

基于卷积深度置信网络的配电网故障分类方法

洪 翠¹, 付宇泽¹, 郭谋发¹, 陈永往²

(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晋江市供电公司, 福建 晋江 362200)

摘要:提出一种基于卷积深度置信网络(CDBN)实现配电网故障分类的方法,利用离散小波包变换(DWPT)分解主变低压侧进线电流和母线电压等电量信号并构造时频矩阵,将时频矩阵转换成时频谱图的像素矩阵后作为CDBN的输入,经CDBN自主提取故障特征量,最终完成配电网故障分类识别。应用典型结构配电网的故障仿真数据与故障实验样本进行故障识别测试,结果表明,所提方法不但具有提取故障特征明显、故障分类正确率较高的特点,并且在系统中性点运行方式及网络结构调整、故障起动检测延迟、分布式电源接入等情况下,均有良好的应用适应性。

关键词:配电网;故障分类;离散小波包变换;时频矩阵;卷积深度置信网络

中图分类号:TM 711

文献标志码:A

DOI:10.16081/j.epae.201910020

0 引言

配电网结构日益复杂,短路、接地等各类故障时有发生^[1]。发生故障后,无论是网络重构、故障定位,还是事故分析、排查检修都十分依赖对故障类型的识别^[2]。因此,高效可靠的故障分类方法对维持配电网安全运行、提高供电可靠性有非常重要的意义。

文献[1]以局部特征尺度分解LCD(Local Characteristic-scale Decomposition)对配电网故障时的电压与电流信号进行奇异值分解,选取奇异谱分布参数作为特征量,输入至多级支持向量机(SVM)中进行故障类型识别;文献[2]将三相电流的故障分量经小波变换后,提取其标准差、相关系数并结合零序电压量作为特征量,输入至自适应神经模糊推理系统中进行故障分类识别;文献[3]通过经验模态分解(EMD)对三相与零序电流进行分解,选取暂态分量高频信号的标准差和相关系数构造特征量,输入至二进制蚁群模糊神经网络中实现故障分类;文献[4]将等效电压和电流相角进行快速傅里叶变换,将频率系数作为多级SVM的输入进行故障分类;文献[5]将三相电压经过Clarke变换与S变换,提取零序信号与电压暂降幅值作为特征量,输入至模糊H网中实现故障类型识别;文献[6]利用平稳小波变换提取故障电流的频带能量,将其与3个既定阈值比较实现故障分类。上述方法首先人工提取能够充分表

征故障类型的特征量,再以合适的模式识别方法完成故障分类,虽能获得良好的分类结果,但故障特征选择与提取的有效性均依赖于相关领域的研究经验,较易受到人为因素干扰;且人工提取的特征量较难适应各类易混淆的故障样本分类。

深度学习方法可从原始输入数据中自动提取分类所需特征,已在图像、语音识别等领域取得了显著成果^[7-10]。配电网的电压、电流信号可综合反映一次设备的工作状况和系统状态信息,但不适用于直接应用图像识别的深度学习方法。如能用合适的信号分析方法对这些信息进行初步处理后以图像的形式呈现,将为面向图像识别的智能故障分类方法提供较好的辨识素材。

本文提出将卷积深度置信网络CDBN(Convolutional Deep Belief Network)应用于配电网故障分类。该分类方法基于暂态电量信号实现,以离散小波包变换(DWPT)对电量信号进行时频分解,获取时频矩阵并转换为时频谱图的像素矩阵作为CDBN模型的输入,CDBN通过无监督学习算法,采用卷积和池化操作自适应地提取识别所需关键特征量;同时,将softmax分类器集成到CDBN中,实现故障特征自动提取与分类识别。

1 基于CDBN的配电网故障分类方法

为适应CDBN的输入信号要求,本文以DWPT处理配电网故障信号,将其转换为时频谱图的像素矩阵并输入至CDBN。基于CDBN的配电网故障分类方法综合了DWPT时频双域性与CDBN主动提取特征的优势,免去了人工提取与选择特征量的过程,可自主提取配电网故障特征并进行学习,从而实现配电网故障的准确分类。基于CDBN的配电网故障分类方法的实现流程如附录A中的图A1所示。

基于CDBN的配电网故障分类实现过程为:

收稿日期:2018-12-06;修回日期:2019-09-12

基金项目:国家自然科学基金资助项目(51677030);福建省自然科学基金资助项目(2016J01218);晋江市科技计划项目(2017C006)

Project supported by the National Natural Science Foundation of China(51677030), the Natural Science Foundation of Fujian Province(2016J01218) and the Science and Technology Projects of Jinjiang City(2017C006)

(1)采集各类故障工况的主变低压母线三相电压、零序电压和主变低压侧三相电流,采样频率为 10 kHz,分别截取故障前后各一周期的信号波形数据作为训练样本;

(2)采用 DWPT 对训练样本数据进行时频分解,求取时频矩阵,进而构造图像大小为 35×380 个像素点的时频谱图,作为 CDBN 的输入;

(3)构建 7 层 CDBN 模型,以无监督学习方式训练 2 个卷积受限玻尔兹曼机 CRBM (Convolutional Restricted Boltzmann Machine),在第 2 个 CRBM 后添加 softmax 分类器,训练网络模型,实现故障特征的有效提取及自动分类;

(4)按照步骤(1)获得测试样本原始数据,按照步骤(2)构造时频谱图,输入至已训练完善的 CDBN 模型中,实现配电网故障分类。

1.1 DWPT

小波包变换可以很好地描述配电网的电量信号波形在时、频域上的局部特征,是一种能有效分析暂态信号的方法^[11]。本文基于 DWPT 对采样获取的故障信号进行初步处理,小波包分解和重构算法分别如式(1)和式(2)所示。

$$\begin{cases} d_l^{j,2n} = \sum_k p_{k-2l} d_k^{j-1,n} \\ d_l^{j,2n+1} = \sum_k q_{k-2l} d_k^{j-1,n} \end{cases} \quad (1)$$

$$d_l^{j-1,n} = \sum_k p_{l-2k} d_k^{j,2n} + \sum_k q_{l-2k} d_k^{j,2n+1} \quad (2)$$

其中, p, q 为滤波器系数; d 为小波包分解系数; k, l 为分解层数; j, n 为小波包节点号。

小波包变换过程中,对高频带的分解会使各子频带顺序交错^[12],使用时需按照频率由低到高将子频带重新排列。本文选取正则性良好的 db4 小波作为小波基函数^[13-14],应用 DWPT 对选定的电压与电流信号进行 4 层分解,并对第 4 层的小波系数进行重构,分别得到信号的低频部分 $S_{4,0}$ 和 高频部分 $S_{4,1} \sim S_{4,15}$ 。通过求取大量时频矩阵后发现信号的瞬时频率集中在 0~3 kHz 范围内。以单相接地故障时的零序电压为例,选取 0~3.125 kHz 部分,即 $S_{4,0} \sim S_{4,4}$ 作为信号分析的频带范围,小波包分解结果如附录 A 中的图 A1 所示。

可见,经小波包分解后所得低频部分表示信号的主要信息,幅值与原始波形相近;高频部分表示信号的突变部分,能量较小,幅值较低。即经过 DWPT 时频分解后的高、低频部分充分包含了信号的时频信息,全面反映了信号含有的暂态特征。

1.2 CDBN

CDBN 模型由多个最大池化卷积受限玻尔兹曼机 (max-pooling-CRBM) 堆叠而成,含池化层的 CRBM 结构如图 1 所示。

图 1 所示的 CRBM 结构中,可见层为 $N_v \times N_v$ 的图




图 1 含池化层的 CRBM 结构图

Fig.1 Structure of CRBM with pooling

像,隐藏层由 K 个特征图构成,表示 K 个从可见层提取的特定特征。每个特征图中的单元通过一大大小为 $N_w \times N_w$ 的卷积核连接被其覆盖的可见层单元。在隐藏层上再堆叠一个池化层,可在保持高层特征局部平移不变性的条件下降维以减小计算负担^[15]。CRBM 模型遵循贪婪的分层训练原则,采用卷积和池化操作获取层次更深、表达能力更强的故障特征。

卷积是 CRBM 模型中可见层到隐藏层的计算,经过卷积操作,在隐藏层生成 K 个特征图作为下一层的输入以提取更高级的特征,每个特征图的规模为 $N_h \times N_h$ ($N_h = N_v - N_w + 1$)。第 k 个特征图的第 i 行第 j 列的隐藏层单元的条件激活概率为:

$$P(h_{ij}^k = 1 | v) = \sigma(b_k + (W^k * v)_{ij}) \quad (3)$$

其中, v, h 分别为可见层与隐藏层单元; W^k 为第 k 组的层间权值; $W^k * v$ 表示第 k 组的层间权值与可见层单元做卷积运算; $\sigma = 1/(1 + e^{-x})$ 为 Sigmoid 激活函数, x 为激活函数的输入数据。

池化是隐藏层到池化层的计算,使用概率最大池化 (probabilistic max-pooling) 方法对隐藏层进行降采样,以不重叠窗口将隐藏层分割成若干的 B_α 区域,区域大小为 $c \times c$ 。取选定区域内最大值作为输出值,得到由若干 P_α^k 区域组成的池化层特征作为下一个 CRBM 的输入,特征规模为 $N_p \times N_p$ ($N_p = N_h / c$)。

作为降维和正则化的操作,池化操作可降低模型的训练复杂度,减小计算负担。

第 k 个池化层单元的条件激活概率为:

$$P(P_\alpha^k = 1 | v) = \frac{\exp(b_k + (W^k * v)_{i'j'})}{1 + \sum_{(i',j') \in B_\alpha} \exp(b_k + (W^k * v)_{i'j'})} \quad (4)$$

其中, b_k 为第 k 个特征图的偏置; (i', j') 表示隐藏层的第 i' 行第 j' 个单元。

将 CRBM 提取的特征图依次按列展开,得到 1 个特征向量,将其映射到样本标记空间,得到 1 个新的特征表达形式,计算当前各样本对应每种类型的概率为:

$$T(i) = Y\left(L = l_i | P_0; (W, b)\right) \quad (5)$$

其中, $Y(\cdot)$ 为 softmax 分类器函数; l_i 为第 i 类输入数据的计算结果; P_0 为总概率; W, b 分别为特征图的权值和偏置。

2 仿真分析

2.1 训练样本

以图2所示的辐射式中压配电网为例,基于PSCAD/EMTDC仿真软件获取故障样本数据。




图2 辐射式配电网络接线示意图

Fig.2 Wiring diagram of radial distribution network

图2所示的配电网中性点采用不接地运行方式,各馈线末端负荷均设定为 $0.5+j0.25 \text{ MV}\cdot\text{A}$, F_1 — F_{15} 为设置的故障点,110 kV主变T和10 kV配电线路的参数分别见附录B中的表B1和表B2。

选定图2中的故障点 F_1 — F_5 ,每个故障点均设置AG、BG、CG、ABG、ACG、BCG、AB、AC、BC、ABC这10种基本故障类型,针对故障初相角区间为 $[0^\circ, 180^\circ)$ 、间隔 30° 、过渡电阻为0、10、100、1000 Ω 及电弧性电阻的单相接地故障及过渡电阻为0、1、5 Ω 的两相接地故障、两相短路故障与三相短路故障,分别进行配电网故障仿真。以仿真所得数据作为CDBN模型的训练样本。

2.2 DWPT时频分解

根据1.1节对样本数据进行DWPT分解并构建时频谱图。选取 $S_{4,0}$ — $S_{4,4}$ 作为时频矩阵的总频带,将各子频带按三相电压、三相电流和零序电压顺序自上而下叠成35行,采样频率为10 kHz,2个周期内的采样点数为400,为抑制边界效应影响,裁剪掉首尾各10个采样点,获得维度为 35×380 的时频矩阵。将时频矩阵转成时频谱图的像素矩阵,像素值反映了时频矩阵数值的大小,以AG、ABG、AB、ABC这4种故障为例,故障信号时频谱图见附录C中的图C1。

由时频谱图可知,发生接地故障时零序电压变化明显,非接地故障和对称故障零序电压几乎为0。发生单相接地故障时,故障相的电压呈跌落现象;发生两相接地故障时,故障两相的电压跌落、电流升高;发生相间短路故障时,故障相电流升高。

综上所述,时频谱图囊括了故障暂态信号的时频特征,可为实现故障分类奠定基础。

2.3 基于CDBN的故障分类

采用附录D中表D1所示的CDBN各层参数配置,设计完成图D1所示的CDBN模型。

图D1亦展现了配电网故障分类CDBN自动提取特征量并分类的过程。与已有的以人工提取故障特征量的故障分类方法不同,CDBN自动从输入样本数据中提取故障特征,最终将在 P_2 层输出12个特征图,以表征原始输入数据的12类固有特征。 P_2 层输出的12个特征图将在全连接层依次按列展开并堆叠成维度为 6192×1 的特征向量,作为softmax分类器的输入,从而在输出层获得 10×1 的类型判别向量输出,分别代表10种常见故障类型的事件概率,取最大值所在位置,编号即可作为最终判别的故障类型。因此,基于CDBN对故障数据实现的分类辨识,具有表达能力更强,区分度更高的特点。

由于输入数据数量和CDBN每层所提取特征的维数较高,并不能直接观察其所提取特征。但若以主成分分析法(PCA)降低数据维度后,再使用 t -分布邻域嵌入(t -SNE)算法将PCA所得结果转换到2维坐标图中,即可直观展现CDBN提取特征的能力^[16]。利用本文所提基于CDBN的配电网故障分类方法,提取特征的前2个主成分 PC_1 、 PC_2 ,其可视化结果如附录E中图E1所示。

由图E1可见,原始输入数据特征交叉在一起,难以区分,经过2轮卷积和池化操作后,同类特征有效聚类,不同特征区分明显。可见,通过本文的CDBN模型,输入图像的数据特征获得了有效分离。

作为无监督学习网络,CDBN训练过程依赖于学习数据分布而不是标签,它通过梯度下降算法调整参数,缩小重构数据与训练数据之间的差异。因此,本文采用重构误差(训练数据经过若干次Gibbs采样后与原数据的一阶范数差值)作为评价CDBN模型训练效果的标准,重构误差曲线如图3所示。




图3 重构误差曲线

Fig.3 Error curve of reconfiguration

从图3可以看出,训练过程中,重构误差随迭代次数增加而逐渐减小,直至趋于平稳;且本文设计的CDBN模型重构误差较低,这也表明经过训练后的CDBN模型具有较强的特征提取能力。

2.4 样本测试

类似于训练样本,综合考虑故障相别、故障初相角、过渡电阻等因素,以图2中的故障点 F_6 — F_{15} 处的故障仿真数据作为测试样本,应用基于CDBN的故障分类方法,测试故障分类识别的准确性,结果见表1。

由于表1可见,针对并未训练过的2160个故障

表 1 样本测试结果

Table 1 Results of testing samples

故障点	故障初相角/(°)	故障类型	过渡电阻	样本数	准确率/%
F_6-F_{15}	0,30,60,90,120,150	AG	0、10、100、1000 Ω 及电弧性电阻	300	100
		BG	0、10、100、1000 Ω 及电弧性电阻	300	100
		CG	0、10、100、1000 Ω 及电弧性电阻	300	100
		ABG	0、1、5 Ω	180	100
		ACG	0、1、5 Ω	180	100
		BCG	0、1、5 Ω	180	100
		AB	0、1、5 Ω	180	100
		AC	0、1、5 Ω	180	100
		BC	0、1、5 Ω	180	100
		ABC	0、1、5 Ω	180	98.3
总计				2160	99.86

样本,本文所提方法仍可较为准确地区分出 10 种常见故障类型,识别准确率达到 99.86%。其中,三相短路故障有 3 个样本被误判为 BC 相间短路,均为故障点 F_{10} 在故障初相角为 150° 时的样本,分析其原因,应是 A 相电流在故障后的第 1 个半周波内的电流增幅小于其他两相,从而引起误判。

3 对比分析

为进一步说明本文所提故障分类方法的识别效果,基于 2.4 节的测试样本将其与同是基于暂态分量进行故障分类的文献[1]、文献[6]的方法进行对比。

3.1 高过渡电阻接地故障识别

发生单相接地故障时,故障相电压跌幅受过渡电阻影响较大,较高的过渡电阻将使故障相电压跌落的现象不够凸显。取 2.4 节测试样本中过渡电阻值为 1000 Ω 的 180 个单相接地故障样本,对比讨论本文所提方法与文献[1]、文献[6]中方法的识别准确率,结果如表 2 所示。

表 2 高过渡电阻单相接地故障的识别准确率对比

Table 2 Identification accuracy comparison of single-phase grounding faults with large transition resistance

故障类型	测试样本容量	准确率/%		
		本文方法	文献[1]方法	文献[6]方法
AG	60	100	88.3	83.3
BG	60	100	96.7	83.3
CG	60	100	100.0	83.3
总计	180	100	95.0	83.3

由表 2 可见,本文提出的基于 CDBN 的故障分类识别方法,在高过渡电阻情况下仍可 100% 准确识别各单相接地故障,准确率高于文献[1]所使用的传统人工提取特征量分类识别方法与文献[6]中的阈值设置识别的方法。

3.2 电弧接地故障识别

发生弧光接地故障时电弧电流与电压呈非线性

关系,因此故障过渡电阻呈非线性,且大小不断变化,可能影响故障类型的有效识别。取 2.4 节中电弧性过渡电阻单相接地故障的 180 个样本,与文献[1]、文献[6]对比讨论本文方法的识别准确率,结果见表 3。

表 3 电弧性过渡电阻单相接地故障的识别准确率对比

Table 3 Identification accuracy comparison of single-phase grounding fault with arc transition resistance

故障类型	测试样本容量	准确率/%		
		本文方法	文献[1]方法	文献[6]方法
AG	60	100	100	90
BG	60	100	80	90
CG	60	100	100	100
总计	180	100	93.3	93.3

由表 3 可见,基于 CDBN 的故障分类识别方法几乎不受电弧接地故障引起的非线性过渡电阻的影响,对电弧接地故障的识别准确率为 100%,高于文献[1]与文献[6]的平均识别准确率 93.3%。

3.3 基本类型故障识别

针对 2.4 节中其余 1800 个测试样本,对比本文和文献[1]、文献[6]的故障识别准确率,结果见表 4。

表 4 3 种分类方法的准确率对比

Table 4 Comparison of three fault classification methods

故障类型	测试样本容量	准确率/%		
		本文方法	文献[1]方法	文献[6]方法
AG	180	100.0	97.2	98.3
BG	180	100.0	100.0	98.3
CG	180	100.0	100.0	98.3
ABG	180	100.0	100.0	79.4
ACG	180	100.0	100.0	87.8
BCG	180	100.0	100.0	77.2
AB	180	100.0	100.0	94.4
AC	180	100.0	100.0	98.9
BC	180	100.0	100.0	95.0
ABC	180	98.3	94.4	30.0
总计	1800	99.8	99.2	85.8

由表 4 可见,在 10 种故障类型下,本文方法的识别准确率高于文献[1]与文献[6]中方法的识别准确率,具有明显的优势。并且,由于故障工况的多变性,阈值的大小往往需要根据具体的配电网进行调整,合理选择文献[6]方法中的 3 个阈值非常困难;文献[1]利用机器学习的方法对故障进行分类,克服了传统方法中人为设置阈值的缺陷,具有较高的准确率,但故障特征的人工提取和选择较为困难且过程繁杂,而依赖浅层网络模型分类算法,其适应性往往较差。利用深度学习自适应提取表达能力更强的故障特征,能够有效避免人工构造特征量所带来的局限性和所需知识的复杂性,且兼具简化识别过程、提高正确率等优势。

4 适应性与实用性分析

本节首先通过改变系统中性点运行方式、调整

辐射式配电网络结构、接入分布式电源等方式,进一步检验所提基于CDBN的故障分类识别方法的应用效果,然后检验输入数据截取窗口偏移的影响,再以贴近实际的故障实验数据检验本文方法的实用性。

4.1 改变中性点运行方式

谐振接地方式因可显著提高故障熄弧率,在国内外中压配电网中获得了广泛应用^[17]。将图2所示配电网网络调整为系统中性点经消弧线圈接地方式运行,设计消弧线圈电感值为0.708 H,电阻值为6.68 Ω ,实现10%过补偿运行。

选定图2中的故障点 F_8 、 F_{10} 、 F_{12} ,对故障相别、故障初相角、过渡电阻等因素的考虑同于表1,仿真获得系统中性点运行方式改变后的648个测试样本,基于CDBN的故障分类识别方法的识别结果见表5。

表5 改变中性点运行方式的测试结果

Table 5 Testing results of changing grounding mode

故障点位置	测试样本容量	准确率/%
F_8	216	100
F_{10}	216	100
F_{12}	216	100
总计	648	100

由表5可见,网络结构不变、只改变系统中性点运行方式时,基于CDBN的故障分类识别方法无需重新训练学习,即可准确识别各类故障。

4.2 调整网络拓扑结构

为了达到平衡负荷、降低网损等目的,配电网拓扑结构经常会发生变化。对图2所示的配电网,设定3种拓扑结构测试拓扑调整对基于CDBN的故障分类识别方法的影响,即删减线路 L_4 、同时删减线路 L_4 和 L_5 、新增1条5 km架空线 L_7 (并在该线路末端设置故障点)。测试样本的故障点选为网络结构改变后位于线路 L_4 — L_7 的所有故障点,其余初始条件同表1,识别结果如表6所示。

表6 网络拓扑改变时的测试结果

Table 6 Testing results of changing network topology

网络结构变化情况	测试样本容量	准确率/%
仅删减 L_4	1080	99.6
删减 L_4 和 L_5	648	100.0
增加5 km的架空线 L_7	1728	99.8

由表6可见,本文所提方法对3种网络拓扑改变的情况同样具有良好的适应性。检查错误样本,发现与表1中相同,均为故障点 F_{10} 在故障初相角为150°时的样本,主要是由于A相电流在故障后的第一个半周波内电流增幅小于其他两相而引起的误判,可见误判原因与网络拓扑改变并无关系。

4.3 故障时刻检测偏差的影响

如第1节所述,本文提出的基于CDBN的故障分类方法以电量信号波形在故障前后各一周期的数据

作为分析依据。在实际应用中,如故障启动时刻的检测存在偏差,将直接影响分类识别使用原始数据的选定,进而可能影响故障分类识别的分析结果。

现有故障检测方法检测时间一般较长^[18],设定 $t=0$ 为故障的实际发生时刻,以检测延迟为例,分别模拟故障后延迟2 ms、3 ms方能检测到故障发生,选择如表1中所示的故障点进行故障仿真获得测试样本,对各种故障类型的识别结果如表7所示。

表7 故障检测延迟测试结果

Table 7 Testing results of fault detection delay

检测延迟/ms	测试样本容量	准确率/%
2	2160	98.7
3	2160	97.7

由表7可见,当测试样本的故障启动的检测时刻迟于实际故障时刻时,故障类型识别的总平均准确率虽然有所下降,但总识别准确率仍达到了97.7%以上,显示出基于CDBN的故障分类方法对故障启动时刻的检测延迟具有较好的包容性。

4.4 分布式电源接入

当前,分布式电源不断接入配电网中,其接入后对配电网故障分类识别的影响不可忽略。分别图2中馈线 L_3 的中部与末端接入1个光伏并网发电系统等效模型,该模型通过对光伏发电等效电路进行简化推导,并根据实验拟合补偿系数建立^[19],选取故障点 F_6 — F_8 ,故障类型、故障初相角及过渡电阻的设置同表1,识别结果如表8所示。

表8 接入分布式电源的测试结果

Table 8 Testing results of DG accessed

分布式电源接入位置	故障点	测试样本容量	准确率/%
L_3 中部	F_6	216	94.9
	F_7	216	93.5
	F_8	216	95.8
L_3 末端	F_6	216	95.4
	F_7	216	94.4
	F_8	216	95.8
总计		1296	95

由于表8可见,分布式电源接入后,本文所提方法仍然具有较高的故障分类识别准确率,综合平均正确率达到了95%以上。通过分析故障波形可知,分布式电源的接入会影响流经主变低压侧的短路电流^[20],且故障点靠近分布式电源的接入点时,在单相接地故障情况下,暂态过程中的非周期分量衰减变慢,将引起误判。

4.5 实用性的实验测试

4.5.1 实验测试

以上测试样本均为基于PSCAD/EMTDC软件仿真获得的故障数据。由于电力系统运行的特殊性,较难在实际配电网中获取到CDBN所需的足够的预定故障工况下的故障波形数据。本文利用配电

网物理仿真实验系统开展配电网故障实验,采集故障波形数据作为测试样本,进一步验证本文所提分类方法的实用性。基于相似性原理搭建的配电网物理仿真实验系统如附录 F 所示,该系统与实际配电系统具有相似的故障暂态特性。

综合考虑故障点位置、中性点接地方式、故障类别、故障初相角、过渡电阻等因素,选取具有代表性的实验测试样本,测试结果如表 9 所示。

表 9 物理仿真系统实验数据测试结果

Table 9 Testing results of physical simulation system's experimental data

故障位置	故障类型	中性点 接地方式	故障初 相角/(°)	过渡 电阻/Ω	样本 数	正确 率/%
$f_1\text{—}f_4$	AG	不接地、 经消弧线圈接地	0,45,90, 135,180	0、100	60	100.0
	BG			0、100	60	100.0
	CG			0、100	60	100.0
	ABG			0	30	80.0
	ACG			0	30	70.0
	BCG			0	30	100.0
	AB			0	30	100.0
	AC			0	30	100.0
	BC			0	30	100.0
	ABC			0	30	86.7
总计					390	95.1

由表 9 可见,利用本文提出的基于 CDBN 的故障分类方法对实验测试样本进行故障分类测试,综合准确率达到 95.1%。分析其误判原因主要为,虽然配电网物理仿真实验系统虽然依据相似性原理搭建,但与软件仿真模型的参数、网络结构、电气量大小都不尽相同,因此存在误判的问题,若将少部分物理仿真实验数据添加至训练样本中训练完善 CDBN 模型,可显著提高分类正确率。

4.5.2 时间测试

本文方法在应用推广时,需考虑所需硬件基础以及识别工作耗时。以图 F1(b)故障点 f_1 处的 10 次故障分类过程为例,分析 MATLAB 故障分类程序运行时间,测试所提方法应用时对单次故障的判别耗时。测试硬件考虑常规主流配置 PC,2.3 GHz Intel CoreTM i5 处理器、8.00 GB RAM,Win64 操作系统。对于 CDBN 模型的训练过程,单次迭代的时间为 50.29 s,图 9 的重构误差曲线显示,超过 10 次迭代后模型的重构误差趋于平稳,当模型训练完善后,可直接应用于故障分类,无需重复训练。本文方法应用于故障分类时,DWPT 时频分解耗时约为 0.2287 s,CDBN 特征提取与分类耗时约为 0.1541 s。

可见,训练 CDBN 模型时,迭代 50 次计算训练时间约为 42 min;CDBN 模型训练完善后,当配电网发生故障时,基于 CDBN 的配电网故障分类识别方法在 0.4 s 内即可实现分类判断,反应较为迅速,具有工程应用意义和实用价值。

5 结论

本文提出基于 CDBN 的配电网故障分类识别方法,并通过大量的软件仿真与实验获得测试样本进行故障分类的识别测试,得出以下结论:

(1)利用 DWPT 构造的时频矩阵包含了配电网故障前后的信号波形在各个子频带内的时频特征,从而为 CDBN 模型的训练提供了更丰富的故障信息;

(2)作为一种深度模型结构,CDBN 能够自主地提取故障特征并进行学习,有效降低了传统方法由于人工选取特征量所造成的不确定性,具有更强的智能性和适应性;

(3)测试结果表明,所提出方法不但适合于典型故障样本,可包容故障启动时刻检测延迟,能有效适应网络拓扑调整、中性点运行方式改变及分布式电源接入的情况,对容易混淆的故障样本亦有较高的识别准确率,还能准确地分类识别故障实验数据。

本文方法以软件仿真故障数据作为训练样本,并在配电网物理仿真实验系统中获得了较高的故障分类准确率,验证了其良好的实用性。实际工程应用时,考虑到实际配电网与软件仿真模型的差异性,可在训练样本中补充实际配电网的故障数据,从而以更丰富的训练样本进一步完善训练 CDBN 模型,优化方法的实用性。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 郭谋发,游林旭,洪翠,等. 基于 LCD-Hilbert 谱奇异值和多级支持向量机的配电网故障识别方法[J]. 高电压技术,2017,43(4):1239-1247.
GUO Moufa,YOU Linxu,HONG Cui,et al. Identification method of distribution network faults based on singular value of LCD-Hilbert spectrums and multilevel SVM[J]. High Voltage Engineering,2017,43(4):1239-1247.
- [2] 张钧,李小鹏,何正友. 采用自适应神经模糊推理系统的配电网故障分类方法[J]. 中国电机工程学报,2010,30(25):87-93.
ZHANG Jun,LI Xiaopeng,HE Zhengyou. Fault classification technique for power distribution network using adaptive network based fuzzy inference system[J]. Proceedings of the CSEE,2010,30(25):87-93.
- [3] 孙鹏,曹雨晨,刘洋,等. 采用二进制蚁群模糊神经网络的配电网故障分类方法[J]. 高电压技术,2016,42(7):2063-2072.
SUN Peng,CAO Yuchen,LIU Yang,et al. Fault classification technique for power distribution network using binary ant colony algorithm and fuzzy neural network[J]. High Voltage Engineering,2016,42(7):2063-2072.
- [4] GOPAKUMAR P,REDDY M J B,MOHANTA D K. Adaptive fault identification and classification methodology for smart power grids using synchronous phasor angle measurements[J]. IET Generation,Transmission & Distribution,2015,9(2):133-145.
- [5] 王思明,童安蓉. 混合模糊 H 网在配电网故障识别中的应用[J]. 电力系统及其自动化学报,2016,28(10):74-79.
WANG Siming,TONG Anrong. Application of hybrid fuzzy H net to recognition of fault types for distribution network[J]. Proceedings of the CSU-EPSSA,2016,28(10):74-79.
- [6] SALIM R H,DE OLIVEIRA K R C,FILOMENA A D,et al.

- Hybrid fault diagnosis scheme implementation for power distribution systems automation[J]. IEEE Transactions on Power Delivery, 2008, 23(4): 1846-1856.
- [7] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436.
- [8] 赵光权, 葛强强, 刘小勇, 等. 基于DBN的故障特征提取及诊断方法研究[J]. 仪器仪表学报, 2016, 37(9): 1946-1953.
- ZHAO Guangquan, GE Qiangqiang, LIU Xiaoyong, et al. Fault feature extraction and diagnosis method based on deep belief network[J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 1946-1953.
- [9] BROSCH T, TAM R. Efficient training of convolutional deep belief networks in the frequency domain for application to high-resolution 2D and 3D images[J]. Neural Computation, 2014, 27(1): 211.
- [10] LEARNEDMILLER E, LEE H, HUANG G B. Learning hierarchical representations for face verification with convolutional deep belief networks[C]//IEEE Conference on Computer Vision and Pattern Recognition. Providence, RI, USA: IEEE, 2012: 2518-2525.
- [11] 余南华, 李传健, 杨军, 等. 基于小波包时间熵的配电网运行状态特征提取方法[J]. 电力自动化设备, 2014, 34(9): 64-71, 79.
- YU Nanhua, LI Chuanjian, YANG Jun, et al. Operating state feature extraction based on wavelet-packet time entropy for distribution network[J]. Electric Power Automation Equipment, 2014, 34(9): 64-71, 79.
- [12] 郭谋发, 杨耿杰, 黄世远. 谐振接地系统暂态特征自适应故障选线方法[J]. 电力自动化设备, 2012, 32(10): 35-41.
- GUO Moufa, YANG Gengjie, HUANG Shiyuan. Adaptive faulty line selection based on transient characteristics for resonant earthing system[J]. Electric Power Automation Equipment, 2012, 32(10): 35-41.
- [13] NGUI W K, LEONG M S, HEE L M, et al. Wavelet analysis: mother wavelet selection methods[J]. Applied Mechanics & Materials, 2013, 393: 953-958.
- [14] 何正友, 钱清泉. 电力系统暂态信号分析中小波基的选择原则[J]. 电力系统自动化, 2003, 27(10): 45-48.
- HE Zhengyou, QIAN Qingquan. Method in the transient signal analysis of electric power systems[J]. Automation of Electric Power Systems, 2003, 27(10): 45-48.
- [15] FENG W, GUAN N, LUO Z. High-performance audio mat-
- ching with features learned by convolutional deep belief network[C]//2016 IEEE 13th International Conference on Signal Processing(ICSP). Chengdu, China: IEEE, 2017: 1724-1728.
- [16] SHAO H, JIANG H, ZHANG H, et al. Electric locomotive bearing fault diagnosis using a novel convolutional deep belief network[J]. IEEE Transactions on Industrial Electronics, 2017, 65(3): 2727-2736.
- [17] 纪鸿彬. 谐振接地系统单相接地故障并联电阻选线的优化[J]. 高电压技术, 2006, 32(8): 124-126.
- JI Hongbin. Optimize of earth fault protection by parallel resistance on resonance earth system[J]. High Voltage Engineering, 2006, 32(8): 124-126.
- [18] 陈丽安, 张培铭, 缪希仁. 基于小波变换的低压系统短路故障的早期预测[J]. 电工技术学报, 2003, 18(2): 91-94.
- CHEN Li'an, ZHANG Peiming, MIAO Xiren. Prediction for the short-circuited fault based on wavelet transform[J]. Transactions of China Electrotechnical Society, 2003, 18(2): 91-94.
- [19] 傅望, 周林, 郭珂, 等. 光伏电池工程用数学模型研究[J]. 电工技术学报, 2011, 26(10): 211-216.
- FU Wang, ZHOU Lin, GUO Ke, et al. Research on engineering analytical model of solar cells[J]. Transactions of China Electrotechnical Society, 2011, 26(10): 211-216.
- [20] 马静, 刘静. 基于故障稳态分量的含DG配电网自适应方向电流保护方案[J]. 电力自动化设备, 2018, 38(1): 1-9.
- MA Jing, LIU Jing. Adaptive directional current protection scheme based on steady state component in distribution network with DG[J]. Electric Power Automation Equipment, 2018, 38(1): 1-9.

作者简介:



洪 翠

洪 翠(1972—),女,福建泉州人,副教授,博士,主要研究方向为配电网及其主设备故障诊断、新能源电力负荷预测(E-mail: hongcui@fzu.edu.cn);

付宇泽(1994—),男,吉林长春人,硕士研究生,主要研究方向为配电网及其自动化技术(E-mail: 735890812@qq.com);

郭谋发(1973—),男,福建福清人,教授,博士,主要研究方向为电力系统自动化(E-mail: gmf@fzu.edu.cn)。

Fault classification method based on CDBN for distribution network

HONG Cui¹, FU Yuze¹, GUO Moufa¹, CHEN Yongwang²

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

2. Jinjiang Power Supply Co., Ltd. of State Grid Fujian Electric Power Company, Jinjiang 362200, China)

Abstract: A novel fault classification method based on CDBN (Convolutional Deep Belief Network) for distribution network is proposed. The DWPT (Discrete Wavelet Packet Transform) is adopted to decompose signals of the main transformer including current of low-voltage inlet line, bus voltage, and so on, to construct time-frequency matrices. Then the time-frequency matrices are transformed into the pixel matrices of the time-frequency spectrum map, which is used as the input of CDBN. Then the fault features are autonomously extracted by CDBN, and the fault classification and recognition of distribution network is completed. Fault classification test is carried out with simulative data and experimental samples of a typical structure distribution network. The testing results show that the proposed method not only can extract obvious fault characteristics with high classification accuracy, but also adapts well to the change of neutral-point grounding mode and system network structure, fault detection delay and connection of distributed generation.

Key words: distribution network; fault classification; discrete wavelet packet transform; time-frequency matrix; convolutional deep belief network

附录 A




图 A1 基于 CDBN 的配电网故障分类方法的实现流程

Fig.A1 Flowchart of fault classification method based on CDBN for distribution network




图 A2 小波包分解分量

Fig.A2 Components of wavelet packet decomposition

附录 B

表 B1 主变压器参数

TableB1 Parameters of main transformer					
容量/（MV A）	电压变比	空载 损耗/kW	短路 损耗/kW	空载电流 百分数/%	短路电压 百分数/%
31.5	110 kV /10 kV (YNd11)	25.6	125.8	0.2	10.5

表 B2 线路单位长度参数

TableB2 Parameters in per unit length				
元件	参数类型	电阻/(Ω·km ⁻¹)	电容/(μF·km ⁻¹)	电感/（mH km ⁻¹ ）
电缆	正序	0.270	0.339	0.255
	零序	2.700	0.280	1.019
架空线	正序	0.125	0.0096	1.300
	零序	0.275	0.0054	4.600

附录 C




图 C1 故障信号的时频谱图

Fig.C1 Time-frequency spectrum diagram of fault signals

表 D1 CDBN 各层的参数配置

TableD1 Parameter configuration of each layer of CDBN

层	卷积核/采样 窗口大小	卷积/池化步 长	输出特征图 大小(数量)
可见层 1 (V_1)	—	—	35×380 (1)
隐藏层 1 (H_1)	4×13	1	32×368 (6)
池化层 (P_1) (可见层 2(V_2))	2×2	2	16×184 (6)
隐藏层 2 (H_2)	5×13	1	12×172 (12)
池化层 (P_2)	2×2	2	6×86 (12)
全连接层	—	—	6192×1 (1)
输出层	—	—	10×1 (1)




图 D1 CDBN 模型的结构图

Fig.4 Structure diagram of CDBN model

附录 E





图 E1 CDBN 提取特征的可视化

Fig.E1 Visualization of CDBN extraction features

附录 F



(a) 实验系统现场布局



(b) 系统电气主回路

图 F1 配电网物理仿真实验系统
Fig.F1 Physical simulation system of distribution network