c 层^[8]。

表 3 改进 SDAE 网络结构相关参数设置

编号	网络层	单元个数	学习率	迭代次数	激活函数	成本函数
1	输入层	500				
2	隐藏层	256	0.005	70	Sigmoid	$J = \min(J_1 + \lambda J_2)$
3	隐藏层	128	0.005	70	Sigmoid	$J = \min(J_1 + \lambda J_2)$
4	隐藏层	64	0.001	70	Sigmoid	$J = \min(J_1 + \lambda J_2)$
5	输出层	6	0.001	70	Sigmoid	$J = \min(J_1 + \lambda J_2)$
6	Softmax	6	0.001	70	Sigmoid	Softmax 交叉熵

为验证所提选线方法的性能,将传统 SDAE 网络用于故障选线作为比较,其参数设置与改进 SDAE 模型类似,但目标函数仅采用式(8)的重构误差项 J_1 。

4.4 仿真结果

图 9 为测试样本的选线结果,可知模型存在将线路 3 故障误认为线路 2 故障的情况,但总体选线准确率达到 99% 以上。表 4 为小电流接地系统单相接地故障选线结果,其中测试选线准确率和耗时均为 10 次随机试验的平均值。可以看出:本文方法增加了损失函数的限制,在模型训练时间上略逊于标准 SDAE 算法,但耗时相差不大,其选线准确率更高。

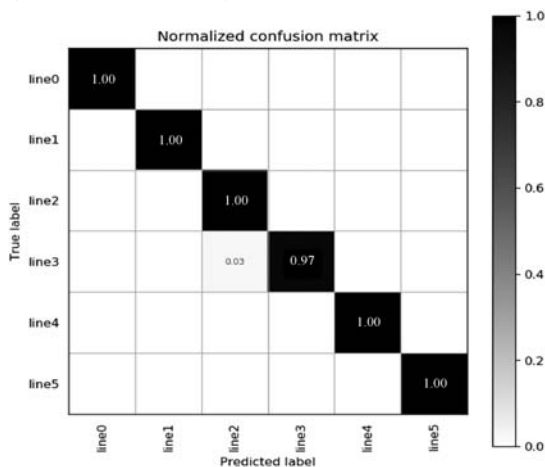


图 9 混淆矩阵

表 4 两种算法实验结果对比

算法	训练样本	训练耗时 /s	测试样本	测试耗时 /s	测试选线准确率
改进 SDAE	1 200	35.059 558	300	0.108 844	0.999 8
标准 SDAE	1 200	34.956 429	300	0.107 643	0.967 2

为了进一步验证所提方法在解决单相接地故障选线问题上的优势,如图 10 所示为本文所提算法与传统 SDAE 算法的选线准确率和迭代次数的关系曲线,可以看出:虽然选线精度均随着迭代次数的增加而逐渐提高,但未改进的 SDAE 算法却存在明显的振荡趋势,这表明本文方法与标准 SDAE 算法相比,模型更易训练。




图 10 两种算法选线准确率与迭代次数的关系曲线

为了测试所提方法针对小样本问题的可行性,划分不同比例的训练数据进行实验,即选用 5%、10%、20%、30%、40%、60% 和 80% 的样本用于训练,其余样本用于测试,统计结果如图 11 所示。可以看出:30% 以下的数据样本训练 SDAE 模型,其测试精度显著降低,而改进的 SDAE 模型测试精度仍较为理想。因此,本文方法不仅提高了单相接地故障的选线精度,而且在训练样本数量较少时仍能训练出具有较高选线精度的模型,即稳定性比传统神经网络好。




图 11 不同训练样本比例实验结果对比

4.5 适应性分析

小电流接地系统单相接地故障选线方法在工程应用中应考虑噪声干扰、变压器反接以及消弧线圈补偿等各种随机情况的影响。

4.5.1 噪声干扰的影响

对于随机噪声干扰情况,在仿真模型不同故障状态下分别添加5、10、15和20 dB的高斯白噪声获得测试样本270组,并对训练好的选线模型进行测试,结果如表5所示,表明在随机噪声情况下,本文方法仍具有较高的选线精度。

表5 噪声干扰的单相接地故障选线结果

线路	测试样本	$\theta/(^\circ)$	R_f/Ω	噪声/dB	准确率
Line 0	45				1.000 0
Line 1	45	0		5	1.000 0
Line 2	45	30	5 ~	10	1.000 0
Line 3	45	45	1 000	15	0.978 0
Line 4	45	90		20	1.000 0
Line 5	45				1.000 0
平均选线准确率					0.996 3

4.5.2 互感器反接的影响

电流互感器在实际使用中,励磁电流的存在会使得零序电流的相位存在一定的角度差。此外,人为因素可能会导致故障馈线的零序电流互感器的安装方向或现场接线方向相反,使故障馈线零序电流极性与健全馈线的极性一致。当互感器存在反接情况时,一些基于零序电流极性实现单相接地故障选过去线的方法会失效。通过反接互感器进行仿真,获得测试样本240组,并对选线模型进行测试,结果如表6所示,可以看出该方法在互感器反向时仍能正确选出故障线路。

表6 互感器反接情况的单相接地故障选线结果

线路	测试样本	$\theta/(^\circ)$	互感器	R_f/Ω	准确率
Line 0	40				0.975 0
Line 1	40	0			1.000 0
Line 2	40	30	反接	5 ~	0.975 0
Line 3	40	45		1 000	1.000 0
Line 4	40	90			1.000 0
Line 5	40				1.000 0
平均选线准确率					0.991 7

4.5.3 消弧线圈补偿作用的影响

小电流接地系统单相接地时产生的零序电流大小与系统的规模和线路类型等参数有关。对于谐振接地

系统,经消弧线圈的补偿后,补偿作用会使得故障线路的零序电流进一步减小,对故障选线造成一定的影响。模拟仿真消弧线圈完全补偿、过补偿度以及欠补偿下的测试样本300组,结果如表7所示,表明本文方法对谐振系统在不同补偿度的情况下同样适用。

表7 消弧线圈不同补偿情况下选线结果

线路	测试样本	$\theta/(^\circ)$	R_f/Ω	消弧线圈补偿度	准确率
Line 0	50				1.000 0
Line 1	50	0		完全补偿	1.000 0
Line 2	50	30	5 ~	欠补偿5%,8%,10%	1.000 0
Line 3	50	45	1 000	过补偿5%,8%,10%	1.000 0
Line 4	50	90			0.980 0
Line 5	50				1.000 0
平均选线准确率					0.996 7

5 结语

基于度量距离限制目标函数改进SDAE网络,并构造接地故障各馈线零序电流图像表示作为模型输入,选线结果作为输出。针对不同单相接地故障条件的仿真结果表明:

- (1) 基于单相接地故障零序电流的预处理方法提供了一种探索原始信号二维特征的方法,同时简化了单相接地故障选线问题;
- (2) 通过度量距离限制目标函数的方法改进SDAE网络的选线方法,无论从单相接地故障选线精度还是适用性方面,都较传统方法取得了更好的效果,并减少了模型训练所需样本数量。

为了提高本文方法在数据不平衡情况下的鲁棒性,将借鉴迁移学习的思想进一步提高单相接地故障选线精度。

参考文献

- [1] 梁睿,辛健,王崇林,等.应用改进型有功分量法的小电流接地选线[J].高电压技术,2010,36(2):375-379.
- [2] 付华,孟繁东.基于VMD双狼群算法的电网单相接地故障选线优化[J].计算机应用与软件,2019,36(2):269-273.
- [3] 束洪春,龚振,田鑫萃,等.基于故障特征频带及形态谱的单相接地故障选线[J].电网技术,2019(3):1041-1048.
- [4] 薛永端,李娟,陈筱霁,等.谐振接地系统高阻接地故障暂态选线与过渡电阻辨识[J].中国电机工程学报,2017(17):5037-5048.

如表 3 所示。

表 3 性能比较

SVM 参数方法	训练 MSE	测试 MSE
GSA	0.022 1	0.243
改进 GSA	0.015 9	0.128

结果表明,基于自适应的 GSA 优化 SVM 参数产生了较高的精度和较强的泛化能力。

两种方法对公安巡防警情信息的分类效果比较如图 4 所示。




图 4 两种方法比较 SVM 分类的效果

可以看出,本文所用的 SVM 参数优化方法无论是在准确率、查全率及综合评价指标 F1 方面,都优于传统 GSA 算法,采用基于自适应 GSA 的 SVM 方法可以得到更优的 SVM 参数。

5 结 语

本文在传统 GSA 的基础上,提出一种自适应的引力搜索算法。该算法避免了传统 GSA 易于得到局部最优解的缺点,用改进的 GSA 优化 SVM 参数,参数优化结果的精度有所提高。将研究的方法应用于实际的公安巡防警情自动分类中,实验结果表明,本文提出的改进方法是合理、有效的。

参 考 文 献

[1] 贝雨馨,崔荣一. 文本分类中特征项权重的计算方法[J]. 延边大学学报(自然科学版),2004,30(3):202-204.

[2] Coelho F, Braga A P, Verleysen M. A mutual information estimator for continuous and discrete variables applied to feature selection and classification problems[J]. International Journal of Computational Intelligence Systems, 2016, 9(4): 726-733.

[3] Rashedi E, Nezamabadi-Pour H, Saryazdi S. GSA: A gravitational search algorithm[J]. Intelligent Information Management, 2012, 4(6): 390-395.

[4] 王蕾,潘丰. 改进多样性和局部优化能力的引力搜索算法

[J]. 计算机工程,2014,40(8):173-178.

[5] 马占飞,陈虎年,杨晋,等. 一种基于 IPSOSVM 算法的网络入侵检测方法[J]. 计算机科学,2018,45(2):231-235,260.

[6] 敖媛,丁学明. 基于自适应引力搜索算法的 T-S 模型辨识[J]. 系统仿真学报,2017,29(3):487-493.

[7] 牛琳. 基于 SVM 的公安情报自动分类系统的设计与实现[D]. 郑州:中国人民解放军信息工程大学,2007.

[8] 杨晋,金溢,马占飞. 基于 IQPSO 算法的网络入侵检测研究[J]. 内蒙古科技大学学报,2018,37(1):96-102.

[9] 董新燕,丁学明,王健. 基于改进的引力搜索算法的 T-S 模型辨识[J]. 电子科技,2015,28(11):16-20.

[10] 陶俐言,杨海斌. 基于改进引力搜索算法的公差多目标优化设计[J]. 机械设计与研究,2017,33(2):133-137.

(上接第 55 页)

[5] 陈奎,陈博博. 基于改进暂态相关分析和支持向量机的电弧故障选线研究[J]. 电力系统保护与控制,2016,44(24):66-73.

[6] 陈奎,韦晓广,陈景波,等. 基于样本数据处理和 ADA-BOOST 的小电流接地故障选线[J]. 中国电机工程学报,2014(34):6228-6237.

[7] Guo M F, Zeng X D, Chen D Y, et al. Deep-learning-based earth fault detection using continuous wavelet transform and convolutional neural network in resonant grounding distribution systems[J]. IEEE Sensors Journal, 2018, 18(3): 1291-1300.

[8] Luo G M, Yao C Y, Liu Y L, et al. Stacked auto-encoder based fault location in VSC-HVDC[J]. IEEE Access, 2018, 6: 33216-33224.

[9] Dai J J, Song H, Sheng G H, et al. Cleaning method for status monitoring data of power equipment based on stacked denoising autoencoders[J]. IEEE Access, 2017, 5: 22863-22870.

[10] Chen K J, Hu J, He J L. A framework for automatically extracting overvoltage features based on sparse autoencoder[J]. IEEE Transactions on Smart Grid, 2018, 9(2):594-604.

[11] 葛眠俊. 基于脉冲神经膜系统的小电流单相接地故障选线[D]. 四川:西南交通大学,2018.

[12] 束洪春,黄海燕,田鑫萃,等. 采用形态学峰谷检测的谐振接地系统故障选线方法[J]. 电力系统自动化,2019,43(1):228-233.

[13] Cheng G, Yang C, Yao X, et al. When deep learning meets metric learning: remote sensing image scene classification via learning discriminative CNNs[J]. IEEE Transactions on Geoscience & Remote Sensing, 2018, 56(5): 2811-2821.

[14] Vincent P, Larochelle H, Bengio Y, et al. Extracting and composing robust features with denoising autoencoders[C]// 25th International Conference on Machine Learning, 2008: 1096-1103.