

基于人工神经网络全连接层优化的线损异常诊断方法研究

李清涛, 任宇驰, 王 远, 李林松, 迟振烨

(国网北京市海淀供电公司发展部, 北京 100091)

摘要: 在一般工商业电价连续下调和国家电网公司打造“三型两网”战略目标的背景下, 通过对线损率的合理管控, 有利于公司降损增效, 提高公司精益化管理水平。为此, 提出一种基于人工神经网络全连接层优化的异常线损诊断方法, 旨在发现异常线损并对成因进行初步诊断。该方法搭建了以全连接层为核心的人工神经网络模型, 利用深度学习强大的自学习能力, 对网络模型的参数不断自适应调节, 通过调整后的模型对线损数据进行逐层提取和筛选, 实现了自动识别和诊断配电网线路或台区的异常线损。最后, 以某地区实际配电网验证了方法的有效性和可行性。

关键词: 线损率; 深度学习; 全连接神经网络; 异常识别

Research on diagnosis method of abnormal line loss based on the fully connected layer of artificial neural network

LI Qingtao, REN Yuchi, WANG Yuan, LI Linsong, CHI Zhenye

(The Development Department of State Grid Beijing Haidian Electric Power Supply Company, Beijing 100091, China)

Abstract: Against the background of the continuous reduction of general industrial and commercial electricity prices and the strategic goal of the State Grid to create a ‘three types and two networks’, the reasonable management and control of the line loss rate will help the State Grid Corporation to reduce losses and increase efficiency, and improve its lean management level. For this reason, a method for diagnosing abnormal line loss based on the fully connected layer of artificial neural network is proposed, which aims to find abnormal line loss and make a preliminary diagnosis of the cause. This method builds an artificial neural network model with a fully connected layer as the core, and uses the strong self-learning ability of deep learning to continuously adaptively adjust the parameters of the network model. The adjusted model is used to extract and screen line loss data layer by layer, to realize automatic identification and diagnosis of abnormal line loss in the distribution network line or station area. Finally, the effectiveness and feasibility of the method are verified with the actual distribution network in a certain area.

Key words: line loss rate; deep learning; fully connected neural network; abnormal recognition

0 引言

随着数据管理技术和数据应用系统不断完善, 为线损的监测和诊断提供了有力支撑。同

时, 线损达标率已经作为国网公司的管理水平和经济性的重要考核指标^[1]。因此, 排查线损异常是维护配电网经济优质运行的关键。

目前国内外异常线损的诊断方法主要为专家经验法和对比分析法,前者依赖于业务专家的经验,通过多系统的线损数据稽查对比,虽然准确率高,但过程复杂,工作量大;后者主要是从数值上比较大小,通过既定的指标标准,从线损数值上判定是否异常,但未进一步给出明确的异常原因^[2]。文献[3]提出了一种基于径向基函数的动态聚类方法,从数值上能高效聚类分析,快速识别出异常线损。文献[4]挖掘了多时间断面的线损数据特征,给出典型线损排查经验。文献[5]采用改进的k-means聚类方法,通过聚类中心距离判别线损是否异常。上述方法主观性较大,主要依赖于个人经验,缺乏科学规范的线损异常诊断体系,智能化程度较低,核查难度大。

另一方面,人工智能和深度学习技术已广泛应用于电力领域。文献[6]根据不同的潮流对线损影响的差异性,构建了神经网络模型,实现了线损理论计算和偷窃电行为分析。文献[7-8]提出一种基于灰色关联的改进神经网络模型,挖掘历史异常线损指标特征,更为精确地对异常线损进行预测。文献[9]提出一种深度学习长短期记忆的神经网络预测模型,实现在大体量数据下的线损预测效率和预测准确度。上述研究通过构建深度学习的神经网络模型,挖掘历史线损数据特征,实现了线损更加高效精准预测,为本文线损诊断提供借鉴,但具体的异常原因诊断仍有进一步研究的空间。

本文首先结合异常线损数值大小和历史异常特征,对大样本异常线损数据进行分类,建立数据集和标签集;然后引入深度学习算法,根据线损样本数据特点逐层搭建全连接神经网络(FCN)模型,训练神经网络模型,并不断反向调整优化模型参数,得到调整后的全连接神经网络模型;最后,通过该模型对配电网的线路或台区进行自动的异常线损判断,并给出初步的异常线损原因,为线损分析工作人员提供技术支撑和借鉴。

1 模型建立

1.1 全连接神经网络基本思想

深度学习由人工神经网络衍生而来,采用分层结构,其模型所含层结构可分为三大类:输入层、隐含层和输出层,由初始输入信息出发,每次训练一个单层网络,通过多隐层结构逐层向上抽样来学习特征,当完成所有层的训练后再采用相关算法调优^[10]。

全连接深度神经网络模型是基于单层感知机网络模型的基础上,加入多个隐含层的人工神经网络。全连接神经网络的特点是相邻层的神经元在权重的联系下两两相连^[11]。

全连接神经网络由两部分组成,分别是线性和非线性。对于输入向量 $x=[x_1, x_2, \dots, x_n]^T$,在经过隐含层后,先得到线性输出向量 $z=[z_1, z_2, \dots, z_n]^T$,输出向量的值主要通过权重向量 w 与偏置向量 b 来确定的,这是神经网络需要学习的重要参数,即

$$z=w \times x+b \quad (1)$$

在得到线性输出向量后,接下来要按照需要转换为非线性向量,通过激活函数对输出向量进行转换后得到隐含层的输出向量 $h=[h_1, h_2, \dots, h_n]^T$,或者输出层的输出向量,即 $y=[y_1, y_2, \dots, y_n]^T$ ^[12]。

通过上面的介绍可以得知,权重与偏置是全连接神经网络中每一个下层神经元都和所有的上层神经元之间联系的重要参数。同时还需要激活函数共同参与,将学习的数据特征与目标联系在一起。全连接神经网络整体结构如图1所示。




图1 全连接神经网络整体结构

Fig. 1 Overall structure of fully connected neural network

1.2 全连接神经网络的模型建立

根据输入的线损数据特点, 本文搭建全连接深度神经网络主要通过Affine层、激活函数ReLU和Softmax-with-Loss层交替实现。首先是正向传播过程, 将线损数据通过Affine层和激活函数ReLU层进行转换, 预测结果通过Softmax进行正则化, 转换为概率输出, 计算损失函数后反向传播, 进行参数更新。其实现过程如图2所示。




图2 全连接神经网络的实现

Fig. 2 Realization of fully connected neural network

1.2.1 全连接Affine层

神经网络的正向传播中, 为了计算加权信号的总和, 使用了矩阵的乘积运算, 这一步骤在几何学领域被称为“仿射变换”。根据这一特性, 仿射变换通过“Affine层”实现。仿射的含意是前面一层中的每一个神经元都连接到当前层中的每一个神经元。仿射层通常被加在神经网络作出预测前的输出的顶层。

假设一个线损数据输入向量为 X , Affine层的权重为 w , 偏置为标量 b , 则Affine层的一般形式为

$$\begin{cases} x = (x_1, x_2, \dots, x_k) \\ w = (w_1, w_2, \dots, w_k) \\ \text{Affine}(x_i, w_i, b) = x_i w_i + b \end{cases} \quad (2)$$

则一次仿射变换为

$$a^T = \text{Affine}(X, W, b) = XW^T + b \quad (3)$$

$$\begin{cases} a^T = \begin{bmatrix} x_{11} & \cdots & x_{1k} \\ \vdots & & \vdots \\ x_{m1} & \cdots & x_{mk} \end{bmatrix} \begin{bmatrix} w_1 \\ \vdots \\ w_k \end{bmatrix} \\ a = (a_1, a_2, a_3, \dots, a_k) \end{cases} \quad (4)$$

式中, X 为 m 行 k 列的输入矩阵; W 为权重矩阵; a 为一次仿射变换后的输出向量。

通过式(3)和式(4), 神经元的加权和和 $Y = XW^T + b$ 计算出来。

1.2.2 激活函数ReLU层

由于线损数据是非线性的, 单层的神经网络无法学习特征, 因此引入激活函数。本文输入层和隐含层的激活函数选择了ReLU函数, ReLU函数表达式为

$$f(x) = \max(0, x) \quad (5)$$

从式(5)可知, ReLU函数在大于零的部分导数为常数, 无论神经元参数如何传递, 梯度都会稳定存在, 而在小于零的区域为零, 使激活函数具有分散、稀疏的特点。ReLU函数的存在可以使神经网络更加准确地学习数据的特征, 使训练更加高效。

1.2.3 Softmax With Loss层

通过神经网络判断线损异常时, 最终的关键一步是确定该数据是否异常并输出异常类别, 就要用到Softmax层。Softmax层在神经网络中用于分类过程, 不论经过全连接神经网络后神经元的输出值是多少, Softmax层都能将它们映射到 $(0, 1)$ 区间内, 这些值累加后和为1, 这便和概率问题结合起来, 在最后选取输出节点时选择值对应的数, 也就是概率最大的作为预测结果。

在实现Softmax层时, 也包含作为损失函数的交叉熵误差(Cross Entropy Error), 所以称为Softmax With Loss层。原始的神经网络输出在经过Softmax层处理之后变成了一个 $(0, 1)$ 之间的概率结果, 然后通过交叉熵来计算预测的概率分布和监督标签的概率分布之间的距离。当交叉熵的计算结果越小, 两个概率分布就越接近。

假设概率分布 p 为期望输出, 概率分布 q 为实际输出, $H(p, q)$ 为交叉熵, 则

$$H(p, q) = -\sum p(x) \log(q(x)) \quad (6)$$

式中, $H(p, q)$ 的值可以表征期望输出与实际输出的距离, 其值越小则越接近期望结果。

在本文中Softmax函数记为Softmax层, 交叉熵误差为Cross Entropy Error层, 由于将电压数据分为了3类, 将从前面的层接收3个输入。Softmax层将输入 (a_1, a_2, a_3) 正规化, 输出 (y_1, y_2, y_3) 。Cross Entropy Error层接收 (t_1, t_2, t_3) 和监督标签 (y_1, y_2, y_3) , 从这些数据中输出损失 L 。计算图如图3所示。




图3 Softmax With Loss层计算图

Fig. 3 Calculation chart of Softmax With Loss layer

Softmax层的反向传播得到了 $(y_1 - t_1, y_2 - t_2, y_3 - t_3)$ 结果, 这是Softmax层的输出和线损样本数据的监督标签的差分, 神经网络的反向传播会把这个差分表示的误差传递给前面的层。

2 线损异常诊断方法

2.1 线损异常标记

本文根据国家电网公司异常线损的管理经验, 将异常原因主要分为档案关系异常或用户偷窃电、表底异常、电能表时钟或采集准确度异常、线路重过载或无功配置不合理以及正常5种类型。

仅从线损率当日数值的大小来判断异常线损原因, 可能出现原因重叠耦合。可以通过近期的历史平均线损率确定本日异常是瞬时还是长期的。本文根据现有的国家电网公司运行的

线损指标和历史统计指标, 初步对异常线损的原因进行分类, 构建初步的异常线损的诊断模式, 该模式如表1所示。

2.2 误差反向传播的神经网络实现

表1 异常原因标记和初步分析

Tab. 1 Abnormal cause labeling and preliminary analysis

标签编号	异常原因	当日线损率	平均线损率
1	档案关系异常 (或偷窃电)	大负损	大负损
		高损	高损
2	表底异常	大负损	正常
		微高	正常
3	电能表时钟或 准确度异常	高损	正常
		小负损	小负损
4	线路重过载, 线路设备老化, 无功补偿不合理	小负损	正常
		正常但偏高	正常但偏高
5	无异常	正常	正常

以上介绍的神经网络各层就好像是等待组装的积木, 要通过组装已经实现的层来构建神经网络。神经网络中有合适的权重和偏置, 调整权重和偏置以便拟合训练数据的过程称为学习。在这个前提下, 神经网络的学习分为以下四个步骤。

步骤1 (mini_batch): 从初始的训练数据中随机选取一部分数据。

步骤2 (计算梯度): 计算损失函数关于各个权重参数的梯度, 本文用反向传播法, 它比数值微分求梯度具有快速高效的特点。

步骤3 (参数更新): 将权重参数沿梯度方向进行微小的更新。

步骤4 (重复): 重复步骤1、步骤2和步骤3。

2.3 全连接神经网络的训练

在完成线损数据异常标识和神经网络的搭建后, 从数据处理、训练全连接深度神经网络和测试准确率三个部分并反复优化实现基于深度学习的线损异常自动识别问题的程序设计。方案设计思路如图4所示。




图4 方案设计思路

Fig. 4 Scheme design idea

深度神经网络训练过程如图5所示，在构建好深度神经网络模型的结构之后，首先将模型参数初始化，将线损数据与标签输入神经网络模型，通过正向传播过程计算模型的输出，并与实际监督标签对比计算误差，然后通过误差的反向传播计算各神经元的误差项以及各参数的梯度，最后将参数迭代更新直至误差收敛。完成模型的训练。




图5 深度神经网络训练

Fig. 5 Deep neural network training

3 算例

本文以某地区39节点配电网进行算例仿真，拓扑如图6所示。该配电网由容量为25 MV·A的三绕组 110/10 kV主变压器T1下的一条10 kV出线构成，共计39个线路节点和27个10 kV低压台区。各台区分界室装有台区电能表，通过

各台区电量与台区下用户电量和之差，可计算各台区线损。




图6 某地区39节点配电网拓扑图

Fig. 6 Topology of distribution networks at 39 nodes in an area

经查询某线损系统获取该配电网的历史线损数据，按照表1中的5类异常原因，将每一类异常线损数据取200组，每组由半个月的15天的异常线损数据组成，构成5组 200×15 体量的样本数据，如表2所示。

表2 神经网络模型训练样本

Tab.2 Neural network model training sample

数据编号	Day1 线损率 (%)	Day2 线损率 (%)	Day3 线损率 (%)	...	Day15 线损率 (%)	异常标签
1	- 25.12	- 29.37	- 24.71	...	- 30.15	1
2	- 17.69	- 13.22	- 15.83	...	- 14.67	1
3	33.4	39.77	27.71	...	27.12	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮
1 000	3.14	2.57	2.73	...	3.78	5

表2中分别为15天的线损率及标签，作为本文的全连接神经网络的输入样本，初试的权重 w 和偏置 b 为 $[-1,1]$ 之间的随机数。随机选取200个神经网络输出标签与实际数据标签的对比结果如图7所示。

从图7中可以看出，在5类异常中，神经网络输出类别基本“嵌套”实际类别，即说明本文的神经网络输出结果与实际类别较为吻合，从第1类~第5类异常的模型训练的准确率如表3所示。




图7 全连接神经网络输出与实际数据对比图

Fig. 7 Comparison chart of fully connected neural network output and actual data

表3 全连接神经网络判别异常的准确率

Tab. 3 The accuracy of fully connected neural network to identify anomalies

异常类别	1	2	3	4	5
模型判别准确率 (%)	92.7	89.2	82.5	94.1	98.1

结合图7和表3可知，在大的训练样本下，通过本文的网络模型不断反向自适应调节参数，然后线损数据进行逐层提取和筛选，得到的异常判别准确率整体水平较高，特别是对第5类正常数据判断准确率为98.1%，说明对正常数据的误判风险较低。

下一步，通过已训练好的模型再对本算例的各台区进行日判别。输入算例的27个台区的某日的线损数据，以及近期14天的历史线损数据，组成 27×15 的输入数据，得到的判别结果如图8所示。




图8 配电网各台区日识别结果

Fig. 8 Daily identification results of each station area of distribution network

从图8中可以看出，经本文全连接神经网络模式判别，当天27个台区有25个是线损正常，其中有3个为线损正常但线损率偏高，归属于第4类；另外有2个台区异常，分别为高损和大负损台区，归属于第1类和第2类，详细数据结果如表4所示。

表4 配电网台区异常线损判别分析

Tab. 4 Discriminant analysis of abnormal line loss in distribution network station areas

台区节点编号	当日线损率 (%)	近期平均线损率 (%)	异常标签判别	异常原因判别	实际原因	判别是否准确
10	7.59	7.52	4	线路过载、线路设备老化、无功补偿不合理	历史配置线径过小导致线损率偏高	是
13	6.54	6.95	4			是
33	8.7	8.01	4			是
18	-31.2	4.04	2	表底异常	台区部分用户表底缺失	是
37	17.78	22.15	1	档案关系异常(或偷窃电)	系统中用户挂接关系异常	是

从表4可知，本文提出的神经网络判别模型可有效识别出异常台区的节点编号，结合当日线损率和近期平均线损率，自动诊断给出异常标签及其异常原因，且诊断结果与实际台区情况相符，可为线损分析人员提供一定的支撑与借鉴。

4 结束语

针对传统的异常线损诊断方法仅从线损率数值大小诊断异常，且未给出具体异常原因的问题，本文提出了一种全连接深度神经网络模型，将线损异常原因与线损率特征相结合，建立训练样本和标签，对模型不断训练与优化参数，能够有效识别异常线损，并给出初步的诊断结果，提高了线损异常识别的效率，节省线损排查分析的人力成本，提高公司精益化管理水平。本文提出的方法数据获取难度低，计算复杂度较低，且有较强的实践应用能力，值得进一步推广。

参考文献

- [1] 余小燕, 罗逸敏. 几种常见的线损异常案例分析及管理措施[J]. 中国电业(技术版), 2014(11): 180-182.
- [2] 王海云, 张岩, 闫富荣, 等. 基于深度神经网络的低压台区线损异常识别方法[J]. 电力需求侧管理, 2018, 20(6): 31-35.
- [3] 姜惠兰, 安敏, 刘晓津, 等. 基于动态聚类算法径向基函数网络的配电网线损计算[J]. 中国电机工程学报, 2005, 25(10): 35-39.
- [4] 郑惠哲. 基于电能量数据分析的线损异常排查方法[J]. 科技技术创新, 2019(22): 144-146.
- [5] 陈洪涛, 蔡慧, 李熊, 等. 基于K-means聚类算法的低压台区线损异常辨别方法[J]. 南方电网技术, 2019, 12(2): 2-6.
- [6] 李植鹏, 侯惠勇, 蒋嗣凡, 等. 基于人工神经网络的线损计算及窃电分析[J]. 南方电网技术, 2019, 12(2): 7-12.
- [7] 邓威, 刘俐, 李勇, 等. 基于GCA和LSTM神经网络的配电网线损预测[J]. 广东电力, 2019, 32(9): 154-159.
- [8] 张义涛, 王泽忠, 刘丽平, 等. 基于灰色关联分析和改进神经网络的10 kV配电网线损预测[J]. 电网技术, 2019, 43(4): 1404-1410.
- [9] 辛永, 黄文思, 陆鑫, 等. 基于深度学习LSTM的线损预测技术研究与应用[J]. 测量与检测技术, 2019, 41(4): 104-106.
- [10] 徐浩, 王钢, 汪隆君. 基于深度学习的暂态电压稳定在线识别[J]. 电气自动化, 2019, 41(1): 41-43, 67.
- [11] 李大中, 刘家瑞, 张华英. 基于深度全连接神经网络的风机叶片结冰预测方法[J]. 电力科学与工程, 2019, 35(4): 39-44.
- [12] 韩伟, 吴艳兰, 任福. 基于全连接和LSTM神经网络的空气污染物预测[J]. 地理信息世界, 2018, 25(3): 34-40.
- [13] 张慧. 深度学习中优化算法的研究与改进[D]. 北京: 北京邮电大学, 2018.

作者简介



李清涛

李清涛(1978—), 男, 高级工程师, 主要研究方向为电网规划管理。

(收稿日期: 2019-09-13) **EA**

(上接第78页)

安全运行水平, 实现电网运行的提质增效。

参考文献

- [1] 王倩. 光声光谱技术在变压器在线监测与故障诊断中的应用研究[D]. 北京: 华北电力大学, 2016.
- [2] 查申龙. 变压器故障气体宽带光声光谱技术研究[D]. 合肥: 中国科学技术大学, 2017.
- [3] 俞洲. 基于光声光谱技术的变压器油中溶解气体分析研究[D]. 大连: 大连理工大学, 2016.
- [4] 王然. 变压器油溶解气的激光光声光谱分析[D]. 大连: 大连理工大学, 2014.
- [5] 史明坤. 变压器油中溶解气体在线监测的光声光谱法研究[D]. 武汉: 华中科技大学, 2015.
- [6] 杨志远. 光声光谱技术检测微量气体浓度研究[D]. 南京: 东南大学, 2018.
- [7] 操敦奎. 变压器油中气体分析诊断与故障检查[M]. 北京: 中国电力出版社, 2005.

作者简介



李红明

李红明(1987—), 男, 工程师, 主要研究方向为电力设备电气试验、电气设备油气分析及在线监测以及电气设备绝缘技术等。

(收稿日期: 2019-07-20) **EA**