

文章编号: 2095-2163(2021)05-0088-06

中图分类号: TN722

文献标志码: A

电气火灾神经网络模型设计

黄文华, 陈茜, 贾明俊

(贵州大学 大数据与信息工程学院, 贵阳 550025)

摘要: 在去年所有火灾的起因中, 电气引发的火灾占比高达三成, 造成的经济损失更是无法估量, 如何减少电气火灾发生的频率一直是一个难题。本文先是采用自组织竞争神经网络进行电气回路的故障判定, 有效的判断电气回路是否存在火灾隐患; 然后采用 SOM 自组织神经网络对存在火灾隐患的回路进行故障分类, 达到了进一步细化故障的目的, 做到了提前预警电气火灾, 减少电气火灾的发生频率。

关键词: 神经网络; SOM; 电气火灾

Electrical fire neural network model design

HUANG Wenhua, CHEN Qian, JIA Mingjun

(School of Big Data and Information Engineering, Guizhou University, Guiyang 550025, China)

[Abstract] In last year, the cause of all fires, electrical causes accounted for up to 30%, the economic losses caused is incalculable, how to reduce the frequency of electrical fires has been a difficult problem. In this paper, the neural network model is used to determine and classify the fire, which can effectively determine whether there are faults in the electrical circuit and classify the faults in the electrical circuit with hidden dangers. The network model in this paper can reduce the frequency of electrical fire to a certain extent.

[Key words] neural network; SOM; electrical fire

0 引言

要构建电气火灾神经网络模型, 首先需要对采集到的特征值进行筛选, 挑选出其中对电气火灾发生具有决定性因素的特征值。比较典型的能够引发电气火灾的故障有三相负序不平衡故障、线缆温度超限故障、剩余电流超限故障等^[1]。可以使用这些典型故障数据对神经网络加以训练, 判定与分类正常电气回路与故障回路。

本文首先给出了一般性的神经网络的数学定义, 为后续使用自组织神经网络与 SOM 竞争网络打下理论基础; 其次, 使用数据分析工具 SPSS 对电气回路特征值进行回归分析, 挑选出合适的特征值; 最后通过自组织神经网络对电气回路故障进行判定, 使用 SOM 竞争网络对故障数据进行分类, 完成了对待测试数据的分析。

1 神经网络的数学定义

神经元通过树突接收其它神经元传输的一定数目的信息, 并且做一些计算, 然后将结果通过轴突传

送到其它节点。由此可以抽象出人工神经网络的模型, 结构如图 1 所示。 x_1, x_2, x_3 为输入节点, x_0 与 $a_0^{(2)}$ 是偏度单元, 在实际应用中偏度单元能够增加函数的灵活性, 提高了神经元的拟合能力, $a_i^{(j)}$ 表示第 j 层的第 i 个神经元, 如 $a_1^{(2)}$ 表示第二层的第一个激励, 是由前面输入节点计算得到的输出结果, 定义权重为第 i 层到第 j 层的作用, 如 $w_{1,2}^{(1)}$ 表示的是第一层的第二个神经元 x_2 到第二层的第一个神经元 $a_1^{(2)}$ 所起到的作用, $H_w(x)$ 表示的是人工神经网络输出的结果。




图1 人工神经网络模型

Fig. 1 Artificial neural network model

本文把第一层作为输入层, x_1, x_2, x_3 也可以称

作者简介: 黄文华(1994-) 男, 硕士研究生, 主要研究方向: 嵌入式开发; 陈茜(1981-), 女, 博士, 教授, 主要研究方向: 半导体技术; 贾明俊(1995-), 男, 硕士研究生, 主要研究方向: 逻辑电路设计。

通讯作者: 陈茜 Email: 61980539@qq.com

收稿日期: 2020-12-25

为特征值,其向量形式为 $\mathbf{X} = [x_0 x_1 x_2 x_3]$, 最后一层为输出层, 中间一层为隐藏层, 输入层到隐藏层的权值矩阵为 $\mathbf{W}_1 = [w_{10}^{(1)} w_{11}^{(1)} w_{12}^{(1)} w_{13}^{(1)}, w_{20}^{(1)} w_{21}^{(1)} w_{22}^{(1)} w_{23}^{(1)}, w_{30}^{(1)} w_{31}^{(1)} w_{32}^{(1)} w_{33}^{(1)}]$, 隐藏层到输出层的权值矩阵为 $\mathbf{W}_2 = [w_{10}^{(2)} w_{11}^{(2)} w_{12}^{(2)} w_{13}^{(2)}]$, 选用 *sigmoid* 函数作为激活函数 $g(x) = \frac{1}{1 + e^{-x}}$, 隐藏层单元的算数表达式(1)所示:

$$\begin{aligned} a_1^{(2)} &= g(w_{10}^{(1)} \cdot x_0 + w_{11}^{(1)} x_1 + w_{12}^{(1)} x_2 + w_{13}^{(1)} x_3); \\ a_2^{(2)} &= g(w_{20}^{(1)} x_0 + w_{21}^{(1)} x_1 + w_{22}^{(1)} x_2 + w_{23}^{(1)} x_3); \\ a_3^{(2)} &= g(w_{30}^{(1)} x_0 + w_{31}^{(1)} x_1 + w_{32}^{(1)} x_2 + w_{33}^{(1)} x_3). \end{aligned} \quad (1)$$

其向量表达式(2)为:

$$\mathbf{g}(\mathbf{W}_1 * \mathbf{x}^T) = \mathbf{a}, \quad (2)$$

最终得到输出神经元的表达式(3):

$$\begin{aligned} H_w(x) &= a_1^{(3)} = g(w_{10}^{(2)} a_0^{(2)} + w_{11}^{(2)} a_1^{(2)} + \\ &w_{12}^{(2)} a_2^{(2)} + w_{13}^{(2)} a_3^{(2)}), \end{aligned} \quad (3)$$

其向量表达式(4)为:

$$\mathbf{H} = \mathbf{g}(\mathbf{W}_2 * \mathbf{a}^T). \quad (4)$$

2 特征值的确定

为了能够较为准确的分析设备是否存在发生火灾的隐患,需要选取合适的特征值作为神经网络的输入,同时分析采集数据之间的相关性,对数据进行简化计算^[2]。选用 SPSS Statistics 进行线性回归分析,分析电气火灾监控系统采集的数据之间是否有关系,是怎样的一种关系,以确定合适的神经网络输入节点^[3]。

根据三相平衡原理,三相电压源必须是正弦波,且频率相同、幅度相同、相位互差 120 °,但因为三相元件、线路参数或负荷不对称可能存在三相电压失衡的情况,需要具体分析三相电压之间的关系^[4]。对三相电各相电压一定时间的采集值进行回归分析,结果见表 1。

表 1 回归 R 方表

Tab. 1 Regress R square table

模型	R	R 方	调整 R 方	标准估计的误差	Durbin-Watson
1	0.995	0.991	0.990	0.375 01	1.312

预测变量(常量): U_b, U_a ; 因变量: U_c 。

可以看出不管是 R 方还是调整后的 R 方都是 99% 以上,说明回归直线对观测值的拟合程度很好。

表 2 的分析结果,方差分析的显著性差异为 0.00,说明 U_a, U_b, U_c 之间存在着显著性的线性关

系。

表 2 回归残差表

Tab. 2 Table of regression residuals

模型	平方和	df	均方	F	Sig
回归	1423.784	2	711.892	5 062.014	0.000
残差	13.501	96	0.141		
总计	1 437.285	98			

预测变量(常量): U_b, U_a ; 因变量: U_c 。

残差的直方图如图 2 所示,可以看出残差服从正态分布,说明该模型具有统计学意义。本次回归分析的回归方程为式(5):

$$H_{x,y} = 0.005 + 0.558X + 0.443Y. \quad (5)$$




图 2 标准化残差直方图

Fig. 2 Standardized residual histogram

因为三相电压之间具有较强的线性相关,可从三相电压值中选取 A 相线电压 U_a 作为其中的一个特征值。从诸多电气火灾产生的成因来看,电线短路产生的电火花和电弧点燃附近的可燃物进而造成火灾,是火灾的一大成因。除此之外,导体截面和设备选择不合理,引起发热并且超过设备长期允许温度;电能消耗过多造成导体过热,装置上选择不适当造成电流状态混乱,进而造成电路过热,这些情况都是造成电气火灾发生的可能原因。因此,可以确定适用于电气火灾的神经网络的 5 个特征值分别为: A 相线电压 U_a , 剩余电流 *LeakCurrent*, 以及线缆温度 $T - A, T - B, T - C$ 。

3 模型的确定

通过对采集的 5 W 条数据进行分析,A 相线电压的幅度区间为 $[385, 425]$, A 相线缆温度的幅度区间在 $[14, 32]$ 之间。剩余电流呈现出规则的波峰,个别尖峰值能够达到 170 ma。对应的时间-剩余电流图表如图 3 所示。

根据国标中关于剩余电流式电气火灾监控探测器的规定,剩余电流的报警值不应该小于 20 ma,不应该大于 1 000 ma^[5]。其中 300 ma 是在实验室条

件下剩余电流产生拉弧引燃脱脂棉的条件,故可以取 300 ma 作为报警阈值。从安全角度上考虑,油浸低绝缘电缆的最高导体允许温度不宜超过 65 ℃,故可以取 65 ℃ 作为线缆温度的报警阈值较为准确。




图3 剩余电流图表

Fig. 3 Residual current diagram

根据中华人民共和国国家标准电能质量标准, 10 kV 及以下的三相供电电压允许偏差为标称系统电压的 $-10\% \sim +10\%$ 之间, 如果电气设备经常处于高于标称电压 10% 时使用寿命只有保持额定值时的 30%, 电子设备各种电子管阴极电压每增加 5%, 阴极寿命减少一半^[6]。同时, 过高电压可能导致设备直接烧坏造成电气火灾, 把 420 V 的单相电压作为电压的阈值为比较合适的选择。

了解了对应的电气标准后, 便可以开始构建自组织竞争性神经网络。自组织竞争网络是一种无导师学习的网络, 主要对输入向量进行区域分类, 其基本思想便是网络竞争层的各个神经元通过竞争来获得对输入模式的响应机会, 最后仅有一个神经元

成为胜利者, 并将与获胜神经元有关的各连接权值向着更加有利于竞争的方向调整, 该神经元也代表着当前输入样本的分布模式^[7]。

图4所示, 输入层是经过筛选过后的特征值, 一共有5个, 分别为单相电压 U_x , 剩余电流 $LeakCurrent$, 以及线缆温度 $T-A$ 、 $T-B$ 、 $T-C$ 。选取这些特征值的原因是其影响程度最大, 与电气火灾的关系最密切。每隔 15 min 电气火灾监控设备将这 5 个特征值上传, 竞争后的权值按照公式(6)更新:

$$w_{ij} = w_{ij} + a \left(\frac{x_i}{m} - w_{ij} \right). \quad (6)$$

其中, a 为学习参数, 取值在 0~1 之间; m 是输入层中输出为 1 的神经元个数; $\frac{x_i}{m}$ 表示当 x_i 活跃时, 对应的第 i 个权值就增加, 反之则减少。经过多次训练后, 自组织竞争网络可以有效的将具有火灾隐患的设备与正常运行的设备区分开来。




图4 电气火灾神经网络

Fig. 4 Electrical fire neural network

4 自组织竞争网络的实现

要实现自组织竞争网络首先需要通过 Matlab 读取 5 个特征值的数据信息, 取一天的观测值绘制曲线图进行分析, 正常运行设备的特征值曲线如图 5 所示。




图5 单日特征值曲线

Fig. 5 One-day eigenvalue curve




图6 特征值比较曲线

Fig. 6 Eigenvalue comparison curve

从图5中可以得知,正常运行设备的各相特征值趋于平稳,在可控的范围内有小幅度的波动,都在可以接受的范围,且远远低于报警阈值。发出报警信号的设备与正常的设备的特征值比较图如图6所示,可以看出二者在线电压和线缆温度上差异并不明显,但是在剩余电流处的幅度差异却很大,二者峰值差距能够达到将近400 mA,可以推断出报警设备的故障情况应该为剩余电流超限。

为使隐藏单元的输入数据分布大致相同,也为了使网络更好的拟合目标,加快收敛速度,需要对数据进行归一化处理,归纳统一样本的统计分布性。选取的归一化函数是 $[y, ps] = \text{map min max}(x, y_{\min}, y_{\max})$, x 是想要归一化的矩阵, $y_{\min} = -1, y_{\max} =$

1,将数值落到区间 $[-1, 1]$ 之间,保证网络处于激活神经与抑制神经元的共同作用下。将发出报警的故障数据与正常数据混合后进行数据归一化处理,得到的结果见表3。

从图7可以看出,发出报警信号的数据在归一化的结果中呈现出临近右边界甚至等于右边界值的情况,与正常数据呈现一正一负2种截然不同的情况,相当于神经元的激活与抑制的2种不同的情形,不同的归一化数值也将使得神经网络的训练向着2种相反的结果靠拢,在电气火灾的模型中就是将设备分类为处于火灾隐患的以及正常运行的两种状态。

表3 标准故障数据归一化表

Tab. 3 Standard fault data normalization

运行情况特征值	电压超限	A相线缆温度超限	B相线缆温度超限	C相线缆温度超限	剩余电流超限	正常	正常
U_a	1	-0.498	-0.436	-0.444	-0.930	-1	-0.922
A相线缆温度	-0.953	1	-1	-1	0.767	-0.898	-0.856
B相线缆温度	-0.947	-0.991	1	-1	-0.769	-0.882	-0.850
C相线缆温度	-0.950	-0.992	-1	1	-0.782	-0.885	-0.858
剩余电流	-0.939	-0.921	-0.939	-1	1	-0.939	-1




图7 特征值归一化图

Fig. 7 Normalized graph of eigenvalues

将神经网络的输出设定为两种分布模式,同时设定好训练速率以及训练迭代的次数,Matlab 会将训练结果分类为 1 和 2 两种不同的输出,对应的是可能有火灾隐患的情况以及正常运行设备 2 种情况^[8]。不妨选取发出剩余电流超限报警设备当日的特征值进行训练,再输入正常运行设备单日特征值观察二者输出情况,如图 8 所示。能够看出正常设备与故障设备的训练结果还是有很大程度的不同,能够从大体上判断出两个设备之间具有明显的差异,输出结果也从侧面证明了该模型具有一定的科学性,但是还需要改进,使得整体的结果更符合预期。




图 8 运行状况图

Fig. 8 Health chart

5 SOM 自组织神经网络构建

SOM 全称是自组织特征映射神经网络 (Self-organizing Feature Maps), 由荷兰神经网络学者 Teuvo Kohonen 于 1981 年提出, 该网络是一个由全连接的神经元阵列组成的无教师、自组织、自学习网络。SOM 自组织网络在接收外界输入时, 将会分类成不同的反应区域, 各个区域对于输入的反应不同。

类似于自组织竞争网络, SOM 同样是一种无导师学习的网络, 主要用于对输入向量进行区域分类, 网络结构上是由输入层和竞争层构成的单层网络^[9]。SOM 网络模型如图 8 所示, 输入和竞争层之间神经元实现双向连接, 竞争层神经元之间存在横向连接, 输入层与竞争层的各个神经元之间实现全连接。SOM 不同于自组织竞争性网络, SOM 自组织神经网络还能够研究输入向量的分布特性和拓扑结构; 在权值更新上不同于自组织竞争网络, 每次只更新获胜神经元权值, SOM 自组织竞争网络不仅更新了获胜神经元, 近邻神经元也会按照某个近邻函数进行更新^[10]。

自组织神经网络的具体实现步骤:

- (1) 用随机数设定输入层和映射层之间权值的初始值, 同时随机取样 XI ;
- (2) 输入向量, 计算输入向量与随机取样 XI 的

欧式距离, 式(7)。计算节点与 XI 的相似度, 选取距离最小的节点作为优胜节点;

$$dist(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}. \quad (7)$$

(3) 根据优胜神经元确定优胜邻域 σ ;

(4) 按照公式(8)修正优胜邻域的权值竞争后的权值;

$$W_{-v}(s+1) = W_{-v}(s) + \lambda(u, v, s)\theta(s)(D(t) - W_{-v}(s)). \quad (8)$$

其中, $W_{-v}(s+1)$, $W_{-v}(s)$ 分别是新权值与原权值; $\lambda(u, v, s)$ 是更新的约束; $\theta(s)$ 为学习率。

(5) 重复随机取样并且计算输出, 判断是否达到了预期设定的要求;

(6) 根据数据聚集的情形分类, 对应到本课题中, 可以分类为电压超限故障、温度超限故障、剩余电流超限故障等等。

应用 SOM 神经网络诊断电气火灾隐患的步骤如下:

(1) 选取不同报警情况的故障样本;

(2) 对每一种情况的故障样本进行学习后, 标记最大输出神经元;

(3) 将待检测样本输入到 SOM 神经网络中;

(4) 若输出神经元与某故障样本位置相同, 则说明两者发生了同样的故障; 若输出神经元介于很多故障位置之间, 则说明各种故障都有可能发生, 具体判断还是得看输出神经元与故障样本的欧式距离。

首先选择 5 项特征值发生报警故障的样本, 对故障样本进行归一化处理, 见表 4。

归一化后需要建立网络以进行训练, 竞争层为 $6 \times 6 = 36$ 个神经元, 拓扑结构设定如图 9 所示的六角型 hex。神经元设定为 3 个维度: A 相电压、线缆温度、剩余电流, 距离函数采用欧式距离公式, 分别对故障数据训练 10、30、50、100、200、500、1 000 次后观察分类情况, 网络经过 1 000 次训练后的分类如图 10 所示。




图 9 SOM 网络模型

Fig. 9 SOM network model

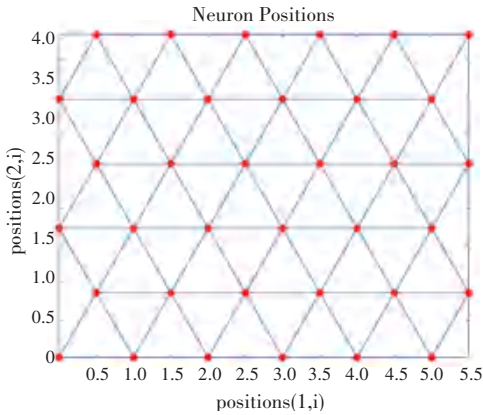


图 10 6×6 网络拓扑模型

Fig. 10 6×6 Network topology model

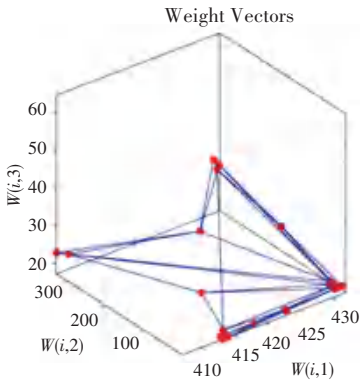


图 11 网络分类情况图

Fig. 11 Network classification diagram

图 10 中, X 轴代表着 A 相电压; Y 轴代表着剩余电流; Z 轴代表着线缆温度, 训练次数越多, 对样本的分类越细致, 结果也会更加精确, 不同特征值引发的故障会被划分为不同的类别, 聚类结果见表 4。

表 4 聚类结果表

Tab. 4 Clustering results table

训练步数	聚类结果				
10	36	36	36	36	4
30	30	36	30	36	7
50	24	36	35	36	31
100	24	31	36	6	17
200	28	31	6	36	1
500	31	36	21	6	1
1 000	16	31	6	36	1

当训练步数为 10 的时候, 故障样本被笼统的划分到一起; 当训练步数为 30 的时候, 故障原因 1、3 分为一类, 2、4 分为一类, 5 单独一类, 说明网络对于样本有了初步的分类, 但精确度不是很高; 当训练步

数为 50 的时候, 除了 2、4 以外, 所有的故障原因都已经区分开来; 当训练步数达到 100、200、500、1 000 的时候, 故障样本已经完全区别开, 分类的结果也更加精确与细化。这种聚类结果说明了 SOM 网络完成学习训练后, 对于每一种不同的故障种类, 输出平面中都有特定的神经元对其敏感, 具有清晰的映射关系, 相比较自组织竞争网络, SOM 网络的分类要更加具体清晰。

6 结束语

电气火灾的发生原因多种多样, 需要先确定好特征值, 并且选取合适的模型进行训练。在本课题使用 SPSS 软件筛选特征值, 筛选出主要的几种影响火灾发生与否的参数, 使用 Matlab 进行神经网络的模型搭建, 构建了自组织竞争网络以及 SOM 自组织网络, 分析电气火灾监控系统收集上来的数据, 并且对两种网络进行分析与比较, 完成了对待测试数据的判定与分类。

参考文献

- [1] 百度文库. 电气故障的分类 [EB/OL]. <https://wenku.baidu.com/view/ee553f4fa66e58fafab069dc5022aaca99841af.html>
- [2] 巴寅亮, 王书提, 谢鑫. 基于自组织竞争神经网络的发动机故障诊断 [J]. 机械制造与自动化, 2017, 46(1): 210-212.
- [3] 小白数据营. SPSS 篇—回归分析 [EB/OL]. https://blog.csdn.net/weixin_37577165/article/details.html
- [4] 百度百科. 三相平衡 [EB/OL]. <https://baike.baidu.com/item/三相平衡.html>
- [5] 国家标准网. DB37/T 2122-2012 电气火灾监控系统设计、施工及验收规范 [EB/OL]. <http://bbs.biaozhuns.com/list-2-1.html>
- [6] 国家标准网. 中华人民共和国国家标准电能质量 [EB/OL]. <http://www.doc88.com/p-018415669819.html>
- [7] 高峰, 刘江, 李艳. 基于 Kohonen 自组织竞争网络的机床温度测点辨识研究 [J]. 中国机械工程, 2014, 25(7): 862-866.
- [8] 李东杰. 基于神经网络模型预测 2017~2018 年成都市危险废物增量研究 [J]. 四川环境, 2021, 40(1): 190-197.
- [9] Mohammad Hossein Shafiabadi, Arman Kavooosi Ghafi, Davood Dehghan Manshady, Negar Nouri. New Method to Improve Energy Savings in Wireless Sensor Networks by Using SOM Neural Network [J]. Journal of Service Science Research, 2019, 11(1): 1-16.
- [10] Zair Mohamed, Rahmoune Chemseddine, Benazzouz Djamel. Multi-fault diagnosis of rolling bearing using fuzzy entropy of empirical mode decomposition, principal component analysis, and SOM neural network neural network [J]. Proceedings of the Institution of Mechanical Engineers, 2019, 233(9): 3317-3328.