

DOI: 10.13382/j.jemi.2017.09.016

基于臀部红外测量的神经网络体温算法研究

陈小惠 王卓培 王悠苒 张永芳 吕亚帅 王晶鑫

(南京邮电大学自动化学院 南京 210023)

摘要: 红外测体温的精度受到多种因素的影响,具有非线性和高度复杂性的特点。为了提高红外测体温的精度,分析了环境温度、测量距离、发射率等对红外测体温精度的影响。研究了基于臀部的红外体温测量方法,建立了由臀部体表温度转化为人体实际体温的温度场扩散模型,利用偏最小二乘法和人工神经网络对温度场模型进行优化补偿,有效的解决了各影响因素之间多重相关性的问题和补偿模型的非线性问题,提高了系统的可靠性。实验结果表明,所提出的红外测体温补偿模型测温误差范围在 $-0.12 \sim 0.11$ $^{\circ}\text{C}$,具有更高的测量精度且适应性更强。

关键词: 偏最小二乘法;人工神经网络;红外测温;补偿模型

中图分类号: TN219 **文献标识码:** A **国家标准学科分类代码:** 510.8040

Research on neural network body temperature algorithm based on hip infrared measurement

Chen Xiaohui Wang Zhuopei Wang Youran Zhang Yongfang Lv Yashuai Wang Jingxin

(College of Automation, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: The accuracy of infrared body temperature measurement is affected by many factors, which is characterized by non-linearity and high complexity. In order to improve the accuracy of infrared body temperature measurement, the influence of ambient temperature, measurement distance and emissivity on the accuracy of infrared body temperature measurement analyzed. The temperature field diffusion model of the hip surface temperature is transformed into the actual body temperature of the human body. The partial least squares method and the artificial neural network are used to optimize the temperature field model, which effectively solves the problem of the temperature field diffusion method. The problem of multiple correlation between influencing factors and the nonlinear problem of compensation model are served effectively, and the reliability of the system is improved. The experimental results show that the temperature measurement error of the proposed infrared temperature compensation model is $-0.12 \sim 0.11$ $^{\circ}\text{C}$, which has higher measurement accuracy and stronger adaptability.

Keywords: partial least squares; artificial neural network; infrared temperature measurement; compensation model

0 引言

人体体温是人健康与否的重要标志之一,是人体进行正常的新陈代谢的结果。近年来,非接触式红外测温仪发展迅速,具有测量速度快、灵敏度高等特点。尤其当今世界范围内时常出现突发性传染性疾病,使用红外测

温仪对发热人群进行初步的筛选,显得尤为重要^[1]。同时,伴随着穿戴式医疗设备的大量出现,将体温作为常规的检测参数越来越普遍,这就对红外测体温的精确度提出了更高的要求^[1-2]。但在实际的测量中,红外测体温容易受到测量距离、环境温度、被测物体表面发射率等因素的影响,同时,红外测体温直接测量的是人体的体表温度,还需要通过一定的转化关系得到人体实际体温,这就

导致了红外测体温普遍存在测量精度不高、测量误差较大等问题,无法达到临床检测的要求。为了提高红外测体温的测量精度,国内外学者都开展了一系列的研究,目前已有多种处理方法,例如徐坤等人^[3]提出的利用多元线性回归的方法,建立人体体温段补偿模型,来提高红外测体温的测量精度,但缺点是补偿模型的相关性较差且物理意义不足,当测体温的影响因素出现突变时,测温模型就无法进行有效的预测出人体的实际温度。为了提高修正精度,孙志远等人^[4]提出了辐射定标数据修正方法,该方法虽然精度有所提高,但是对于大规模的红外测温仪需要进行不同的修正,操作成本太高。除了上述红外测体温受各种影响因素的影响外,在红外测体温的使用中还有传感器自身非线性的特性的相关问题需要解决。因此分析红外测体温的综合影响因素,研究各个因素之间对红外测体温的影响关系,建立高精度的测温模型,提高人体红外测体温的精度,具有重要的社会意义和实用价值。

针对上述红外测体温中存在的优缺点,本文研究了基于臀部的红外体温测量方法,将红外传感器置于座便器的表面测量人体的臀部体表温度,建立了由臀部体表温度转化为人体实际体温的温度场扩散模型,利用偏最小二乘法(PLS)和神经网络对温度场模型进行优化补偿^[5]。提出的基于臀部的红外体温测量方法,相比传统的手持式红外测温仪,因固定于座便器的表面,测温环境相对稳定,可以有效的减小因测量距离和环境温度的较大变化对测温效果的影响。提出的人体红外测体温误差补偿模型,相比传统的温度补偿模型,有效解决了线性关系的简单处理带来的测量误差,利用偏最小二乘法实现主成分分析、多元线性回归和典型相关分析的综合,有效地克服了各影响因素之间的多重相关性的问题^[6],在此基础上结合神经网络原理,解决了耦合模型的非

线性问题,简化了网络结构^[7-8],构建了一个高精度的红外测温补偿模型,提高了系统的可靠性和适应性,实现对人体温度的精确测量。

1 测温系统及工作原理

红外辐射俗称红外线,它是一种人眼不可见的光线,介于可见光中红色光和微波之间的光线。任何物体,只要它的温度高于绝对零度,就会不停地向周围空间发出红外辐射能量,能量波长主要集中在 0.8 ~ 15 μm。其辐射能量密度与温度的关系符合斯蒂芬-波尔兹曼辐射定律:

$$E = \epsilon\sigma T^4 \tag{1}$$

式中: E 为辐射出射度,即单位面积所发射的辐射功率,单位为 W/m^3 , ϵ 为物体的辐射率; σ 为斯蒂芬-波尔兹曼常数; T 为物体的热力学温度,单位为 K。由式(1)可知,物体的温度越高,辐射功率也就越大。同理,如果测量出物体的辐射功率,即可确定物体的温度,这就是红外测温的客观依据^[9]。本文的红外测体温系统是基于实验室研究开发的一种臀部无创多生理参数监测系统,体温是其中的一个检测参数,通过将红外传感器固定在座便器的表面来采集人体的臀部体表温度,将采集到的人体臀部体表温度根据建立的温度场扩散模型转化为人体的实际温度,构建了人体臀部的红外体温测量系统,测温系统由数字红外传感器、处理电路、微处理器和显示器等组成,将红外传感器置于座便器的表面采集人体臀部的红外体温参数,将采集到红外信号经过一系列的放大和滤波后传输至微处理器进行处理,利用存储在处理器中的红外体温计算算法计算出人体实际温度,在显示器上进行显示,实现对人体体温的测量。系统结构原理如图1所示。

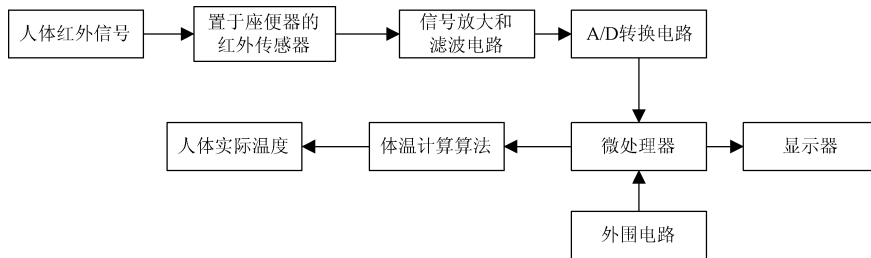


图1 红外测温系统结构

Fig. 1 Block diagram of infrared temperature measurement system structure

2 偏最小二乘和神经网络耦合模型

实际应用中,在对红外测体温的测量误差进行补偿修正时,通常会采用回归分析方法,其中,使用最多的为

最小二乘拟合模型,对事先测定的影响因素进行筛选和系数求解,但这种模型普遍存在着两个问题:1)影响红外测体温的因素之间会存在着严重的相关性,这种相关性对分析结果产生较大的影响,更有甚者使建立的补偿模型失效;2)红外测体温系统是非线性的,导致线性关系的

简单处理会带来测量误差^[10]。为了解决以上两个问题，建立了偏最小二乘和神经网络相结合的耦合模型。利用PLS实现主成分分析、多元线性回归和典型相关分析的综合，有效地克服了各影响因素之间的多重相关性的问题^[11-12]。同时，结合人工神经网络模型具有很强的自学习性、自组织性和非线性逼近功能的特点，能有效的降低线性处理中带来的预测误差，解决了补偿模型的非线性问题^[13-14]。本文将PLS和径向基神经网络(RBF)进行耦合建立补偿模型。

2.1 构造网络输入层

用偏最小二乘回归提取关于自变量和因变量的主成分，红外测体温可归结为单因变量回归问题，则设有 q 个因变量 $\{y_1, y_2, \dots, y_q\}$ 和 p 个自变量 $\{x_1, x_2, \dots, x_p\}$ ，为了研究自变量与因变量之间的统计关系，采集 m 个红外测温数据 $\mathbf{X} = [x_1, x_2, \dots, x_p]_{m \times p}$ 和 $\mathbf{Y} = [y_1, y_2, \dots, y_q]_{m \times q}$ ，分别对 \mathbf{X} 和 \mathbf{Y} 做标准化处理为 $\mathbf{E}_0 = (E_{01}, E_{02}, \dots, E_{0p})_{m \times p}$ ， $\mathbf{F}_0 = (F_{01}, F_{02}, \dots, F_{0q})_{m \times q}$ 。从 \mathbf{E}_0 中提取第一个主成分 t_1 ， $t_1 = \mathbf{E}_0 \mathbf{W}_1$ ，其中 \mathbf{W}_1 为 \mathbf{E}_0 的第1个轴， $\|\mathbf{W}_1\| = 1$ ；同理，从 \mathbf{F}_0 中提取第一个成分 u_1 ， $u_1 = \mathbf{F}_0 \mathbf{C}_1$ ，其中 \mathbf{C}_1 为 \mathbf{F}_0 的第1个轴， $\|\mathbf{C}_1\| = 1$ 。根据PLS中主成分分析原理要求 t_1 和 u_1 相关性最大，即为求 t_1 和 u_1 协方差最大，可计算出 t_1 和 u_1 。分别建立 \mathbf{E}_0 和 \mathbf{F}_0 对 t_1 和 u_1 的回归方程， $\mathbf{E}_0 = t_1 \mathbf{p}_1^T + \mathbf{E}_1$ ， $\mathbf{F}_0 = t_1 \mathbf{r}_1 + \mathbf{F}_1$ ，其中 \mathbf{p}_1 ， \mathbf{r}_1 分别为回归系数， \mathbf{E}_1 、 \mathbf{F}_1 分别为对应的残差矩阵。以 \mathbf{E}_1 、 \mathbf{F}_1 分别代替 \mathbf{E}_0 和 \mathbf{F}_0 ，及求出 t_2 和 u_2 ，如此往复，直到求出主成分个数 h ，其中 h 可用交叉有效性原理求出。设 y_i 为原始数据， t_1, t_2, \dots, t_h 是在建模过程中提取的主成分。 $\hat{y}_{h(i)}$ 是使用全部样本点并取 t_1, t_2, \dots, t_h 回归建模后，第 i 个样本的拟合值。 $\hat{y}_{h(-i)}$ 是在建模时删去第 i 个样本点，取 t_1, t_2, \dots, t_h 回归建模后，再用此模型计算 y_i 的拟合值。记：

$$Q_h^2 = 1 - \frac{p_h}{s_h - 1} \tag{2}$$

式中： $s_h = \sum_{i=1}^n (y_i - y_{h(i)})^2$ ， $p_h = \sum_{i=1}^n (y_i - y_{h(-i)})^2$ 。当 $Q_h^2 \geq (1 - 0.95^2) = 0.0975$ ，说明插入的新成分对模型的预测能力有明显的改善作用。此时提取的 h 个主成分作为RBF输入层的输入，构造神经网络模型如图2所示，设隐含层有 N 个神经元，任意神经元用 i 表示， $\phi(\mathbf{X}, \mathbf{X}_i)$ 为“基函数”，它是第 i 个隐单元的激励输出；输出层有 J 个神经元，其中任一神经元用 j 表示。隐含层与输出层突触权值用 w_{ij} ($i = 1, 2, \dots, N; j = 1, 2, \dots, J$) 表示。

2.2 构建输出层

设有训练样本 N 个，训练样本集为 $\mathbf{X} = [X_1, X_2, \dots,$

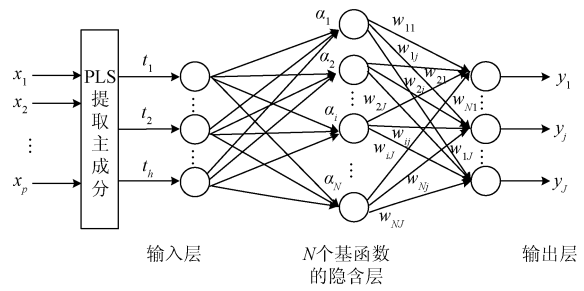


图2 PLS和RBF耦合模型结构

Fig.2 Structure of PLS and RBF coupling model

$X_k, \dots, X_N]^T$ ，其中任一训练样本 $\mathbf{X}_k = [X_{k1}, X_{k2}, \dots, X_{km}, \dots, X_{kM}]$ ，($k = 1, 2, \dots, N$)，对应的实际输出为 $\mathbf{Y}_k = [y_{k1}, y_{k2}, \dots, y_{kj}, \dots, y_{kj}]$ ，($k = 1, 2, \dots, N$)，期望输入为 $\mathbf{d}_k = [d_{k1}, d_{k2}, \dots, d_{kj}, \dots, d_{kj}]$ ，($k = 1, 2, \dots, N$)。

当网络输入训练样本 \mathbf{X}_k 时，网络第 j 个输出神经元的实际输出为：

$$y_{kj}(\mathbf{X}_k) = w_{0j} + \sum_{i=0}^I w_{ij} \phi(\mathbf{X}_k, t_i) \quad j = 1, 2, \dots, J \tag{3}$$

当“基函数”为高斯函数时，可如下表示：

$$\phi(\mathbf{X}_k, t_i) = G(\|\mathbf{X}_k - t_i\|) = \exp\left(-\frac{1}{2\sigma_i^2} \|\mathbf{X}_k - t_i\|^2\right) = \exp\left(-\frac{1}{2\sigma_i^2} \sum_{m=1}^M (x_{km} - t_{im})^2\right) \tag{4}$$

式中： $t_i = [t_{i1}, t_{i2}, \dots, t_{iM}]$ ，为函数的中心； σ_i 为函数的方差。

2.3 网络学习算法

RBF网络要学习的参数有3个：基函数的中心和方差以及隐含层与输出层间的权值^[10]。径向基函数有多种学习方法，本文采用自组织选取中心方法，该方法分为两个步骤进行，学习隐含层基函数的中心与方差的阶段和学习输出层权值阶段。

1) 学习中心 t_i ($i = 1, 2, \dots, D$)。自组织学习过程要用到聚类算法，常用的聚类算法是 K -均值聚类算法。假设聚类中心有 I 个，设 $t_i(n)$ ($i = 1, 2, \dots, D$)，是第 n 次迭代时基函数的中心， K -均值聚类算法具体步骤如下：(1) 初始化聚类中心，即根据经验从训练样本集中随机选取 I 个不同的样本作为初始中心 $t_i(0)$ ，($i = 1, 2, \dots, D$)，设置迭代步数 $n = 0$ 。(2) 输入训练样本 \mathbf{X}_k ，找到 $i(\mathbf{X}_k)$ 使其满足 $i(\mathbf{X}_k) = \arg \min_i \|\mathbf{X}_k - t_i(n)\|$ ， $i = 1, 2, \dots, I$ ，式中， $t_i(n)$ 是第 n 次迭代时基函数的第 i 个中心。(3) 调整中心如下：

$$t_i(n+1) = \begin{cases} t_i(n) + \eta[\mathbf{X}_k(n) - t_i(n)], & i = i(\mathbf{X}_k) \\ t_i(n), & \text{其他} \end{cases} \tag{5}$$

调整基函数的中心。 η 是学习步长且 $0 < \eta < 1$ 。(4) 判断是否学完所有的训练样本且中心的分布不再变化, 则结束; 否则 $n = n + 1$, 转到步骤(2), 最后得到的 $t_i (i = 1, 2, \dots, I)$ 即为 RBF 网络最终的基函数的中心。

2) 方差 $\sigma_i (i = 1, 2, \dots, I)$; 由于在前面径向基函数我们选择了高斯函数, 方差计算如下:

$$\sigma_1 = \sigma_2 = \dots = \sigma_I = \frac{d_{\max}}{\sqrt{2I}} \quad (6)$$

式中: I 为隐单元的个数, d_{\max} 为所选取中心之间的最大距离。

3) 学习权值 $w_{ij} (i = 1, 2, \dots, I; j = 1, 2, \dots, J)$ 。权值的学习采用伪逆的方法求解, 即:

$$W = G^+ D \quad (7)$$

式中: $D = [d_1, \dots, d_k, \dots, d_N]^T$, 是期望响应; G^+ 是矩阵 G 的伪逆。

$$G^+ = (G^T G)^{-1} G^T \quad (8)$$

矩阵 G 由下式确定:

$$G = \left\{ g_{ki} = \exp\left(-\frac{I}{d_{\max}^2} \|X_k - t_i\|^2\right), \right. \\ \left. k = 1, 2, \dots, N; i = 1, 2, \dots, I \right\} \quad (9)$$

权矩阵 W 为:

$$W = \{w_{ij}\} \quad i = 1, 2, \dots, I; j = 1, 2, \dots, J \quad (10)$$

W 即为所求。

3 耦合模型在红外测温中的应用

为了验证以上耦合模型能否有效的预测红外测体温中人体的真实体温, 利用实验室制作的置于座便器上的红外测温仪对人体的臀部温度进行采集实验, 前端采用数字红外温度传感器和实验室自行研发的处理电路模块, 将采集模块置于座便器的表面, 首先对采集到的人体体表红外信号进行收集处理转化为人体体温, 设计在不同的实验环境下, 多次重复测量人体体温, 通过设定在不同环境温度、测量距离和发射率等条件下, 对红外测体温效果的影响, 收集测温数据进行分析, 实验结果表明, 红外测温主要受到测温的环境温度、测量距离和发射率的影响。本文收集了红外测温仪测温中环境温度、测量距离、发射率、臀部测量温度和人体实际温度(表1), x_1 为环境温度($^{\circ}\text{C}$), x_2 为测量距离(cm), x_3 为发射率, x_4 为人体臀部温度($^{\circ}\text{C}$)。

3.1 多重相关性分析

计算各自变量和因变量的相关系数, 如表2所示, 从表2可以看出自变量之间存在着多重相关性, 例如 x_1 与 x_4 的相关系数为 0.902, x_2 与 x_4 的相关系数为 0.623。

表1 红外测温的影响因素和测量结果

Table 1 Influence factors and measurement results of infrared temperature measurement

测量次数	x_1	x_2	x_3	x_4	实际体温
1	16	2	0.98	34.32	36.42
2	18	2	0.98	34.47	36.45
3	20	2	0.98	34.62	36.52
4	22	2	0.98	34.86	36.62
5	24	2	0.98	34.93	36.83
6	26	2	0.98	35.34	37.05
7	28	2	0.98	35.63	37.16
8	20	1	0.98	34.95	36.53
9	20	1.5	0.98	34.84	36.52
10	20	2.5	0.98	34.47	36.35
11	20	2	0.95	34.65	36.64
12	20	2	1.00	34.69	36.72
13	20	2	0.98	34.74	36.41
14	20	2	0.98	34.83	36.74
15	20	2	0.98	34.80	36.53
16	22	2	0.98	34.93	36.52
17	24	2	0.98	35.06	36.65
18	22	1	0.98	35.24	36.23
19	24	1	0.98	35.33	36.72
20	24	1.5	0.98	35.14	36.35

表2 各变量之间的相关系数

Table 2 Correlation coefficients between variables

变量	x_1	x_2	x_3	x_4	y
x_1	1.000	-0.126	0.034	0.902	0.648
x_2		1.000	-0.028	0.623	0.109
x_3			1.000	0.048	-0.020
x_4				1.000	0.548
y					1.000

3.2 提取主成分

根据 PLS 的交叉有效判别法提取主成分^[15], 利用式(2)计算交叉有限性, 当主成分提取到 t_4 时, $Q_h^2 < 0.0975$, 可得 $h = 4$, 所以说明提取 3 个主成分即可, 提取的 3 个主成分表达式如下:

$$\begin{bmatrix} t_1 \\ t_2 \\ t_3 \end{bmatrix} = \begin{bmatrix} 0.6055 & 0.1070 & 0.0196 & -0.479 \\ -0.207 & 0.8166 & 0.1990 & -0.422 \\ 0.0333 & -0.204 & 0.9774 & 0.0461 \end{bmatrix} E_0^T \quad (11)$$

式中: E_0^T 表示为原始自变量数据标准化的矩阵, 即 $E_0^T = [e_1, e_2, e_3, e_4]$, 用 PLS 提取主成分, 集主成分分析、多元线性回归分析和典型相关分析于一体, 提取出的主成分对自变量和因变量都具有最佳的解释能力。

3.3 PLS 和 BRP 耦合模型拟合和检验

将提取的 t_1, t_2, t_3 作为神经网络的输入, 学习步长取

0.3,将输出数据限制在0.2~0.8。建立2个输入节点,3个隐节点和1个输出节点的BRF训练模型,将训练样本输入神经网络进行反复的训练,当训练量达到128次时,误差函数趋于稳定并满足设定的精度要求,训练结束。

为了检验PLS和BRF耦合模型的红外测温效果,利用PLS和BRF耦合模型进行红外测温数据拟合,用该模型预测了16组在人体正常体温段的红外测体温结果,同时采用了最小二乘回归模型进行了对比研究,各模型拟合如图3所示。




图3 各模型拟合结果

Fig.3 Fitting results of each model

图3中可以看出PLS-RBF耦合模型曲线相比于最小二乘模型曲线与人体实际体温曲线更加相对接近,说明PLS-RBF耦合模型预测结果较好,优于最小二乘模型曲线。

表3所示为PLS-RBF耦合模型预测值与人体实际体温值的相关性分析,从表3可知16组红外测温数据计算出的耦合模型预测值与人体实际体温值的Pearson相关系数为0.992,它的实际显著水平为0.001,远小于理论显著水平0.01,说明PLS-RBF耦合模型预测体温值与人体实际体温存在高度的线性正相关。

表3 耦合模型的相关性分析

Table 3 Correlation analysis of coupling model

	人体实际体温	耦合模型预测值
Pearson 相关性	1	0.992 **
人体实际体温 显著性(双侧)		0.001
N	16	16
Pearson 相关性	0.992 **	1
耦合模型预测值 显著性(双侧)	0.001	
N	16	16

* *. 在0.01水平(双侧)上显著相关

表4所示为两种模型的检验结果及绝对误差。从表中可以看出,PLS-RBF耦合模型对人体红外测温的预测效果明显高于单一的最小二乘法回归模型,更接近于人

表4 两种模型结果对比

Table 4 Comparison of the results of the two models (°C)

实际值	PLS-BRF 耦合模型		最小二乘法回归模型	
	预测值	绝对误差	预测值	绝对误差
36.52	36.59	0.07	36.71	0.19
36.21	36.21	0	36.32	0.11
35.93	35.82	-0.11	36.09	0.16
36.05	35.97	-0.08	35.63	0.48
36.32	36.31	-0.01	36.52	0.20
36.71	36.59	-0.12	36.49	-0.22
36.59	36.54	-0.05	36.32	-0.27
36.21	36.3	-0.09	36.57	0.36
36.53	36.63	0.1	36.72	0.19
36.71	36.72	0.01	36.51	-0.20
35.76	35.86	0.10	36.39	-0.37
36.88	36.79	-0.09	37.20	0.32
36.71	36.82	0.11	36.92	0.21
36.29	36.36	0.07	36.58	0.29
36.63	36.56	-0.07	36.32	-0.31
36.42	36.38	-0.04	36.24	-0.18

体实际体温,在人体正常体温段35.8~37.5℃之间时,耦合模型测温结果的绝对误差范围为-0.12~0.11℃,而单一最小二乘回归模型的预测值与实际体温值之间相差较大,预测结果相对较差,测温结果的绝对误差分布在-0.37~0.48℃。检验结果显示PLS和RBF耦合模型能较好地反映红外测体温与其各影响因素之间的变化关系,也进一步体现了该耦合模型在处理自变量之间多重相关性和非线性问题方面的优势。

4 结论

针对红外测体温精度易受到测温环境的影响,设计基于臀部的红外体温测量方法,采用PLS和RBF相耦合的温度补偿模型,对红外测体温进行优化补偿,可以有效的克服各影响因素之间存在的多重相关性问题,提高了测温拟合精度,同时利用神经网络进行优化模型,解决了耦合模型的非线性问题,提高了系统的稳定性。实验结果表明,在红外测体温时,神经网络优化过的偏最小二乘法测量精度比单一的最小二乘回归模型精度高,可靠性好,能更好地满足红外测体温的实际应用要求。

参考文献

[1] 苏建奎,桂星雨. 医用红外体温测量仪的现状与发展[J]. 医疗卫生装备,2016(1):110-112.
 SU J K, GUI X Y. Present situation and development of medical infrared Thermometer [J]. Medical Equipment, 2016, 37 (1): 110-112.
 [2] 郑逸凡,于香红. 可穿戴式高精度体温监测系统[J].

- 数字技术与应用,2016(2):219-221.
- ZHENG Y F, YU X H. Wearable high precision body temperature monitoring system [J]. Digital Technology and Application, 2016(2): 219-221.
- [3] 徐坤,赵麟,袁园,等. 医用红外测温仪测量误差分析及补偿试验研究[J]. 电子测量技术,2014,37(10): 104-108.
- XU K, ZHAO L, YUAN Y, et al. Study on measurement error and compensation test of medical infrared thermometer [J]. Electronic Measurement Technology, 2014,37(10): 104-108.
- [4] 孙志远,王旻,常松涛,等. 环境温度对红外辐射测量精度的影响及修正[J]. 激光与红外,2014(5): 525-527.
- SUN ZH Y, WANG M, CHANG S T, et al. Effect of ambient temperature on the accuracy of infrared radiation measurement and correction [J]. Laser and Infrared, 2014(5): 525-527.
- [5] WANG W, DENG C H, SONG J Y. Estimation of dissolved oxygen via PLS and neural networks [C]. 12th World Congress on Intelligent Control and Automation, 2016:621-624.
- [6] 陈刚,杨志强,刘秉权. 一种基于 PLS 的概率神经网络分类算法[J]. 微电子学与计算机,2015,32(5): 73-78.
- CHEN G, YANG ZH Q, LIU B Q. A probabilistic neural network classification algorithm based on [J]. PLS Microelectronics and Computer, 2015,32(5): 73-78.
- [7] 席剑辉,李晴晴,傅莉. 基于神经网络的红外辐射大气透过率建模及计算[J]. 红外,2014,35(2):33-36.
- XI J H, LI Q Q, FU L. Modeling and calculation of atmospheric transmittance of infrared radiation based on neural network [J]. Infrared, 2014,35(2): 33-36.
- [8] 孙志远,李清安,乔彦峰,等. 提高红外测温系统测温精度的研究[J]. 仪器仪表学报,2006,27(S1):67-69.
- SUN ZH Y, LI Q AN, QIAO Y F, et al. Study on improving the accuracy of infrared temperature measurement system [J]. Chinese Journal of Scientific Instrument, 2006, 26(S1): 67-69.
- [9] NING B, WU Y C. Research on non-contact infrared temperature measurement [C]. International Conference on Computational Intelligence and Software Engineering, 2010:1-4.
- [10] ZHANG J, LOU Y S. Water level prediction based on improved grey RBF neural network model [J]. IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), 2016:775-779.
- [11] 彭基伟,吕文华,行鸿彦,等. 基于改进 GA-BP 神经网络的湿度传感器的温度补偿[J]. 仪器仪表学报, 2013,34(1):153-160.
- PENG J W, LV W H, XING H Y, et al. Temperature compensation for humidity sensor based on improved GA-BP neuralnetwork [J]. Chinese Journal of Scientific Instrument,2013,34(1):153-160.
- [12] XIE X C, SUN W, CHEUNG K C. An advanced PLS approach for key performance indicator-related prediction and diagn-osis in case of outliers [J]. IEEE Transactions on Industrial Electronics,2016:2587-2594.
- [13] LU Y, ZHANG T K, ZENG Z M, et al. An improved RBF neural network for short-term load forecast in smart grids [J]. IEEE International Conference on Communication Systems (ICCS),2016:1-6.
- [14] TAO Y, ZHENG J Q, WANG T M, et al. A state and fault prediction method based on RBF neural networks[J]. IEEE Workshop on Advanced Robotics and its Social Impacts (ARSO), 2016: 221-225.
- [15] LI Q, LIU W Y, BA W, et al. Online monitoring of glutamic solution concentration based on PLS regression[J]. The 27th Chinese Control and Decision Conference (2015 CCDC),2015: 754-759.

作者简介



陈小惠,1961 年出生,南京邮电大学教授,主要研究方向为网络化测控系统、嵌入式系统与智能仪器、传感器网络与信息融合。

E-mail:chenxiaohui@njupt.edu.cn

Chen Xiaohui was born in 1961. And he is a Ph. D. and professor in Nanjing University of Posts and Telecommunications. His main research interests include networked measurement and control system, embedded system and intelligent instrument, sensor network and information fusion.



王桌培,1992 年出生,南京邮电大学硕士研究生,主要研究方向为网络化测控与网络测试技术。

E-mail:1156345048@qq.com

Wang Zhuopei was born in 1992. And now, he is a M. Sc. candidate in Nanjing University of Posts and Telecommunications. His main research interest is networked measurement and control technology and network measurement.