

RBF 网络在多光谱测温中的应用研究*

丛大成 戴景民 孙晓刚 褚载祥

(哈尔滨工业大学计算机与电气工程学院, 黑龙江, 哈尔滨, 150001)

摘要 介绍了一种人工神经网络在多光谱测温数据处理中的应用。利用人工神经网络, 结合多种发射训练样本模型, 可以自动辨识被测目标的发射率模型, 从而得到目标的真温和光谱发射率。应用二次细分的方法进一步提高了测量精度, 并分析了各种测量误差对测温精度的影响。仿真结果表明此方法是获知真温与发射率的一种较好的方法。

关键词 多光谱辐射测温, 人工神经网络, 二次细分, 真温, 发射率。

STUDY OF THE APPLICATION OF RBF NETWORK TO MULTI-SPECTRAL THERMOMETRY*

CONG Da-Cheng DAI Jing-Min SUN Xiao-Gang CHU Zai-Xiang

(School of Computer Science and Electric Engineering, Harbin Institute of Technology,
Harbin, Heilongjiang 150001, China)

Abstract The application of artificial neural network to data processing of multi-spectral radiation thermometry was presented. By taking advantages of neutral network and various emissivity samples, the emissivity models of the targets were identified and the true temperature and spectral emissivity were available simultaneously. The measurement accuracy was improved further by subdivision. The effects of measurement errors on the measurement accuracy of temperature and emissivity were also analyzed. Computer simulation results proved that the method is an effective way for both temperature and emissivity measurements.

Key words multi-spectral thermometry, artificial neural network, subdivision, true temperature, emissivity.

引言

多光谱测温法是利用目标的多个光谱辐射测量信息经过数据处理得到目标真温和材料光谱发射率, 真温的获得还依靠目标材料发射率信息, 而目标材料发射率不仅取决于材料组份、表面状态, 还和表面形状、测量角度、波长等多种因素有关。因此用辐射法测量真温成了一个大难题。Gardner^[1]在发射率对数和波长成线性关系的假设模型基础上建立了六波长高温计, 研究了最小二乘拟合在多波长数据处理中的应用; Coates^[2]指出由于发射率假设模型的不确定性, 会导致一个不可预见的, 较大的系统误差, 因此用窄带辐射温度对材料发射率粗略估计会得到更好的测量结果; Gathers^[3]用 Monte Carlo 法对多波长的测量精度进行了估计, 得到了同 Coates 相一

致的结论。戴景民和孙晓刚^[4,5]应用逐步拟合法对一些材料发射率模型进行了自动判别, 取得了较好的结果。

人工神经网络是新近发展起来的一门交叉学科, 用物理可实现的系统去模仿人脑神经的结构和功能的系统。在模式识别、系统辨识、信号处理等方面得到了广泛的应用, 可以对一般非线性系统进行一致最优逼近。

文中将人工神经网络应用于多光谱测温技术, 实现了线性及非线性发射率模型的自动辨识, 消除了发射率假设模型带来的误差, 提高了多光谱测温精度。

1 数学模型的建立

多光谱辐射温度计具有 n 个通道, 则第 i 通道

* 国家自然科学基金(编号 69777020)资助项目

稿件收到日期 2000-05-13, 修改稿收到日期 2000-12-07

* The project supported by the National Natural Science Foundation of China.

Received 2000-05-13, revised 2000-12-07

的输出信号 S_i 可表示为：

$$S_i = G_i \int_{\Delta\lambda} \tau(\lambda_i) R(\lambda_i) \varepsilon(\lambda_i, T) c_1 \lambda_i^{-5} [\exp(-\frac{c_2}{\lambda_i T}) - 1]^{-1} d\lambda, \quad (1)$$

或

$$S_i = G_i \int_{\Delta\lambda} \tau(\lambda_i) R(\lambda_i) c_1 \lambda_i^{-5} [\exp(-\frac{c_2}{\lambda_i T}) - 1]^{-1} d\lambda, \quad (2)$$

式(1)和式(2)中 G_i 是仪器的几何因子, 它与目标尺寸、仪器入瞳等因素有关; $\tau(\lambda_i)$ 是光学系统的光谱透过率; $R(\lambda_i)$ 是探测器的光谱响应率; $\varepsilon(\lambda_i, T)$ 为目标光谱发射率; c_1, c_2 为普朗克第一、第二常数; T 为目标真温, T_i 为目标亮温, $\Delta\lambda$ 是带宽。

根据有效波长的概念和维恩近似公式, 式(1)和式(2)可分别表示为:

$$S_i = A_i \varepsilon(\lambda_i, T) c_1 \lambda_i^{-5} \exp(-\frac{c_2}{\lambda_i T}), \quad (3)$$

$$S_i = A_i c_1 \lambda_i^{-5} \exp(-\frac{c_2}{\lambda_i T}), \quad (4)$$

式(3)和式(4)中 $A_i = G_i \tau(\lambda_i) R(\lambda_i)$,

根据式(3)、式(4)有

$$\frac{1}{T} - \frac{1}{T_i} = \frac{\lambda_i}{c_2} \ln \varepsilon_{\lambda_i, T}, \quad (5)$$

由式(5)可知, 目标的真温 T 与各通道下的 T_i 成某种非线性关系, T 与 T_i 的非线性映射关系可用径向基函数网络解决。

2 径向基函数(RBF)神经网络^[6,7,8]

从神经网络的函数逼近功能角度讲, 神经网络可分为全局逼近神经网络和局部逼近神经网络。RBF 神经网络是一种典型的局部逼近神经网络, 对于输入, 只有少数几个权值需要调整, 从而具有学习速度快的特点。BP 网络用于函数逼近时, 权值的调整是梯度下降法, 存在局部极小和收敛速度慢等特点, 而 RBF 网络在逼近能力、分类能力和学习速度等方面均优于 BP 网络。RBF 网络是一个三层前向网络, 包括: 输入层、隐层和输出层。

每层的输入、输出关系如下:

输入层为

$$I_i = R_i, \quad (6)$$

隐层为

$$Y_i = \exp \left\{ -\frac{\|R_i - Z_i\|^2}{\sigma_i^2} \right\}, \quad (7)$$

输出层为

$$F_k(W, R) = \sum_{i=1}^l W_{ik} Y_i = \sum_{i=1}^l W_{ik} \exp \left\{ -\frac{\|R_i - Z_i\|^2}{\sigma_i^2} \right\}, \quad (8)$$

式中 Z_i 是第 i 个神经元的中心矢量; σ_i 是第 i 个神经网络的形状参数; W_{ik} 为隐层和输出层之间的连接权值。

RBF 神经网络的学习分两步进行, 即隐含层的学习和输出层的学习, 其中隐含层的学习采用 K-均值集群法确定 RBF 中心 $\{Z_i\}$, 输出层的学习采用最陡下降法。

3 实验方法及计算机仿真结果

3.1 发射率样本的选择

采用 8 波长辐射温度计: 有效波长分别为 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0, 1.1 μm ; 11 个温度训练点为: 1800K, 1820K, 1840K, 1860K, 1880K, 1900K, 1920K, 1940K, 1960K, 1980K, 2000K。5 类发射率样本模型如图 1 所示, 其中 a_0, b_0, c_0, d_0, e_0 为训练样本示意图; a_2, b_2, c_2, d_2, e_2 为测试样本二示意图, 与训练样本的变化趋势及规律均一致; a_1, b_1, c_1, d_1, e_1 为测试样本一示意图, 它与训练样本的变化趋势一致, 但变化规律不同。每种训练样本包括 10 种发射率模型。

为了消除“平台现象”, 网络的输入采取归一化处理^[9,10], 即:

$$R'_i = \frac{R_i - A_{\min}}{A_{\max} - A_{\min}}, \quad (9)$$

式(12)中 A_{\max}, A_{\min} 分别为输入范围内的最大和最小值。

为了由网络的输出直接得到目标的真温及光谱发射率, 网络输出的训练样本应同时包括真温和光谱发射率。

3.2 测试样本的仿真

3.2.1 仿真方法

为了获得某种材料的真温及光谱发射率, 计算机仿真包括两部分内容: 初分和二次细分。首先将所选几类发射率样本作为训练样本, 对网络进行训练。训练过的网络已经具有一定的发射率模型辨识能力, 能够比较准确的识别出某种测试样本的光谱

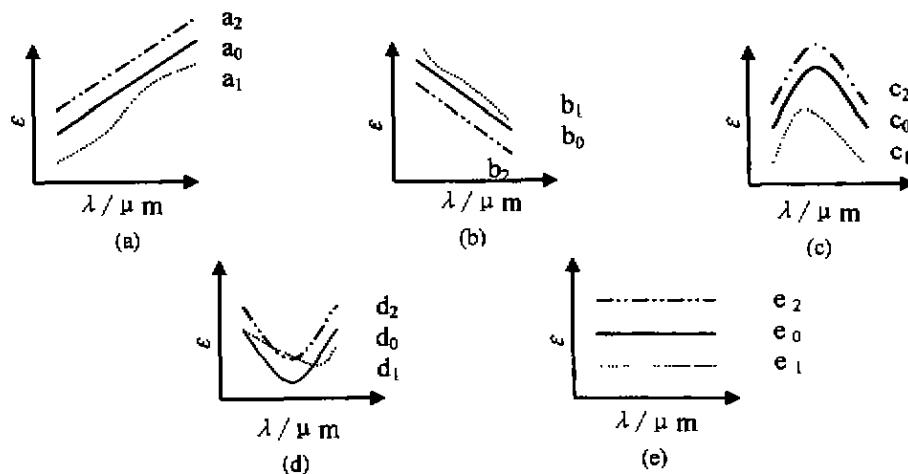


图 1 发射率样本模型示意图
Fig. 1 Models of emissivity samples

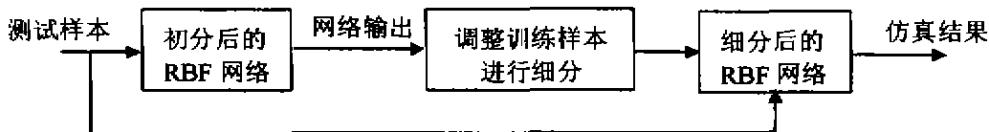


图 2 仿真方法
Fig. 2 Simulation method

表 1 测试样本的仿真结果
Table 1 Simulation results of test samples

真温(T)		1816	1837	1889	1924	1954
a_1	仿真温度(T')	1802.059	1826.380	1879.437	1912.044	1933.912
	ϵ_{a1}	0.70979	0.68732	0.68787	0.71177	0.77416
	ϵ_{a2}	0.73247	0.71398	0.71355	0.73122	0.78016
	ϵ_{a3}	0.74759	0.73097	0.73007	0.74409	0.78504
	ϵ_{a4}	0.76272	0.74795	0.74658	0.75696	0.78991
	ϵ_{a5}	0.78293	0.76932	0.76787	0.77557	0.80304
	ϵ_{a6}	0.80867	0.79657	0.79554	0.80171	0.82516
	ϵ_{a7}	0.83442	0.82381	0.82321	0.82784	0.84728
	ϵ_{a8}	0.86017	0.85106	0.85088	0.85397	0.86939
a_2	仿真光谱发射率(ϵ)	1815.966	1837.036	1889.141	1924.487	1852.833
b_1		1793.315	1818.433	1876.005	1925.500	1962.112
b_2		1816.035	1837.063	1889.123	1923.356	1954.174
c_1		1798.024	1824.932	1878.372	1916.102	1935.893
c_2		1816.026	1837.065	1888.973	1924.116	1954.133
d_1		1814.788	1832.698	1881.911	1910.123	1937.036
d_2		1816.109	1837.047	1888.690	1924.031	1955.140
e_1		1815.759	1836.788	1889.106	1923.938	1952.071
e_2		1816.063	1837.161	1888.327	1923.991	1951.201

发射率变化趋势。然后,根据初分结果在训练样本集中加入大量与此种测试样本发射率模型相近的训练样本,进行二次细分训练,得到更加准确的测试结果,其结构如图2所示。

3.2.2 测试样本的仿真结果

表1中列出了各类测试样本的仿真结果,各种情形如图1所示。其中详细列出了测试样本a₁真温和光谱发射率的仿真结果,测试样本a₁的光谱发射率分别为0.64,0.67,0.69,0.71,0.73,0.76,0.79,0.81。

由表1可以得出以下几点结论:(1)当测试样本发射率模型与训练样本相同或变化规律相同时,如情形a₂,b₂,c₂,d₂,RBF网络的计算结果与真实值非常接近;(2)测试样本与训练样本差别较大时,如情形a₁,b₁,c₁,d₁,计算结果与真实值差别较大;(3)对于灰体(情形e₁,e₂),由于测试样本与训练样本只有一种变化形式,因此计算结果与真实值始终符合的很好。

3.2.3 细分的仿真结果

由表1的情形a₁表明(其它情形亦相同),虽然由RBF网络得到的温度及发射率与真实值差别较大,但已从几类训练样本中辨别出了发射率变化模式,因此可以采用细分的方法进一步提高光谱发射

率及温度的测量精度,即根据已求得的光谱发射率变化趋势,在网络训练中加入大量此种变化模式的发射率训练样本和温度点,求得更准确的结果。表2为情形a₁的细分仿真结果,由表2见仿真结果普遍好于与表1对应的仿真结果。

3.2.4 测量误差对细分结果影响

表3是目标真温为1954K,测试样本为a₁时,各种测量噪声对网络输出结果的影响。其中情形A为各通道均无测量噪声;情形B为各通道均有+5%的测量噪声;情形C为各通道均有一-5%的测量误差;情形D为各通道有强度为2%的高斯噪声。

由表3可以得到以下几点结论:(1)在理想情况下,计算出的真温和各通道的光谱发射率与理想值符合的很好;(2)当各通道存在随机噪声或固定噪声时,计算结果也与理想值符合较好。

4 结语

本文介绍了一种基于RBF网络的多光谱辐射测温数据处理方法。由于RBF网络具有很强的逼近和分类能力,我们采用二次细分类的方法得到了更好的结果,并根据各种测量情况进行了大量的仿真计算,得到了比较好的结果。

表2 细分仿真结果
Table 2 Subdivided simulation results

真温(T)		1816	1837	1889	1924	1954
a ₁	仿真温度(T')	1813.870	1834.840	1886.011	1920.815	1951.810
	ϵ_{A1}	0.65704	0.63733	0.66178	0.66662	0.65556
	ϵ_{A2}	0.68289	0.68348	0.68745	0.69176	0.68224
	ϵ_{A3}	0.70132	0.70131	0.70423	0.70795	0.69898
	ϵ_{A4}	0.72718	0.72746	0.72990	0.73309	0.72566
	ϵ_{A5}	0.74561	0.74529	0.74669	0.74928	0.74340
	ϵ_{A6}	0.77146	0.77144	0.77235	0.77442	0.76908
	ϵ_{A7}	0.78989	0.78928	0.78914	0.79060	0.78583
	ϵ_{A8}	0.81574	0.81543	0.81481	0.81575	0.81251

表3 测量噪声对细分仿真结果的影响
Table 3 Effects of measurement errors on subdivided simulation results

情形		仿真温度(T')	ϵ_{A1}	ϵ_{A2}	ϵ_{A3}	ϵ_{A4}	ϵ_{A5}	ϵ_{A6}	ϵ_{A7}	ϵ_{A8}
a ₁	A	1951.810	0.65556	0.68224	0.69898	0.72566	0.74240	0.76908	0.78583	0.81251
	B	1958.468	0.64418	0.67965	0.69901	0.73447	0.75383	0.78930	0.80866	0.84412
	C	1947.612	0.64745	0.66889	0.68326	0.70471	0.71908	0.74052	0.75489	0.77634
	D	1965.519	0.57239	0.60988	0.63065	0.66814	0.68891	0.72640	0.74717	0.78466

REFERENCES

- [1] Gardner J L, Jones T J, Davies M R. A six-wavelength pyrometer. *High Temp. High Press.*, 1981, **13**: 459—466
- [2] Coates P B. The least-square approach to multi-wavelength pyrometry. *High Temp. High Press.*, 1988, **20**: 433—441
- [3] Gathers G R. Monte Carlo studies of multi-wavelength pyrometry using linearized equations. *Int. J. Thermal-physics*, 1992, **13**(2): 326—328
- [4] Dai Jing-Min. Study of the technique of multi-spectral radiation thermometry. PH. D. Thesis, Harbin Institute of Technology (戴景民. 多光谱辐射测温技术研究, 博士学位论文, 哈尔滨工业大学), 1995
- [5] SUN Xiao-Gang, DAI Jing-Min, CONG Da-Cheng, et al. Theoretical study of multi-wavelength radiation thermometry-autosearch for emissivity expression general. *Journal of Infrared and Millimeter Waves* (孙晓刚, 戴景民, 丛大成, 等. 多光谱辐射测温的理论研究-发射率模型的自动判别, 红外与毫米波学报), 1998, **17**(3): 221—225
- [6] Carroll S M, Dickinson W. Construction of neural nets using random transform. *IJCNN*, 1989, **1**: 607—611
- [7] Hornik K. Approximation capabilities of multilayer feedback network. *Neural Networks*, 1991, **4**(2): 251—257
- [8] LI Biao, LI Ji-Cheng, SHEN Zhen-Kang. A new method of object recognition using a neural network. *Systems Engineering and Electronics* (李彪, 李吉成, 沈振康. 一种基于神经网络的红外目标识别方法, 系统工程与电子技术), 1999, **21**(2): 39—42
- [9] WANG Ke-Jun, WANG Ke-Cheng. *Neutral Network Modeling, Forecasting and Control*. Harbin: Harbin Engineering University Press (王科俊, 王克成. 神经网络建模、预报与控制, 哈尔滨: 哈尔滨工程大学出版社), 1996: 32—59
- [10] SUN Xiao-Gang. Study of the theory and experiments of multi-spectral thermometry. PH. D. Thesis. Harbin Institute of Technology (孙晓刚. 多光谱辐射测温的理论及实验研究, 博士学位论文, 哈尔滨工业大学), 1998