

文章编号: 1671-0444(2018)04-0595-07

基于 SOM 神经网络的岸桥起升电机状态聚类分析

唐刚, 姚小强, 胡雄

(上海海事大学 物流工程学院, 上海 201306)

摘要: 为解决岸桥起升电机状态识别及复杂非线性模式分类的问题, 分析了起升电机采集信号训练样本集、特征提取方式等因素对电机状态识别的影响, 并设计了基于 SOM(自组织特征映射)神经网络的状态聚类分析方法。Python 仿真结果表明: 起升电机振动烈度可以聚类为 5 种类别, 分别对应电机的 5 种工作状态, 并且可以得到每类振动烈度数据的区间范围。这种方法可达到电机振动烈度有效快速地自适应分类, 实现岸桥起升电机的状态识别, 为岸桥起升电机的维护保养提供一定的依据。

关键词: 岸桥起升电机; 状态识别; SOM 神经网络; 聚类中心

中图分类号: TP 2062

文献标志码: A

Clustering Analysis of Quayside Hoist Motor Status Based on SOM Neural Network

TANG Gang, YAO Xiaoqiang, HU Xiong

(College of Logistics Engineering, Shanghai Maritime University, Shanghai 201306, China)

Abstract: In order to identify the status and classify the complex non-linear mode of quayside hoist motor, we analyzed the factors which influence the identification of motor status, such as motor training signal set, feature extraction method and so on, and designed a status clustering analysis method based on SOM(self-organizing feature map) neural network. The simulation results of Python show that the vibration intensities of hoisting motor can be clustered into five categories, which correspond to the five working states of the motor, and the range of each kind of vibration intensity data can be obtained. This method can implement the adaptive classification of motor vibration intensity effectively and rapidly, identifying the status identification of quayside hoisting motor and providing basis for the maintenance of quayside hoisting motor.

Key words: quayside hoist motor; status identification; SOM neural network; clustering center

岸桥体积大, 结构复杂, 故障输入输出特性对应不明显, 难以用简化的数学模型进行描述分析, 并且

故障特征和故障类别并非简单线性对应关系。因此, 岸桥故障诊断实际上是典型的复杂非线性分类

收稿日期: 2018-01-22

基金项目: 国家高新技术研究发展计划(863)资助项目(2013A20411606); 国家自然科学基金资助项目(31300783); 中国博士后科学基金资助项目(2014M561458); 教育部博士点基金联合资助项目(20123121120004); 上海高校一流学科——管理科学与工程资助项目; 上海海事大学科研基金资助项目(20130474)

作者简介: 唐刚(1982—), 男, 重庆人, 副教授, 博士, 研究方向为机器人与智能制造, E-mail: gangtang@shmtu.edu.cn
胡雄(联系人), 男, 教授, E-mail: huxiong@shmtu.edu.cn

问题^[1]。

近年来对神经网络算法的研究为岸桥故障诊断提供了新的解决方法,神经网络的非线性分类特性非常适合岸桥这种复杂系统的故障诊断。Haroun 等^[2]基于 SOM(自组织映射)神经网络对轴承进行故障检测与诊断,结果表明,使用 SOM 神经网络聚类对提高故障检测的分类性能有很好的效果。Li 等^[3]使用改进的隐马尔可夫模型和自组织映射数据驱动对轴承故障进行识别,识别率高达 99.58%,具有非常显著的效果。SOM 神经网络是一种无导师自学习算法,具有结构简单、自组织和自学习能力强等优点,并拥有信息的分布存储、并行处理、全局集体应用以及侧向联想等功能^[4]。

本文将 SOM 神经网络应用于岸桥起升电机的状态聚类分析中,通过 SOM 网络实现起升电机振动烈度数据的有效快速自适应聚类,并对岸桥起升电机的工作状态进行较准确地识别,为电机的维护保养提供依据。

1 岸桥起升电机振动信号的采集与处理

1.1 振动信号采集

在岸桥左、右侧起升电机的输出端上安装加速度传感器,设置采样周期为 10 s,即每 10 s 用信号调理采集器采集一个振动信号。将加速度传感器、信号调理采集器、测点监控板以及工控机等硬件设备连接在一起,让其共同组成信号处理柜,并与计算机连接在一起,将得到的模拟信号转变为数字信号存储。传感器每天采集到 8 000 个左右振动信号,本文选取采样时间为 2010 年 1 月 7 日 0 时到 1 月 20 日 12 时,对为期 2 周的振动信号进行研究。岸桥起升电机传感器安装位置如图 1 所示。其中,(1)为传





图 1 岸桥起升电机传感器安装示意图

Fig. 1 Sensor installation instruction of the quayside hoist motor


感器安装位置,(2)为左侧起升电机,(3)为右侧起升电机,(4)为齿轮箱。

1.2 振动信号时域图


为了更加直观地了解岸桥起升电机振动信号变化的趋势,使用 Matlab R 2017 仿真软件画出从 1 月 7 日到 1 月 20 日每天起升电机振动信号的时域图(如图 2 所示)。起升电机振动信号均值为 15.29 mm/s,振动信号幅值位于均值以上为振幅较大的信号,反之为振幅较小的信号。由振动信号时域图可知,起升电机在大部分时间内振幅较小,电机在这部分时间内相对安全。而在小部分时间内电机的振幅较大,此时电机处于不安全状态,在此状态下长时间工作会导致起升电机甚至岸桥损坏^[1]。因此,需要通过起升电机的振动信号对其进行状态识别,保证电机在相对安全的状态下工作。




(a) 1月7日




(b) 1月8日




(c) 1月9日




(d) 1月10日




(e) 1月11日




(l) 1月18日




(f) 1月12日




(m) 1月19日




(g) 1月13日




(n) 1月20日




(h) 1月14日



(i) 1月15日



(j) 1月16日



(k) 1月17日

图 2 岸桥起升电机振动信号时域图

Fig. 2 The time domain instruction of the vibration signal of quayside hoist motor

2 振动信号特征提取

对振动信号进行特征提取可以用来判断岸桥起升电机的运行状态。基于统计学的研究^[5]可知,大型设备的故障诊断实际上是一种模式识别问题,通过分析设备的故障特点可以将整个模式空间划分为几个不同的子模式区间,然后判断每种工作状态所属的子模式区间,以上即为故障诊断的基本过程。然而,样本空间的划分要符合实际工程应用背景以及物理意义,其划分所依据的分类临界值是本文重点研究的问题。

本文基于统计学原理对岸桥起升电机振动信号做了大量的研究,发现岸桥起升电机的振动信号可以用来反映电机的机械性能特征,振动信号中的异常数据蕴含了电机状态的危险程度信息,异常振动数据偏离正常振动数据均值的程度越大,对起升电机的危害也会越大,因此可以据此制定电机工作状态的参考标准。本文将起升电机的状态分为良好、正常、预警、警告和危险五种。准确识别岸桥起升电机工作状态的关键为寻找电机工作状态所对应的临界点和区间范围^[6]。通过查询 ISO 标准^[7]可知,机

器振动烈度可用振动速度的最大均方根来表示,可将振动烈度应用到电机的振动状态分析中^[8-10]。本文提取岸桥起升电机振动烈度数据的有效值(X_{RMS})和方差(S)作为特征值进行聚类分析。

$$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (1)$$

$$S = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N} \quad (2)$$

式中: x_i 为电机振动信号; \bar{x} 为电机振动信号均值; N 为振动信号个数。

3 SOM 神经网络聚类原理与步骤

3.1 SOM 神经网络聚类原理

SOM 神经网络是一种无导师学习网络,具有模拟人类大脑神经自组织特征映射的功能,通过主动寻找样本数据存在的规律和本质属性,自组织、自适应地改变网络间的连接权值。该网络结构包含输入层和竞争层两部分,输入层与一个高维的输入向量相对应,竞争层由二维网格上的有序节点构成,输入向量与输出节点之间通过权值向量连接^[11]。SOM 神经网络基本结构如图 3 所示。




图 3 SOM 神经网络拓扑结构
Fig. 3 Topological instruction of SOM neural network

SOM 神经网络输入层的神经元单元与竞争层的神经元单元通过权值相连,网络训练过程中,首先寻找与输入向量距离最短的竞争层单元,即获胜单元。同时,将邻近区域的权值更新,使输出节点保持输入向量的拓扑特征^[12]。通过网络训练,建立一种拓扑网络布局,使获胜单元的权值向量位于输入向量聚类的中心^[13-14]。聚类前后神经元权值分布情况如图 4 所示,其中,图中白色正方形 A, B, C, D, E 为聚类前神经元初始权值的位置,黑色圆点为起升电机振动烈度原始数据。





图 4 聚类前后神经元权值分布图
Fig. 4 Distribution of neuronal weights before and after clustering

3.2 SOM 神经网络聚类步骤

SOM 神经网络对输入层的样本数据选择性给予反应,依据输入样本数据间存在的相似度,自动将相似的样本数据在网络上就近配置^[15],学习步骤如下所述。

3.2.1 权值初始化^[16-17]

权值初始化是指输入神经元与输出神经元之间的连接权值经过反复训练后不断聚拢,最终使得权值的初始位置与输入神经元分布的区域相互重合的过程。初始权值的选取最常用的两种方法如下:

(1) 从岸桥起升电机振动烈度数据中选取 n 个数据作为 SOM 神经网络的训练样本 $X = [x_1, x_2, \dots, x_n]^T$, 并从所有的训练样本集中随机抽取 m 个输入样本作为初始权值,则

$$W_j = [\omega_{j1}, \omega_{j2}, \dots, \omega_{jm}]^T$$

式中: $\omega_{j1}, \omega_{j2}, \dots, \omega_{jm}$ 为初始权值。

(2) 从岸桥起升电机振动烈度数据中选取 n 个数据作为 SOM 神经网络的训练样本 $\hat{X} = [x_1, x_2, \dots, x_n]^T$, 计算所有起升电机振动样本数据的中心向量,在此中心向量基础上叠加小随机数

作为初始权值。本文使用方法(1) 选取初始权值。

3.2.2 权值归一化

$$w_{ji}^{\wedge} = \frac{w_{ji}}{\|w_{ji}\|}, 1 \leq i \leq m \quad (3)$$

式中: w_{ji} 为初始权值; $\|w_{ji}\|$ 为权值向量的欧几里得范数。

3.2.3 训练样本归一化

$$\mathbf{X} = \frac{\hat{\mathbf{X}}}{\|\hat{\mathbf{X}}\|} = \left[\frac{x_1}{\sqrt{\sum_{j=1}^n x_j^2}}, \dots, \frac{x_n}{\sqrt{\sum_{j=1}^n x_j^2}} \right]^T \quad (4)$$

式中: $\hat{\mathbf{X}}$ 为训练样本; $\|\hat{\mathbf{X}}\|$ 为训练样本向量的欧几里得范数; x_j 为训练样本向量的第 j 个特征分量值。

3.2.4 得到获胜神经元

将岸桥起升电机振动烈度归一化后的样本数据放入 SOM 神经网络的输入层,计算训练样本数据与权值向量的欧几里得距离,距离最小的神经元即为获胜神经元。

$$d_j = \|\mathbf{X} - \mathbf{W}_j\| = \sqrt{\sum_{i=1}^m (x_i(t) - \omega_{ji}(t))^2} \quad (5)$$

式中: d_j 为训练样本数据与权值向量的欧几里得距离,其中,获胜神经元 $d_k = \min(d_j)$ 。

3.2.5 定义优胜邻域

优胜邻域是指以获胜神经元单元为中心,最终得到 t 时刻的权值调整域,训练前初始邻域 $N_{j^*}(0)$ 范围较大,训练一段时间后邻域 $N_{j^*}(t)$ 逐渐缩小,优胜邻域的大小用邻域的半径表示。

$$r(t) = C_1 \left(1 - \frac{t}{T_{\max}}\right) \quad (6)$$

$$r(t) = C_1 e^{-\frac{B_1 t}{T_{\max}}}$$

式中: C_1 为与输出层神经元节点数有关的常数,且该常数大于 0; B_1 为大于 1 的常数; T_{\max} 为网络训练前设定的最大训练次数。

3.2.6 调整权值

调整优胜邻域内各个神经元连接权值,计算如式(7)所示。

$$w_{ij}(t+1) = w_{ij}(t) + \eta(t, N) [x_i^p - w_{ij}(t)] \quad (7)$$

$i = 1, 2, \dots, n; j \in N_{j^*}(t)$

式中: $w_{ij}(t+1)$ 为调整后的神经元连接权值; $\eta(t, N)$ 是关于训练时间 t 和邻域内第 j 个神经元与获胜神经元 j^* 之间拓扑距离 N 的多元函数。

3.2.7 判断网络训练结果

将每次训练后第 j 个神经元与获胜神经元拓扑距离的函数值 $\eta(t)$ 与最初设定的最小的拓扑距离函数值 η_{\min} 进行比较,若 $\eta(t) < \eta_{\min}$, 结束网络训练;否则,返回步骤 3.2.3 继续执行上述步骤。

4 Python 仿真


系统采用 Python 3.6 作为仿真测试平台,对试验数据归一化处理,得到可用于 SOM 网络训练的样本集。将训练样本输入网络中,得到起升电机振动烈度数据的聚类中心,如表 1 所示。

表 1 起升电机振动烈度数据聚类中心
Table 1 Clustering center of vibration intensity data in quayside hoist motor


	坐标轴 x 和 y	聚类中 心 1	聚类中 心 2	聚类中 心 3	聚类中 心 4	聚类中 心 5
1月7日	x	0.72	0.51	0.87	0.21	0.98
	y	0.69	0.86	0.49	0.98	0.21
1月8日	x	0.71	0.51	0.86	0.20	0.98
	y	0.71	0.86	0.52	0.98	0.21
1月9日	x	0.72	0.58	0.85	0.26	0.98
	y	0.69	0.82	0.53	0.97	0.22
1月10日	x	0.71	0.52	0.86	0.22	0.98
	y	0.70	0.85	0.50	0.98	0.21
1月11日	x	0.69	0.50	0.84	0.20	0.97
	y	0.72	0.87	0.54	0.98	0.25
1月12日	x	0.71	0.53	0.84	0.22	0.97
	y	0.71	0.85	0.53	0.98	0.22
1月13日	x	0.69	0.48	0.85	0.18	0.97
	y	0.73	0.88	0.53	0.98	0.23
1月14日	x	0.70	0.51	0.85	0.20	0.97
	y	0.72	0.86	0.53	0.98	0.24
1月15日	x	0.72	0.55	0.86	0.24	0.98
	y	0.69	0.84	0.51	0.97	0.21
1月16日	x	0.72	0.54	0.86	0.23	0.97
	y	0.69	0.84	0.52	0.97	0.22
1月17日	x	0.71	0.55	0.84	0.25	0.97
	y	0.70	0.83	0.54	0.97	0.24
1月18日	x	0.71	0.53	0.86	0.23	0.98
	y	0.70	0.85	0.51	0.97	0.22
1月19日	x	0.70	0.50	0.85	0.19	0.97
	y	0.72	0.87	0.52	0.98	0.22
1月20日	x	0.71	0.54	0.85	0.24	0.97
	y	0.70	0.84	0.52	0.97	0.22

根据表1所得岸桥起升电机振动烈度聚类中心,通过 Matlab R2017 绘制出 14d 聚类中心的变化

趋势,如图5所示,横坐标表示聚类中心 x ,纵坐标表示聚类中心 y 。



(a) 1月7日~1月13日



(b) 1月14日~1月20日

图5 聚类中心分布图

Fig. 5 Distribution of cluster center

由图5可知,1月7日至1月13日和1月14日至1月20日聚类中心的变化曲线各自近似重合,因此岸桥起升电机振动烈度数据的聚类中心近似相等,取14d振动烈度数据聚类中心的平均

值,将其等效为通常情况下起升电机振动烈度数据的聚类中心,通过 Matlab R2017 对数据进行分类,得到每一个聚类中心的分类区间,如表2所示。

表2 起升电机振动烈度数据分类区间

Table 2 Classification interval of hoist motor vibration intensity data

	区间1	区间2	区间3	区间4	区间5
1月7日	(0, 1.99)	(1.99, 6.87)	(6.87, 11.76)	(11.76, 16.64)	(16.64, ∞)
1月8日	(0, 1.59)	(1.59, 6.62)	(6.62, 11.65)	(11.65, 16.68)	(16.68, ∞)
1月9日	(0, 1.04)	(1.04, 4.90)	(4.90, 8.76)	(8.76, 12.62)	(12.62, ∞)
1月10日	(0, 1.51)	(1.51, 5.32)	(5.32, 9.12)	(9.12, 12.93)	(12.93, ∞)
1月11日	(0, 1.45)	(1.45, 5.66)	(5.66, 9.87)	(9.87, 14.08)	(14.08, ∞)
1月12日	(0, 1.38)	(1.38, 5.40)	(5.40, 9.41)	(9.41, 13.42)	(13.42, ∞)
1月13日	(0, 1.73)	(1.73, 6.19)	(6.19, 10.64)	(10.64, 15.10)	(15.10, ∞)
1月14日	(0, 1.69)	(1.69, 5.60)	(5.60, 10.31)	(10.31, 14.62)	(14.62, ∞)
1月15日	(0, 1.71)	(1.71, 5.46)	(5.46, 9.21)	(9.21, 12.97)	(12.97, ∞)
1月16日	(0, 1.64)	(1.64, 5.20)	(5.20, 8.77)	(8.77, 12.34)	(12.34, ∞)
1月17日	(0, 1.46)	(1.46, 5.45)	(5.45, 9.44)	(9.44, 13.43)	(13.43, ∞)
1月18日	(0, 1.30)	(1.30, 5.56)	(5.56, 9.81)	(9.81, 14.07)	(14.07, ∞)
1月19日	(0, 1.69)	(1.69, 5.97)	(5.97, 10.24)	(10.24, 14.51)	(14.51, ∞)
1月20日	(0, 1.32)	(1.32, 5.19)	(5.19, 9.05)	(9.05, 12.91)	(12.91, ∞)

由表2可知,14d内每一天起升电机振动烈度的分类临界值非常靠近,存在的微小差距可能是由测量误差引起的。因此,可以通过求14d内分类临界值的平均值来减小误差。计算得到分类临界值分别为1.54、5.70、9.86和14.02。分类区间依次为

区间1(0, 1.54]、区间2(1.54, 5.70]、区间3(5.70, 9.86]、区间4(9.86, 14.02]和区间5(14.02, ∞)。

根据起升电机振动烈度数据分类区间将电机的状态划分为良好、正常、预警、警告和危险这5类,区

区间1内的振动烈度代表电机良好状态,区间2内的振动烈度代表电机正常状态,区间3内的振动烈度代表电机预警状态,区间4内的振动烈度代表电机警告状态,区间5内的振动烈度代表电机危险状态。

本文通过SOM神经网络算法找到了起升电机振动烈度数据与电机工作状态的对应关系,通过采集的振动烈度数据与分类区间对比,可以判断起升电机的工作状态。

5 结 语

本文选取岸桥起升电机振动烈度信号,运用SOM神经网络算法,将电机振动烈度分为5类,分别对应电机的5种工作状态,并且得到每类振动烈度数据的区间范围。通过对岸桥起升电机的工作状态进行较准确地识别,方便岸桥操作人员及时做出回应,减少经济损失,同时岸桥上其他电机的工作状态也可进行聚类分析。由于本次训练样本数据较少,通过SOM神经网络训练得到的分类临界值和分类区间还不够精确,当采集的振动信号数据库足够大时,可以建立电机状态与振动烈度之间更准确的关系。

参 考 文 献

- [1] 王志欣. 岸桥机械动态特征信息的数据挖掘与状态识别[D]. 上海:上海交通大学机械与动力工程学院,2008:79-81.
- [2] HAROUN S, SEGHIR A N, TOUATI S. Feature selection for enhancement of bearing fault detection and diagnosis based on self-organizing map [J]. *Lecture Notes in Electrical Engineering*, 2017, 411(2):233-246.
- [3] LI Z F, FANG H J, HUANG M. Data-driven bearing fault identification using improved hidden Markov model and self-organizing map [J]. *Computers and Industrial Engineering*, 2018, 116(1):37-46.
- [4] 张彼德, 欧建, 孙才新. 汽轮发电机多故障诊断的SOM神经网络方法[J]. *重庆大学学报(自然科学版)*, 2005, 28(2):36-38.
- [5] 叶铂. 基于统计学方法的水面目标特征提取与识别方法的研究[D]. 哈尔滨:哈尔滨工程大学信息与通信工程学院, 2010:31-37.
- [6] 郭维. 桥吊电机机械性能参数的统计特征与状态聚类分析[D]. 上海:上海海事大学物流工程学院, 2006:25-39.
- [7] 丁奎元. ISO2373-1974, 轴心高为80到400毫米旋转电机的机械振动——振动烈度的测量与评定[S]. 郑州:机械工业部标准化研究, 机械工业部郑州机械研究所, 1984.
- [8] MOHANTY S, GUPTA K K, RAJU K S. Vibration Feature Extraction and Analysis of Industrial Ball Mill Using MEMS Accelerometer Sensor and Synchronized Data Analysis Technique[J]. *Procedia Computer Science*, 2015, 58(2):217-224.
- [9] 佟佩声. 滚动轴承变工况条件下静电监测特征提取及故障程度识别方法研究[D]. 南京:南京航空航天大学民航学院, 2014:22-24.
- [10] 王鹏, 王太勇, 董靖川. 基于EEMD时频谱二值化的振动信号微弱特征提取方法[J]. *天津大学学报(自然科学与工程技术版)*, 2016, 49(7):667-673.
- [11] SONG Q, WANG A M. Fault diagnosis of marine diesel engines based on SOM neural network[J]. *Advanced Materials Research*, 2011, 219-220(2):809/813.
- [12] MENG L H, WANG P Z, LIU Z G. Safety Assessment for Electrical Motor Drive System Based on SOM Neural Network [J]. *Mathematical Problems in Engineering*, 2016, 2016(6):221-229.
- [13] 程鹏, 潘宏侠. SOM—BP复合神经网络在齿轮箱故障诊断中的应用研究[J]. *噪声与振动控制*, 2010, 30(5):165-168.
- [14] YI R Q, LI W H, WANG D. Feature recognition based on self-organized neural network [J]. *Journal of Jilin University*, 2009, 39(1):148-153.
- [15] 周晶, 余家详, 司南, 等. 基于SOM神经网络的航舵故障分类方法[J]. *信息与电子工程*, 2012, 10(3):339-342.
- [16] 陶刚, 闫永刚, 刘俊, 等. 基于改进的SOM聚类连续属性离散化算法[J]. *计算机应用*, 2015, 35(S1):89-92.
- [17] GAN M L, LIU H X. On Five Amplitude Demodulating Approaches for Vibration Acceleration Signals [J]. *Vibration and Shock*, 2000, 19(1):32-33.

(责任编辑:郭小敏)