小电流接地系统单相接地故障选线空间域 图像生成及融合方法

程文傲,徐 明,高金峰 (郑州大学 电气工程学院,河南 郑州 450001)

摘要:为发挥深度学习算法特征自学习及其在图像处理领域的优势,避免当前小电流接地系统单相接地故障 选线中人工提取故障特征信息缺失的问题,提出了一种通过生成故障电流全信息空间域图像,再利用图像识 别与分类算法实现故障选线的方法。所提方法首先使用三相电流构建三维空间域图像,并分别在3个平面 上进行投影得到多幅投影图像,解决了获取二维图像的关键问题;然后对投影图像进行二次像素级图像融 合,得到了相应的RGB彩色图像,最后使用深度学习算法对图像进行识别与分类从而实现故障选线。将所 提方法与已有方法的故障选线结果进行对比,结果表明所提方法在多种因素影响下,均不损失故障信息,图 像故障特征更明显、分类准确率更高,且具有抗噪声能力,证明其用于小电流接地系统单相接地故障选线具 有可行性。

关键词:小电流接地系统;故障选线;空间域;图像融合;深度学习 中图分类号:TM 727 文献标志码:A

DOI:10.16081/j.epae.202105012

0 引言

随着配电网中电缆线路的不断增加,电力系统 对地电容电流不断增大,我国配电网大多为小电流 接地系统,其中经消弧线圈接地方式在中低压配电 系统中被广泛应用。单相接地故障是配电网故障的 主要形式,虽然经消弧线圈接地系统发生单相接地 故障时,三相线电压仍保持对称,可以短时维持向用 户供电,但是系统长时间带故障运行,可能引发电缆 起火及其他故障,严重影响电力系统的安全运行和 电能质量。单相接地故障的故障特征量很小,所以 其故障选线一直是国内外配电网继电保护的研究热 点¹¹。针对该问题,国内外研究学者已经提出了一 系列故障选线的方法:文献[2]利用小波变换提取各 线路的零序电流高频分量的幅值和相位作为选线依 据,该方法在高频暂态分量较小或故障初相角在0° 附近时可靠性较低;文献[3]依据自定义特征频段内 各线路的无功功率方向选出故障线路,该方法在故 障初相角为0°或发生高阻接地故障时选线效果欠 佳;文献[4]利用零序电流高频分量经过小波包变换 后的子频段、全频段的零序电流能量分别形成主、副 判据。上述方法大部分采用特定特征频带的信息量 作为选线依据,但是最能代表故障特征的频带是随 着故障类型、系统接线方式的不同而变化的[5-6],特 征频带的人工选择造成了大量有效信息的缺失。故 障线路零序电流与非故障线路零序电流之间的特征

收稿日期:2020-06-01;修回日期:2021-03-10 基金项目:国家自然科学基金资助项目(51307152) Project supported by the National Natural Science Foundation of China(51307152) 关系受到系统过补偿度、故障初相角等因素的影响, 直接通过零序电流进行故障选线可靠性不高。零序 电流是通过三相电流叠加计算而来的,通过大量仿 真数据可以发现,三相电流也包含可用于故障选线 的多种特征分量^[1,7]。

传统的机器学习方法应用于故障选线时均依赖 于人工提取特征量,且需要选择合适的分类器进行 分类,此过程带有极强的主观性,将直接影响故障选 线的准确性,另外此类方法的泛化能力较弱。如果 能够直接基于完整原始数据进行数据挖掘和深度学 习^[8],势必能够简化分类算法的设计难度,提高辨识 准确率。目前,深度学习算法在图像识别和图像分 类方面的表现尤其优越^[9],将故障辨识问题转换为 图像处理问题逐渐成为一个研究趋势:在电机轴承 故障诊断领域,将振动信号转变为振动图像后使用 深度学习算法进行故障诊断后,准确率从传统方法 的80%提高到98%左右^[10-13];在电能质量扰动分类 领域,将一维电能质量扰动数据映射为二维灰度图 后使用深度学习算法进行分类,准确率提高到99% 左右,并且具有较强的抗干扰能力^[14-15]。

当前,人工智能技术也在配电网故障诊断方面 得到了广泛应用^[16-18]。根据各种不同工况下的小电 流接地系统单相接地故障在空间域图像上存在显著 的特征和差异,笔者认为将对应的故障选线问题转 变为图像问题处理,并应用深度学习算法中的卷积 神经网络 CNN(Convolutional Neural Network)进行 故障选线是一种新的尝试^[19-20],如何将三维电流信 号转化为二维图像是运用 CNN 的关键问题。如果 直接将同一种工况下各馈线的三相电流三维空间图 像进行投影,则1条馈线就可得到3幅图像,若直接 采用 CNN 进行学习,特别是对于馈线数目较多的配 电网,则图像数量过多,势必会导致 CNN 的网络层 数增加和网络参数成倍增加,使得网络训练时间和 难度大幅增加。因此,为了发挥 CNN 的最佳性能进 行小电流接地系统单相接地故障选线,需要提出一 种空间域图像生成及融合的方法将三相电流信号的 信息以图像的形式完整地表现出来。

本文结合理论分析和仿真建模的方法对小电流 接地系统发生单相接地故障后三相电流的空间域图 像融合方法进行研究,通过图像融合将同一种工况 下各馈线三相电流的三维投影融合成一幅完整保留 故障信息的RGB彩色图像。对引入电缆线路、不同 故障初相角、故障距离和接地点过渡电阻下的三相 电流时域波形和空间域融合图像进行对比,证明了 本文所提空间域图像融合方法能够明显表现出故障 特征。采用CNN对融合图像进行分类,结果证明分 类准确率得到了极大的提升,且具有较强的抗噪声 能力,验证了本文所提空间域图像生成及融合方法 的有效性。

1 图像生成原理

1.1 信号的3种展示方式

对于典型的中性点经消弧线圈接地系统,其所 有出线的每相电流作为系统的1个状态变量,包含 了系统的运行信息。显然,可以通过对所有相(线) 电流进行分析得到系统的运行情况。目前,对特定 系统的输出进行分析和展示的方式共有以下3种。

(1)时域示波方式。该方式是对信号进行分析 和展示的最原始方式。针对每个状态变量,利用横 轴、纵轴分别表示时间的演化方向、信号的幅值,可 以从波形上清晰地看到系统每个状态变量的演化情 况。目前所有小电流系统接地故障的时域分析方法 都是以状态信息的波形特征为依托开展,甚至一些 基于深度学习算法的故障诊断方法也是通过学习系 统状态波形的特征来实现故障分类与诊断。

(2)频域或变换域特征提取方式。该方式以频 率作为变量,可以深入信号的本质,看到信号的组成 部分,小电流接地系统发生单相接地故障后,通过快 速傅里叶变换得到故障电气量的频谱分布,根据不 同线路结构和运行方式选取特征频带,根据特征频 带内电流、电压幅值和相位等特征量进行故障选线。

(3)空间域展示方式。该方式以空间坐标作为 变量进行研究,也是一种重要的信号分析方法。小 电流接地系统正常运行时,三相电流对称,各相相电 流瞬时表达式为:

$$\begin{cases} i_{\rm A} = I_{\rm m} \sin\left(\omega_0 t + \varphi\right) \\ i_{\rm B} = I_{\rm m} \sin\left(\omega_0 t + \varphi - 120^\circ\right) \\ i_{\rm C} = I_{\rm m} \sin\left(\omega_0 t + \varphi + 120^\circ\right) \end{cases}$$
(1)

其中, i_{A} 、 i_{B} 、 i_{C} 为三相电流; I_{m} 为相电流峰值; ω_{0} 为工 频; φ 为故障初相角。

第41卷

三相电流信号具有较强的周期性,正常运行状态下,其各周期的图像在三维空间完全重合,表现为一个椭圆,如附录A图A1所示。将A、B、C相数据分别作为X、Y、Z轴数据,为了便于直观理解,将投影平面记为AOB、BOC和AOC平面。将图A1中的图形分别向AOB、BOC、AOC平面投影,相平面轨迹图是一个较平滑的椭圆形,吸引子呈环形(周期性)状态。

发生低阻接地故障时,由于过渡电阻较小,电容 充电速度快,此时消弧线圈等效阻抗远大于所有出 线对地分布电容之和的等效容抗,因此可以忽略消 弧线圈对故障暂态的影响,暂态过程主要由线路的 等效电感L和分布电容C之间的串联谐振构成,此 时由于消弧线圈几乎不起作用,三相故障相电流暂 态过程故障量较大,对应的相平面轨迹从光滑的椭 圆环表现为1个椭圆外围存在振荡扰动,椭圆代表 故障稳态过程,椭圆外振荡扰动代表故障暂态过程。 故障馈线的3个投影面中,含有故障相的投影面轨 迹存在明显的外围振荡,形态具有明显的区分度。 初相角以π为周期对暂态电流幅值有较大的影 响^[21]。故障暂态电流_i为:

$$i_{\rm f} = U_{\rm m}\omega_0 C \left[\frac{1/(LC)}{\omega_0\omega_{\rm f}} \sin\varphi\sin\left(\omega_{\rm f}t\right) + \frac{\delta}{\omega_{\rm f}}\cos\varphi\sin\left(\omega_{\rm f}t\right) - \cos\varphi\cos\left(\omega_{\rm f}t\right) \right] {\rm e}^{-\delta t} + U_{\rm m}\omega_0 C\cos\left(\omega_0 t + \varphi\right)$$
(2)

其中,U_m为系统相电压峰值;ω_f为主谐振频率;δ = *R*/(2*L*),为衰减因子,衰减因子受故障距离和故障电 阻的影响^[22]。当故障电阻一定时,若故障距离与单 位距离之比大于1,则衰减因子随故障距离的增加 而减小,反之随故障距离的增加而增大。当故障距 离一定时,衰减因子随接地点过渡电阻的增大而增 大。衰减因子反映暂态过程的持续时间,衰减因子 越小,衰减速度越慢。

发生高阻接地故障时,等效电阻 R 近似等于 3 倍的接地点过渡电阻 R_r。由于暂态谐振频率较低, 可以忽略等效电感 L,暂态过程主要由消弧线圈等 效电感 L_p和分布电容 C 之间的并联谐振构成,由于 消弧线圈的作用,三相故障相电流的暂态过程故障 量较小。此时可以忽略故障距离的影响,故障电流 幅值随故障电阻的增大而减小,衰减因子亦减小^[22]。 对应的相平面轨迹几乎表现为一个椭圆,故障馈线 3个投影面中含有故障相的投影面仍存在外围振 荡,但振荡幅值已非常小。

1.2 小电流接地故障空间域图像展示

结合实际运行情况,利用 MATLAB / Simulink

建立图1所示的典型110 kV / 10 kV 配电系统模型, 其包含1条纯电缆线路(馈线L₁)和3条架空线路(馈 线L₂—L₄),各段线路长度已在图中标出,线路阻抗 参数见附录A表A1。消弧线圈按10%过补偿整定 时,计算得出消弧线圈的等效电阻 R_p =29.94 Ω 、等效 电感 L_p =1.907 H。





在实际的中性点经消弧线圈接地系统中,一般 在故障发生5~6个周期后,暂态分量已经很小,可认 为电磁暂态过程基本结束^[23]。而传统的故障选线方 法为了简化特征处理过程,一般仅截取故障特征最 明显的故障前1个周期和故障后的2~4个周期的信 号进行处理。本文提取故障前1个周期和故障后9 个周期的信号进行处理,保证了电磁暂态过程完全 结束,从而可以完整地保留所有的故障信息,正常运 行状态下每个周期的信息完全重叠,有效减少了特 征信息的冗余,并且使得扰动特征的分布更加集中。 馈线 L₂距线路首端 3.6 km 处,发生故障初相角为 51.9°的金属性单相接地故障(故障相为A相)时,故 障馈线 L₂、健全馈线 L₃的三相电流时域波形和三维 空间图分别如图2、3所示。

由图2可见,发生单相接地故障时,故障馈线的 故障相电流幅值明显大于非故障相电流幅值,且两 者突变方向相反,将三相电流*i*_A、*i*_B、*i*_c分别作为*X*、*Y*、 *Z*轴数据绘制三维空间图,图形表现为椭圆外围存 在较大扰动。由图3可见,健全馈线的各相电流幅 值突变量较小且方向相同,三维空间图近似为椭圆。

将故障馈线L₂、健全馈线L₃的三相电流三维空间







健全馈线 L₂的三相电流



图像分别向AOB、BOC、AOC平面投影,投影结果分 别如附录B图B1、B2所示。由图B1可见,对于L₂, BOC投影平面中不含故障相电流,对应的图像几乎 为椭圆曲线;AOB、AOC投影平面均含有故障相A相 电流,且故障电流大,故障特征明显,椭圆外围振荡 幅度较大。由图B2可见,对于健全馈线L₃,3个投影 平面中的图像均为大小、位置几乎相同的椭圆曲线。

2 图像融合

2.1 加权平均融合算法

图像像素的显著性指像素亮度与图像平均亮度 之间的差异,其表达式为:

$$S_n(x, y) = I_n(x, y) - u_n \tag{3}$$

其中,x、y分别表示二维图像中的第x行、第y列; S_n(x,y)为图像像素的显著性;I_n(x,y)为图像像素 值;u_n为图像像素均值。图像的显著像素通常对应 着重要的特征信息,应该在融合图像中尽量保留。 而深度学习算法能够自动将注意力聚集在显著区 域,摒弃大量的无关信息。这与底层视觉特征,如颜 色、边缘、轮廓等有很大的关系。为了使底层视觉特 征明显,本文采用不同颜色绘制各馈线的不同投影 平面图像,具体颜色参数见附录B表B1。

发生单相接地故障时,由于故障相未知,同一条 馈线的3个投影平面图像的显著性是一致的,因此 采用加权平均的融合方法进行融合,赋予各投影图 像的权值均为1/3,具体如式(4)所示。

$$C_{i}'(x, y) = \frac{1}{3} \left(C_{i1}(x, y) + C_{i2}(x, y) + C_{i3}(x, y) \right) \quad (4)$$

其中,*i*=1,2,3,4; $C'_i(x,y)$ 为第*i*条馈线投影平面融 合图像像素值; $C_{i1}(x,y)$ 、 $C_{i2}(x,y)$ 、 $C_{i3}(x,y)$ 为第*i*条 馈线的投影平面图像像素值。

由于故障线路也未知,同一工况下得到的各馈 线的融合图像的显著性仍是一致的,仍然采用加权 平均进行二次融合,即赋予各馈线融合图像权值1/4, 具体如式(5)所示。

$$C'(x, y) = \frac{1}{4} \Big(C'_1(x, y) + C'_2(x, y) + C'_3(x, y) + C'_4(x, y) \Big) (5)$$

其中,C'(x,y)为第2次融合后图像像素值。

2.2 图像融合总体框架

同一种工况下,1条馈线的三相电流可以得到3 幅三维空间投影图像,则本文所研究的四出线配电 系统可以得到12幅R、G、B三通道的彩色图像。这 12幅图像之间存在很多冗余信息,像素级加权平均 图像融合通过互补信息的有机集成,能够减少或抑 制单一、重复信息对感知对象可能存在的不完整性、 不确定性和误差,最大限度地利用各种特征信息,为 下一步深度学习算法的使用奠定了基础。像素级图 像融合结构示意图如附录C图C1所示,具体步骤 如下:

(1)将馈线L₁的三相电流三维空间图像分别向 AOB、BOC、AOC平面投影得到3幅投影图像;

(2)对3幅投影图像进行尺度标准化处理,然后 进行图像配准像素级图像融合得到融合图像1;

(3)重复步骤(1)、(2)得到融合图像2-4;

(4)对4幅融合图像再次进行尺度标准化处理 后,进行像素级图像融合,生成1幅RGB彩色图像。

三相电流图像融合过程中各阶段的图像如附录 C图C2所示,故障设置与第1节相同。第1次图像 融合将同一馈线的各投影平面图像进行融合,电缆 线路L₁为健全线路,但其对地电容远大于架空线的 对地电容,所以L₁的故障电流远大于健全架空线路 L₃、L₄的故障电流,融合图像中椭圆外围扰动明显。 架空线路L₂为故障线路,融合图像中椭圆外围扰动 幅度最大。第4次图像融合完整保留了同一馈线故 障相暂态电流信息,使融合图像显著性信息的对比 度更高。第2次图像融合将不同馈线的融合图像再 次进行融合,最终得到的RGB彩色图像完全呈现了 故障特征信息,细节更丰富,边缘更清晰。本文融合 规则充分考虑了故障发生的随机性,融合图像故障 特征信息更加集中,图像细节和轮廓保留更加完整, 更有利于深度学习算法进行辨识。

3 空间域图像融合效果分析

3.1 电缆对融合图像的影响

随着配电网规模的扩大以及城网、农网改造的 进一步深化,配电网电缆化程度不断提高,将纯架空 线路与电缆-架空线混合线路进行比较具有深刻的 意义。为了验证融合图像在电缆线路引入时的有效 性,本文设置馈线L₂在距线路首端2km处,发生故 障初相角为90°的金属性接地故障。然后将图1所 示仿真模型中的电缆线路L₁替换成为架空线路,架 空线路参数仍按照附录A表A1进行设置,消弧线圈 按10% 过补偿整定。相同的故障条件下,纯架空线 路和电缆-架空线混合线路故障馈线的三相电流与 融合图像分别如附录D图D1和图D2所示。由图D1 和图D2可得以下结论。

(1)电缆-架空线混合线路的故障馈线故障相暂态电流幅值明显大于纯架空线路,融合图像中含故障相的投影部分扰动幅度更大。因为电缆线路对地电容是架空线路对地电容的十几倍,电缆线路对地电容电流更大,而故障线路中流过的电容电流是所有健全线路电容电流之和,因此电缆-架空线混合线路的故障电流更大,融合图像故障特征更明显。

(2)纯架空线路中,故障电流暂态分量在2~3个 周期内衰减至0。电缆-架空线混合线路中,故障电 流暂态分量在1~2个周期内衰减至0,其衰减过程更 快。因为纯架空线路的电感远大于混合线路的电 感,衰减时间常数更大,衰减时间更长。在时域方式 中,在故障发生1个周期后,时域波形中的故障特征 已变得不明显,而融合图像中仍存在明显扰动。

(3)纯架空线路和电缆-架空线混合线路的融合 图像中,最大扰动幅度出现的位置相同,这与故障发 生条件有关。

鉴于目前大部分小电流接地系统中均含有电缆 线路,所以下文的讨论均采用电缆-架空线混合线路 模型。

3.2 故障初相角对融合图像的影响

为研究故障初相角对空间域特征的影响,对 距馈线 L₂首端 2 km 处发生故障初相角不同的单相 接地故障的情况进行仿真,接地点过渡电阻设置为 1 Ω,故障初相角分别设置为 0°、30°、60°。所得不同 故障初相角情况下的故障线路时域波形与融合图 像如附录 D 图 D3 所示。由图 D3 可以得到以下 结论。

(1)各融合图像中,不同馈线、不同投影平面的 故障暂态电流差异明显,故障馈线L₂含故障相的投 影平面的扰动幅值最大,如图中的蓝色、洋红色曲线 所示。时域波形中,仅故障馈线的故障相时域波形 在故障发生后第1个周期特征明显,相比时域波形, 融合图像的故障特征更加清晰。

(2)随着故障初相角的不断减小,故障暂态电流 幅值逐渐降低,融合图像中椭圆外围扰动幅度不断 减小。当故障初相角为0°时,时域波形的变化幅度 非常小,在实际系统中存在噪声干扰的情况下,几乎 无法辨识出故障线路,但是融合图像中仍存在十分 明显的扰动,这与第1节理论分析一致。

3.3 故障距离对融合图像的影响

分别在馈线L₂距离线路首端1、3、7 km处,设置 故障初相角为90°、接地点过渡电阻为1Ω的单相接 地故障进行仿真,不同故障距离下的故障线路时域波 形和融合图像如附录D图D4所示。由图可见,在其 他故障条件相同、仅改变故障距离的情况下,不同融 合图像的轮廓、位置大致相同,故障点越靠近母线,椭 圆外围扰动幅度略微增加,与时域波形的变化特征相同,说明故障距离的变化对融合图像的影响较小。

3.4 接地点过渡电阻对融合图像的影响

实际单相接地故障发生时,接地点过渡电阻一般为0~2000 Ω 。对馈线 L₂在距离首端 2 km 处,故障初相角为90°,接地点过渡电阻分别为10、100、500、1000、2000 Ω 时发生单相接地故障的情况进行仿真。所得不同故障电阻情况下的故障线路时域波形和融合图像如附录D图D5所示。

(1)发生低阻接地故障时,随着故障电阻的增加,故障暂态电流的幅值与接地点过渡电阻成反比, 随着接地点过渡电阻的增大,暂态过程持续时间短, 扰动衰减速度快。由图D5(a)—(c)可见,对于故障 馈线的时域波形,仅故障相存在短暂故障特征,但是 在融合图像中包含故障相的投影都存在故障特征, 相当于时域波形中故障特征的2倍。且融合图像中 椭圆外围扰动幅度、色彩、轮廓差异明显,符合第1 节的理论分析结果。

(2)由图 D5(d)、(e)可见,发生高阻接地故障时,时域波形已没有明显的故障特征,但是融合图像中椭圆外围扰动仍存在,色彩、轮廓特征与正常运行状态依旧有明显的差异,这对深度学习算法的有效使用提供了条件。

4 对比分析

4.1 抗噪性能分析

根据实际工况,为了验证在不同噪声干扰下,均 能利用 CNN 基于本文方法得到的融合图像进行 有效的故障选线,笔者将支持向量机 SVM(Support Vector Machine)、随机森林 RF(RandomForest)、决 策树 DT(Decision Tree)、深度前馈神经网络 DFN (Deep Feedforward Network)与 CNN进行比较,数据 集相关说明见附录 E,自动化仿真流程见附录 E表 E1。不同噪声情况下各网络分类准确率如图4所示。





Fig.4 Classification accuracy of each machine learning algorithm under different noise conditions

由图4可以看出,基于本文方法得到的融合图像,CNN在不同噪声强度下的选线准确率均最高,准确率至少为99.63%,说明利用CNN基于融合图像进行故障选线具有良好的抗噪声干扰性能。传统的机

器学习方法(SVM、RF、DT)均为浅层学习模型,其能 够学习到的特征有限且需要特征区分度明显,如果 这些特征受到噪声干扰将会对选线准确率产生较大 的影响。深度学习算法属于数据驱动,其网络层 数更多,在海量数据中能够自学习到很多特征,且 层数越深提取到的特征越抽象,噪声干扰对其学 习到的抽象特征影响较小,故而 DFN 和 CNN 抗噪 性能更好。目前,在图像识别领域 CNN 的效果明 显优于其他深度学习算法并且应用广泛。为了说 明 CNN 各层的特征提取能力,笔者利用主成分分 析法 PCA(Principal Components Analysis)和t-分布 领域嵌入 t-SNE(t-distributed Stochastic Neighbor Embedding)算法将 CNN 提取特征可视化。实验硬 件平台、CNN 各层的参数配置和可视化过程如附录 F所示。

4.2 不同采样频率下的故障选线效果对比

考虑到实际情况中各运维部门采用的故障采集 设备采样频率存在差异,探究不同采样频率下本文 方法的故障选线效果对实际应用具有重要的参考意 义。笔者通过设置12.8、6.4、3.2、1.6、0.8 kHz这5种 不同采样频率进行实验得到样本数据,为了避免随 机因素的干扰,保证实验结果的准确性,在每个采样 频率下进行10次重复实验,取10次实验的准确率和 误差的平均值如表1所示。

表1 不同采样频率下测试样本的准确率和 误差的平均值

 Table 1
 Accuracy and average error of test samples at different sampling frequencies

采样频	准确率	误差	采样频	准确率	误差
率 / kHz	平均值	平均值	率 / kHz	平均值	平均值
12.8	0.9987	0.0011	1.6	0.9814	0.0123
6.4	0.9974	0.0027	0.8	0.9732	0.0195
3.2	0.9914	0.0078			

由表1可知,随着采样频率的降低,故障选线的 准确率平均值降低,误差平均值增大。在12.8 kHz 的采样频率下,故障选线的准确率平均值可以达到 99.87%,而当采样频率为0.8 kHz时仅为97.32%,这 是因为在数据采样的过程中,故障的特征信息部分 缺失,模型在低采样频率下难以提取到完整的故障 特征,因此较高的采样频率能够保证故障选线的准 确率。

4.3 时间测试

为了进一步验证完全融合后的图像相比于各馈 线的原始投影图像和仅融合1次得到的各馈线融合 图像结合CNN使用性能更佳,笔者分别将原始投影 图像结合CNN进行学习(Model-1),融合一次图像结 合CNN进行学习(Model-2),完全融合图像结合CNN 进行学习(Model-3)。在相同的计算机环境下,计算 3种方法对于1个测试样本的测试时间和分类准确 率,结果如表2所示。

表2 各方法测试时间及分类准确率

Table 2 Test time and classification accuracy

of each method

方法	测试时间 / ms	准确率 / %
Model-1	485	98.65
Model-2	217	99.14
Model-3	60	99.87

从表2中可看出,Model-1、Model-2要比Model-3 耗费更多时间且分类准确率更低,这是因为Model-1、 Model-2的数据处理量是Model-3的好几倍,且包含 多种重复特征信息,极大地增加了网络训练难度和 过拟合的风险。而采用完全融合图像进行深度学 习,对1个测试样本的测试时间仅为81 ms,比人类 反应速度(100~400 ms)还要快,分类准确率可以达 到99.87%。

5 结论

本文提出了一种新型的小电流接地系统发生单 相接地故障选线,利用三相电流三维投影融合图像 作为深度学习算法输入量,能够自适应地提取故障 特征。本文所提方法具有以下优点:

(1)相比于传统方法仅截取部分故障信息,本文 方法能够完整地保留所有的故障信息,通过融合图 像样本进行深度学习,是一种基于数据的方法,能更 好地契合样本的特征;

(2)发生高阻接地故障时,因为故障特征不明显,传统故障选线方法的分类准确率很低,而通过空间域图像融合方法将含有故障相的所有投影图像特征融合到了1幅RGB图像上,故障特征得到了明显的集中和真实的展示,能够充分利用深度学习在图像领域的优势进行选线;

(3)利用CNN对完全融合图像样本进行故障选线,分类准确率最高可以达到99.87%,具有较好的抗噪能力和反应速度,验证了本文方法的有效性。

本文方法以仿真数据作为实验样本,获得了较高的选线准确率,但是对于单相高阻接地故障,故障初相角较低时的故障情况选线效果有待进一步提升,同时考虑到实际配电网数据与仿真数据的差异性,下一步的研究方向将对本文提出的图像生成及融合方法采用多类输入、多网络融合的模型,并在训练样本中添加实际电网的故障数据,进一步完善故障选线模型,提高方法的实用性。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

[1] 洪翠,付宇泽,郭谋发,等. 基于卷积深度置信网络的配电网故

障分类方法[J]. 电力自动化设备,2019,39(11):64-70. HONG Cui,FU Yuze,GUO Moufa,et al. Fault classification method based on CDBN for distribution network[J]. Electric Power Automation Equipment,2019,39(11):64-70.

- [2] 林军.小波变换在零序电流暂态高频信号分析中的应用[J]. 电工技术学报,2004,19(4):91-94.
 LIN Jun. Application of wavelet transform to analysis of transient high frequency signal on zero sequence current[J]. Transactions of China Electrotechnical Society,2004,19(4):91-94.
- [3] 薛永端,冯祖仁,徐丙垠,等.基于暂态零序电流比较的小电流 接地选线研究[J].电力系统自动化,2003,27(9):48-53.
 XUE Yongduan,FENG Zuren,XU Bingyin, et al. Earth fault protection in non-solidly earthed network based on transient zero sequence current comparison[J]. Automation of Electric Power Systems,2003,27(9):48-53.
- [4] 毛鹏,孙雅明,张兆宁,等.小波包在配电网单相接地故障选线中的应用[J].电网技术,2000,24(6):9-13.
 MAO Peng,SUN Yaming,ZHANG Zhaoning, et al. Wavelets packet based detection of phase-to-ground fault in distribution automation system[J]. Power System Technology,2000,24 (6):9-13.
- [5] 王耀南,霍百林,王辉,等. 基于小波包的小电流接地系统故障 选线的新判据[J]. 中国电机工程学报,2004,24(6):54-58.
 WANG Yaonan, HUO Bailin, WANG Hui, et al. A new criterion for earth fault line selection based on wavelet packets in small current neutral grounding system[J]. Proceedings of the CSEE,2004,24(6):54-58.
- [6] 赵慧梅,张保会,段建东,等.一种自适应捕捉特征频带的配电 网单相接地故障选线新方案[J].中国电机工程学报,2006,26 (2):41-46.
 ZHAO Huimei,ZHANG Baohui,DUAN Jiandong, et al. A new scheme of faulty line selection with adaptively capturing the feature band for power distribution networks[J]. Proceedings
- [7] 束洪春. 配网选线保护与故障定位[M]. 北京:科学出版社, 2016:26.

of the CSEE, 2006, 26(2): 41-46.

- [8] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015,521(7553):436-444.
- [9] KRIZHEVSKY A, SUTSKEVER I, HINTON G. Imagenet classification with deep convolutional neural networks [C]//Proceedings of the Advances in Neural Information Processing Systems. Lake Tahoe, USA: ACM, 2012:1097-1105.
- [10] ZHANG W, PENG G, LI C, et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals[J]. Sensors, 2017, 17(2):425.
- [11] LI G, DENG C, WU J, et al. Sensor data-driven bearing fault diagnosis based on deep convolutional neural networks and S-transform[J]. Sensors, 2019, 19(12):2750.
- [12] CHEN Lu, WANG Zhenya, ZHOU Bo. Intelligent fault diagnosis of rolling bearing using hierarchical convolutional network based health state classification[J]. Advanced Engineering Informatics, 2017, 32:139-151.
- [13] OH J W, JEONG J. Convolutional neural network and 2d image based fault diagnosis of bearing without retraining[C]// ICCDA 2019. New York, USA: ACM, 2019:134-138.
- [14] 瞿合祚,李晓明,陈陈,等. 基于卷积神经网络的电能质量扰动 分类[J]. 武汉大学学报,2018,51(6):534-539.
 QU Hezuo, LI Xiaoming, CHEN Chen, et al. Classification of power quality disturbances using convolutional neural network
 [J]. Engineering Journal of Wuhan University, 2018, 51(6): 534-539.
- [15] 尹立敏,齐敏,雷钢,等.基于超完备字典的压缩感知电能质量数据重构[J].电力系统保护与控制,2018,46(8):93-99.

103

YIN Limin, QI Min, LEI Gang, et al. Reconstruction of compressed sensing power quality data based on overcomplete dictionary[J]. Power System Protection and Control, 2018, 46 (8):93-99.

- [16] 谢小瑜,周俊煌,张勇军. 深度学习在泛在电力物联网中的应用与挑战[J]. 电力自动化设备,2020,40(4):77-87.
 XIE Xiaoyu, ZHOU Junhuang, ZHANG Yongjun. Application and challenge of deep learning in Ubiquitous Power Internet of Things[J]. Electric Power Automation Equipment, 2020,40 (4):77-87.
- [17] 王秋杰,金涛,梅李鹏,等. 基于模型分层的配电网故障诊断方法[J]. 电力自动化设备,2020,40(1):73-79.
 WANG Qiujie,JIN Tao, MEI Lipeng, et al. Model-based hierarchical diagnosis method for distribution network faults[J]. Electric Power Automation Equipment,2020,40(1):73-79.
- [18] 王艳松,宗雪莹,衣京波. 配电网故障定位容错算法[J]. 电力 自动化设备,2018,38(4):9-15.
 WANG Yansong,ZONG Xueying,YI Jingbo, et al. Fault-tolerant algorithm for fault location in distribution network[J]. Electric Power Automation Equipment,2018,38(4):9-15.
- [19] 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.
 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.
- [20] GUO Moufa, ZENG Xiaodan, CHEN Duanyu, et al. Deep-learning-based earth fault detection using continuous wavelet transform and convolution neural network in resonant grounding distribution system[J]. IEEE Sensors Journal, 2018(2): 1291-1300.
- [21] 薛永端,李娟,陈筱薷,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,2017,37(17):

5037-5048.

XUE Yongduan, LI Juan, CHEN Xiaoru, et al. Faulty feeder selection and transition resistance identification of high impedance fault in a resonant grounding system using transient signals[J]. Proceedings of the CSEE, 2017, 37(17):5037-5048.

- [22] 薛永端,李娟,徐丙垠.中性点经消弧线圈接地系统小电流 接地故障暂态等值电路及暂态分析[J].中国电机工程学报, 2015,35(22):5703-5714.
 XUE Yongduan,LI Juan,XU Bingyin. Transient equivalent circuit and transient analysis of single-phase earth fault in arc suppression coil grounded system[J]. Proceedings of the CSEE,
- 2015,35(22):5703-5714.
 [23] 张海申,何正友,张钧. 谐振接地系统单相接地故障频谱特征 分析[J]. 电力系统自动化,2012,36(6):79-84.
 ZHANG Haishen,HE Zhengyou,ZHANG Jun. Frequency spectrum characteristic analysis of single-phase grounding fault in resonant grounded systems [J]. Automation of Electric Power Systems,2012,36(6):79-84.

作者简介:



程文傲(1995—),男,湖北天门人,硕 士研究生,主要研究方向为人工智能技术 在电力系统中的应用(E-mail:chengwenaoa@ 163.com);

徐 明(1988—),女,河南郑州人,博士 研究生,主要研究方向为故障诊断(E-mail: 535397130@qq.com);

高金峰(1963—),男,河南项城人,教 授,博士,主要研究方向为电工理论与新技

术(E-mail:jfgao@zzu.edu.cn)。

(编辑 任思思)

Spatial domain image generation and fusion method of single-phase grounding fault line selection for small current grounding system

CHENG Wenao, XU Ming, GAO Jinfeng

(School of Electrical Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: In order to take full use of feature self-learning advantage of deep learning algorithm and its advantages in the field of image processing, and to avoid the information loss problem of manual fault feature extraction in single-phase grounding fault line selection for small current grounding system, a method is proposed by generating a full-information space domain image of fault current and then using image recognition and classification algorithm to select the fault line. Firstly, three-phase current is used to construct a three-dimensional spatial domain image, which is respectively project on three planes to obtain multiple projection images, so the key problem of acquiring two-dimensional images is solved. Then, the secondary pixel-level images fusion of the projected images is carried out, by which the corresponding RGB color image is obtained. Finally, the deep learning algorithm is used to identify and classify the image to achieve fault line selection. The comparison of fault line selection results between the proposed method and the existing methods show that under the influence of various factors, the proposed method has no loss of fault information, more obvious image fault characteristics, higher classification accuracy and anti-noise ability, which proves its feasibility in single-phase grounding fault line selection for small current grounding system.

Key words: small current grounding system; fault line selection; spatial domain; image fusion; deep learning



图 A1 正常运行时三相电流三维空间图

Fig.A1 Three-dimensional space diagram of three-phase current during normal operation

表 A1 仿真模型线路参数						
TableA1 Line parameters of simulation model						
线路	电阻/		电感/		对地电容/	
	$(\mathbf{\Omega} \boldsymbol{\cdot} \mathbf{km}^{-1})$		$(mH \cdot km^{-1})$		$(\mu F \bullet km^{-1})$	
尖尘	正序	零序	正序	零序	正序	零序
架空线	0.178	0.25	1.21	5.54	0.015	0.012
电 缆	0.27	2.7	0.255	1.02	0.339	0.28

附录 A



Fig.B2 Projection planes of healthy feeder L₃

表 B1 各馈线各投影平面颜色参数

Table B1 Color parameters of each feeder and each projection plane

投影面 馈线	AOB 平面	BOC 平面	AOC 平面
Lı	黑色	红色	绿色
L_2	蓝色	青色	洋红色
L ₃	黄色	深黄色	海军蓝色
L_4	紫色	酒红色	橄榄绿色

附录 C



图 C1 像素级图像融合结构示意图







Fig.D1 Three-phase current and fusion image of pure overhead line



Fig.D2 Three-phase current and fusion image of hybrid cable-overhead line



Fig.D3 Time-domain waveforms and fused images of faulted lines at different initial phase angles





Fig.D4 Time-domain waveforms and fused images of faulty lines under different fault distances





Fig.D5 Time-domain waveforms and fused images of fault lines under different fault resistances

附录 E

深度学习需要海量的标注样本为模型训练提供数据支撑,以此才能充分挖掘数据隐藏特征 得到泛化能力较强的模型。在仿真过程中,如果通过人为手动更改仿真模型参数根本无法实现大 规模样本数据集的制备,并且无法模拟实际运行中故障发生的随机性。MATLAB 支持通过编写 脚本来实现批量化操作,通过脚本程序,不仅能够实现仿真模型自动启停,而且可以任意改变元 件参数。

本文设计的故障条件包括不同故障相位、不同故障初相角、不同故障线路、不同故障距离。 采样频率为 12.8kHz,采样时间为 0.2s,系统正常运行状态 0.02s 后施加故障,每次仿真对线路 的电流采样 2560 个点,模型具有 4 条馈线,每条馈线具有三相线路,故每个样本规格为 3×4× 2560。故障相位在 A、B、C 三相间随机选择,故障初相角在0°到360°间随机选择。考虑到电缆 线路接地故障不容易发生,如果发生接地故障,位置往往在电缆接头处。故本文故障位置仅在馈 线架空线部分随机选取,接地阻抗在 0.1Ω到 2000Ω之间随机选取。每条架空馈线产生 6000 个故 障样本,正常运行状态下产生 6000 个正常样本。整个数据集共计 24000 个样本。其中 14400 个 样本作为训练样本集矩阵 $G_{\text{train}} \in \mathbb{R}^{14400 \times (2560 \times 4 \times 3)}$,4800 个样本作为验证样本集矩阵 $G_{\text{validation}} \in \mathbb{R}^{4800 \times (2560 \times 4 \times 3)}$,剩余 4800 个样本作为测试样本集矩阵 $G_{\text{test}} \in \mathbb{R}^{4800 \times (2560 \times 4 \times 3)}$,具体的流程如表 E1 所示。

	Table 1 Simulation process of automated algorithm
步骤	基于 MATLAB/Simulink 的故障仿真自动化
1	调用 Simpower System 工具箱搭建 10kV 配电系统模型
2	配置故障参数:不同故障线路、相位、阻抗和位置
3	启动仿真,运行 0.02s 时施加故障
4	运行 0.2s 后停止仿真
5	读取 3×4 通道的电流仿真数据(3×4×2560)并保存为 mat 文件
6	重复步骤 2—5 以产生每条故障线路所需的 6000 个样本
7	重复步骤 6 得到 3 类故障样本数据,共计 18000 个样本
8	随机配置不同相位,重复正常运行 6000次,产生正常状态 6000个样本
9	将4类状态数据集共计24000个样本,按0.6:0.2:0.2比例划分训练、验证、测试数
	据集

表 E1 自动化算法仿真流程 TableE1 Simulation process of outcompted algorithm

为模拟实际工况中的噪声污染,对数据集加上不同程度的高斯白噪声,信噪比 SNR 分别为 45、40、35、30dB。根据本文方法将含有不同噪声的样本数据集转换为图像数据集。

附录 F

本文实验以 Dell R730 服务器为硬件平台, CPU 型号为 Intel Xeon E5-2630 v4、内存为 64G、 GPU 型号为 NVIDIA TITAN Xp,操作系统为 Windows Server R2012 R2,样本处理和模型训练均 采用 Python 语言,模型在 Keras 深度学习框架下以 TensorFlow 为后端实现, CNN 各层参数配置 如表 F1 所示, CNN 提取特征可视化过程如图 F1 所示。图中 0 代表馈线 2 故障,1 代表馈线 3 故障,2 代表馈线 4 故障,3 代表系统正常运行状态。

Tab.F1 Specific structural parameters of CNN				
网络层	卷积核/采样窗口大小	输出特征图大小		
Input		150×150		
Conv2D_1	3×3	148×148		
MaxPooling2D_1	2×2	74×74		
Conv2D_2	3×3	72×72		
MaxPooling2D_2	2×2	36×36		
Conv2D_3	3×3	34×34		
MaxPooling2D_3	2×2	17×17		
Conv2D_4	3×3	15×15		
MaxPooling2D_4	2×2	7×7		
Flatten		6272×1		
Dense		512×1		
Output		6×1		

表 F1 CNN 的具体结构参数 Tab.F1 Specific structural parameters of CNN





图 F1 CNN 提取特征可视化

Fig.F1 CNN Extract feature visualization

为了直观地展现 DSCNN 提取特征的能力, 笔者利用 PCA 降低数据维度后, 使用 t-分布领 域嵌入算法 t-SNE(t-distributed Stochastic Neighbor Embedding)将 PCA 所得降维结果转换到二 维图像中,第一个卷积层为各种边缘检测器的集合,这一层几乎保留着原始图像的所有信息, 如图 F1(a)所示,此时正常状态样本因为与故障样本特征明显不同直接在第一个卷积层就可 有效识别出。但是3类不同故障馈线的情况仍交织在一起。随着层数的加深,特征会变得越来 越抽象,它们将无关的信息过滤掉,并放大和细化了有用的信息,是更能代表原始图像的抽象 特征。经过多个卷积池化层,最终得到128个特征图,表征原始数据的128个抽象特征,经过 展开层得到维度为 6272×1 的特征向量,由图 F1(e)可见,此时特征已经有较明显的分界线。 通过全连接层降维为 512×1 的特征向量,由图 F1(f)可见,此时特征已经有明显的分界线。 综上所述,通过本文的 CNN 模型,融合图像的故障特征能够有效分离。