

DOI:10.12158/j.2096-3203.2019.05.002

基于 TensorFlow 框架的有源配电网深度学习故障定位方法

刘成民¹, 戴中坚², 陈轩¹

(1. 国网江苏省电力有限公司检修分公司, 江苏 南京 211102;

2. 东南大学电气工程学院, 江苏 南京 210096)

摘要:随着大规模分布式电源(DG)接入配电网,配电网的结构由传统的辐射型变为多端电源结构,传统的故障定位方法不再完全满足含DG的配电网系统,对此提出一种基于深度学习的有源配电网故障定位方法。首先通过馈线监控终端采集过电流故障数据与节点电压数据,结合各电源出力数据,形成故障数据向量;然后使用Tensorflow构建基于全连接网络的深度神经网络模型,挖掘故障数据向量与故障支路之间的映射联系,形成故障定位模型;最后利用该模型在线定位故障并验证其有效性。模型测试结果表明,与反向传播神经网络、学习向量量化神经网络模型相比,深度学习模型收敛速度更快,故障定位准确率更高,同时在数据畸变或缺失时,模型具有较高的容错性。

关键词:Tensorflow;分布式电源;配电网;深度学习;故障定位

中图分类号:TM711

文献标志码:A

文章编号:2096-3203(2019)05-0008-08

0 引言

随着一流配电网建设的开展,社会对供电可靠性要求越来越高^[1-2]。配电网故障定位技术能够在配电网馈线支路发生故障时,及时准确地定位故障区段,以便隔离故障区域并尽快恢复非故障区域供电,对提高供电可靠性具有重要意义^[3-7]。

分布式电源(distributed generation, DG)的分散式接入使得传统配电网从单电源辐射状网变为功率双向流动的复杂多源网络,具有拓扑结构复杂,潮流方向多变以及DG出力不定等特点^[8-10]。其故障特征与传统配电网存在较大差异,使得配电网现有的继电保护容易发生误动和拒动^[11-12],传统的故障定位方法不再完全适用^[13]。

目前,针对含DG配电网的故障定位研究按照定位精度可以分为故障区段定位和故障精确定位。故障精确定位一般适用于长直导线的故障测距,很少用于线路长度较短的含DG配电网^[14]。故障区段定位法按照采集故障特征的不同分为稳态法^[15-16]和暂态法^[17-20]。相较于基于稳态电气量特征的故障区段定位,暂态特征量不易监测,硬件设备昂贵,而在限制一定DG渗透率的情况下,基于稳态电气特征量差异的故障区段定位依然有效^[21],其按照具体算法的不同主要分为矩阵法^[22-23]和人工智能法^[24-25]。矩阵法基于图论,具有建模直接,定位

高效等优点,但容错率不高,易受逻辑矩阵中数值稳定性制约^[26]。人工智能法通过构建网络模型实现故障定位,能容忍数据缺失,但该类方法模型构建复杂,且对通信的实时性要求较高。

配电自动化的发展使得数据采集与通信传输问题有效改善。文献[27]基于多种群遗传算法对含DG的配电网故障区段定位,但是其使用的随机迭代搜索算法容易产生局部最优;文献[28]基于学习向量量化(learning vector quantization, LVQ)神经网络,对不同分支的反射行波进行特征提取,但在大样本下的表现还有待进一步研究;文献[29]使用广域量测系统实时量测信息,但数据采集智能电子设备(intelligent electronic device, IED)数量较多。

文中根据Tensorflow框架,提出一种基于深度学习的有源配电网故障定位方法。介绍了TensorFlow框架及其深度学习模型结构,提出一种故障数据处理方式,通过馈线监控终端(feeder terminal unit, FTU)采集故障过电流数据与节点电压数据,结合各电源出力,形成故障数据向量集,基于全连接网络(fully connected network, FCN)的深度神经网络(deep neural network, DNN)模型,将采集的故障数据向量集载入模型,完成故障定位。经算例对比验证,证实该方法能准确故障定位,并对数据畸形与缺失有较好的容错率。

1 深度学习框架Tensorflow及模型介绍

1.1 Tensorflow 框架

TensorFlow 是当今最为流行的深度学习框架,

收稿日期:2019-03-17;修回日期:2019-04-21

基金项目:国家电网有限公司总部科技项目(SGTYHT/17-JS-199)

是谷歌基于 DistBelief 研发的第二代人工智能学习系统,该框架中所有数据均以 Tensor(张量)形式流动。文中根据各节点的 FTU 装置得到故障数据向量数据集,通过 Tensorflow 框架,构建并训练 DNN 模型,实现故障定位。

1.2 基于 Tensorflow 框架的深度学习模型

文中基于 TensorFlow 搭建的深度学习模型中数据传输方向如图 1 所示,主要分为数据处理与模型搭建 2 部分。第一部分为有源配电网故障数据处理。根据各节点的 FTU 装置采集过电流故障数据与节点电压数据,结合各电源的出力得到故障数据向量数据集,同时对数据进行标签化与数据清洗。第二部分为在 Tensorflow 框架内构建基于 DNN 的有源配电网故障定位模型,使用经过处理与标签化的故障数据训练,在训练结束后形成最终的故障定位模型。

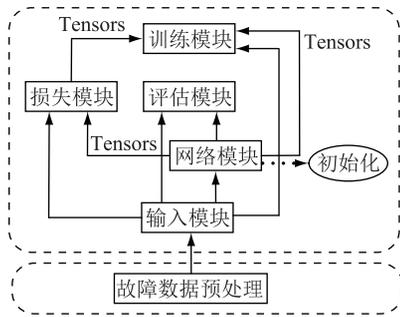


图 1 基于 Tensorflow 框架的深度学习模型

Fig.1 Deep learning model based on Tensorflow

2 有源配电网故障数据处理

2.1 有源配电网故障数据向量

当馈线发生故障时,安装于各分段开关处的 FTU 会监测到故障电流,将带有时标的过电流报警信息传输到控制主站,可以通过采集监测点电流与电压值按学习特征规律实现故障定位^[30]。由于 DG 的接入,配电网拓扑结构变得更加复杂,其故障电流方向与单电源故障时的电流方向不同,容易产生误判,所以需要传统故障数据进行处理。

首先在每个开关处装置一个功率方向继电器监测电流方向,同时数据向量需要加入主电源及各 DG 的出力。定义距离该节点最近的电源为节点主电源,该开关 FTU 监测电流正方向为主电源单独工作时的电流方向,扩展后的故障数据向量为式(1)。

$$\mathbf{a}_i = [i_1, i_2, \dots, i_n, u_1, u_2, \dots, u_n, P_{DG1}, P_{DG2}, \dots, P_{DGm}] \quad (1)$$

式中: i_n 为节点 n 处 FTU 采集到的三相电流值,包含 3 个维度,当电流方向监测为负方向时,取为负

值; u_n 为第 n 个 FTU 采集的节点电压值; P_{DGm} 为第 m 个 DG 的有功出力。

2.2 故障数据标签 One-Hot 编码

由于所构建的深度学习结构为有监督学习,故障支路作为标签,因此需要对标签进行编码处理。故障支路标签数据为离散值,具有分类特征,所以使用 One-Hot 编码处理故障支路标签,编码规则如表 1 所示。

表 1 One-Hot 编码

Table 1 One-Hot code

故障支路	自然编码	One-Hot 编码
1—2	00	0001
2—3	01	0010
3—4	10	0100
4—5	11	1000

2.3 故障数据畸形缺失处理及标准化

实际中由于多种原因,FTU 上传数据时会遇到数据畸变或者缺失问题。数据清洗包括无效数据清除,缺失值处理等,数据清洗的目的是消除数据中的错误、冗余和数据噪音。当在数据预处理阶段监测到某数据异常时,该数据将被历史故障数据集的此点数据平均值覆盖。

同时,为了防止数据中数量级差异,导致训练时数据淹没,故障数据向量在作为输入数据之前,均需要通过归一标准化,预处理后,各维数据值均处于 0~1 域内。在本模型中,归一化处理采用 min-max 法,其主要计算方式如式(2)所示。

$$\mathbf{y}_n^* = \frac{\mathbf{y}_n - \min(n)}{\max(n) - \min(n)} \quad (2)$$

式中: $\mathbf{y} = [y_1, y_2, y_3, \dots, y_i]$; i 为数据集维数; $\max(n)$ 为 n 维样本数据的最大值; $\min(n)$ 为 n 维样本数据的最小值。

3 基于深度学习的有源配电网故障定位模型

3.1 有源配电网故障定位逻辑

文中提出一种基于深度学习的有源配电网故障定位模型,模型的基本逻辑结构如图 2 所示。该模型通过深度学习挖掘故障支路与故障数据之间的非线性映射关系,对故障区段进行定位。该方法的具体实现步骤如下:

(1) 首先对已有的历史故障向量数据集预处理,并划分为训练集与测试集,对训练集数据激励。

(2) 在 Tensorflow 框架内,构建或更新基于 FCN 的 DNN 模型,对多隐层神经元采用随机失

活技术(Dropout)。

(3) 每个步长内,通过步骤(1)所得训练集激励数据,在 DNN 模型中进行学习训练,计算损失值并以减少该值为目标梯度优化,给出反馈调节 DNN 参数信号以供网络参数调整使用。

(4) 每个步长内,经过步骤(2)–(3),能够生成故障定位模型。使用步骤(1)所得的测试集数据载入该定位模型,测试模型准确率,从而监测训练步数增多时,模型效果的变化。

(5) 若达到设置步长,则停止训练,并输出最终故障定位模型。若未达到训练步长,则模型根据步骤(3)调整信号,更新 DNN 参数,重复步骤(2)–(4),继续训练直至达到设定步长。

(6) 已有最终故障定位模型。若发生故障,则将采集的故障向量数据载入模型,输出故障定位支路,实现对有源配电网的故障定位。

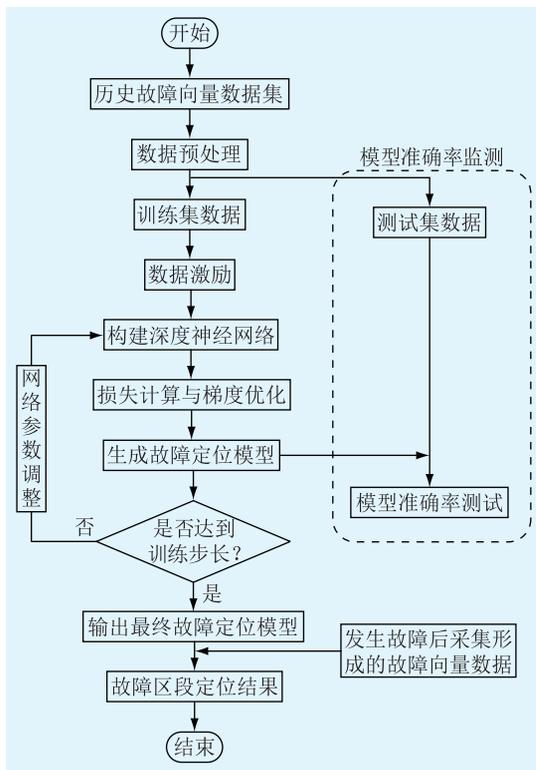


图2 有源配电网故障定位方法

Fig.2 Flow chart of distribution network fault location with distributed generation

3.2 输入模块

在输入模块中,需要使用到激活函数对数据进行激励,主要体现为图2的数据激励部分。深度学习模型使用数据为来自于配电网发生故障时 FTU 的改进故障数据向量。数据集分为 10 000 条数据的训练集,1 000 条测试集,每条数据对应的标签数据为故障支路。

由于故障定位问题可以考虑为多分类问题,文中使用 softmax 激励函数,如式(3)所示。

$$\sigma_j(\mathbf{z}) = e^{z_j} / \sum_{i=1}^k e^{z_i} \quad (3)$$

式中: j 为分类数目; $\mathbf{z}=[z_1, z_2, z_3, \dots, z_i]$ 为输出层预测向量; $\sigma_j(\mathbf{z})$ 为属于 j 类的概率。

通过激励函数,可以表示不同支路的故障概率,概率最大的支路标签即为预测故障支路。

3.3 网络模块

3.3.1 DNN 模型

在网络模块中,需搭建 DNN 模型。根据 3.2 节所使用的输入数据维度与标签数据维度确定其网络结构参数。为了实现有源配电网故障定位,文中利用一个由 3 层 FCN 组成的 DNN 结构,实现多层特征匹配训练,对故障数据向量与对应故障支路映射。DNN 模型结构如图 3 所示。

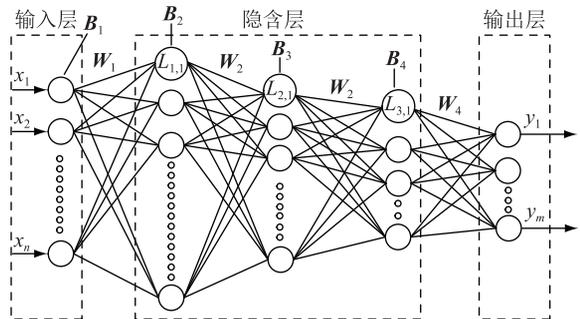


图3 深度神经网络结构

Fig.3 Deep learning network structure

其中,输入层中 $\mathbf{x}=[x_1, x_2, \dots, x_n]$ 为故障数据向量, n 为故障数据向量集的维度,输出层中 $\mathbf{y}=[y_1, y_2, \dots, y_m]$, m 为数据中故障支路标签个数; $\mathbf{W}_1, \mathbf{W}_2, \mathbf{W}_3, \mathbf{W}_4$ 均为二阶权重矩阵,表示相邻网络层的连接权重; $\mathbf{B}_1, \mathbf{B}_2, \mathbf{B}_3, \mathbf{B}_4$ 均为偏置矩阵,表示该层网络各神经元的偏置值; $L_{k,t}$ 为第 k 层网络层的第 t 个节点。

该 DNN 模型能够根据输入层输入数据的维度调整每层隐含层的神经元个数。以 IEEE 33 节点算例为例,故障数据向量维度为 132 维,可故障支路共 31 条。所以输入层的输入数据为 132 维,输出层输出数据为 31 维。隐含层维数由经验公式确定,公式可参考文献[31]。

3.3.2 网络神经元 Dropout

在网络模块中,由于所搭建的深度学习 DNN 模型包含 3 层隐含层,模型参数较多,为了避免模型参数膨胀,陷入过拟合,对网络神经元采取 Dropout,在每一个输入样本训练一个模型,然后在测试阶段将每个模型取均值,通过所有模型共同作用,将样本

最有用的信息提取出来,并且能够过滤部分噪声。具体过程如下:

(1) 以随机概率 p 删除第 k 层网络中部分隐藏神经元,相邻层的神经元个数保持不变。

(2) 第 k 层网络中神经元的输入通过修改后的第 k 层网络前向传播,将得到的损失结果通过修改后的第 k 层网络反向传播。

(3) 训练一个批次的故障数据向量集,更新第 k 层未被删除的神经元中的偏置矩阵 \mathbf{B}_k 和其与第 $k+1$ 层神经元连接权重矩阵 \mathbf{W}_{k+1} ,删除的神经元参数保持不变。

(4) 重复步骤(1)–(3),直至训练结束。

使用 Tensorflow 框架中 Dropout 函数进行操作,Dropout 超参数通过试凑法设为 0.5。

3.4 损失模块与训练模块

在损失模块中,使用交叉熵损失函数计算损失,主要表现为预测值与实际值的偏离距离。所用交叉熵损失函数如式(4)所示。

$$f_{\text{loss}} = - \sum_{i=1}^n y_{\text{label}} \lg(y_{\text{pre}}) \quad (4)$$

式中: f_{loss} 为交叉熵损失值率; y_{label} 为标签向量; y_{pre} 为预测向量。

在训练模块中,主要根据数据结构,采用最佳优化函数,以减少损失模块输出损失量为主要目标,其能够反向传播数据,对 DNN 参数进行反馈调节,实现对模型的训练学习。考虑到数据标签采用 One-Hot 编码,为稀疏矩阵,优化函数一般采用 Adam、SGD 或 Momentum 函数。经算例对比验证,采用 Tensorflow 框架封装的 Adam 算法,处理该类稀疏结构数据效果最好,且能有效进行调节反馈学习。设置函数训练步长为标准值 0.01。

3.5 评估模块

在评估模块中需要监测模型定位准确率,在每个训练步长结束,均会形成有源配电网故障定位模型,此时需要通过测试集数据对模型进行测试,验证模型的正确性。文中使用准确率评估算法评估所建立的模型。定义标签数据为故障支路标号,算法如式(5)与式(6)所示。

$$H[x, y] = \begin{cases} 0 & x \neq y \\ 1 & x = y \end{cases} \quad (5)$$

$$P_{\text{acc}} = \frac{\sum_{i=1}^n H[L_{\text{max}}(y_{\text{label}}), L_{\text{max}}(y_{\text{pre}})]}{n} \quad (6)$$

式中: $L_{\text{max}}(y)$ 为标签向量 y 中最大值所在标号; P_{acc} 为故障定位准确率。

定位准确率表示了所建深度学习故障定位模

型中预测标签与实际标签的匹配样本数占有所有样本数的比值。定位准确率能反映所建深度学习模型训练正确性,定位准确率越高,代表模型的精确度越高。

文中在算法最后加入监测部分,由于每个训练步长均会使用测试集测试模型定位准确率,采用固定步长输出定位准确率值,通过模型定位准确率变化曲线能实时掌控模型精确度,同时能为总结模型的训练习惯,避免出现局部最优点现象提供方向。

4 算例分析

4.1 算例说明

为了验证方法的有效性,文中以 IEEE 33 节点^[32]为原型,在 Matlab 中搭建含 DG 配电网模型进行仿真,形成历史故障向量数据集,拓扑结构如图 4 所示。各节点均装置有 FTU 监测点,在 17、21 及 24 节点处装配 3 台 DG。历史故障数据集通过 Matlab 建模仿真实现对实际数据的补充。每次仿真均假设为考虑负荷及 DG 出力不断变化的单支路故障,其中负荷与 DG 出力数据为方差均为 5% 的随机值以模拟实际的电网波动情况。

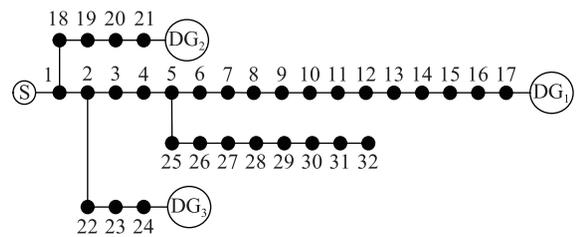


图 4 有源配电网拓扑

Fig.4 Active distribution network topology

文中对比另外以下几种能使用同故障数据集故障定位的方法:(1) 文中方法,使用 Tensorflow 框架,深度学习模型包含 3 层隐含层,每层神经元 100 个,隐含层使用 Dropout 技术,Adam 优化函数学习率为 0.01。(2) 传统反向传播(back propagation, BP)神经网络算法,采用 Matlab 建模,隐含层神经元 300 个,激活函数为 Sigmoid 函数。(3) 基于 LVQ 的故障定位算法,采用 Matlab 建模,竞争层神经元 300 个,学习率 0.1。

在训练时,均规定训练步长为 1 000 步,输出最终模型与测试集跟随模型不断训练的准确率曲线结果,此时神经网络均处于收敛阶段。

4.2 故障定位模型定位结果验证

文中一共训练 2 种模型,首次训练时训练集数据均为正常数据,最终模型为 M_1 ;第二次模型训练时,在训练数据集中选取约 200 条数据,设置了部分

节点的 FTU 上传数据畸形或缺失,最终模型为 M_2 。利用 2 种故障定位模型对故障定位进行分析,结果如表 2 所示。

表 2 单相短路故障下配电网故障区段定位结果

Table 2 Partial results of fault section location under single phase short circuit fault for distribution network

模型	故障区段	信息畸形或缺失节点	基于 LVQ 方法定位结果	基于深度学习定位结果
M_1	区段 10—11	无	区段 10—11	区段 10—11
	区段 4—5	无	区段 4—5	区段 4—5
	区段 10—11	4	区段 11—12	区段 10—11
	区段 4—5	4,10	区段 25—26	区段 7—8
	区段 4—5	4,5	区段 5—25	区段 6—7
M_2	区段 10—11	无	区段 10—11	区段 10—11
	区段 4—5	无	区段 4—5	区段 4—5
	区段 10—11	4	区段 11—12	区段 10—11
	区段 4—5	4,10	区段 25—26	区段 4—5
	区段 4—5	4,5	区段 10—11	区段 6—7

分析表 2,在 FTU 数据正常情况下训练的模型 M_1 ,当故障发生时有单节点数据畸形或缺失的情况下,基于深度学习的故障定位模型仍能定位准确,但对故障区段相关节点出多数据畸形则会误判,这表示虽然有数据预处理的过程,但是对于相关性高的多节点畸形,经过处理后仍然缺失特征,难以定位。如果在数据中加入部分畸形或缺失数据进行训练得到模型 M_2 ,则在 2 个节点信息畸形时,若节点非故障区段端点,仍能准确定位,但若是故障区段端点,则由于端节点相关性高,采用数据预处理仍无法使 DNN 映射正确区段。

4.3 模型测试结果对比分析

4.3.1 Dropout 对结果的影响分析

从损失值的变化曲线分析是否采用 Dropout 技术对最终结果的影响。使用 Tensorflow 框架构建模型进行仿真,Dropout 参数设置为 0.5,每 50 个训练步长导出当前模型损失值,是否采用 Dropout 的损失值对比如图 5 所示。

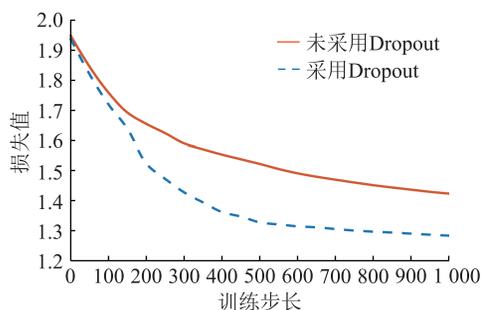


图 5 采用 Dropout 前后损失值对比

Fig.5 Comparison of loss values before and after using Dropout

由此可得,经过 1 000 个步长的训练,未采用 Dropout 技术则在约 150 步长后逐渐收敛,且损失值很高,表示陷入过拟合,而采用 Dropout 技术后,损失值能够持续减少。综合可见,运用 Dropout 能有效避免陷入过拟合,损失值能够有效地传输到底层进行调参,这也体现在最终模型准确率中。

4.3.2 优化函数对结果的影响分析

从测试集预测准确率分析优化函数对训练结果的影响。一共比较 3 种优化函数,分别是 Adam 函数、SGD 函数及 Momentum 函数,学习率参数通过试凑法选取。实际训练模型过程中每 50 个训练步长导出当前模型准确率值,3 种优化函数的准确率对比如图 6 所示。

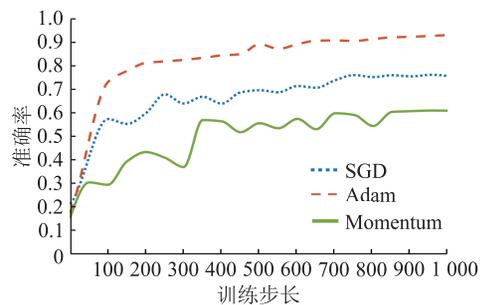


图 6 不同优化函数下模型准确率对比

Fig.6 Comparison of model accuracy using different optimizers

由此可得,对比 Adam、SGD、Momentum 3 种优化函数,采用 Adam 函数的模型收敛速度更快,在 150 步时可看出收敛现象,同时最终准确率为 0.930 8;SGD 法表现中等,最终准确率为 0.754 9;而 Momentum 法表现最差,最终准确率为 0.607 1,且在 850 步前一直处于强振荡状态。因此由 FTU 采集的节点电压过电流数据等组成的故障向量数据集,采用 Adam 优化函数最为合适,并且 Adam 优化函数能根据每个步长训练,自适应地调整学习率,能更好地适应该 DNN 结构。

4.3.3 不同故障定位方法结果对比

文中共比较 3 种方法(BP、LVQ、深度学习),每 50 个训练步长导出当前模型准确率值,3 种方法准确率曲线对比如图 7 所示。

使用测试集数据对比,基于深度学习的故障定位模型最终准确率为 0.930 8。BP 神经网络模型的最高准确率为 0.771 3, LVQ 神经网络准确率为 0.852 8。BP、LVQ 神经网络仅凭借单隐层难以高效提取故障特征向量中的非线性特征,准确率不高。而深度学习方法凭借对数据特征的处理以及多层隐层调参,可有效利用节点过电流、电压数据以及电源出力数据对故障支路的高精度映射。

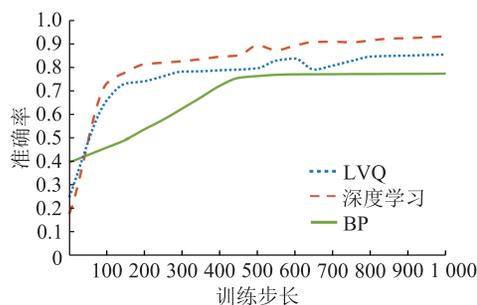


图7 深度学习模型与传统BP神经网络模型准确率对比

Fig.7 Comparison of accuracy between deep learning model and BP neural network model

5 结论

文中针对有源配电网,提出一种基于深度学习的故障定位方法。首先通过FTU采集过电流故障数据与节点电压数据,结合各电源出力数据,形成故障数据向量;然后使用Tensorflow构建基于FCN的DNN模型;最后,在发生故障时,根据故障数据载入模型,完成故障定位,并且将本次故障数据扩充至历史数据集中。文中通过算例仿真得出以下几点结论:

(1) 所提定位方法不受DG接入规模的影响,同时对神经元采用Dropout能有效避免过拟合。与BP、LVQ神经网络模型相比,该模型准确度更高,收敛速度更快,有效缩短模型的计算时间,为在线调整模型参数提供技术支持。

(2) 模型在训练数据无畸形缺失情况下,模型准确率很高,若多节点数据畸形或缺失,在历史故障向量数据集中加入少量的畸形数据,能够对模型进行修正,提高模型容错率。

(3) 深度神经网络训练时需要设置很多超参数。例如Dropout参数,优化函数学习率,网络层数,隐含层神经元个数等,所提方法只在有限的仿真使用试凑法选取最合适的参数,但由于参数与结果具有非相关性,所以,如何合理设置超参数,以提高模型的准确性,加快模型收敛速度,是后续研究重点之一。

参考文献:

[1] 胡顺威,周晖,从黎,等. 基于故障树的含电力电子变电站配电网可靠性分析[J]. 电力系统保护与控制,2018,46(21):25-31.
HU Shunwei,ZHOU Hui,CONG Li,et al. Reliability analysis of distribution network with power electronic substation based on fault tree[J]. Power System Protection and Control,2018,46(21):25-31.

[2] 潘翀,袁霞,唐伦. 大型城市高压配电网可靠性分析[J]. 电力系统保护与控制,2017,45(3):131-138.

PAN Chong, YUAN Xia, TANG Lun. Reliability analysis for high voltage distribution network in big cities[J]. Power System Protection and Control,2017,45(3):131-138.

[3] 唐金锐,尹项根,张哲,等. 配电网故障自动定位技术研究综述[J]. 电力自动化设备,2013,33(5):7-13.
TANG Jinrui, YIN Xianggen, ZHANG Zhe, et al. Survey of fault location technology for distribution networks [J]. Electric Power Automation Equipment, 2013,33(5):7-13.

[4] 陈彬. 基于稳态特征的配电网小电流接地故障定位方法[J]. 广东电力,2017,30(10):116-120.
CHEN Bin. Grounding fault location method for small current of power distribution network based on steady-state characteristic [J]. Guangdong Electric Power,2017,30(10):116-120.

[5] 朱正鼎,潘文霞,苏铸. 新型基于频率特性的电缆故障定位方法[J]. 广东电力,2018,31(12):86-92.
ZHU Zhengding, PAN Wenxia, SU Qi, et al. New cable fault location method based on frequency characteristics [J]. Guangdong Electric Power,2018,31(12):86-92.

[6] 刘健,董新洲,陈星鸾. 配电网故障定位与供电恢复[M]. 北京:中国电力出版社,2012:1-8.
LIU Jian, DONG Xinzhou, CHEN Xingluan. Fault location and power restoration for distribution network [M]. Beijing: China Electric Power Press,2012:1-8.

[7] 何正友. 配电网故障诊断[M]. 成都:西南交通大学出版社,2011:1-9.
HE Zhengyou. Distribution network fault diagnosis [M]. Chengdu:Southwest Jiaotong University Press,2011:1-9.

[8] 牛耕,周龙,裴玮,等. 低压有源配电网在线故障区间定位与识别方法[J]. 中国电机工程学报,2017,37(9):55-69.
NIU Geng, ZHOU Long, PEI Wei, et al. On-line fault section location and classification technique for low voltage active distribution network [J]. Proceedings of the CSEE,2017,37(9):55-69.

[9] 张振伟,赵晋泉,韩佳兵,等. 考虑大量分布式电源接入的主配网协同优化控制[J]. 电网与清洁能源,2017,33(7):110-115.
ZHANG Zhenwei, ZHAO Jinqun, HAN Jiabing, et al. Collaborative optimization control of the transmission and distribution networks considering a large number of dgs connected [J]. Power System and Clean Energy,2017,33(7):110-115.

[10] 周海军,王飞,周冬. 含分布式电源配电网故障的Petri网诊断方法[J]. 电网与清洁能源,2018,34(9):39-46.
ZHOU Haijun, WANG Fei, ZHOU Dong. A petri net diagnosis method for distribution network faults with distributed generation access [J]. Power System and Clean Energy,2018,34(9):39-46.

[11] FIROUZ Y, FARHADKHANI S, SALIM R, et al. Numerical comparison of the effects of different types of distributed generation units on overcurrent protection systems in MV distribution grids[J]. Renewable Energy,2014,69(9):271-283.

[12] CONTI S, NICOTRA S. Procedures for fault location and isolation to solve protection selectivity problems in MV distribution

- networks with dispersed generation [J]. Electric Power Systems Research, 2009, 79(1): 57-64.
- [13] 王飞, 孙莹. 配电网故障区段定位的改进矩阵算法[J]. 电力系统自动化, 2003, 27(24): 45-46.
WANG Fei, SUN Ying. Improved matrix algorithm for fault location of distribution network [J]. Automation of Electric Power Systems, 2003, 27(24): 45-46.
- [14] BRAHMA S. Fault location in power distribution system with penetration of distributed generation[J]. IEEE Transactions on Power Delivery, 2011, 26(3): 1545-1553.
- [15] 郭壮志, 陈波, 刘灿萍, 等. 基于遗传算法的配电网故障区段定位[J]. 电网技术, 2007, 31(11): 88-92.
GUO Zhuangzhi, CHEN Bo, LIU Canping, et al. Fault location of distribution network based on genetic algorithm[J]. Power System Technology, 2007, 31(11): 88-92.
- [16] 高孟友, 徐丙垠, 张新慧. 基于故障电流幅值比较的有源配电网故障定位方法[J]. 电力自动化设备, 2015, 35(7): 21-25.
GAO Mengyou, XU Bingyin, ZHANG Xinhui. Fault location based on for active fault current amplitude comparison distribution network[J]. Electric Power Automation Equipment, 2015, 35(7): 21-25.
- [17] 鲍海, 杨以涵, 张利, 等. 基于零序电流突变量的配电网单相故障带电定位判据[J]. 中国电机工程学报, 2010, 30(31): 118-122.
BAO Hai, YANG Yihan, ZHANG Li, et al. Criterion based on the fault component of zero sequence current for online fault location of single-phase fault in distribution network [J]. Proceedings of the CSEE, 2010, 30(31): 118-122.
- [18] 贾清泉, 王宁, 刘楚, 等. 基于故障方向测度的配电网故障区段定位方法[J]. 中国电机工程学报, 2017, 37(20): 5933-5941.
JIA Qingquan, WANG Ning, LIU Chu, et al. A method of fault section location in distribution networks based on fault direction measures [J]. Proceedings of the CSEE, 2017, 37(20): 5933-5941.
- [19] 张姝, 何正友, 李小鹏, 等. 基于线路暂态重心频率的配电网故障区段定位[J]. 中国电机工程学报, 2015, 35(10): 2463-2470.
ZHANG Shu, HE Zhengyou, LI Xiaopeng, et al. Fault section location of the distribution network based on transient center frequency [J]. Proceedings of the CSEE, 2015, 35(10): 2463-2470.
- [20] 薛永端, 李天友, 徐丙垠, 等. 小电流接地故障暂态分析及区段定位新方法[J]. 电力系统自动化, 2014, 38(23): 101-107.
XUE Yongrui, LI Tianyou, XU Bingyin, et al. A novel method of transient analysis and faulty section location for single-phase earth fault in non-effectively earthed network [J]. Automation of Electric Power Systems, 2014, 38(23): 101-107.
- [21] 梁睿, 孟祥震, 周鲁天, 等. 配电网故障定位技术发展现状及展望[J]. 电力工程技术, 2018, 37(6): 20-27.
LIANG Rui, MENG Xiangzhen, ZHOU Lutian, et al. Status quo and prospect of distribution network fault location [J]. Electric Power Engineering Technology, 2018, 37(6): 20-27.
- [22] 梅念, 石东源, 杨增力, 等. 一种实用的复杂配电网故障区段定位的矩阵算法[J]. 电力系统自动化, 2007, 31(10): 66-70.
MEI Nian, SHI Dongyuan, YANG Zengli, et al. A practical matrix-based fault location algorithm for complex distribution network [J]. Automation of Electric Power Systems, 2007, 31(10): 66-70.
- [23] BO Z Q, WELLER G, REDFERN M A. Accurate fault location technique for distribution system using fault-generated high [J]. IEE Proceedings-Generation, Transmission and Distribution, 1999, 146(1): 73-79.
- [24] 束洪春, 董俊, 段锐敏, 等. 基于自然频率的辐射状配电网分层分布式 ANN 故障区段定位方法[J]. 电力系统自动化, 2014, 38(5): 83-89.
SHU Hongchun, DONG Jun, DUAN Ruimin, et al. A fault location method for radial distribution networks with layered and distributed ann based on natural frequency [J]. Automation of Electric Power Systems, 2014, 38(5): 83-89.
- [25] 严凤, 许海梅. 基于神经网络的配电线路综合故障定位方法[J]. 电力系统及其自动化学报, 2015, 27(5): 86-91.
YAN Feng, XU Haimei. Composite fault location method based on PNN for distribution lines [J]. Journal of Electric Power Systems and Automation, 2015, 27(5): 86-91.
- [26] 郭壮志, 徐其兴, 洪俊杰, 等. 配电网故障区段定位的互补约束新模型与算法[J]. 中国电机工程学报, 2016, 36(14): 3742-3750.
GUO Zhuangzhi, XU Qixing, HONG Junjie, et al. A novel fault section location model with complementarity constraints and its optimization algorithm for distribution network [J]. Proceedings of the CSEE, 2016, 36(14): 3742-3750.
- [27] 刘鹏程, 李新利. 基于多种群遗传算法的含分布式电源的配电网故障区段定位算法[J]. 电力系统保护与控制, 2016, 44(2): 36-41.
LIU Pengcheng, LI Xinli. Fault-section location of distribution network containing distributed generation based on the multiple-population genetic algorithm [J]. Power System Protection and Control, 2016, 44(2): 36-41.
- [28] 刘文轩, 严凤, 田霖, 等. 基于 LVQ 神经网络的配电网故障区段定位方法[J]. 电力系统保护与控制, 2012, 40(5): 90-95.
LIU Wenxuan, YAN Feng, TIAN Lin, et al. LVQ neural network approach for fault location of distribution network [J]. Power System Protection and Control, 2012, 40(5): 90-95.
- [29] 吴浩, 李群湛, 易东. 基于广域状态信息和模糊 C 均值聚类的电网故障区域判别[J]. 电力自动化设备, 2013, 33(7): 39-45.
WU Hao, LI Qunzhan, YI Dong. Faulty region identification based on wide-area state information and fuzzy C-means clustering [J]. Electric Power Automation Equipment, 2013, 33(7): 39-45.

- 39-45.
- [30] 李澄,袁磊平,严慧,等. 基于函数幅值和线路等分法的双端故障定位研究[J]. 电力工程技术,2018,37(4):126-131.
LI Cheng, YUAN Leiping, YAN Hui, et al. Two-terminal fault location method based on amplitude of function and line equal partition[J]. Electric Power Engineering Technology, 2018, 37(4):126-131.
- [31] 葛哲学,孙志强. 神经网络理论与 MATLAB R2007 实现[M]. 北京:电子工业出版社,2008.
GEI Zhexue, SUN Zhiqiang. Neural network theory and MATLAB R2007 application[M]. Beijing: Publishing House of Electronics Industry, 2008.
- [32] BARAN M E, WU F F. Network reconfiguration in distribution systems for loss reduction and load balancing[J]. IEEE Transactions on Power Delivery, 1989, 4(2): 1401-1407.

作者简介:



刘成民

刘成民(1963),男,硕士,高级工程师,从事电力系统分析、配电工作(E-mail:yilimi_m@js@sina.com);

戴中坚(1995),男,硕士在读,研究方向为人工智能与数据挖掘;

陈轩(1989),男,硕士,工程师,从事带电检测技术与运用工作。

A fault location method for active distribution network based on Tensorflow deep learning

LIU Chengming¹, DAI Zhongjian², CHEN Xuan¹

(1. State Grid Jiangsu Electric Power Co., Ltd. Inspection Branch, Nanjing 211102, China;

2. School of Electrical Engineering, Southeast University, Nanjing 210096, China)

Abstract: With the high penetration of distributed generators, the radial structure of conventional distribution network system will change to a multi-terminal type, the traditional fault location method will be invalid. In this paper, a fault location method based on deep learning for active distribution network is proposed. This method firstly collects the current and voltage data through the feeder terminal unit. Combining the power output data, a fault data vector is formed; secondly, it uses tensorflow framework to build a deep neural network model based on fully connected network to mine the mapping relations between fault data vectors and fault sections and form the final fault location model through training. Finally, the fault location results demonstrate the effectiveness of the proposed method. Case studies show that compared with the traditional BP and learning vector quantification neural network model, the deep learning model has faster convergence speed and higher fault location accuracy. The final model has high fault tolerance to information distortion and loss.

Keywords: Tensorflow; distributed generation; distribution network; deep learning; fault location

(编辑 方晶)