

文章编号: 1006-2467(2021)07-0891-08

DOI: 10.16183/j.cnki.jsjtu.2020.027

基于 PCA-ELM 的红外多光谱辐射测温

席剑辉, 姜瀚, 陈博, 傅莉

(沈阳航空航天大学 自动化学院, 沈阳 110136)

摘要: 在目标发射率未知的情况下, 建立一种基于主元分析(PCA)与极限学习机(ELM)相结合的红外多光谱测温方法. 分析目标温度与辐射亮度谱的非线性数学模型, 确定初始输入向量包含温度估计所需的充分信息; 引入 PCA 方法从输入向量中提取相互独立的主元成分, 降低神经网络输入维数; 基于 ELM 网络对样本数据充分学习, 最终建立 PCA-ELM 目标红外测温模型. 利用黑体和未知发射率材料涂层目标作为测试目标源, 验证该方法的有效性.

关键词: 主元分析; 极限学习机; 多光谱测温; 辐射亮度

中图分类号: TB 133; TN 219

文献标志码: A

Infrared Multispectral Radiation Temperature Measurement Based on PCA-ELM

XI Jianhui, JIANG Han, CHEN Bo, FULi

(School of Automation, Shenyang Aerospace University, Shenyang 110136, China)

Abstract: In the case of unknown target emissivity, an infrared multispectral radiation temperature measurement method based on principal component analysis (PCA) and extreme learning machine (ELM) is established. The nonlinear mathematic model of target temperature and radiance spectrum is analyzed to find a set of initial input vectors, which include sufficient information to estimate temperature. The PCA method is used to extract the independent principle components in input vectors. This method can also reduce the input dimension for neural network. Based on ELM network, the sample data is sufficiently learned to build the target infrared temperature measurement model by PCA-ELM. The effectiveness of the proposed method is verified by using the blackbody and the coating material with unknown emissivity as test target sources.

Key words: principal component analysis (PCA); extreme learning machine (ELM); multispectral thermometry; radiance

红外辐射测量得到的目标热辐射通量与目标温度以及材料发射率紧密相关, 所以红外测温通常需要已知目标的发射率^[1-2]. 常用的测温方法主要有光

谱极值法、全辐射测温法和亮度测温法等^[3-5]. 光谱极值法用于当目标为黑体或灰体时, 发射率为一个小于或等于 1 的固定常数. 通过测量辐射峰值点处

收稿日期: 2020-01-22

基金项目: 国际科技合作计划项目(WQ20122100063), 国家自然科学基金青年基金资助项目(61503256), 辽宁省自然科学基金项目(2015020069), 沈阳市科技创新团队项目(src201204)

作者简介: 席剑辉(1975-), 女, 辽宁省沈阳市人, 副教授, 主要研究方向为复杂系统模型辨识、故障检测与诊断、红外辐射测试与分析等.

通信作者: 傅莉, 女, 教授, 电话(Tel.): 15840355071; E-mail: ffulli@163.com.

波长,根据 Wien 位移定律计算温度.全辐射测温法依据 Stefan-Boltzmann 定律,通过测量目标的总辐射能量计算目标温度,只能通过局部波段能量近似获得.亮度测温法通过测量目标在给定波长下的辐射亮度值,获得与目标光谱辐射亮度相等的黑体温度,称为亮温,再根据亮温和发射率求得目标温度.

但在实际测量中,发射率与目标材料的成分、表面状况、所处的温度和考察的波长等因素均有关,无法建立完备的目标发射率数据库,因此在测温过程中,目标的发射率往往都是未知的.目前,针对目标发射率未知情况下的红外测温方法一般有比色测温法^[6-7]以及多光谱测温法^[8-9].比色测温法是通过测量两个波段的辐射能量之比计算温度的.通常选取两个相近波段,认为两者的发射率近似相等可以互相消除.若所选波段的发射率发生较大变化时,其相应的测温误差也会较大.多光谱测温法通过测量多个目标光谱的辐射亮度建立测温模型.最初,Svet 等^[10]引入发射率非线性模型,建立一组与模型未知参数个数相等的方程组,通过求解方程组估计目标温度和光谱发射率.所建立的方程组数量与结构对估计结果的影响较大,线性方程难以表征目标温度与红外光谱信息之间的强非线性关系.建立非线性高阶方程组会导致方程组维数迅速上升,对样本数量和求解算法提出更高的要求.测温过程中,大气、背景等复杂影响因子要求模型辨识方法应该具有良好的稳健性和适应性.近年来,自适应的智能模型辨识方法经常被用于多光谱测温^[11-12].

神经网络通过充分的样本训练自适应学习样本中隐含的非线性关系,进而建立测温模型,建模过程不需要预知目标光谱发射率^[12-14].本文主要采用一种动态神经网络极限学习机(ELM),学习在不同温度情况下,目标辐射亮度谱与温度之间的非线性映射关系;引入主元分析(PCA)方法对输入向量降维且保留主元特征,减弱输入样本中的冗余信息,避免网络过度学习,提高建模精度.

1 目标辐射温度建模

当温度为 T 时,目标辐射亮度的典型曲线如图 1 所示.其中: λ_j 为波长; $L_j(\lambda_j, T)$ 为辐射亮度.当 λ_j 分别取固定值为 $\lambda_1, \lambda_2, \dots, \lambda_p$ 时,固定温度下对应的辐射亮度值分别为 L_1, L_2, \dots, L_p .

由 Planck 定律和光谱发射率定义可得,当温度为 T 时,目标的辐射亮度为

$$L_j(\lambda_j, T) = \epsilon(\lambda_j, T) \frac{C_1}{\pi \lambda_j^5} \frac{1}{e^{C_2/\lambda_j T} - 1} \quad (1)$$




图 1 当温度为 T 时的典型目标辐射亮度曲线

Fig. 1 Radiance curve of a typical target at a temperature of T

式中: $\epsilon(\lambda_j, T)$ 为光谱发射率; C_1 和 C_2 分别为第一热辐射常数、第二热辐射常数.在同一温度 T 下,不同波长 $\lambda_1, \lambda_2, \dots, \lambda_p$ 对应的亮度为

$$\left. \begin{aligned} L_1 &= \epsilon(\lambda_1, T) \frac{C_1}{\pi \lambda_1^5} \frac{1}{e^{C_2/\lambda_1 T} - 1} \\ L_2 &= \epsilon(\lambda_2, T) \frac{C_1}{\pi \lambda_2^5} \frac{1}{e^{C_2/\lambda_2 T} - 1} \\ &\vdots \\ L_p &= \epsilon(\lambda_p, T) \frac{C_1}{\pi \lambda_p^5} \frac{1}{e^{C_2/\lambda_p T} - 1} \end{aligned} \right\} \quad (2)$$

式中: $\epsilon(\lambda_1, T), \epsilon(\lambda_2, T), \dots, \epsilon(\lambda_p, T)$ 为未知的光谱发射率,只与 T 和 λ_j 有关.因此, L_1, L_2, \dots, L_p 可以看成 p 个关于温度 T 和 λ_j 的隐函数,通过选用固定波长下的多光谱亮度信息,就可以对温度进行估计,建立基于多光谱亮度信息的目标温度模型.

由式(2)可知:① 方程组具有强非线性,常规模型辨识方法很难获取亮度谱与温度之间的关系;② 方程组个数 p 不少于等式右边展开后未知参数的个数, p 值过大时,式(2)求解困难.神经网络不需要具体知道系统动态特性,无需建立初始数学模型,尤其适用于难以用确定数学模型表达的非线性系统建模^[13].所设计的测温模型结构如图 2 所示,其中 $z_1, z_2, \dots, z_m (m < p)$ 为主元成分.模型输入端为 L_1, L_2, \dots, L_p ,输出端为 T .通过在已知温度下测量亮度谱曲线,获取输入输出样本对;再利用神经网络的强学习能力寻找输入输出间的潜在规律.为使输入包含足够的建模信息,输入亮度 L_1, L_2, \dots, L_p 往往取值密集,造成输入维数 p 数值高、建模困难.输入变量之间存在较强的相关性和冗余信息,导致网络学习精度下降,可泛化性弱.因此,在神经网络输入

端引入 PCA 层提取输入变量中的主元成分 $z_1, z_2, \dots, z_m (m < p)$, 通过降低输入维数, 以提高建模精度.




图 2 测温模型结构框图

Fig. 2 Structure diagram of temperature measurement model

2 PCA-ELM 红外光谱测温方法

在不同温度 T 下测量光谱亮度, 总共测量 n 个不同温度. 设第 k 个温度下, 对应 p 个波长的光谱辐射亮度输入为 $\mathbf{L}(k) = [L_1(k) \ L_2(k) \ \cdots \ L_p(k)]^T$ ($k = 1, 2, \dots, n$). 若输入变量间方差越大, 相关性越小, 则越具有好的区分能力. PCA 方法正是利用这一规律, 以确定具有较大方差的主元变量为目标, 对输入变量进行线性组合, 使获得的输入向量具有更好的模式区分能力.

ELM 是一种单隐层前馈网络, 网络结构简单, 输入层与隐含层连接权值以及隐含层神经元阈值在训练过程中无需调整, 训练时间快, 因此本文神经网络选用 ELM 神经网络.

2.1 PCA 的原理和步骤

设有 n 个不同温度下的目标辐射亮度向量, 每个向量包含 p 个不同波长下对应的亮度值, 构成一个 $p \times n$ 阶的矩阵 \mathbf{A} ,

$$\mathbf{A} = \begin{bmatrix} L_1(1) & L_1(2) & \cdots & L_1(n) \\ L_2(1) & L_2(2) & \cdots & L_2(n) \\ \vdots & \vdots & \ddots & \vdots \\ L_p(1) & L_p(2) & \cdots & L_p(n) \end{bmatrix}_{p \times n} \quad (3)$$

令 $\mathbf{z}(k) = [z_1(k) \ z_2(k) \ \cdots \ z_m(k)]^T$ ($m < p$), 为 \mathbf{A} 中蕴含的主元变量, 为便于表达, 把变量 k 省略, 则不同温度下, 都满足下式:

$$\left. \begin{aligned} z_1 &= a_{11}L_1 + a_{12}L_2 + \cdots + a_{1p}L_p \\ z_2 &= a_{21}L_1 + a_{22}L_2 + \cdots + a_{2p}L_p \\ \vdots & \\ z_m &= a_{m1}L_1 + a_{m2}L_2 + \cdots + a_{mp}L_p \end{aligned} \right\} \quad (4)$$

式中: $a_{i1}^2 + a_{i2}^2 + \cdots + a_{ip}^2 = 1$ ($i = 1, 2, \dots, m$). 确定

原则为^[15]: ① z_i 与 z_j ($i \neq j, i, j = 1, 2, \dots, m$) 相互无关; ② z_1 为 L_1, L_2, \dots, L_p 一切线性组合中的方差最大者; ③ z_2 为与 z_1 不相关的 L_1, L_2, \dots, L_p 所有线性组合中方差最大者; ④ z_m 为与 z_1, z_2, \dots, z_{m-1} 均不相关的 L_1, L_2, \dots, L_p 所有线性组合中方差最大者. 则新输入变量 z_1, z_2, \dots, z_m 称为原输入变量 L_1, L_2, \dots, L_p 的第 $1, 2, \dots, m$ 个主成分.

从以上分析可以看出, 主成分分析的实质是确定权值 a_{ij} ($i = 1, 2, \dots, m; j = 1, 2, \dots, p$), 分别为相关矩阵 m 个较大特征值所对应的特征向量. PCA 的步骤如下^[15-16]:

- (1) 将原始数据标准化.
- (2) 建立变量的相关系数矩阵 $\mathbf{R} = [r_{ij}]_{p \times p}$.

$$r_{ij} = \frac{\sum_{k=1}^n (L_i(k) - \bar{L}_i)(L_j(k) - \bar{L}_j)}{\sqrt{\sum_{k=1}^n (L_i(k) - \bar{L}_i)^2 \sum_{k=1}^n (L_j(k) - \bar{L}_j)^2}} \quad (5)$$

式中: \bar{L}_i 为 L_i 的均值; \bar{L}_j 为 L_j 的均值.

- (3) 求 \mathbf{R} 的特征根 $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_p > 0$ 及其相应的单位特征向量.

$$\begin{aligned} \mathbf{a}_1 &= [a_{11} \ a_{12} \ \cdots \ a_{1p}]^T \\ \mathbf{a}_2 &= [a_{21} \ a_{22} \ \cdots \ a_{2p}]^T \\ &\vdots \\ \mathbf{a}_p &= [a_{p1} \ a_{p2} \ \cdots \ a_{pp}]^T \end{aligned}$$

- (4) 计算前 m 个特征值的累计贡献率 γ_m .

$$\gamma_m = \frac{\sum_{k=1}^m \lambda_k}{\sum_{k=1}^p \lambda_k} \quad (6)$$

- (5) 一般当 $\gamma_m > 85\% \sim 95\%$ 时, 可得 m 个主成分 z_i , 令 $i = 1, 2, \dots, m$

$$z_i = a_{i1}L_1 + a_{i2}L_2 + \cdots + a_{ip}L_p \quad (7)$$

2.2 ELM 的原理

ELM^[14-17] 是一种单隐层神经网络, 可以随机初始化输入权重和偏置, 网络结构图如图 3 所示, 其中 N 为隐含层神经个数.

对第 k 个学习样本, 有网络输入为 $\mathbf{z}(k) = [z_1(k) \ z_2(k) \ \cdots \ z_m(k)]^T$, 网络输出为对应该输入的第 k 个温度 $T(k)$. 共测量 n 个温度, 则有 $k = 1, 2, \dots, n; m$ 为 PCA 确定的主元维数. ELM 网络隐含层的输出为

$$T(k) = \sum_{l=1}^N \beta_l g(\mathbf{W}_l \cdot \mathbf{z}(k) + b_l) \quad (8)$$

式中: $g(\cdot)$ 为激活函数, ELM 对激活函数没有特别要求, 常见的激活函数有 sigmoid 函数和 tanh 函




图 3 ELM 网络结构图

Fig. 3 Structure of ELM network

数; \mathbf{W}_l 为输入权重; β_l 为隐含层第 l 个神经元到输出的权重; b_l 为隐含层第 l 个神经元的阈值. 单隐层神经网络的训练目标是要使得拟合的误差最小, 即网络输出 $T(k)$ 与理想输出 $O(k)$ 差的范数趋向于 0, 可表示为

$$\sum_{k=1}^n \|O(k) - T(k)\| = 0 \quad (9)$$

寻找 $b_l, \mathbf{W}_l, \beta_l$ 使得

$$\sum_{l=1}^N \beta_l g(\mathbf{W}_l \cdot \mathbf{z}(k) + b_l) = O(k) \quad (10)$$

设 \mathbf{Y} 为隐含层节点输出矩阵, 通过矩阵初等变换得到矩阵的秩为 h , 则矩阵 \mathbf{Y} 可分解为

$$\mathbf{Y}(\mathbf{W}_1 \cdots \mathbf{W}_N, b_1 \cdots b_N, \mathbf{z}(1) \cdots \mathbf{z}(n)) = \begin{bmatrix} g(\mathbf{W}_1 \cdot \mathbf{z}(1) + b_1) & \cdots & g(\mathbf{W}_N \cdot \mathbf{z}(1) + b_N) \\ \vdots & \ddots & \vdots \\ g(\mathbf{W}_1 \cdot \mathbf{z}(n) + b_1) & \cdots & g(\mathbf{W}_N \cdot \mathbf{z}(n) + b_N) \end{bmatrix} = \mathbf{F}\mathbf{G} \quad (11)$$

式中: \mathbf{F} 为 $n \times h$ 满秩矩阵; \mathbf{G} 为 $h \times N$ 满秩矩阵.

最终找到 $\hat{\mathbf{W}}_l, \hat{b}_l, \hat{\beta}_l$ 使得式(9)取最小, 即等价于求解最小化损失函数:

$$E = \sum_{k=1}^n \left[\sum_{l=1}^N \hat{\beta}_l g(\hat{\mathbf{W}}_l \cdot \mathbf{z}(k) + \hat{b}_l) - O(k) \right]^2 \quad (12)$$

输入权重 $\hat{\mathbf{W}}_l$ 和阈值 \hat{b}_l 可随机确定, 即可求出隐含层的输出矩阵 \mathbf{Y} , 不需要不断地调整迭代参数. 单隐层神经网络便转化成了求解线性系统, 可表示为

$$\mathbf{Y}\hat{\boldsymbol{\beta}} = \mathbf{T} \quad (13)$$

式中: $\hat{\boldsymbol{\beta}}$ 为输出权重矩阵; \mathbf{T} 为 ELM 网络的温度输出向量, 由 $T(k)$ 组成. 由式(11)可唯一确定 \mathbf{Y} 的 Moore-Penrose 逆 \mathbf{Y}^+ :

$$\mathbf{Y}^+ = \mathbf{G}^H (\mathbf{G}\mathbf{G}^H)^{-1} (\mathbf{F}^H \mathbf{F})^{-1} \mathbf{F}^H \quad (14)$$

式中: \mathbf{G}^H 和 \mathbf{F}^H 为 \mathbf{G} 和 \mathbf{F} 的共轭转置矩阵, 则有:

$$\hat{\boldsymbol{\beta}} = \mathbf{Y}^+ \mathbf{T} \quad (15)$$

3 具体实例

实验采用加拿大 ABB BOMEN 的 MR170 型光谱辐射计, 测量目标在不同温度下的辐射特性. 辐射计的分辨率为 32/cm, 探测器的光谱范围为 3~14 μm 波段.

3.1 黑体测温及验证

实验室现有 3 种不同型号的黑体, 发射率出厂值以及测温范围略有不同. 黑体 A 的发射率为 0.98、有效测温范围为 50~250 $^{\circ}\text{C}$; 黑体 B 的发射率为 0.96、有效测温范围为 300~600 $^{\circ}\text{C}$; 黑体 D 的发射率为 0.99、有效测温范围为 700~1 200 $^{\circ}\text{C}$. 分别将 3 种黑体作为测试目标源, 利用光谱辐射计分别测量不同温度下的辐射特性, 得到 43 组样本数据, 其中黑体 A 有 28 组、黑体 B 有 9 组、黑体 D 有 6 组. 3 种黑体的发射率有差异、温度范围没有交叉, 现将这 3 种黑体的数据同时做为训练样本, 验证所提方法的测温精度. 测试曲线采用文献[13]的方法进行校准补偿, 最终得到测量波段光谱亮度样本, 随机选取 7 组不同温度下的亮度曲线如图 4 所示.




图 4 黑体在不同温度下的光谱辐射亮度

Fig. 4 Spectral radiance of blackbody at different temperatures

光谱亮度会受到杂散辐射、大气吸收散射等影响, 导致某些固定波段内的值会产生较大震荡. 选择测温训练样本时, 可以避开这些波段. 在同一温度下, 选择有效辐射亮度值 141 个, 样本可对测量波段全覆盖, 使得构成的输入向量中包含温度估计需要的光谱信息, 最终获取样本共 43 组, 部分样本数据

如表 1 所示。

在不同温度段随机选取 35 组光谱亮度做为训练样本,可得式(3)的亮度矩阵 \mathbf{A} 是一个 35×141 阶矩阵。根据 PCA 计算主元成分,获得的特征值和特征向量如表 2 所示。

表 1 黑体光谱亮度样本

Tab. 1 Samples of spectral radiance from blackbody

$T/^\circ\text{C}$	$L_1/(\text{W} \cdot \text{m}^{-2} \cdot \text{sr}^{-1} \cdot \mu\text{m}^{-1})$	$L_2/(\text{W} \cdot \text{m}^{-2} \cdot \text{sr}^{-1} \cdot \mu\text{m}^{-1})$...	$L_{141}/(\text{W} \cdot \text{m}^{-2} \cdot \text{sr}^{-1} \cdot \mu\text{m}^{-1})$
80	0.629	0.671	...	17
85	0.755	0.781	...	17
\vdots	\vdots	\vdots	...	\vdots
1 300	24 158	23 740	...	416

表 2 黑体光谱亮度 PCA 结果

Tab. 2 PCA results of spectral radiance of blackbody

特征值	特征向量
$\lambda_1=138.718\ 6$	$\mathbf{a}_1=[0.082\ 0\ 0.082\ 1\ \cdots\ 0.084\ 5]^T$
$\lambda_2=2.276\ 2$	$\mathbf{a}_2=[0.171\ 3\ 0.169\ 4\ \cdots\ -0.062\ 1]^T$
$\lambda_3=0.005\ 1$	$\mathbf{a}_3=[0.269\ 6\ 0.249\ 0\ \cdots\ 0.083\ 4]^T$
\vdots	\vdots
$\lambda_{141}=0$	$\mathbf{a}_{141}=[0.060\ 2\ -0.063\ 0\ \cdots\ -0.285\ 7]^T$

由式(6)可知,计算前两个特征值的贡献率 $\gamma_1=98.3\%$, $\gamma_2=1.614\%$,累计贡献率达 99.9%,确定主成分为 2,得到降维后的网络输入为 $z_1(k)=\mathbf{a}_1 \cdot \mathbf{L}(k)$, $z_2(k)=\mathbf{a}_2 \cdot \mathbf{L}(k)(k=1,2,\cdots,n)$ 。

将 z_1 和 z_2 输入 ELM 网络,网络输出为 T ,隐含层节点数为 8 个。训练结束后,将 8 组测试样本输入网络得到的验证结果如图 5 所示。

由图 5 中可以看出,ELM 网络输出的温度与真实温度非常相近,且精度较高。具体结果如表 3 所示。其中, T_1 为真实温度; T_2 为网络输出温度; $\frac{|O(k)-T(k)|}{O(k)}$ 为温度估计相对误差; $\bar{\epsilon}$ 为平均发射率。由表 3 可知,温度估计最大相对误差为 3.58%。基于温度测量结果可进一步估计目标当前温度下的光谱发射率。某一温度 T 下,令 $j=1,2,\cdots,p$,一般目标接近朗伯体,光谱发射率 $\epsilon(\lambda_j,T)$ 与方向无关,可表示为

$$\epsilon(\lambda_j,T)=\frac{L_j(\lambda_j,T)}{L_{\text{bb}}(\lambda_j,T)}\tag{16}$$

式中: $L_{\text{bb}}(\lambda_j,T)$ 为温度 T 时的标准黑体光谱辐射




图 5 黑体温度的 ELM 网络输出值与实测值比较

Fig. 5 Comparison of blackbody temperature between estimated values obtained by ELM network and practical values

亮度。理想黑体光谱发射率不随波长变化,表现为常值,所测黑体为哈尔滨工业大学自动检测与过程控制系统研究所研制的面源黑体,发射率出厂值为 0.98。根据表 3 得到的温度可获得理想黑体辐射亮度,根据式(16)计算的光谱发射率如图 6 所示,其中 $T(1),T(2),\cdots,T(8)$ 为 8 个温度。由图 6 可知,不同温度下光谱发射率在 0.98 上下浮动,且比较恒定。计算测量波段的平均发射率 $\bar{\epsilon}$ 并将其与真实值 0.98 进行比较, $\frac{|0.98-\bar{\epsilon}|}{0.98}$ 为计算相对误差。由表 3 可

以看出,平均发射率的最大相对误差为 4.3%,说明所提方法可以实现目标温度与光谱发射率的同步估计,且可达到较高的精度。

表 3 黑体的测温结果及其相对误差

Tab. 3 Temperature measurement results of blackbody and its relative errors

$T_1/^\circ\text{C}$	$T_2/^\circ\text{C}$	$\frac{ O(k)-T(k) }{O(k)}\bigg/\%$	$\bar{\epsilon}$	$\frac{ 0.98-\bar{\epsilon} }{0.98}\bigg/\%$
95	97.476 2	2.61	0.931 8	4.8
115	119.121 2	3.58	0.967 3	1.3
135	131.841 3	2.34	1.011 0	3.2
155	150.740 1	2.75	1.021 7	4.3
180	176.303 1	2.05	1.015 1	3.6
450	455.943 1	1.32	0.941 0	4.0
520	517.708 2	0.44	0.968 8	1.1
1 000	1 025.300 0	2.53	0.952 3	2.8




图 6 黑体测试样本的光谱发射率估计

Fig. 6 Estimation of spectral emissivity for testing samples of blackbody

通过黑体实验可以验证所提测温方法的合理性,且测温范围广,主要取决于所选网络训练样本的温度范围.

3.2 目标涂层的测温及验证

将所提方法应用于飞机机身表面涂层的温度估计,如图 7 所示. 涂层温度通过外接温度控制器控制,利用光谱辐射计测量表面涂层的辐射特性,得到 41 组不同温度下的光谱亮度辐射数据,温度范围为 80~180 ℃.




图 7 钢板涂层目标

Fig. 7 Steel plate coating target

与黑体实验相同,在每条温度曲线上,选取 141 个不同波长对应的辐射亮度值作为初始输入向量. 部分样本数据如表 4 所示.

随机选取 34 组训练样本,可得式(3)的亮度矩阵 \mathbf{A} 是一个 34×141 阶矩阵. 根据 PCA 计算主元成分,得到特征值和特征向量如表 5 所示. 计算累计贡献率,确定主成分为 1,得到降维后的网络输入为 $z_1(k) = \mathbf{a}_1 \cdot \mathbf{L}(k), k = 1, 2, \dots, n$. 得到第 k 个样本降维后的输入变量为

表 4 目标涂层光谱亮度部分样本

Tab. 4 Samples of spectral radiance from coating target

$T/^\circ\text{C}$	$L_1/(\text{W} \cdot \text{m}^{-2} \cdot \text{sr}^{-1} \cdot \text{mm}^{-1})$	$L_2/(\text{W} \cdot \text{m}^{-2} \cdot \text{sr}^{-1} \cdot \text{mm}^{-1})$...	$L_{141}/(\text{W} \cdot \text{m}^{-2} \cdot \text{sr}^{-1} \cdot \text{mm}^{-1})$
80	0.516	0.567	...	13.852
83	0.562	0.614	...	14.117
⋮	⋮	⋮	⋮	⋮
180	2.417	2.233	...	17.000

表 5 目标涂层光谱亮度 PCA 结果

Tab. 5 PCA results of spectral radiance of coating target

特征值	特征向量
$\lambda_1 = 125.3228$	$\mathbf{a}_1 = [0.0475 \quad 0.0386 \quad \dots \quad 0.0796]^\text{T}$
$\lambda_2 = 12.0106$	$\mathbf{a}_2 = [0.1931 \quad 0.2276 \quad \dots \quad -0.0362]^\text{T}$
$\lambda_3 = 2.6217$	$\mathbf{a}_3 = [0.2838 \quad 0.2372 \quad \dots \quad -0.2458]^\text{T}$
⋮	⋮
$\lambda_{141} = 0$	$\mathbf{a}_{141} = [0.0007 \quad -0.0020 \quad \dots \quad 0.5271]^\text{T}$

$$z_1(k) = 0.0475L_1(k) + 0.0386L_2(k) + \dots + 0.0796L_{141}(k)$$

将降维后的输入向量送入 ELM 网络,输出为温度,隐含层节点数为 20,训练 ELM 网络. 目标涂层 7 组测试样本的仿真结果如图 8 所示.

从图 8 中可以看出,网络的输出温度与样本的实际温度比较吻合. 目标涂层 7 个测试样本的测温结果以及相对误差如表 6 所示.




图 8 目标涂层温度的 ELM 网络输出与实测值比较

Fig. 8 Comparison of coating target temperature between estimated values obtained by ELM network and practical values

表 6 涂层的测温结果以及相对误差

Tab.6 Temperature measurement results and relative errors of coating target

$T_1/^\circ\text{C}$	$T_2/^\circ\text{C}$	$\frac{ O(k)-T(k) }{O(k)}\%$	$\bar{\epsilon}$
88	88.814 8	0.93	0.819 7
98	98.747 4	0.71	0.802 6
113	112.321 1	0.60	0.771 8
130	129.397 8	0.46	0.668 4
143	143.648 9	0.45	0.594 1
158	157.922 7	0.04	0.536 4
168	167.549 3	0.27	0.514 3

由表 6 可以看出,目标涂层 7 个测试样本的测温结果与真实温度很相近,相对误差都不大,最大相对误差为 0.93%,说明这种测温方法精度很高,进一步验证了该方法的合理性.所测材料的光谱发射率未知,沿用黑体测试的思路,根据估计的温度计算对应理想黑体的亮度值,根据式(16)就可获取材料的光谱发射率,为下一步实验验证提供数据指导和支持.由表 6 中给出的所测材料不同温度下测量波段的平均发射率可以看出其低发射率的特征.

4 结语

本文提出一种未知目标发射率的红外辐射测温方法.由红外辐射基本定律,目标温度与光谱辐射亮度之间存在着强非线性关系,很难应用常规辨识建模方法.建立一种基于主元分析与极限学习机相结合的测温模型.首先,建立能够充分包含温度估计信息的高维输入向量;利用 PCA 实现输入降维,确定线性无关的主元输入变量;利用 ELM 网络自适应学习多光谱亮度与目标温度之间的潜在规律,建立目标温度测温模型,最终构建未知发射率情况下的目标红外多光谱测温方法框架.用黑体和未知发射率的隐身材料涂层分别作为测试目标,获得的测温结果与实际温度的相对误差都很小,说明了这种测温方法的合理性.

参考文献:

[1] 杨永军,王中宇,张术坤,等.基于多光谱测温优化的材料光谱发射率测量[J].北京航空航天大学学报,2014,40(8):1022-1026.
YANG Yongjun, WANG Zhongyu, ZHANG Shukun, et al. Material spectral emissivity measure-

ment optimized by multi-spectral temperature measured[J]. Journal of Beijing University of Aeronautics and Astronautics, 2014, 40(8): 1022-1026.
[2] MADURA H, KASTEK M, PIATKOWSKI T. Automatic compensation of emissivity in three-wavelength pyrometers[J]. Infrared Physics & Technology, 2007, 51(1): 1-8.
[3] 王新北,萧鹏,戴景民.基于傅里叶红外光谱仪的光谱发射率测量装置的研制[J].红外与毫米波学报,2007,26(2):149-152.
WANG Xinbei, XIAO Peng, DAI Jingmin. Development of spectral emissivity measurement system based on Fourier transform infrared spectrometer(ft-ir)[J]. Journal of Infrared and Millimeter Waves, 2007, 26(2): 149-152.
[4] 曹立华,杨词银,万春明.基于标校的双波段比色测温法[J].仪器仪表学报,2012,33(8):1882-1888.
CAO Lihua, YANG Ciyin, WAN Chunming. Correction-based dual-waveband color comparison thermometric method[J]. Chinese Journal of Scientific Instrument, 2012, 33(8): 1882-1888.
[5] 原遵东.辐射测温的广义有效亮度温度[J].仪器仪表学报,2012,33(4):721-726.
YUAN Zundong. Generalized effective radiance temperature in radiation thermometry[J]. Chinese Journal of Scientific Instrument, 2012, 33(4): 721-726.
[6] 杨桢,杨立,张士成,等.基于双温双波段法的郎伯体红外测温技术[J].工程热物理学报,2013,34(11):2132-2135.
YANG Zhen, YANG Li, ZHANG Shicheng, et al. Infrared temperature measurement technology on lambertian based on the dual temperature and dual-band method[J]. Journal of Engineering Thermophysics, 2013, 34(11): 2132-2135.
[7] 孙元,彭小奇.基于彩色 CCD 的双色与三色比色测温法比较研究[J].传感技术学报,2015,28(8):1184-1187.
SUN Yuan, PENG Xiaoqi. Comparative study on two-color and three-color colorimetric temperature measurement based on colored CCD[J]. Chinese Journal of Sensors and Actuators, 2015, 28(8): 1184-1187.
[8] SADE S, KATZIR A. Spectral emissivity and temperature measurements of selective bodies using multiband fiber-optic radiometry[J]. Journal of Applied Physics, 2004, 96(6): 3507-3513.
[9] FU T R, LIU J F, TANG J Q, et al. Temperature measurements of high-temperature semi-transparent infrared material using multi-wavelength pyrometry

- [J]. **Infrared Physics & Technology**, 2014, 66: 49-55.
- [10] SVET D Y, MOSKALENKO N V. Radiative temperature-measurement in the presence of attenuation due to brown smoke[J]. **High Temperature**, 1989, 27 (5): 783-787.
- [11] ZOU X B, ZHAO J W, POVEY M J W, *et al.* Variables selection methods in near-infrared spectroscopy [J]. **Analytica Chimica Acta**, 2010, 667 (1/2): 14-32.
- [12] 孙晓刚, 原桂彬, 戴景民. 基于遗传神经网络的多光谱辐射测温法[J]. **光谱学与光谱分析**, 2007, 27 (2): 213-216.
SUN Xiaogang, YUAN Guibin, DAI Jingmin. Multi-spectral thermometry based on GA-BP algorithm[J]. **Spectroscopy and Spectral Analysis**, 2007, 27 (2): 213-216.
- [13] 席剑辉, 徐振方, 傅莉, 等. 红外辐射亮度的 RBF 网络建模及其光谱发射率估计[J]. **红外与激光工程**, 2016, 45(Sup. 1): 1-6.
XI Jianhui, XU Zhenfang, FU Li, *et al.* Modeling infrared radiance and calculating spectral emissivity based on RBF network[J]. **Infrared and Laser Engineering**, 2016, 45(Sup. 1): 1-6.
- [14] YANG J Z, FENG Z, WANG X D, *et al.* Research on pipeline blocking state recognition algorithm based on mixed domain feature and KPCA-ELM[J]. **International Journal of Computing Science and Mathematics**, 2018, 9(5): 442-454.
- [15] MAGALLON-BARO A, GRANTON P V, MILDER M T W, *et al.* A model-based patient selection tool to identify who may be at risk of exceeding dose tolerances during pancreatic SBRT[J]. **Radiotherapy and Oncology**, 2019, 141: 116-122.
- [16] POTAPOV P, LUBK A. Optimal principal component analysis of STEM XEDS spectrum images[J]. **Advanced Structural and Chemical Imaging**, 2019, 5 (1): 1-21.
- [17] 刘嘉蔚, 李奇, 陈维荣, 等. 基于在线序列超限学习机和主成分分析的蒸汽冷却型燃料电池系统快速故障诊断方法[J]. **电工技术学报**, 2019, 34 (18): 3949-3960.
LIU Jiawei, LI Qi, CHEN Weirong, *et al.* Fast fault diagnosis method of evaporatively cooled fuel cell system based on online sequential extreme learning machine and principal component analysis[J]. **Transactions of China Electrotechnical Society**, 2019, 34(18): 3949-3960.

(本文编辑: 石易文)