

基于深度-迁移学习的输电线路故障选相模型及其可迁移性研究

杨毅¹, 范栋琛¹, 殷浩然^{2,3}, 韩 佶^{2,3}, 苗世洪^{2,3}

(1. 国网江苏省电力有限公司 电力科学院研究院, 江苏 南京 211103;

2. 华中科技大学 电气与电子工程学院 强电磁工程与新技术国家重点实验室, 湖北 武汉 430074;

3. 电力安全与高效湖北省重点实验室, 湖北 武汉 430074)

摘要:为提高输电线路故障诊断模型的可迁移性,根据迁移学习理论将输电线路分为源线路和目标线路,提出一种基于深度-迁移学习的输电线路故障类型识别方法。通过组合不同故障条件,生成输电线路故障期间的时序数据,并通过对数据的预处理,得到面向卷积神经网络的输入数据样本;利用源域数据对初始卷积神经网络进行预训练,获取适用于源线路故障类型识别的预训练模型;采用最大均值差异法对源线路和目标线路进行相似性检验,筛选出待迁移的源域预训练模型;利用目标域数据对预训练模型进行微调迁移训练,获取最终的目标域故障诊断模型。仿真结果表明,利用源域数据量5%的目标域数据对预训练模型进行微调迁移训练,得到的目标域模型对目标线路故障诊断的准确率达99%以上。

关键词:输电线路;迁移学习;深度学习;故障类型识别;卷积神经网络

中图分类号:TM 77

文献标志码:A

DOI:10.16081/j.epae.202008008

0 引言

输电线路故障类型识别是故障分析及处理的前提,对提高系统安全稳定性具有重要意义^[1]。传统故障类型识别方法主要基于发生故障时的电气量,分为暂态量选相方法、稳态量选相方法以及前两者相结合的选相方法3种。基于电气量的选相方法实现较为简单,但容易受负荷电流、系统运行方式、故障位置、过渡电阻及故障相角等因素的限制,且不同类型的故障需要使用不同类型的选相元件^[2]。

电网数据采集系统和故障信息系统的建立,可以提供故障期间的事件信息和录波数据,为人工智能算法的应用奠定了数据基础。已有学者提出将传统人工智能算法,例如支持向量机SVM(Support Vector Machines)^[3-4]、人工神经网络^[5-6]、模糊推理^[7]等应用到故障类型识别。然而,上述传统浅层学习算法均包含特征参数提取环节和分类识别环节两部分,其识别效果很大程度上依赖人工设计的特征参数提取环节,特征参数选择的优劣会直接影响整个模型的识别效果。深度学习不依赖于人工设计的特征提取环节,通过海量数据训练,构建深层神经网络,自动提取输入数据特征并进行归纳分类,在故障类型识别方面具有较大的应用潜力。目前,已

有部分国内外学者将深度学习应用到输电线路的故障类型识别,文献[8]基于深度卷积神经网络CNN(Convolutional Neural Network)模型实现了输电线路的故障类型识别和区内外故障判断,证明了深度学习在电力系统中应用的可行性和优势;文献[9]改进了CNN的输入数据格式,显著提高了CNN在复杂系统故障诊断方面的正确率;文献[10]利用栈式稀疏自编码器提取线路故障深层特征,并利用SVM进行分类,实现了线路跳闸故障检测;文献[11]考虑了实际电网的负荷波动,基于CNN构建深度学习模型,故障类型识别正确率高达99.99%。上述研究均证明了深度学习在故障类型识别方面的应用效果。

然而,深度学习模型构建过程需要海量训练数据,若存在数据量不足或数据缺失等问题,模型的识别率将严重下降;此外,采用深度学习训练出的模型只适用于产生数据的特定线路,若将模型应用于参数不同的其他线路的故障诊断,诊断准确率将严重降低,需要重新生成用于模型训练的海量数据,模型构建复杂耗时。近年来,迁移学习(Transfer Learning)受到了国内外学者的广泛关注。迁移学习能够对深度学习无法直接应用的历史数据、残缺数据进行充分提取,将其作为辅助数据,利用辅助数据预先训练深度学习模型,然后将预训练模型的特征迁移应用到新的目标模型,可以解决数据量少、标注缺失等问题。文献[12]基于经过训练的CNN模型,对其隐含层进行迁移应用,在图像识别领域取得了良好的效果;文献[13]基于迁移学习,对液压泵实验过程中的历史数据加以应用,提高了液压泵深度学习

收稿日期:2020-01-07;修回日期:2020-06-12

基金项目:国家自然科学基金资助项目(61602251);国家电网公司科技项目(5210EF190010)

Project supported by the National Natural Science Foundation of China(61602251) and the Science and Technology Project of State Grid Corporation of China(5210EF190010)

健康评估的准确率。实际电网中不同输电线路之间存在相似性,线路长度、电气参数等差异不大,在发生同类型故障时电气量具有相似特征。

因此,本文基于迁移学习和深度学习提出一种输电线路故障类型识别方法,利用目标域数据对预训练深度学习模型进行微调迁移训练,将单一线路深度学习模型迁移至其他线路,实现了深度学习模型的迁移应用,提高了深度学习模型的泛化能力。仿真实验结果显示:利用少量(源域数据的5%)目标域数据对预训练模型进行迁移微调训练,即可得到适用于目标域线路的迁移深度学习模型,从而解决了深度学习训练面临的数据缺失、数据量少等问题。

1 面向CNN的数据样本生成

1.1 时序数据生成

输电线路发生不同类型的故障期间,线路两端的电压和电流包含对应的特征,据此可实现对线路故障类型的识别^[14]。本文通过构建输电线路故障仿真模型生成模型训练所需的大量故障数据样本。

本文研究的单回输电线路模型如图1所示。图中, l_1 和 l_2 为故障点距线路两端母线的长度,线路总长为 L ;线路两端等值为发电机;变压器接线方式为Yg- Δ ;负荷采用数值可变的有功负荷。图1中各元件参数值见附录A中的表A1。




图1 线路故障仿真模型拓扑图

Fig.1 Topology diagram of simulation model of line fault

考虑到输电线路等值方式对本文的故障类型识别方法影响较大,对于单回输电线路,主要等值模型有一字型等值模型、 π 形等值模型和分布参数模型。分布参数模型虽然能准确反映输电线路的实际情况,但会影响仿真速度,且分布参数线路需要考虑波的传播过程,故障点的距离设置应满足式(1),无法模拟采样点附近发生故障的场景; π 形等值模型不存在上述劣势,且与一字型等值模型相比考虑了导纳参数,更接近实际场景,因此本文中输电线路采用 π 形等值模型。

$$x > v/f_s \quad (1)$$

其中, x 为故障点到采样点的距离; v 为波速; f_s 为采样频率。

时序数据的生成过程如图2所示,步骤如下。

(1)在Simulink中构建图1所示的单回输电线路




图2 时序数据生成步骤

Fig.2 Generation steps of timing data

故障仿真模型。

(2)结合实际输电线路参数波动设置参数遍历取值范围如表1所示,表中, f_N 、 S_N 、 R_s 分别为仿真模型的额定频率、额定负荷和接地故障最大过渡电阻;ABC、AB、ABG、AG分别表示三相短路故障、AB两相短路故障、AB相接地故障、A相接地故障,其他依此类推;电压为标么值。根据表1对不同参数下故障期间的电气量进行遍历采集。

表1 遍历参数取值范围

Table 1 Range of traversing parameter

参数	参数取值范围
电压	0.9~1.1
频率	$0.98f_N \sim 1.02f_N$
故障位置	$0 \sim L$
负荷	$0.8S_N \sim 1.2S_N$
过渡电阻	$0 \sim R_s$
故障类型	ABC, AB, AC, BC, ABG, ACG, BCG, AG, BG, CG

(3)调节输电线路长度、单位长度阻抗和感抗,分别模拟目标线路和其他辅助源域线路,从而分别产生目标域和源域时序数据。

(4)采集各线路两端三相电压和三相电流,共12个电气量的时序数据,构成如式(2)所示的12维电气量向量,得到满足预训练、微调训练和测试要求的时序数据。

$$\mathbf{X}_{12} = [u_{1a} \ u_{1b} \ u_{1c} \ u_{2a} \ u_{2b} \ u_{2c} \ i_{1a} \ i_{1b} \ i_{1c} \ i_{2a} \ i_{2b} \ i_{2c}] \quad (2)$$

1.2 数据预处理

仿真模型生成的故障时序数据量很大,且由于各电气量单位不同,数值大小差异很大。因此,需对时序数据进行等间隔采样和归一化处理,并组合成二维矩阵,以生成面向CNN的数据样本。

(1)等间隔采样。

模型的仿真步长为50 ms,即数据获取的采样频率为2000 Hz,在此采样频率下,故障发生前后的3个周期内包含上百个数据点,如果直接用于模型训练,将导致计算量过大、训练时间很长。由于线路的故障特征主要体现在电气量幅值的变化情况,所以获取测量数据后,进一步对数据进行采样,每间隔

10 个点取 1 个点,在故障点前、后进行等间隔采样后,获取的数据点仍包含线路故障特征。

为突出电气量的幅值变化特征,首先将采集的电气量变换为有效值;然后对故障发生前 1 个周期到发生后 2 个周期内的时序数据进行等间隔采样,在 3 个周期内采集 12 个数据点,每个电气量均由 12 个数据点组成,从而构成 12×12 维的二维数据矩阵。

(2) 归一化处理。

由于量纲和取值范围的差异,故障仿真模型生成的 12 个电气量数据的各数值之间差异很大,故障特征分布不均匀,导致数值较小的电气量包含的特征难以提取。因此,对 12 个电气量分别进行归一化处理,使故障特征在样本矩阵中均匀分布。

利用式(3)对各组电气量分别执行归一化处理,将各电气量的幅值变化量规范至 0~1 之间,从而在归一化数据的同时,将故障特征最大化。

$$\bar{x}_{ij} = [x_{ij} - \min(X_j)] / [\max(X_j) - \min(X_j)] \quad (3)$$

其中, x_{ij} 为式(2)所示电气量矩阵中的数据点, X_j 为该数据点所在的列向量; $\bar{x}_{ij}$ 为归一化处理后的数据点。

2 基于 CNN 的模型预训练

2.1 典型 CNN 结构及训练方法

作为深度学习的一种, CNN 具有局部连接、权值共享和空间相关等特性以及强鲁棒性和容错能力,适用于深层数据特征提取。经典 CNN 模型结构如附录 A 中的图 A1 所示,其包含输入层、隐含层、全连接层、输出层,其中隐含层由卷积层和降采样层交替构成,是 CNN 提取输入数据深层特征的关键结构。

CNN 的输入层是一组二维数据样本矩阵 ($n \times n$ 维),由卷积核 ($k_1 \times k_1$) 与样本矩阵进行卷积运算,滑动步长为 s ,并经过激活函数,得到一层特征面 ($m \times m$),利用不同的卷积核得到多个特征面,构成 CNN 的卷积层,卷积运算过程如式(4)所示。

$$\mathbf{M}_{\text{out}}^l = F(\mathbf{M}_{\text{in}}^{l-1} \otimes \mathbf{K}_{\text{core}}^l) \quad (4)$$

其中, l 为网络层序; $\mathbf{M}_{\text{out}}^l$ 为第 l 层网络输出的特征面; $\mathbf{M}_{\text{in}}^{l-1}$ 为第 $l-1$ 层网络输出的特征面; $\mathbf{K}_{\text{core}}^l$ 为第 l 层卷积核矩阵; $F(\cdot)$ 表示激活函数; $\otimes$ 表示 CNN 中的滑动卷积过程。

降采样层紧邻卷积层,同样由多个特征面 ($s \times s$) 构成,与卷积层的特征面一一对应,卷积层的特征面通过降采样核 ($k_2 \times k_2$) 进行降分辨率采样作为二次特征提取过程,均值降采样的运算过程如式(5)所示;最后的降采样层与全连接层相连,整合由卷积层和降采样层提取出的特征信息,输入 Softmax 层进行逻辑回归分类。

$$\mathbf{M}_{\text{out}}^{l+1} = \mathbf{M}_{\text{in}}^l \otimes \frac{1}{k_2} \quad (5)$$

根据式(4)和式(5)的运算过程,输入层矩阵阶数 n 、卷积层特征面阶数 m 和降采样层特征面阶数 s 满足式(6),式中各变量均为正整数。

$$\begin{cases} m = n - k_1 + 1 \\ s = m/k_2 \end{cases} \quad (6)$$

CNN 的有监督学习训练过程通过 BP 算法进行,与传统人工神经网络类似,包含前向传播和反向传播过程。

(1) 初始化网络:训练前,根据式(7)对核参数进行随机初始化,从而使网络获得学习能力。

$$X_{ij} = f_{\text{rand}}([-1, 1]) \quad (7)$$

其中, $f_{\text{rand}}(\cdot)$ 为随机函数。

(2) 前向传播:以一组样本矩阵 $\mathbf{N}_1$ 作为输入层,根据式(8)逐层经过卷积层、降采样层、全连接层,得到实际的输出 O_r 。

$$O_r = f_{s2}(f_{c2}(f_{s1}(f_{c1}(\mathbf{N}_1)))) \quad (8)$$

其中, f_{c1} 和 f_{c2} 表示卷积层运算过程; f_{s1} 和 f_{s2} 表示降采样层运算过程。

(3) 反向传播:通过比较实际输出与训练数据标签之间的误差并反向传播至降采样层和卷积层,将核参数向降低误差的方向调整。

$$X'_{ij} = X_{ij} + f_{\text{bp}}(\alpha E_1) \quad (9)$$

其中, X'_{ij} 为调整后的核参数; E_1 为实际输出与数据标签之间的误差,通常表示为二者的方差; $f_{\text{bp}}(\cdot)$ 表示反向传播的运算过程; α 为学习率,用于改变核参数的调整幅度。

CNN 的训练过程即将训练数据输入网络并与标签值对比,从而调整核参数的过程。CNN 利用隐含层中的卷积层和降采样层学习训练数据的深层特征,使网络具备特征提取能力,但是为了使 CNN 得到充分训练并具有较好的泛化能力,需要大量带标签的训练样本数据,这也是制约 CNN 应用的因素之一^[16]。

2.2 模型预训练

如上所述, CNN 在挖掘数据深层特征方面具有很大优势,然而,模型的训练需要海量数据,且会面临数据缺失等问题。本文将迁移学习引入线路故障类型识别 CNN 模型,迁移学习可以对历史数据、类似数据进行迁移应用,能够解决深度学习面临的数据量少、数据缺失等问题。

首先,利用大量源域数据得到预训练模型,作为迁移的基础。本文的预训练模型采用经典 CNN 模型,其结构为输入层、隐含层、全连接层和输出层,其中隐含层由卷积层和降采样层交替构成,是 CNN 提取输入数据深层特征的关键结构^[16]。针对故障选相问题,本文中 CNN 的输入层为经过预处理的线路故障样本,每个故障样本用一个 12×12 维的矩阵表示; CNN 的输出层为一个 1×10 维的矩阵,10 个元素分

别表示样本属于10种故障类型的概率大小,数值越大则表示样本属于该故障类型的可能性越高,CNN将选取概率值最大的故障类型作为样本的故障类型。CNN的层数、特征面数量、卷积核大小、降采样核大小以及训练过程均会影响最终识别的效果,因此本文采用由结构到网络参数再到训练参数的逐层训练步骤,首先根据输入样本的维度,确定CNN的层数和特征面数目并固定;随后利用控制变量法,逐层确定卷积核及降采样核的大小;最后根据识别率和训练时间调整迭代次数、批训练数量和学习效率。最终确定效果较优的CNN结构参数如附录A中的表A2所示。

预训练过程原理如附录A中的图A2所示。预训练过程以初始CNN为基础,输入大量的源域标签数据对CNN进行有监督训练,根据式(9),训练过程中卷积核内部权重会逐步适应源域数据,经过若干次迭代,得到的预训练模型可以准确地对源域测试数据进行故障类型识别,但由于源域与目标域数据的差异性,预训练模型对目标域数据的识别率很低。

3 基于迁移卷积神经网络的模型迁移训练

3.1 迁移卷积神经网络理论框架

本文将经过迁移训练的CNN定义为迁移卷积神经网络T-CNN(Transfer-Convolutional Neural Network)。T-CNN的训练流程如附录A中的图A3所示,具体步骤为:

(1)基于第1节所述的数据生成及处理方法,分别构建源线路和目标线路故障模型,产生大量面向CNN的源域数据样本和少量的目标域数据样本;

(2)利用源域数据对CNN进行预训练,获取适用于源线路的预训练模型;

(3)将预训练模型的网络结构迁移到目标域模型,输入少量目标域数据对卷积核进行微调训练,获取目标域模型。

相对于传统的CNN,T-CNN的优势在于在目标线路故障数据不足或数据缺失的情况下,利用具备类似特征的源线路故障数据获取预训练模型,对预训练模型网络结构进行迁移应用,仅需少量目标域数据对预训练模型进行微调,即可构建适用于目标线路的深度模型。

3.2 源域与目标域相似性检验

与目标域相似性强的源域数据有助于迁移学习,相似性弱的源域数据可能会造成负迁移,因此,源域和目标域之间的相似性检验十分必要。本文利用最大均值差异^[17](MMD)对源域数据和目标域数据进行相似性检验,选取相似性较大的源域数据对应的预训练模型进行迁移。

MMD的原理为:2组样本分别分布于 p 和 q ,计

算其样本空间上的连续函数 $f: X \rightarrow \mathbf{R}$ 随机映射,再计算投影的均值,将2组样本分别对应的均值作差,得到两分布对应于函数 f 的均值差异,当某个 f 对应的均值差异最大时,即取得MMD。将MMD作为检验统计量,可以衡量两分布的相似性。

$$V_{\text{MMD}}(F, p, q) = \sup_{f \in F} (E_x[f(x)] - E_y[f(y)]) \quad (10)$$

其中, V_{MMD} 为MMD值; $\sup_{f \in F}(\cdot)$ 表示集合的上确界, F 为样本数据集 X 映射到实数集 $\mathbf{R}$ 的函数集合, f 为 F 中的一个映射关系; E_x 和 E_y 表示求取映射均值的过程; $x \in p; y \in q$ 。

设源域和目标域分别对应分布 p 和分布 q , X 和 Y 分别为从上述分布中得到的2个数据集,大小分别为 m, n ,则其MMD经验估计值 V'_{MMD} 为:

$$V'_{\text{MMD}}(X, Y) = \left\| \frac{1}{n} \sum_{i=1}^n f(x_i) - \frac{1}{m} \sum_{j=1}^m f(y_j) \right\| \quad (11)$$

MMD越小,表明两分布越相似;MMD为0时表示两分布相同。本文假设有多条源线路可以使用,利用MMD判断各源线路与目标线路的相似性,选取和目标线路相似性最高的一条源线路的故障数据用于CNN预训练,以降低负迁移的可能性。

3.3 模型微调训练

预训练模型具备正确识别源域数据的能力,但不能直接用于识别目标域数据。根据迁移学习的思想,当源域数据与目标域数据具有类似的结构特征时,在预训练模型的基础上,使用少量目标域数据对其进行微调训练,就能够得到效果较好的目标域深度学习模型。

T-CNN微调迁移训练原理如附录A中的图A4所示。设CNN初始状态为 a ,利用源域数据对其进行预训练,CNN参数经过多次自我更新后达到状态 b 。保留预训练模型隐含层的网络结构及卷积核权重、降采样核权重等参数,迁移至目标域模型网络结构,然后利用少量目标域数据对网络进行微调迁移训练,根据式(9),在反向传播过程中,卷积核权重和降采样核权重等参数会自我更新以逐渐适应目标域,最终达到状态 $b+$ 。深度学习模型的直接训练相当于 $a \rightarrow b+$ 的过程,基于迁移学习,只需利用现有的状态 b 模型进行迁移微调训练就可以快速得到状态 $b+$ 的目标域模型。

4 仿真与实验

4.1 源域与目标域数据样本生成

在Simulink中按照图1搭建220 kV单回输电线路故障仿真模型。考虑电网实际运行情况,电网电压、频率、输电线路故障位置、负荷大小及故障过渡电阻取值需覆盖一定范围,因此,制定参数遍历表如

附录B中的表B1所示。遍历所有可变参数的各个取值,提取故障期间的电气量时序数据。为分别产生大量源域数据和少量目标域数据,通过改变线路长度和电气参数分别模拟源线路和目标线路。本文中假设有4条源线路和1条目标线路,其线路参数存在一定差异,如附录B中的表B2所示。

在上述仿真条件下,采集故障期间线路两端的三相电压和电流。每条源线路产生26250组故障数据,目标线路产生2500组故障数据。由于源线路与目标线路存在一定差异性,为了使迁移学习的效果最好,需要选取与目标线路最为相似的1条源线路,在该条源线路的深度学习模型的基础上进行迁移。因此,依据第3节所述相似性检验方法,针对上述4条源线路和1条目标线路,在10种故障类型中各选取一组故障数据用于求取MMD,每条线路可对应计算出10个MMD值,根据10种故障类型的MMD均值,来判定4条源线路与目标线路的相似性。

根据MMD均值,选取与目标线路相似性最高的源线路,选取该源线路产生的26250组故障数据作为源域数据,其中25000组作为预训练数据,1250组作为测试数据;目标线路产生的2500组目标域数据中,1250组作为迁移训练数据,1250组作为测试数据。通过仿真产生的源线路故障时序数据经等间隔采样和归一化处理后如附录B中的图B1所示。

经过等间隔采样和归一化预处理的故障时序数据无法直接用于深度学习模型的训练,需要进一步构建二维矩阵,得到源域和目标域二维数据样本,其中某2组二维数据样本如图3所示,二维数据样本即可作为深度学习模型的输入数据,用于后续的预训练和迁移训练。




图3 二维数据样本灰度图

Fig.3 Grayscale of 2D data sample

4.2 故障识别率影响因素

深度学习模型的结构参数、训练参数会直接影响预训练模型的训练时间和对测试数据的识别准确率,微调率(目标域数据量与源域数据量的比值)会影响预训练模型迁移到目标域模型的效果,本文分别研究上述因素对预训练模型和迁移学习模型的影响。

(1) CNN 结构参数的影响。

利用源域数据对初始CNN进行预训练时,CNN

的结构参数对源域测试数据的识别率有很大影响。设置批训练数量为50,迭代次数为12,其他训练条件均相同,不同CNN结构的训练时间和识别率如图4所示。图中,3-2-2-1表示第1层卷积核大小为 3×3 、第1层降采样核大小为 2×2 、第2层卷积核大小为 2×2 、第2层降采样核大小为 1×1 ,其他结构依此类推。可以看出,预训练模型的训练时间和测试数据的识别率与CNN的卷积核大小和降采样核大小有关,其中结构7-1-3-2对应的识别率高达100%,且训练时间较短,后续的迁移微调训练的网络结构也使用该结构。




图4 不同CNN网络结构下的识别率和训练时间

Fig.4 Recognition rate and training time corresponding to different CNN network structures

(2) 微调率的影响。

整个模型的训练过程中,预训练利用的源域数据量和微调训练利用的目标域数据量之间的关系对模型最终的识别率有较大的影响。图5显示了在源域数据量为25000组、预训练迭代4次、微调训练迭代15次的情况下,模型识别率随微调率的变化情况。可以看出,当微调率较高时有利于模型的训练,当微调率达到5%时,即能够满足训练需要。可见,迁移深度学习只需要少量目标域数据即可实现模型的构建,有助于解决数据量少的问题。




图5 T-CNN 识别率随微调率的变化情况

Fig.5 Recognition rate of T-CNN varying with fine-tuning rate

4.3 预训练模型和目标域模型测试

(1) 预训练模型测试。模型预训练过程中,以25000组源域数据作为预训练输入,以1250组源域数据作为预训练模型测试数据。此外,为观测预训练模型对目标域数据的识别效果,利用1250组目标域测试数据对预训练模型进行测试。附录B中的图B2(a)、(b)展示了利用源域数据和目标域数据对预训练模型进行测试的结果。图中,蓝色表示正确识

别,红色表示错误识别,后同。源域测试数据的测试结果显示,1250组测试样本中没有识别错误的样本,错误率为0;针对目标域测试数据的测试结果显示,1250组测试样本中有870组识别错误,错误率为69.6%。上述结果表明,经源域数据训练得到的预训练模型适用于源域数据的识别,但无法直接应用于目标域数据的识别。

(2)目标域模型测试。在预训练模型的基础上,将1250组目标域数据作为输入,对模型进行微调迁移训练,得到目标域模型,利用1250组目标域测试数据对迁移训练得到的目标域模型进行测试。附录B中的图B3为经过迁移训练的目标域模型识别率测试结果。由图可见,1250组测试样本中,经过微调训练的模型有5组识别错误,错误率为0.4%。上述结果表明,将预训练模型迁移到目标域后,使用少量数据对其进行微调训练,识别效果明显优于直接训练得到的深度学习模型。

4.4 抗谐波干扰性分析

为验证迁移深度学习模型的抗谐波干扰性,在故障仿真模型中引入幅值为5%的3次谐波,生成带谐波干扰的测试数据样本。输入经过迁移训练的目标域模型进行测试,测试结果如附录B中的图B4所示。由图可见,引入幅值为5%的3次谐波的情况下,迁移深度学习模型的识别率达到99.6%,具有较高的抗谐波干扰能力。

4.5 CNN与T-CNN识别率对比

本节研究分别利用CNN、T-CNN时识别率随迭代次数的变化情况。除迁移训练步骤外,T-CNN与CNN的训练条件保持一致,具体训练参数如表2所示,识别率测试结果如图6所示。可以看出,单独利用少量目标域数据训练的CNN模型识别率随着迭代次数的增长而增大,迭代20次时可以达到90%

表2 CNN和T-CNN训练参数

训练参数	CNN	T-CNN	
		预训练	微调训练
批训练数量	25	50	25
迭代次数	5~15	4	5~15
学习率	1	1	1
总数数据量	1250	25000	1250




图6 CNN和T-CNN识别率随迭代次数变化情况

Fig.6 Recognition rate of CNN and T-CNN varying with iterations

以上;而基于预训练模型进行微调训练后,T-CNN模型的识别率在迭代3次后便达到90%以上,且随着迭代次数的增长,识别率维持在99%以上。由此也可以看出在数据量较少时深度迁移学习相对于单独的深度学习具有较大优势。

4.6 实际线路测试

实际中,一条500 kV线路投切至少需要调度、检修、电科院和送变电相配合,不可能完全利用实际线路数据对模型进行迁移。为模拟实际线路的测试效果,利用实际线路的参数构建仿真模型生成适量故障数据,并对预训练模型进行迁移训练,得到适用于实际线路的深度学习模型,再将实际线路的历史故障录波数据输入模型中进行测试。

以江苏尧阳2567线为例,根据故障录波记录,其于2019年12月发生B相接地故障,并具有完整的故障录波数据。尧阳2567线的参数如附录B中的表B3所示。首先基于尧阳2567线路参数构建仿真模型,与前文仿真实验类似,生成1250组故障数据;由于不同线路之间发生故障后的电气量波形具有相似性,利用尧阳线生成的1250组故障数据对4.3节中的源域模型迁移训练,获取适用于尧阳2567线的深度学习模型。

为了验证生成的深度迁移学习模型的可用性,导出尧阳2567线的实际故障录波数据,包括线路两端节点的三相电压和三相电流,波形如附录B中的图B5所示,其中录波采样间隔为312 μ s。进一步对导出电气量进行有效值转换、采样及归一化处理,形成一个 12×12 维的测试样本矩阵。将此测试样本输入迁移训练后的深度学习模型中,导出深度学习模型全连接层的输出,即针对输入的测试样本,利用模型计算得到的10种故障类型概率,输出结果如表3所示。网络最后的Softmax层会选取概率最大的类别作为模型的判别结果,所以针对尧阳2567线路的故障录波数据,深度学习模型判别结果为98.03%的概率为B相接地故障,与实际故障类型一致。

表3 CNN全连接层输出结果

Table 3 Output results of CNN fully connected layer			
故障类型	输出结果	故障类型	输出结果
AG	0.001069	AC	9.87×10^{-6}
BG	0.980307	ABG	0.000422
CG	7.48×10^{-7}	BCG	2.24×10^{-5}
AB	0.017002	ACG	0.00233
BC	1.26×10^{-10}	ABC	6.29×10^{-11}

2019年江苏省共计发生线路故障60次,按照相同的实验过程,对部分故障线路的历史录波数据进行测试,测试结果如表4所示。测试结果表明,本文提出的故障诊断模型能够基于故障录波数据进行故障选相,且准确度很高。同时也证明,在某条线路故障

表 4 部分实际线路测试结果

Table 4 Test results of partial actual transmission lines

线路	实际故障	测试结果
晓中 2578 线	CG	CG
尧阳 2567 线	BG	BG
美延 4559 线	BG	BG
东秦 4531 线	BC	BC
运园 2X24 线	CG	CG
兴白 4657 线	AG	AG
朱淮 2W99 线	AG	AG
任上 5237 线	AG	AG
徐西 4E41 线	BG	BG

数据不足以直接训练深度学习模型时,利用该线路的少量故障数据对现有的源域模型进行微调迁移训练,即可生成适用于该线路的深度学习故障选相模型。

5 结论

本文基于迁移学习和深度学习理论提出了一种输电线路故障选相方法,并通过仿真模型进行了验证。通过理论分析与实验验证,可以得出如下结论。

(1) 基于 CNN 模型可以实现对输电线路故障类型高准确率识别。本文基于 CNN 生成预训练模型的过程中,利用源域测试数据对预训练模型进行了测试,1 250 组测试数据全部识别准确,正确率达到 100%。

(2) 当目标域数据源域数据格式类似时,利用源域数据训练得到的预训练模型可以迁移到目标域模型。本文利用少量目标域数据(源域数据量的 5%)对预训练模型进行迁移训练后,生成的目标域模型可以实现对目标域线路故障类型高准确率识别,且准确率和迭代次数均优于单独的深度学习模型。

(3) 预训练模型迁移到目标域模型的过程中,微调率对于迁移效果具有重要影响。本文研究了目标域模型识别率随微调率的变化情况,当微调率高于某个阈值(本文中微调率阈值为 5%)时迁移效果较好,低于该阈值时迁移效果较差。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] KEZUNOVIC M. Smart fault location for smart grids[J]. IEEE Transactions on Smart Grid, 2011, 2(1): 11-22.
- [2] 黄建明, 李晓明, 瞿合祚, 等. 考虑小波奇异信息与不平衡数据集的输电线路故障识别方法[J]. 中国电机工程学报, 2017, 37(11): 45-53, 311.
HUANG Jianming, LI Xiaoming, QU Hezuo, et al. Method for fault type identification of transmission line considering wavelet singular information and unbalanced dataset[J]. Proceedings of the CSEE, 2017, 37(11): 45-53, 311.
- [3] WANG Yufei, WU Chunguo, WAN Liming, et al. A study on SVM with feature selection for fault diagnosis of power systems[C]//International Conference on Computer & Automation Engineering. Singapore: IEEE, 2010: 173-176.

- [4] 李晓晨, 李天云, 陈昌雷. 基于固有模态能量熵和支持向量机的输电线路故障选相新方法[J]. 电力自动化设备, 2009, 29(5): 104-108.
LI Xiaochen, LI Tianyun, CHEN Changlei. Fault phase selection of transmission lines based on intrinsic mode energy entropy and SVM[J]. Electric Power Automation Equipment, 2009, 29(5): 104-108.
- [5] 林圣, 何正友, 臧天磊, 等. 基于粗神经网络的输电线路故障分类方法[J]. 中国电机工程学报, 2010, 30(28): 72-79.
LIN Sheng, HE Zhengyou, ZANG Tianlei, et al. Novel approach of fault type classification in transmission lines based on rough membership neural networks[J]. Proceedings of the CSEE, 2010, 30(28): 72-79.
- [6] 李东敏, 刘志刚, 苏玉香, 等. 基于多小波包和人工神经网络的电力系统故障类型识别[J]. 电力自动化设备, 2009, 29(1): 99-103.
LI Dongmin, LIU Zhigang, SU Yuxiang, et al. Fault recognition based on multi-wavelet packet and artificial neural network[J]. Electric Power Automation Equipment, 2009, 29(1): 99-103.
- [7] 孙来军, 杨国辉. 故障诊断专家系统高速模糊推理的 CPLD 实现[J]. 电力自动化设备, 2008, 28(7): 107-110.
SUN Laijun, YANG Guohui. High-speed fuzzy reasoning with CPLD in fault diagnosis expert system[J]. Electric Power Automation Equipment, 2008, 28(7): 107-110.
- [8] 魏东, 龚庆武, 来文青, 等. 一种基于卷积神经网络的输电线路区内外故障判断及故障选相方法研究[J]. 中国电机工程学报, 2016, 36(增刊): 21-28.
WEI Dong, GONG Qingwu, LAI Wenqing, et al. Research on internal and external fault diagnosis and fault-selection of transmission line based on convolutional neural network[J]. Proceedings of the CSEE, 2016, 36(Supplement): 21-28.
- [9] YANG Dongsheng, PANG Yongsheng, ZHOU Bowen, et al. Fault diagnosis for energy internet using correlation processing-based convolutional neural networks[J]. IEEE Transactions on Systems, Man and Cybernetics: Systems, 2019, 49(8): 1739-1748.
- [10] WANG Yixing, LIU Meiqin, BAO Zhejing, et al. Stacked sparse autoencoder with PCA and SVM for data-based line trip fault diagnosis in power systems[J]. Neural Computing and Applications, 2019, 31(10): 6719-6731.
- [11] 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, 323.
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, 323.
- [12] OQUAB M, BOTTOU L, LAPTEV I, et al. Learning and transferring mid-level image representations using convolutional neural networks[C]//Computer Vision & Pattern Recognition. Columbus, OH, USA: IEEE, 2014: 1717-1724.
- [13] 刘志宇, 黄亦翔. 基于深度学习和迁移学习的液压泵健康评估方法[J]. 机械与电子, 2018, 36(9): 69-73.
LIU Zhiyu, HUANG Yixiang. Health assessment for hydraulic pump based on deep learning and transfer learning[J]. Machinery & Electronics, 2018, 36(9): 69-73.
- [14] 周念成, 廖建权, 王强钢, 等. 深度学习在智能电网中的应用现状分析与展望[J]. 电力系统自动化, 2019, 43(4): 267-284.
ZHOU Niancheng, LIAO Jianquan, WANG Qianggang, et al. Analysis and prospect of deep learning application in smart grid[J]. Automation of Electric Power Systems, 2019, 43(4): 267-284.
- [15] 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: AMC, 2012: 1097-1105.

- [16] 周飞燕,金林鹏,董军. 卷积神经网络研究综述[J]. 计算机学报,2017,40(6):1229-1251.
ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [17] 王毅星. 基于深度学习和迁移学习的电力数据挖掘技术研究[D]. 杭州:浙江大学, 2019.
WANG Yixing. Power data mining technology based on deep learning and transfer learning[D]. Hangzhou: Zhejiang University, 2019.
- [18] 邱宁佳,王晓霞,王鹏,等. 结合迁移学习模型的卷积神经网络算法研究[J]. 计算机工程与应用, 2019(5):1-8.
QIU Ningjia, WANG Xiaoxia, WANG Peng, et al. Research on convolutional neural network algorithm combined with transfer learning model[J]. Computer Engineering and Applications, 2019(5): 1-8.
- [19] 何俊涛,车仁飞,孟庆萌,等. 基于广域录波数据和FCM聚类的电网故障诊断方法[J]. 电力自动化设备, 2019, 39(5): 179-184.
HE Juntao, CHE Renfei, MENG Qingmeng, et al. Fault diagnosis method of power grid based on wide-area recorder data and fuzzy C-means clustering[J]. Electric Power Automation Equipment, 2019, 39(5): 179-184.
- [20] 宋福海. 基于信息触发的智能变电站保护功能判定方法研究[J]. 电力工程技术, 2019, 38(6): 99-106.
SONG Fuhai. Decision method of protection function of intelligent substation based on information triggering[J]. Electric Power Engineering Technology, 2019, 38(6): 99-106.
- [21] 黄新波,胡潇文,朱永灿,等. 基于卷积神经网络算法的高压断路器故障诊断[J]. 电力自动化设备, 2018, 38(5): 136-140, 147.
HUANG Xinbo, HU Xiaowen, ZHU Yongcan, et al. Fault diagnosis of high-voltage circuit breaker based on convolution neural network[J]. Electric Power Automation Equipment, 2018, 38(5): 136-140, 147.
- [22] 黄凯,邱颖宁,秦伟,等. 基于实时电流幅值的风电整流器故障诊断方法[J]. 电力工程技术, 2019, 38(2): 25-31.
HAUNG Kai, QIU Yingning, QIN Wei, et al. Fault diagnosis algorithm for wind power rectifier based on real-time current amplitude[J]. Electric Power Engineering Technology, 2019, 38(2): 25-31.
- [23] 刘文泽,张俊,邓焱. 基于深度置信网络和多维信息融合的变压器故障诊断方法[J]. 电力工程技术, 2019, 38(6): 16-23.
LIU Wenze, ZHANG Jun, DENG Yan. Transformer fault diagnosis method based on deep learning and multi-dimensional information fusion[J]. Electric Power Engineering Technology, 2019, 38(6): 16-23.
- [24] 吴素我,张焰,苏运. 基于配用电数据关联的中压配电网断线故障诊断方法[J]. 电力自动化设备, 2017, 37(7): 101-109.
WU Suwo, ZHANG Yan, SU Yun. Open-line fault diagnosis based on data association of MV distribution network [J]. Electric Power Automation Equipment, 2017, 37(7): 101-109.

作者简介:



杨毅

杨毅(1983—),男,江苏南京人,高级工程师,博士,研究方向为电力系统保护与控制、电力工控安全、柔性交流输电技术等(E-mail: yang_yi_ee@163.com);

殷浩然(1997—),男,河北保定人,硕士研究生,通信作者,研究方向为人工智能在电力系统中的应用(E-mail: hr_yin@126.com);

苗世洪(1963—),男,湖北随州人,教授,博士,研究方向为电力系统继电保护及其自动化、电力系统智能调度与自动化等(E-mail: shmiao@hust.edu.cn)。

(编辑 任思思)

Transmission line fault phase selection model based on deep-transfer learning and its transferability

YANG Yi¹, FAN Dongchen¹, YIN Haoran^{2,3}, HAN Ji^{2,3}, MIAO Shihong^{2,3}

(1. State Grid Jiangsu Electric Power Research Institute, Nanjing 211103, China;

2. State Key Laboratory of Advanced Electromagnetic Engineering and Technology, School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China;

3. Hubei Electric Power Security and High Efficiency Key Laboratory, Wuhan 430074, China)

Abstract: In order to improve the transferability of transmission line fault diagnosis models, the transmission lines are divided into source lines and target lines based on transfer learning theory, then a method based on deep-transfer learning for identifying transmission line fault types is proposed. The time series data during transmission line faults is generated by combining different fault conditions, and the input data samples of CNN (Convolutional Neural Network) are obtained by data preprocessing. Then the initial CNN is pre-trained by using the source domain data to obtain a pre-trained model of the source line fault type identification. Next, the maximum mean difference method is used to test the similarity of source and target lines, and the source domain pre-trained model to be migrated is screened out. The target domain data is used to fine-tune the migration training to obtain the final target domain fault diagnosis model. The simulative results show that by using the target domain data of 5% of the source domain data to fine-tune the migration training of the pre-trained model, the target line fault diagnosis accuracy of the target domain model can reach more than 99%.

Key words: power transmission line; transfer learning; deep learning; fault type identification; convolutional neural network

表 A1 仿真模型参数表
Table A1 Simulation model parameter

元件	元件参数
G_1	18kV, 50Hz
G_2	220kV, 50Hz
变压器变比 k	242 kV /18 kV
线路长度 L	60km
负荷	100MW
过渡电阻	0~100 Ω

注：发电机和变压器参数取典型值。




图 A1 典型 CNN 结构
Fig.A1 Typical structure of CNN

表 A2 CNN 模型结构及参数
Table A2 Structure and parameters of CNN model

序号	结构	参数
1	输入层	12×12
2	卷积层	卷积核大小 7×7，卷积步长为 1
3	特征面	6 组，6×6
4	降采样层	降采样核大小 1×1，采样步长为 2
5	卷积层	卷积核大小 3×3，卷积步长为 1
6	特征面	12 组，4×4
7	降采样层	降采样核大小 2×2，采样步长为 2
8	Softmax 层	—
9	输出层	1×10 维概率向量




图 A2 预训练过程原理图
Fig.A2 Principle diagram of pre-training process




图 A3 T-CNN 模型训练过程理论框图

Fig.A3 Theoretical block diagram of T-CNN model training process




图 A4 T-CNN 微调迁移训练原理图

Fig.A4 Principle diagram of T-CNN fine-tuning transfer training

表 B1 故障仿真模型参数遍历表

Table B1 Traversal table of fault simulation model parameter

参数	取值
电压/kV	198, 209, 220, 231, 242
频率/Hz	49, 49.5, 50, 50.5, 51
故障位置/km	1, 0.17l, 0.33l, 0.67l, 0.83l, l-1
负荷/MW	100, 80, 120
过渡电阻/ Ω	0.1, 1, 5, 10, 100
故障类型	ABC, AB, AC, BC, ABG, ACG, BCG, AG, BG, CG

表 B2 源线路和目标线路参数

Table B2 Source line and target line parameters

线路	长度/km	$(R_1, R_0) / (\Omega \cdot \text{km}^{-1})$	$(L_1, L_0) / (\text{H} \cdot \text{km}^{-1})$	$(C_1, C_0) / (\text{F} \cdot \text{km}^{-1})$
源线路 L_1	90	(0.1225, 0.403)	(1.11×10^{-3} , 3.41×10^{-3})	(11.33×10^{-9} , 5.01×10^{-9})
源线路 L_2	100	(0.12, 0.413)	(1.05×10^{-3} , 3.25×10^{-3})	(11.5×10^{-9} , 5.01×10^{-9})
源线路 L_3	60	(0.1153, 0.413)	(1.08×10^{-3} , 3.32×10^{-3})	(11×10^{-9} , 5.01×10^{-9})
源线路 L_4	70	(0.11, 0.413)	(1×10^{-3} , 3.32×10^{-3})	(12×10^{-9} , 5.01×10^{-9})
目标线路 L_0	80	(0.12, 0.413)	(1.08×10^{-3}, 3.32×10^{-3})	(11×10^{-9}, 5.01×10^{-9})




图 B1 预处理后的时序数据

Fig.B1 Preprocessed time series data




图 B2 预训练模型测试结果

Fig.B2 Results of pre-training model test




图 B3 迁移训练模型测试结果
Fig.B3 Schematic diagram of transfer model




图 B4 T-CNN 抗谐波能力测试结果
Fig.B4 Results of anti-harmonic ability of T-CNN test

表 B3 尧阳 2567 线参数
Table B3 Parameters of Yaoyang 2567 line

电压等级	长度	R_1/Ω	X_1/Ω	R_0/Ω	X_0/Ω
220kV	15.952km	0.569	5.403	2.074	11.954




图 B5 尧阳 2567 线路故障录波数据
Fig.B5 Wave recording data of Yaoyang 2567 Line