

基于动态测点选择的温度状态识别

朱春鸯,郭其一

(同济大学 电子与信息工程学院,上海 201804)

(zhuzhuMotto@hotmail.com)

摘要:为实现对设备表面温度状态的实时识别及相关分析的智能决策化,引入了改进的层次分析法(AHP),动态地对设备表面多个监测点进行相关分析,选择出反映设备温度状态的关键测点,同时建立Kohonen自组织特征映射神经网络,对关键测点温度序列值进行一段时间的更新跟踪融合识别,获取关键测点的温度状态以此来表明设备的温度状态。以牵引电机为例,用Matlab软件仿真分析,识别正确率为89%,有效地降低了火灾发生的误报率。

关键词:地铁火灾;关键测点;温度状态识别;层次分析法;Kohonen自组织特征映射;牵引电机

中图分类号: TP277 **文献标志码:** A

Temperature state recognition based on dynamical selection of measuring point location

ZHU Chun-yang, GUO Qi-yi

(School of Electronics and Information Engineering, Tongji University, Shanghai 201804, China)

Abstract: In order to realize intelligent recognition of temperature state and related analysis for devices surface temperature states, an improved Analytic Hierarchy Process (AHP) model was introduced, which could dynamically analyze the relevance among several measuring points of temperature and selected key measuring point which could reflect the temperature state for devices. At the same time, Kohonen Self-Organizing Feature Map (SOFM) neural network was established, which could update and follow and recognize temperature serials value of key measuring points during some time, so that show device temperature status. Take traction motor for example, Matlab software simulation analysis show its recognition rate is 89%, which effectively reduces the false positive rate of fire.

Key words: subway fire; key measuring point; temperature state recognition; Analytic Hierarchy Process (AHP); Kohonen Self-Organizing Feature Map (SOFM); traction motor

0 引言

近年来,随着城市化进程的加速,城市轨道交通自动化技术的发展,地铁作为城市轨道交通的主要交通方式正处于史无前例的大发展时期,由此地铁安全问题成为一个突出问题,尤其地铁火灾时有发生,如何有效地预防地铁火灾发生成为当前亟待解决的迫切问题。如果火灾发生前能及时准确地探测出火灾状态信息及其他相关信息,提前预警,可将损失降至最低。据国内外文献资料记载,国外地铁列车火灾防护技术已得到充分的发展和普遍的应用,如英国伦敦地铁采用光纤技术火灾报警网络系统;俄罗斯地铁车厢安装了一种称为包括“指针”装置的火灾自动探测报警网络系统;而国内在火灾防护方面起步比较晚,大部分地铁应用国外进口的火灾报警网络系统。尽管这样,火灾的误报和漏报警时有发生,2007年上海磁悬浮发生火灾,大功率设备“空调系统”的排风系统、“蓄电池”成为火灾原因的争执焦点,原因可能是蓄电池运行的环境如温度、湿度等与德国的环境不同。地铁火灾发生是一个复杂的火灾系统,致使地铁火灾发生的可燃物、人的行为、设备故障、环境条件等具有随机性,以及人们对火灾认知和信息的不确定性,采用传统的火灾报警网络系统无法真正避免火灾的发生。

火灾发生的机理和规律在其他领域的研究已比较成熟,

如森林、城市、建筑等,通过对火灾发生时环境条件模拟试验挖掘影响火灾的有利因子进行火灾风险评估^[1-5],然而针对地铁火灾的模拟研究,侧重于运用计算流体动力学(Computational Fluid Dynamics, CFD)方法和 $k-\varepsilon$ 湍流模型,对地铁车站站台、地铁车厢中部尾部等不同位置火灾发生时的气流场、温度场等进行数值模拟,选择合理的通风环控方案,侧重点在火灾发生时使火灾损失降至最低^[6-7]。由于地铁火灾发生时条件的复杂性、随机性、偶然性及不确定性,无法真正对地铁火灾发生时的各种环境条件进行真实的模拟,同时非火灾噪声数据的影响,无法精准地提取火灾数据,且耗资巨大。如果有针对性地确定监控研究对象,对研究对象进行状态监控,则能有效预防和降低火灾发生率。

地铁车辆车载的各种大功率电气设备在地铁安全运行中举足轻重的地位,它们的运行状态直接关系到地铁机车能否安全运行。大功率设备指制动电阻、牵引电机、牵引变流器、空调、镉镍蓄电池、动力电缆等。对这些大功率电气设备的工作原理、设备表面及相关位置的温度场进行分析^[1-4],发现具备一个共同点,即设备的温度状态是反映大功率设备是否正常运行的直接索引和表示,同时也是火灾发生前的一个极其重要的状态参数,适时全面地获取和监测设备表面温度状态有利于掌握大功率电气设备的运行状态,便于及时发现设备的异常状态,同时也有利于避免火灾的发生。以大功率

收稿日期:2010-07-14;修回日期:2010-09-29。

作者简介:朱春鸯(1974-),女,四川南充人,助教,博士研究生,主要研究方向:模式识别、分布式智能信息系统;郭其一(1961-),男,浙江建德人,教授,博士生导师,主要研究方向:信息自动化及电气自动化领域的检测控制、故障诊断、分布式测控系统、电力系统分析。

设备表面温度状态及相关位置的温度状态为监测对象在地铁火灾防护系统中尚属空白,很少有涉及分析。因此,本文确立了以大功率设备表面温度状态及相关位置温度状态为研究对象,为克服目前火灾防护中误报和漏报的缺点,需要对设备表面或相关位置尽可能多地布置温度监测点。同时,温度状态是一个随时间变化的动态过程,可能某测点某时刻的温度突然上升幅度比较大表现异常,而下一时刻又恢复到正常状态,这种情况下该干扰点容易引起误报,如何从众多的测点中挑出反映设备温度状态的关键测点避免漏报呢?如何对各个测点进行关联分析?如何解决因干扰点出现的误报呢?近年来,信息融合的智能决策方法在其他领域运用广泛,如改进的层次分析 (Analytic Hierarchy Process, AHP) 方法^[12] 及 Kohonen 自组织特征映射 (Self-Organizing Feature Map, SOFM)^[13] 人工自组织特征映射神经网络。本文引入改进的 AHP 方法动态地对各个测点进行相关分析获取反映设备温度状态的关键测点温度,同时运用 Kohonen SOFM 方法对关键测点温度序列值进行一段时间的跟踪识别,即信息融合判别当前设备的温度状态,提高设备对象温度状态判别的可靠

性,以期利用地铁火灾防护技术为地铁车载大功率电气设备运行状态的安全预报开拓一条新的思路。

1 层次分析多测点温度状态识别递阶层次模型

地铁车载大功率电气设备分布在地铁列车上,有的分布在车厢底部,有的分布在车厢顶部,要实现对车载大功率电气设备温度的监测,单单孤立地研究某个时刻监测对象表面的某个位置的单个测点的温度值不能准确地反映设备的温度状态。设备处于一个动态的空间,其温度状态是受多个因素的影响,待监测的大功率电气设备外围需要布置很多传感器对其进行多点温度检测,避免因诸多未考虑到的意外条件引起的误报警或漏报警。应从众多测点的温度中找到关键点的温度或者关键异常点的位置来反映设备的温度状态,监测点布置得越多可能在一定程度上提高了对设备温度状态识别的可靠性和准确性,但增加了系统的复杂性,同时也影响了关键点作用的体现。在此,引入改进的 AHP 和 SOFM 神经网络构建的层次分析多测点温度状态识别递阶层次模型如图 1 所示。

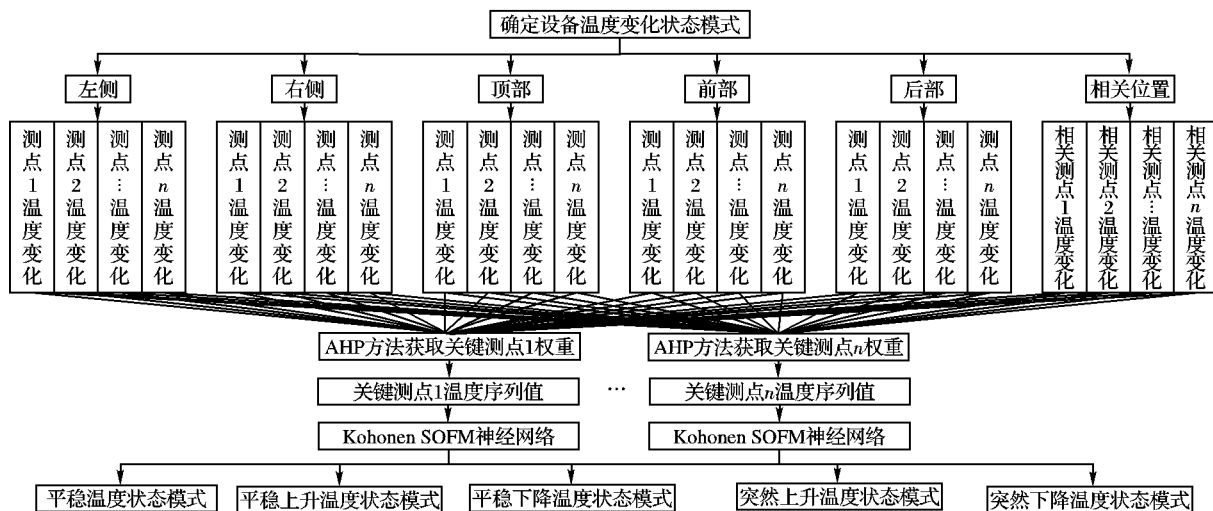


图1 大功率设备多点位置检测的设备温度状态识别递阶层次模型

图1中最顶层是总的目标确定对象设备的温度变化状态模式,各个部位布置许多温度监测点构成递阶层次运用改进的 AHP 方法对各个测点温度变化进行排序获取关键测点。传统的 AHP 方法^[6] 在评价各个因素的权重时是通过专家经验根据各因素的重要程度排列各因素的顺序,并通过互反矩阵求出各个因素的权重,通过专家经验获取的数据具有任意性而且不同的专家给出的经验数据可能相互冲突,同时,专家经验一旦形成和确定,各个因素的权重成为固定值,而被监控设备的各个测点温度是一个动态的特征量,随时间变化的,不能用同一固定权重的测点来衡量和确定不同时期的设备温度状态。因此,应用改进的层次分析 AHP 随时间变化动态地提取权重最大的测点即关键测点,提取在该时刻关键测点的一个周期内的温度序列值作为 SOFM 神经网络的输入参数,并持续地更新与跟踪识别输入参数序列值,以进一步确定该测点的温度变化状态是稳定持续的还是异常情况,提高温度状态判别的可靠性。SOFM 神经网络是一种聚类方法,是以无导师监督的方式对网络进行训练,在网络输出节点的权向量空间形成输入数据分布的拓扑图,温度状态相近或相似的温度序列值被聚类到输出层的同一个区域。反映设备温度状态关键点是动态变化,训练好的人工自组织神经网络 SOFM 可

以动态地对输入参数进行非线性拟合实现对温度状态的最优分类识别,定义 7 种温度状态模式即:平稳温度状态、平稳上升的温度状态、平稳下降的温度状态、突然上升温度状态、突然上升后平稳状态、突然下降状态和突然下降后平稳状态。

2 改进的 AHP 对测点温度变化动态选择

利用改进的 AHP 方法实现对设备表面上的多个测点进行动态选择,即代替基于专家经验构成的互反矩阵决定各因素权重的传统 AHP 方法,根据各测点相应的监测数据的变化排列各测点的位置并根据顺序给出相应的奇整数,通过两两测点的相互比较形成一个互反矩阵,各个测点的权重由此生成。一旦空间测点的监测数据发生变化,各个测点又形成一个新排列,新的互反矩阵重新形成,权重由此也改变,反映设备的关键点也重新选择,根据监测数据做相应调整的权重及反映设备温度状态的关键点是一个动态的过程,随时间而变化的,不是一个固定值。如何对各个测点温度变化状态进行排序呢?首先需要确定评价因素参数。

2.1 确定评价因素参数

令 $x(t_0)$ 为设备的初始温度, $x_i(t)$ 为第 i 个测点在 t 时刻的温度, $x_i(t+1)$ 是测点 i 在 $t+1$ 时刻的温度值,温度在

一段时间的状态模式跟在相应的时间段的变化幅值 ($x_i(t+1) - x_i(t)$) 有很大的关系,随时间变化设备的各测点温度值可能会不一样,可能变化幅值存在较大的差异,利用其幅值变化相对于初始温度变化率 $y_{i1}(t)$ 作为一个评价因素,其定义如式(1)。

$$y_{i1}(t) = \frac{x_i(t+1) - x_i(t)}{x(t_0)} \quad (1)$$

同时,测点温度 $x_i(t)$ 相对于平稳运行时温度 $x(t_s)$ 变化率 $y_{i2}(t)$,也有利于判断该测点温度变化是否存在异常或其他情况,则测点温度相对于平稳状态的温度变化率参数 $y_{i2}(t)$ 定义如下。

$$y_{i2}(t) = \frac{x_i(t) - x(t_s)}{x(t_s)} \quad (2)$$

参数 $y_{i2}(t)$ 值也可能出现或正或负的情况。设备在运行时温度一般低于或等于设备平稳运行时的温度,如果参数 $y_{i2}(t) > 0$ 温度异常,设备可能存在故障,可见 $y_{i2}(t)$ 也是一个重要的评价因素。

2.2 互反矩阵的确立及各个测点温度变化的权重

在确立互反矩阵前,需要根据 $y_{i1}(t)$ 、 $y_{i2}(t)$ 评价因素对各个测点进行排序。以牵引电机为例,设牵引电机初始温度为 40℃,平稳运行时温度为 80℃,安全报警温度为 90~100℃,设温度变化为 ΔT ,当 $|\Delta T| \leq 5^\circ\text{C}$ 为温度平稳变化; $5^\circ\text{C} < \Delta T \leq 15^\circ\text{C}$ 为温度平稳上升; $\Delta T > 15^\circ\text{C}$ 为温度突然上升;反之, $-15^\circ\text{C} \leq \Delta T < -5^\circ\text{C}$ 为温度平稳下降; $\Delta T < -15^\circ\text{C}$ 为温度突然下降。根据 ΔT 来确定评价因素 $y_{i1}(t)$ 、 $y_{i2}(t)$ 组合的不同状态。

状态 1: $y_{i1}(t) \geq 0.375$, $y_{i2}(t) \geq 0$ 。

状态 2: $y_{i1}(t) > 0.375$, $y_{i2}(t) < 0$ 。

状态 3: $y_{i1}(t) \leq -0.375$, $y_{i2}(t) \geq 0$ 。

状态 4: $y_{i1}(t) < -0.375$, $y_{i2}(t) < 0$ 。

状态 5: $0.125 \leq y_{i1}(t) \leq 0.375$, $y_{i2}(t) \geq 0$ 。

状态 6: $0.125 < y_{i1}(t) < 0.375$, $y_{i2}(t) < 0$ 。

状态 7: $-0.375 \leq y_{i1}(t) < -0.125$, $y_{i2}(t) \geq 0$ 。

状态 8: $-0.375 < y_{i1}(t) < -0.125$, $y_{i2}(t) < 0$ 。

状态 9: $|y_{i1}(t)| \leq 0.125$, $y_{i2}(t) \geq 0$ 。

状态 10: $|y_{i1}(t)| \leq 0.125$, $y_{i2}(t) < 0$ 。

某时刻各个测点的温度变化排序根据各自评价因素所属的状态按上面的状态顺序进行第一轮排序。在第一轮排序中,如果有多个测点处于同一类状态,则分配相同的序号,被分配相同序号的测点在同一状态内可以进行第二轮排序,最后综合第一轮、第二轮排序获得测点的最终排序。

传统的层次分析法 AHP 确定互反矩阵是通过专家的经验 and 标准获得,在此,由于设备的温度状态的随时间变化的,

其互反矩阵是根据各测点评价因素排序决定的,某时刻,采集的监测温度值不一样,各个测点排列顺序也不一样的,其互反矩阵也动态跟随测点的温度变化。改进 AHP 方法大致如下:

1) 连续的奇整数 ($p_1(1), p_2(3), \dots, p_k(2k+1)$, 其中 $k=0$) 代表各个测点的重要程度,根据评价因素的状态获取的各个测点从小到大排列顺序分配给各个测点奇整数 ($p_k(2k+1), \dots, p_2(3), p_1(1)$),如果有评价因素状态一样,则相同的奇整数分配给相应的测点。

2) 计算各个测点的奇整数相对比 ($p_{ij} = p_i/p_j$) 就可以获取互反矩阵。

3) 各个测点的权重计算跟传统的 AHP 方法一致,互反矩阵通过一致性检验即可获得各个测点的权重大小。

改进的 AHP 方法能动态地根据评价因素的变化修改各个测点的排序,通过互反矩阵获取各个测点的权重能动态地选择反映设备温度状态的关键测点。

3 应用仿真

3.1 动态测点选择

采集设备对象温度以牵引电机外壳表面温度为例,由于牵引电机工作运行时,发热比较严重,通常表面发热由内部发热引起。因此,在此相关位置指监测设备内部,将内部与外部结合起来关联分析,针对牵引电机内部相关位置发热部位比较多,如轴承、换向器、电枢回路及电机线圈漆包线等,由于篇幅有限,相关位置只针对电机线圈部分测点的温度值。如表 1 所示,牵引电机处于平稳上升状态时各位置测点温度变化,根据评价因素 $y_{i1}(t_1)$ 、 $y_{i2}(t_1)$ 获得各个测点的最终排序,并按顺序分配 $p_{13}(25), \dots, p_2(3), p_1(1)$ 获取互反矩阵,如表 2 所示,该互反矩阵通过一致性检验,相关位置的权重最大,其次就是表面顶部测点 1 及测点 2 权重跟其接近且是表面测点中权重最大的。可见,相关位置的各个测点的变化状态(内因)可以通过牵引电机表面测点表现出来,可暂时确定顶部测点 1、测点 2 为 t_1 时刻反映设备温度的关键测点。表 2 所示的是牵引电机某测点温度突然变化其他测点平稳时各测点温度变化排序,同时根据其评价因素 $y_{i1}(t_2)$ 、 $y_{i2}(t_2)$ 对其进行排序并获取如表 4 所示的互反矩阵,表 4 中温度发生大幅度改变的测点 4 权重最大超过相关测点位置的权重,其他测点位置权重变化很小几乎没变,由于相关测点权重无变化,内部温度平稳变化,则测点 4 温度异常可能是外部引起的,可暂定测点 4 为 t_2 时刻的关键测点。通过列举其他的数据仿真分析,可得出一般规律,当设备温度平稳变化时,各个测点权重保持如表 3 的状态或有微小的变化,顶部测点 1、测点 2 是设备的关键测点。当设备温度异常,某些测点权重会发生重大

表 1 牵引电机平稳运行时温度处于平稳状态时各测点温度变化排序

指标	左侧		右侧		前部		后部		顶部			相关位置	
	测点 1	测点 2	测点 1	测点 2	测点 1	测点 2	测点 1	测点 2	测点 1	测点 2	测点 3	测点 1	测点 2
$x_i(t_1 - 1)$	67.20	65.30	64.70	62.30	75.30	77.90	55.30	56.20	79.70	79.20	75.70	132.70	128.20
$x_i(t_1)$	68.20	66.50	65.80	63.70	79.40	80.00	56.00	57.10	80.80	80.40	77.90	134.80	130.50
$x_i(t_1) - x_i(t_1 - 1)$	1.00	1.20	1.10	1.50	4.10	0.10	0.70	0.90	0.30	0.80	2.20	2.10	2.30
$y_{i1}(t_1)$	0.02	0.03	0.03	0.04	0.10	0.00	0.02	0.02	0.01	0.02	0.06	0.05	0.06
$y_{i2}(t_1)$	-0.15	-0.17	-0.18	-0.20	-0.01	0.00	-0.30	-0.29	0.01	0.01	-0.00	0.69	0.63
第一顺序	10	10	10	10	10	9	10	10	9	9	10	9	9
第二顺序	10.6	10.4	10.5	10.3	10.1	9.5	10.8	10.7	9.4	9.3	10.2	9.2	9.1
最终顺序	11	9	10	8	6	5	13	12	4	3	7	2	1

表 2 表 1 中数据状态的互反矩阵及其各个测点的权重 ($\lambda_{\max} = 13.872, CI = 0.073, CR = 0.047$)

测点	左侧		右侧		前部		后部		顶部			相关位置		权重	
	测点 1	测点 2	测点 1	测点 2	测点 1	测点 2	测点 1	测点 2	测点 1	测点 2	测点 3	测点 1	测点 2		w_{ij}
左侧	测点 1	1	5/9	5/7	5/11	5/15	5/17	5/1	5/3	5/19	5/21	5/13	5/23	5/25	0.030
	测点 2	9/5	1	9/7	9/11	9/15	9/17	9/1	9/3	9/19	9/21	9/13	9/23	9/25	0.054
右侧	测点 1	7/5	7/9	1	7/11	7/15	7/17	7/1	7/3	7/19	7/21	7/13	7/23	7/25	0.041
	测点 2	11/5	11/9	11/7	1	11/15	11/17	11/1	11/3	11/19	11/21	11/13	11/23	11/25	0.065
前部	测点 1	15/5	15/9	15/7	15/11	1	15/17	15/1	15/3	15/19	15/21	15/13	15/23	15/25	0.088
	测点 2	17/5	17/9	17/7	17/11	17/15	1	17/1	17/3	17/19	17/21	17/13	17/23	17/25	0.101
后部	测点 1	1/5	1/9	1/7	1/11	1/15	1/17	1	1/3	1/19	1/21	1/13	1/23	1/25	0.006
	测点 2	3/5	3/9	3/7	3/11	3/15	3/17	3/1	1	3/19	3/21	3/13	3/23	3/25	0.018
顶部	测点 1	19/5	19/9	19/7	19/11	19/15	19/17	19/1	19/3	1	19/21	19/13	19/23	19/25	0.112
	测点 2	21/5	21/9	21/7	21/11	21/15	21/17	21/1	21/3	21/19	1	21/13	21/23	21/25	0.124
	测点 3	13/5	13/9	13/7	13/11	13/15	13/17	13/1	13/3	13/19	13/21	1	13/23	13/25	0.088
相关位置	测点 1	23/5	23/9	23/7	23/11	23/15	23/17	23/1	23/3	23/19	23/21	23/13	1	23/25	0.136
	测点 2	25/5	25/9	25/7	25/11	25/15	25/17	25/1	25/3	25/19	25/21	25/13	25/23	1	0.148

表 3 牵引电机平稳运行时某测点温度突然变化时各测点温度变化排序

指标	左侧		右侧		前部		后部		顶部			相关位置	
	测点 1	测点 2	测点 1	测点 2	测点 1	测点 2	测点 1	测点 2	测点 1	测点 2	测点 3	测点 1	测点 2
$x_i(t_2 - 1)$	68.600	66.700	65.900	62.300	79.500	79.300	56.300	57.500	81.000	80.300	78.000	136.200	131.400
$x_i(t_2)$	69.600	66.800	66.200	91.200	79.700	80.200	56.300	57.600	81.000	81.100	78.200	137.300	132.300
$x_i(t_2) - x_i(t_2 - 1)$	0.000	0.100	0.300	28.900	0.200	0.700	0.000	0.100	0.000	0.800	0.200	1.200	0.900
$y_{i1}(t_2)$	0.000	0.003	0.008	0.723	0.005	0.018	0.000	0.003	0.000	0.020	0.005	0.030	0.023
$y_{i2}(t_2)$	-0.130	-0.165	-0.173	0.140	-0.004	0.003	-0.296	-0.280	0.000	0.014	-0.023	0.716	0.646
第一顺序	10	10	10	1	10	9	10	10	9	9	10	9	9
第二顺序	10.6	10.4	10.1	1.0	10.2	9.4	10.7	10.5	9.5	9.3	10.3	9.1	9.2
最终顺序	11	9	7	1	12	5	13	10	6	4	8	2	3

表 4 表 3 中数据状态的互反矩阵及其各个测点的权重 ($\lambda_{\max} = 13.872, CI = 0.073, CR = 0.047$)

测点	左侧			右侧		前部		后部		顶部			相关位置		权重
	测点 1	测点 2		测点 1	测点 2	测点 1	测点 2	测点 1	测点 2	测点 1	测点 2	测点 3	测点 1	测点 2	
左侧	测点 1	1	5/9	5/13	5/25	5/3	5/17	5/1	5/7	5/15	5/19	5/11	5/23	5/21	0.030
	测点 2	9/5	1	9/13	9/25	9/3	9/17	9/1	9/7	9/15	9/19	9/11	9/23	9/21	0.054
右侧	测点 1	13/5	13/9	1	13/25	13/3	13/17	13/1	13/7	13/15	13/19	13/11	13/23	13/21	0.088
	测点 2	25/5	25/9	25/13	1	25/3	25/17	25/1	25/7	25/15	25/19	25/11	25/23	25/21	0.148
前部	测点 1	3/5	3/9	3/13	3/25	1	3/17	3/1	3/7	3/15	3/19	3/11	3/23	3/21	0.018
	测点 2	17/5	17/9	17/13	17/25	17/3	1	17/1	17/7	17/15	17/19	17/11	17/23	17/21	0.101
后部	测点 1	1/5	1/9	1/13	1/25	1/3	1/17	1	1/7	1/15	1/19	1/11	1/23	1/21	0.006
	测点 2	7/5	7/9	7/13	7/25	7/3	7/17	7/1	1	7/15	7/19	7/11	7/23	7/21	0.041
顶部	测点 1	15/5	15/9	15/13	15/25	15/3	15/17	15/1	15/7	1	15/19	15/11	15/23	15/21	0.088
	测点 2	19/5	19/9	19/13	19/25	19/3	19/17	19/1	19/7	19/15	1	19/11	19/23	19/21	0.112
	测点 3	11/5	11/9	11/13	11/25	11/3	11/17	11/1	11/7	11/15	11/19	1	11/23	11/21	0.065
相关位置	测点 1	23/5	23/9	23/13	23/25	23/3	23/17	23/1	23/7	23/15	23/19	23/11	1	23/21	0.136
	测点 2	21/5	21/9	21/13	21/25	21/3	21/17	21/1	21/7	21/15	21/19	21/11	21/23	1	0.124

改变,如表 4 所示,此刻挑选出权重发生重大改变的测点作为设备的关键测点,但不能单单根据某时刻单个温度值而判断此时的温度,会引起误判别。需要对关键测点进行一个周期的跟踪识别,以提高温度判别的可靠性。

3.2 T Kohonen 自组织神经网络对测点温度状态识别

3.2.1 T Kohonen 人工自组织神经网络模型的确立

1) 输入参数的确定。

前面 AHP 应用牵引电机实例中,各个测点温度每 15 s 采集一次,2 min 为一个时间段即一个周期,如表 3 中 t_2 时刻的关键测点温度 $x_i(t_2)$ 为 91.2 ℃, t_2 时刻后持续采集 7 次,共一个周期的温度序值 8 个作为输入参数,即输入参数为 8 个

神经元节点,某测点一个周期内温度序列值。

2) 输出层节点神经元的确定。

牵引电机有 7 种温度状态,输出层采用神经元节点数为 7,每个神经元节点表示一种温度状态即可以表达温度状态的模式,由于温度序列的多样性,为了提高对温度状态的识别概率,输出层采用二维平面 8 × 8 的点阵结构,即通过对训练样本的学习训练 SOFM 能将相近或相类似的状态数映射到同一个区域。

3.2.2 牵引电机温度状态识别

1) 训练样本准备及训练网络。

根据对现场设备运行时温度记录的观察及专家经验,选

择了400个训练样本对网络训练,由于篇幅有限,列举部分训练样本如表5所示,其中平稳温度状态 T_s 、平稳上升温度状态 T_r 、突然上升温度状态 T_{sr} 、突然下降温度状态 T_{sd} 、突然上升后平稳状态 T_{srh} 、突然下降后的平稳状态 T_{sds} 。

表5 各个温度状态的典型样本

样本 序列	温度 状态	输入特征向量							
		$x_k(t_1)$	$x_k(t_2)$	$x_k(t_3)$	$x_k(t_4)$	$x_k(t_5)$	$x_k(t_6)$	$x_k(t_7)$	$x_k(t_8)$
1	T_s	76.3	77.1	77.5	78.4	78.5	78.5	78.8	78.9
2	T_s	75.4	75.2	76.1	76.1	76.2	77.5	77.7	78.0
3	T_{sds}	92.3	64.3	65.8	66.4	67.8	67.9	69.3	72.4
4	T_r	40.7	46.8	51.9	59.2	64.7	70.6	73.4	77.7
5	T_r	52.5	58.3	65.7	77.6	78.9	78.9	79.3	80.4
6	T_{srh}	64.3	80.4	80.6	80.9	81.3	81.6	81.4	81.9
7	T_{sr}	43.2	58.7	61.6	65.7	73.9	78.4	79.6	81.5

2) 识别检验。

网络训练完成后,记住了各输出神经元节点与输入神经元节点的联接权重,建立了基于时间的温度测值序列与温度状态相对应的非线性映射关系。为验证该模型建立的有效性,利用100个未参加训练的样本作为“未知”样本,运用该模型已掌握的知识信息识别,按其输出节点(即最大的内积值的节点)的类别判别其待识别样本的类别,识别正确率89%。表6所列举的3个样本是针对表3中右部测点2在 t_2 时刻一个周期可能会出现的样本序列,利用SOFM对其识别结果。其中,样本1预测是平稳状态,则需要报警,因其平稳状态是保持 t_2 时刻异常升高的温度。样本2识别结果是在突然下降后的平稳状态, t_2 时刻后一个周期内温度又回到突变之前的状态,即正常状态,即不需要报警。样本3除个别点外,保持上升的趋势,即异常变温度之后的温度继续上升,因此也需要报警。由此可见,引入SOFM对关键测点进行一段时间的识别提高了温度判别的可靠性。

表6 待测样本识别结果与实际相比较

样本 序列	输入特征向量								预测 状态	实际 状态
	$x_k(t_1)$	$x_k(t_2)$	$x_k(t_3)$	$x_k(t_4)$	$x_k(t_5)$	$x_k(t_6)$	$x_k(t_7)$	$x_k(t_8)$		
1	91.2	91.8	91.9	92.0	92.0	92.1	92.7	93.2	T_s	T_s
2	91.2	67.2	67.2	67.3	67.2	67.2	67.5	67.9	T_{sds}	T_{sds}
3	91.2	68.5	69.2	94.3	82.5	96.3	100.2	104.5	T_{sr}	T_{sr}

4 结语

以牵引电机外壳多测点的温度监测为例,为减少因过多测点带来的繁琐复杂性引入AHP方法对各个测点进行动态时刻选择,挑选能反映当前设备温度的关键测点,同时引入T Kohonen人工自组织神经网络对选择的测点的温度进行一段时间的跟踪识别与温度判别,提高了识别的可靠性并能准确地找到关键测点。本文的方法中体现了3个比较新颖的方面。

1) AHP方法的成功引入,不是孤立地研究设备的某一测点,而是设备外壳很多的测点及内部相关测点。当外壳某测点出现异常,可以关联地判别是否是内部相关测点的温度变化而引起的,避免了孤立地研究一个测点的信息单一化,增加了表达设备温度状态知识信息的丰富性。

2) Kohonen人工自组织输入参数的确定,当某测点某时刻的温度被AHP排序选中,Kohonen对此点的温度进行一个周期的跟踪识别,而不是孤立地研究某时刻的温度值进行判别,提高了温度状态判别的可靠性。

3) 由于表达温度状态的温度序列值的多样性,利用了Kohonen人工自组织的优点,将高维映射到低维,将相近或相似的温度序列映射到二维空间相近或相同的区域,保持了其拓扑结构的不变性,同时也提高了分类能力。

参考文献:

- [1] 张甲敏,陈军龙,邹朝军,等. 温度对密封镉镍蓄电池容量的影响[J]. 电源技术, 2007, 31(3): 225-227.
- [2] 杨丽伟,张奕黄. 异步牵引电机的温度场分析[J]. 防爆电机, 2008, 43(2): 18-21.
- [3] 张舟云,徐国卿,沈祥林. 牵引逆变器散热系统的分析与设计[J]. 同济大学学报: 自然科学版, 2004, 32(6): 775-778.
- [4] 于建国,叶庆泰,吕晨亮. 地铁用制动电阻弹性热力耦合仿真分析[J]. 计算机仿真, 2004, 21(10): 167-169.
- [5] ZHANG YAN, ZHANG HONG; ZHONG ZHENYU, et al. Objectively evaluating environmental comprehensive quality by improved AHP method[C] // The 2nd International Conference on Bioinformatics and Biomedical Engineering. Washington, DC: IEEE Computer Society, 2008: 4645-4649.
- [6] 高隽. 人工神经网络原理及仿真实例[M]. 北京: 机械工业出版社, 2003: 146-152.
- [7] 刘新亮,朱道立. 选择与判断——AHP(层次分析法)决策[M]. 上海: 上海科学普及出版社, 1990: 45-55.

《计算机应用》2011年选题方向和重点组稿内容

网络与通信 物联网技术(RFID应用)、嵌入式技术、无线传感网、通信技术、互联网体系结构、网络协议、下一代网络(未来网络)技术、社交网络。

信息安全 密码技术、数据安全、计算机病毒与防治、网络安全、水印技术。

先进计算 社会计算、云计算、海计算、绿色计算、云计算、网格计算、普适计算、可信计算、可视计算、智能计算、移动计算、仿生计算、生物医学计算、分布式计算。

人工智能 机器学习、模式识别、智能感知、神经网络、专家系统、自然语言处理、认知科学、认知技术。

图形图像技术 图形学、图像处理、机器视觉、虚拟现实(虚拟仿真、建模技术、识别与合成技术、虚拟平台/应用、交互技术、增强现实与视觉合成、人机交互)。

数据库技术 XML数据管理、数据仓库、数据流管

理、Web数据库、数据集成、数据挖掘、特种数据库、海量数据存储与处理、语义Web。

计算机软件技术 操作系统、编译系统、软件开发环境与开发技术、软件工程。

现代服务业信息技术 电子商务、电子政务、数字金融、数字医疗、数字教育、数字旅游、数字媒体、数字娱乐、现代物流。

典型应用 计算机控制(智能控制技术、模糊控制、现场总线技术、嵌入式控制)、先进制造、智能交通、节能环保、现代农业、电子技术应用、监控系统。

2011年将特别关注物联网、云计算、绿色计算、下一代网络(未来网络)技术等方面的文章。

《计算机应用》编辑部

2011年1月