

基于 PSO-ELM 算法的红外目标模拟器 校准数据拟合方法研究

张馨怡, 陈振林

(海军航空大学, 山东 烟台 264001)

摘要: 提高红外目标模拟器校准数据的拟合精度, 对于红外目标的辐射照度等辐射特性的测量有着重要意义; 针对校准数据具有很强的非线性, 传统的拟合算法精度不高的问题, 引入一种基于粒子群算法优化的极限学习机算法 (PSO-ELM), 以标准黑体辐射温度作为输入因子, 以 MCT 探测器实际测量出的辐射照度作为输出因子, 建立 PSO-ELM 模型, 利用粒子群算法 (PSO) 对连接隐藏神经元和输入层的权值和隐藏神经元阈值进行优化, 拟合出输入参数和输出参数之间的非线性关系; 这两个参数的优化提高了极限学习机算法 (ELM) 的性能, 该方法的主要优点是具有较强的容错性、较好的对复杂非线性数据处理性能和 ELM 算法参数设置上的优化机制; 通过与 GA-ELM 模型、ELM 模型进行对比, 验证了与传统数据拟合方法相比, 基于 PSO-ELM 的方法拟合精度有了很大提高, 为红外目标模拟器校准数据拟合提供了新的方法。

关键词: 红外目标模拟器; 辐射测量; 校准; 数据拟合; 极限学习机

Research on Calibration Data Fitting Algorithm of Infrared Target Simulator Based on PSO-ELM Algorithm

ZHANG Xinyi, CHEN Zhenlin

(Naval Aviation University, Yantai 264001, China)

Abstract: Improving the fitting accuracy of calibration data of the infrared target simulator is of great significance for the measurement of irradiance and other radiation characteristics of the infrared target. In view of the strong nonlinearity of calibration data of the infrared standard simulator and the poor accuracy of the traditional fitting algorithm, a particle swarm optimization extreme learning machine (PSO-ELM) is introduced in this paper. The standard black body radiation temperature is taken as the input factor and the irradiance, which is actually measured by the MCT detector as the output factor, and the PSO-ELM-based model is established. In the PSO-ELM-based method, the connection weight matrix from the input layer to the hidden layer and the bias vector of the hidden layer are optimized by the PSO algorithm, and a nonlinear relationship between input parameters and output parameters is fitted. The optimization of these two parameters has greatly improved the predictive ability of original ELM. This method has main advantages of strong fault tolerance, better processing performance for complex nonlinear data, and the optimization mechanism in a kernel parameter setting of ELM. Comparing with genetic algorithm extreme learning machine (GA-ELM), extreme learning machine (ELM), The superior fitting accuracy of the PSO-ELM-based method is verified in contrast to the conventional data fitting method, which provides a new method for infrared target simulator calibration data fitting.

Keywords: infrared target simulator; radiometry; calibration; data fitting; extreme learning machine

0 引言

红外辐射计主要用于红外目标的辐射照度等辐射特性的准确测量, 不同拟合方法会对测量精度产生较大影响。对于红外目标模拟器校准装置, 很多因素都可能导致校准数据呈现出非线性的特点, 主要可分为两大类^[1-5]: 系统自身所带来的非线性和环境引入的非线性。导致系统自身带来非线性的主要因素包括: 光学系统中, 镜面加工精度、孔径、焦距、光轴偏转角度等; 探测器的灵敏度; 系统电

路对电信号进行放大处理时, 电信号进入不同放大器。环境引入的非线性一般难以预测, 主要由背景辐射的变化导致。

在红外目标模拟器的校准数据处理中, 最常见的方法是最小二乘法 (LS, ordinary least squares)。但最小二乘法只注重寻找局部极值点, 找到的并不一定是全局最优解。而且最小二乘法很难精确拟合标准辐射源辐射和探测器实际测量辐射照度之间的非线性关系。文献 [6] 在最小二乘

收稿日期: 2022-03-30; 修回日期: 2022-04-08。

作者简介: 张馨怡 (1997-), 女, 天津北辰人, 硕士研究生, 主要从事计量技术方向的研究。

陈振林 (1966-), 男, 山东平度人, 硕士, 教授, 硕士研究生导师, 主要从事计量技术方向的研究。

引用格式: 张馨怡, 陈振林. 基于 PSO-ELM 算法的红外目标模拟器校准数据拟合方法研究 [J]. 计算机测量与控制, 2022, 30(7): 207-212, 218.

法的基础上提出偏最小二乘—投影寻踪回归法 (PLSPP, partial least squares regression projection pursuit), 主要利用降维的方法用较少的因素描述数据, 但此方法更适用于大规模数据集, 且对于非线性数据的处理仍不理想。之后, 文献 [7-8] 针对数据非线性的问题提出了基于粒子群优化的自适应支持向量回归算法 (PSO-ASVM, particle swarm optimization-adaptive support vector regression), 但同样存在一些弊端, 支持向量机算法非常难以训练。

相较于最小二乘法, 神经网络算法的容错性以及对待复杂非线性数据处理性能较好, 但传统的 bp 神经网络 (BPNN, back propagation neural network) 速度较慢, 且易陷入局部最优解。相较于 bp 神经网络, 极限学习机 (ELM, extreme learning machine) 具有其独特的优越性, 前人的研究表明, ELM 的精度更高, 具有较好的泛化能力, 处理速度更快^[9]。但由于该算法参数设置往往是通过个人经验和简单调整, 难以得到最优拟合精度, 所以文中采用粒子群算法 (PSO, particle swarm optimization) 对 ELM 参数进行优化。PSO-ELM 与传统的机器学习算法相比, 具有更高的预测精度和更强的泛化能力。本研究的目的如下:

- 1) 解决 ELM 模型随机参数对预测结果的影响;
- 2) 提高红外目标模拟器校准数据精度。

1 模型建立

1.1 ELM-PSO 算法

BP 神经网络是典型的多层前馈神经网络, 采用梯度下降法对网络进行训练, 但梯度下降法有一定的局限性, 在训练过程中需要设置各种参数值。此外, 在迭代过程中需要调整网络的权值, 使得模型的计算速度较慢, 而且往往收敛于局部最小值, 拟合精度不高。ELM 针对这些不足进行改进, 它实际上是一个基于单隐层前馈神经网络 (SLFNs, single-hidden layer feedforward neural network) 的网络结构, 只有一个输入层、一个隐含层和一个输出层^[10-11]。基于反向传播法, 多层前馈神经网络在迭代过程中需要更新权值, 但 ELM 算法在迭代过程中不需要更新的随机初始权值, 因为它的训练过程是基于输出权值和随机生成的输入隐含层参数 (权值和阈值)。因此, 不需要像传统方法那样调优所有的网络参数, 从而可以克服基于梯度的方法的许多问题, 如学习速率、局部最小值和学习时间。它解决了现有基于神经网络的算法训练速度慢和过拟合的问题。

前人的研究表明, ELM 的精度最高, 处理时间比 SVM 和 BPNN 分别快 1180 倍和 809 倍。ELM 具有较好的泛化能力, 处理时间较 BPNN 快^[12-13]。

设训练样本集是一组点 $\{x_i, t_i\}$, 其中 $i = 1, 2, \dots, N$ 。具有 L 个隐藏神经元和激活函数 $h(x)$ 的标准 SLFNs 的数学模型/一般估计函数可表示成如下形式:

$$\sum_{i=1}^N \beta_i h_i(x_j) = \sum_{i=1}^N \beta_i h_i(\omega_i x_j + b_i) = o_j \quad (1)$$

这里, $j = 1, 2, \dots, N$, $\omega_i = (\omega_{i1}, \omega_{i2}, \dots, \omega_{iD})^T$, 代表连接第 i 个隐藏神经元和输入层的权重向量; $\beta_i = (\beta_{i1}, \beta_{i2}, \dots, \beta_{iK})^T$ 代表连接第 i 个隐藏神经元和输出层的权重向量, b_i 是第 i 个隐藏神经元的阈值。

具有 L 个隐藏神经元和激活函数 $h(x)$ 的标准 SLFNs 模型的可以写成矩阵形式:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (2)$$

其中:

$$\mathbf{H} = \begin{bmatrix} h_1(\omega_1 x_1 + b_1) & \cdots & h_L(\omega_L x_1 + b_L) \\ \vdots & \ddots & \vdots \\ h_1(\omega_1 x_N + b_1) & \cdots & h_L(\omega_L x_N + b_L) \end{bmatrix}_{N \times L}$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times K} \quad \mathbf{T} = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times K}$$

\mathbf{H} 称为神经网络的隐层输出矩阵; \mathbf{H} 的第 i 列是第 i 个隐层节点对输入 x_1, \dots, x_N 的输出, 若已知激活函数 $h(x)$ 、 ω_i 、 b_i 和 x_i , 就可以直接计算出 \mathbf{H} 。

求解 $\hat{\omega}_i, \hat{b}_i, \hat{\beta}$ 符合下列表达式:

$$\| \mathbf{H}(\hat{\omega}_1, \dots, \hat{\omega}_N, \hat{b}_1, \dots, \hat{b}_N) \hat{\boldsymbol{\beta}} - \mathbf{T} \|_F = \min_{\omega_i, b_i, \beta} \| \mathbf{H}(\omega_1, \dots, \omega_N, b_1, \dots, b_N) \boldsymbol{\beta} - \mathbf{T} \|_F \quad (3)$$

令 $\varepsilon = \| \mathbf{H}(\hat{\omega}_1, \dots, \hat{\omega}_N, \hat{b}_1, \dots, \hat{b}_N) \hat{\boldsymbol{\beta}} - \mathbf{T} \|_F$ 为训练误差。基于文献 [14-15] 提出的研究成果可以看出: 当激活函数 $h: R \rightarrow R$ 满足在任意区间上无限可微这个条件, 对于输入层和隐含层间的连接权值和隐含层神经元的偏置随机产生, 不需要迭代调整; 又因为式子 $\| \mathbf{T} - \mathbf{H}\boldsymbol{\beta} \|_F \leq \varepsilon$ 以概率一成立, 则输出层的偏置也不再需要。对于输出层权值则利用隐含层神经元的激活函数而得出的输出矩阵计算得到, 采用最小二乘法求解隐含层与输出层的连接权值, 从而完成所有网络节点权值和偏差的训练。

如果 ω_i 和 b_i 预先确定, 根据式 (3), 则可以把训练过程等价于一个求线性系统 $\mathbf{H}\boldsymbol{\beta}$ 的问题:

$$\| \mathbf{H}(\hat{\omega}_1, \dots, \hat{\omega}_N, \hat{b}_1, \dots, \hat{b}_N) \hat{\boldsymbol{\beta}} - \mathbf{T} \|_F = \min_{\beta} \| \mathbf{H}(\omega_1, \dots, \omega_N, b_1, \dots, b_N) \boldsymbol{\beta} - \mathbf{T} \|_F \quad (4)$$

这个方程具有唯一的解, $\boldsymbol{\beta}$ 由下式计算可得:

$$\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{T} \quad (5)$$

其中: \mathbf{H}^+ 为 \mathbf{H} 广义逆矩阵。

因此, ELM 算法的拟合精度很大程度上依赖于激励函数 $h(x)$ 以及 ω_i 和 b_i 的选取。当预先给定一个激励函数时, 随机选取的不同权值 ω_i 和阈值 b_i 会产生不同的隐层输出矩阵 \mathbf{H} , 可能导致不同的训练误差。所以可以将优化过程描述为以下形式:

$$\min_{\omega_i, b_i} \| \mathbf{H}(\omega_1, \dots, \omega_N, b_1, \dots, b_N) \boldsymbol{\beta} - \mathbf{T} \|_F \quad (6)$$

其中: $\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{T}$ 。

当给定训练数据集的激活函数 $h(x)$ 和隐藏神经元数 L

时, 可以通过以下步骤建立 ELM:

- 1) 初始化输入权值、阈值和隐藏节点数;
- 2) 计算隐含层输出矩阵 \mathbf{H} ;
- 3) 利用广义逆矩阵 \mathbf{H}^+ 计算隐含神经元到输出层的权值向量 $\boldsymbol{\beta}$;
- 4) 计算回归输出。

ELM 模型虽然具有良好的模型性能和快速的学习速度, 但由于一般随机确定模型参数, 缺乏泛化能力。通常情况下, ELM 模型随机调整权值和阈值, 可能导致模型无法得到最优解, 增加了拟合过程中的不确定性。因此, 利用优化算法确定 ELM 模型的初始参数可以避免非最优解, 提高模型性能。PSO 算法和遗传算法 (Genetic Algorithm, GA) 是两种广泛使用的参数优化算法, 都属于群体搜索算法, 通过群体之间的合作来完成搜索。与 GA 算法相比, PSO 算法的性能更好, 速度更快^[16]。本文采用 PSO 算法对 ELM 初始参数进行优化。

PSO 算法是一种基于速度和位置两种信息的搜索算法, 利用个体之间的信息共享从而得到最优解, 不需要设置大量参数且易于实现。PSO 算法的参数或可能的解集包含在一个向量 $x_i(k)$ 中, 该向量称为群粒子, 表示其在可能解搜索空间中的位置。粒子维度是参数的数量。随机设定粒子的初始位置 $x_i(0)$ 及其速度 $v_i(0)$ 。然后计算每个粒子的适应度函数值, 并根据这些值更新速度和位置。该算法更新粒子的位置和速度, 表示为:

$$v_i(k+1) = \omega \cdot v_i(k) + c_1 \cdot r_1 \cdot (p_{ibest} - x_i(k)) + c_2 \cdot r_2 \cdot (g_{best} - x_i(k)) \quad (7)$$

$$x_i(k+1) = x_i(k) + v_i(k+1) \quad (8)$$

c_1, c_2 为学习因子; r_1, r_2 为 $[0, 1]$ 范围内的随机数; p_{ibest}, g_{best} 表示粒子 k 在个体及群体中的极值位置; ω 为惯性权重, 通过调整 ω 的值可以实现对全局搜索和局部搜索的能力, 本文采用线性递减权值 (linearly decreasing weight, LDW) 策略, 表示为:

$$\omega = (\omega_{ini} - \omega_{end})(G_k - g)/G_k + \omega_{end} \quad (9)$$

其中: ω_{ini} 为初始设定的惯性权重, G_k 为最大迭代次数, g 为当前迭代次数, ω_{end} 为迭代完成后的惯性权重, 惯性权重的引入极大的提高了 PSO 性能。

在初始迭代中, 粒子群中的每个粒子根据自身的记忆和经验在整个区域内分别寻找最优解, 并将其作为当前个体极值。在此算法中是多个粒子同时移动的, 每个粒子将自身搜寻到的个体最优解与其他粒子共享并进行对比, 找到最适当的解, 作为整个粒子群的当前全局最优解。每个粒子的当前位置 $x_i(k)$ 和速度 $v_i(k)$ 将根据其在上一部中的状态、粒子的局部最优解位置 p_{ibest} 和全局最优解位置 g_{best} 进行调整。并随着迭代的进行逐渐缩小其搜索范围。在初始阶段, 该算法对合理区域进行探索性搜索, 在最后的迭代中, 改进了最佳解。

在 ELM 预测模型中, 为了以尽可能少的隐含层节点的

情况下达到尽可能高的预测精度, 需要对输入权值 ω_i 和阈值 b_i 进行优化。在基于混合 PSO-ELM 的方法中, 利用 PSO 算法实现了 ELM 方法中的优化机制以获得输入权值和阈值的最优参数, 粒子维数 D 及粒子群中第 i 个粒子 θ^i 表示为:

$$D = t(n+1) \quad (10)$$

$$\theta^i = [\omega_{11}^i, \omega_{12}^i, \dots, \omega_{1t}^i, \omega_{21}^i, \omega_{22}^i, \dots, \omega_{n1}^i, \omega_{n2}^i, \dots, \omega_{nt}^i, b_1^i, b_2^i, \dots, b_t^i] \quad (11)$$

式中, t, n 分别为输入层和隐含层神经元的个数; ω_{uv}^i, b_v^i 分别为输入权值和隐含层阈值, 均为 $[-1, 1]$ 内的随机数, $1 < u < n, 1 < j < t$ 。

1.2 算法流程

基于 PSO-ELM 的红外目标模拟器校准数据拟合可详细描述如下。

- 1) 读取实验所得不同波段内的温度及其对应辐射照度数据, 将数据集随机划分为训练集和测试集, 并对样本数据进行归一化预处理;
- 2) 设置 PSO 相关参数: 粒子群规模 N 、最大迭代次数 G_k 、学习因子 c_1 和 c_2 ; 并对粒子速度和位置进行初始化, 设第 i 个粒子初始位置 $x_i(0)$ 及其速度 $v_i(0)$;
- 3) 将粒子位置和训练集代入式 (12), 计算适应度函数值, 寻找局部最优解位置 p_{ibest} 和全局最优解位置 g_{best} ;

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

- 4) 设终止条件为当前迭代次数 $g > G_k$ 或全局最优解满足最小界限。若不满足终止条件, 则更新 PSO 算法的粒子速度和位置, 并重复步骤 3), 更新 p_{ibest}, g_{best} ; 若满足终止条件, 则可得到最优网络初始权值和阈值;

- 5) 将最优网络初始权值和阈值带入 ELM 模型进行训练, 计算隐含层输出矩阵 \mathbf{H} ;

- 6) 通过式 (5) 即利用广义逆矩阵 \mathbf{H}^+ 计算隐含神经元到输出层的权值向量 $\boldsymbol{\beta}$;

- 7) 更新权值和阈值;

- 8) 判断是否满足终止条件, 即判断当前隐藏节点数是否大于搜索限制的隐藏节点数, 若不满足终止条件则继续训练 ELM 网络, 即重复步骤 5) ~ 步骤 7); 若满足终止条件则得到最优 ELM 模型, 并输出当前拟合结果。

基于 PSO-ELM 的红外目标模拟器校准数据拟合流程图, 如图 1 所示。

通过对数据进行预处理, 可以减少或消除可能的极值、非正态分布或数量级的剧烈变化。PSO 方法根据适应度函数搜索输入权值和阈值的最优参数, 采用均方根误差 (RMSE) 作为主要适应度因子。

2 仿真分析

2.1 实验步骤

本节将 PSO-ELM 模型应用于红外目标模拟器校准的数据拟合, 样本数据集通过实验室搭建的红外目标模拟器

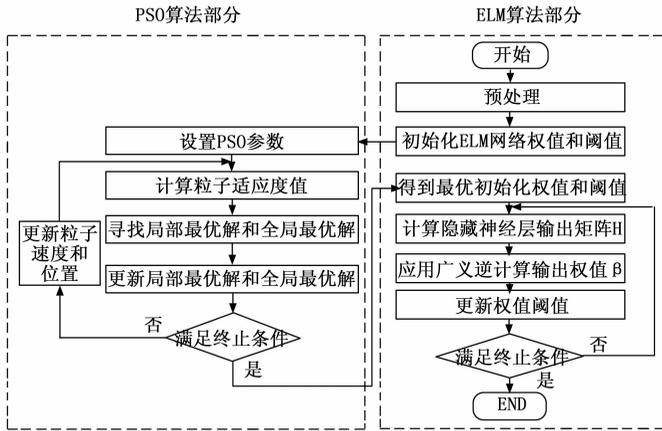


图 1 PSO-ELM 数据处理流程

校准装置进行实验获得。通过对不同数据拟合方法的比较,验证了 PSO-ELM 方法在实际标定中的有效性。红外目标模拟器校准装置包括标准黑体辐射源、平行光管、精密转台平面镜、红外辐射计和计算机^[17-18]。

实验步骤如下:

1) 在实验室环境下,测试背景信号,并记录背景辐射的响应电压 V_0 。

2) 设置标准黑体辐射源辐射温度为 T , 将其作为校准数据的自变量,并计算所对应的光谱辐射照度 $E_b(\lambda, T)$ 和标准积分辐射照度 $E_{\lambda, T}$, 其中

$$E_b(\lambda, T) = \epsilon_0 c_1 \lambda^{-5} \left[\exp\left(\frac{c_2}{\lambda T}\right) - 1 \right]^{-1} \times \left(\frac{r}{f}\right)^2 \quad (13)$$

$$E_{\lambda, T} = \int_{\lambda_{起始}}^{\lambda_{截止}} E_b(\lambda, T) \times r(\lambda) \cdot d\lambda \quad (14)$$

3) 测试目标的响应电压 V_i 。

4) 计算辐射照度响应度,将其作为校准数据的因变量

$$R(\lambda, T) = E_{\lambda, T} \times (V_i - V_0) \quad (15)$$

5) 利用 PSO-ELM 方法得到校准数据的因变量和自变量之间的关系;

为验证校准数据具有非线性特点,设置标准黑体辐射源温度范围为 $100 \sim 1\,000\text{ }^\circ\text{C}$, 分别对 $1 \sim 3\text{ }\mu\text{m}$ 、 $3 \sim 5\text{ }\mu\text{m}$ 、 $8 \sim 14\text{ }\mu\text{m}$ 波段进行测试。对测试数据进行拟合,结果如图 2 所示。

如图 2 所示,在 $1 \sim 3\text{ }\mu\text{m}$ 、 $3 \sim 5\text{ }\mu\text{m}$ 、 $8 \sim 14\text{ }\mu\text{m}$ 三个波段下,温度和辐射照度之间都具有强非线性。红外辐射计的响应主要取决于探测器的探测能力^[19],探测器的响应随着温度的升高而增长,并且根据维恩位移定律,黑体辐射的峰值波长随黑体温度的升高而向短波方向移动^[20-21]。除此之外,探测器采用制冷型 MCT 探测器,随着黑体辐射源温度升高会使其性能下降^[22]。由于上述数据呈现非线性特性以及实验数据样本小的限制,红外辐射计标定中常用的传统数据拟合方法不能达到足够的拟合精度。

2.2 评价指标

为了评价该模型回归精度,本文以决定系数 R^2 、平均

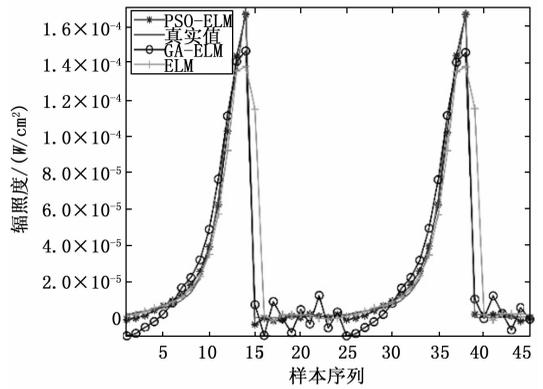


图 2 辐射度随波长分布图

相对误差 MRE 作为预测结果的评价指标。评价公式如式 (16) ~ (17) 所示。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

$$MRE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (17)$$

式中, y_i 为真实值; \hat{y}_i 为预测值; \bar{y} 为真实值的平均值。

2.3 结果分析

为了验证本文所提的方法在红外目标模拟器校准上的可靠性,将 PSO-ELM 方法与其他传统的数据分析方法进行了仿真对比。本文分别采用 PSO-ELM, GA-ELM, ELM 算法进行仿真,仿真对比结果如图 3~5 所示。

为了验证 PSO-ELM 算法在拟合红外目标模拟器校准数据上的性能,将实验得到的 96 组样本数据通过随机函数进行预处理,使样本数据处于无序排列状态,并随机选取其中 51 组数据作为训练集,剩余 45 组数据作为测试集,分别使用单一 ELM 模型、GA-ELM 模型和 PSO-ELM 模型对红外目标模拟器校准数据进行拟合。

PSO 算法设置粒子群规模为 20,最大迭代次数为 100,最小速度为 -1,最大速度为 1,当波段为 $1 \sim 3\text{ }\mu\text{m}$ 、 $3 \sim 5\text{ }\mu\text{m}$ 时 $c_1 = c_2 = 2$,当波段为 $8 \sim 14\text{ }\mu\text{m}$ 时学习因子 $c_1 = 2.5$ 、 $c_2 = 2$,学习因子通过正交实验多次测试确定最优参数。

GA 算法参数设置个体数目为 20,最大遗传代数为 100,变量的二进制位数为 10,代沟为 0.95,交叉概率为 0.7,变异概率为 0.01。

采用 3 种算法进行对比实验,并比较这 3 种算法的拟合结果,验证不同拟合方法在处理红外目标模拟器校准数据时的性能。拟合结果如图 3~5 所示,拟合误差分布如图 6~8 所示,相关的评价指标计算结果如表 1 所示。

如图 3~5 所示,在 3 个波段内 ELM 模型拟合误差明显大于另外两种模型,主要偏差出现在辐射度峰值部分,即标准黑体辐射源温度较高、系统接收入射辐射较高时。

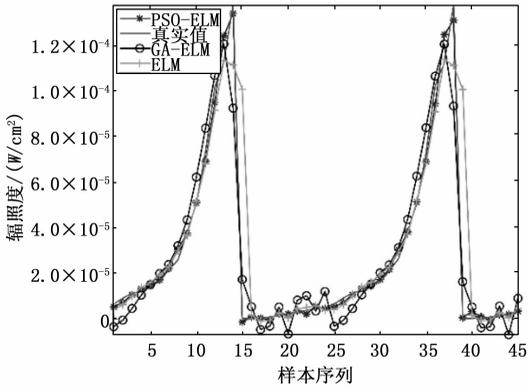


图 3 1~3 μm 数据拟合结果

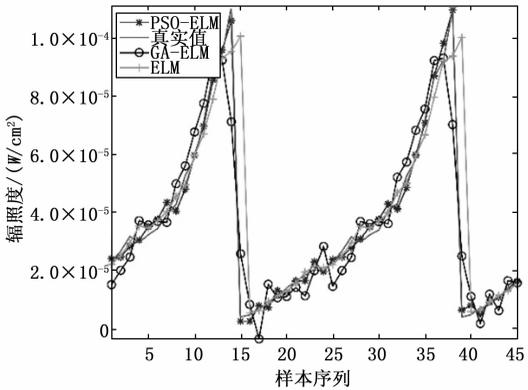


图 4 3~5 μm 数据拟合结果

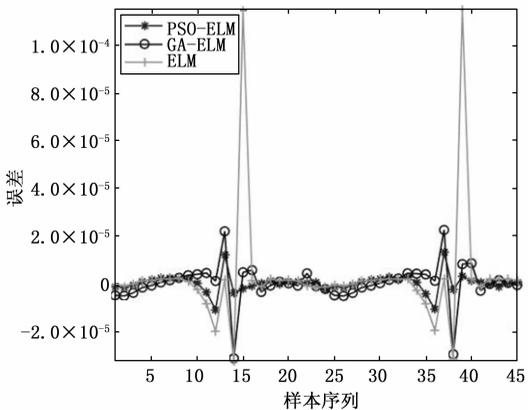


图 5 8~14 μm 数据拟合结果

GA-ELM 相较于 ELM 拟合精度有所提高, 对于辐照度峰值部分的拟合也更优于 ELM, 但是在辐照度较低时在真实值上下波动较为明显, 当标准黑体辐射源温度较低、系统接收入射辐射较低时稳定性更差。

可以明显看出, GA-ELM 算法和 PSO-ELM 算法可以获得比 ELM 算法更好的拟合结果, 对 ELM 初始权值和阈值进行优化可以有效提高拟合精度和稳定性。但 GA-ELM 方法出现振荡现象, 尤其是当校准点数量较少且拟合数据非均匀分布时。为了提高拟合精度, 将基于 PSO-ELM 的方

法应用于红外目标模拟器的校准中。

将 PSO-ELM 方法与 GA-ELM 方法、ELM 方法的拟合误差进行比较, 验证了 PSO-ELM 方法的性能。

如图 6~8 所示, 在 3 个波段下, ELM 模型的拟合误差均存在峰值。出现峰值的原因有二: 1) 校准数据本身具有较强的非线性, 且背景辐射会影响辐照度值, 这对拟合模型的稳定性和准确性造成了一定影响; 2) ELM 算法中的随机参数对模型的拟合稳定性有较大的影响。然而, ELM 模型本身并不能求解随机参数。基于以上两个原因, ELM 算法在红外目标模拟器校准数据拟合的过程中可能存在较大的误差。为了减少拟合结果中的峰值, 需要选择最优的模型参数。PSO-ELM 模型和 GA-ELM 模型的拟合性能均优于 ELM 模型, 也可以证明参数优化提高了 ELM 模型的预测精度和稳定性。

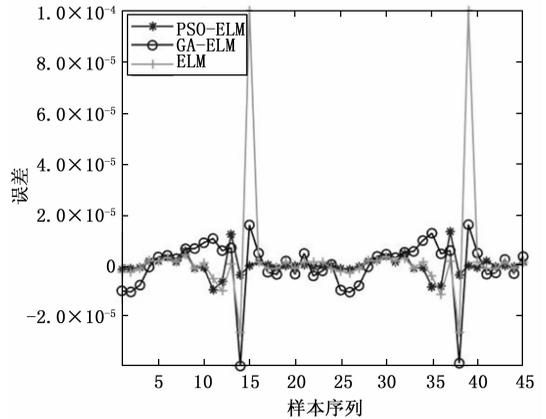


图 6 1~3 μm 数据拟合误差

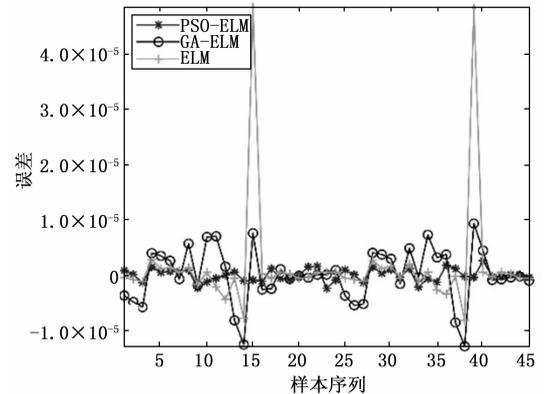


图 7 3~5 μm 数据拟合误差

3 种算法模型的拟合性能在辐照度较低的部分更好, 随着标准黑体辐射源温度升高, 拟合误差也逐步增大, 可能造成这种现象的原因是校准数据的后半部分校准点的数量限制。当使用较少的校准点时, 拟合误差将增加。PSO-ELM 方法的优越性能在辐照度较高时相对于另外两种算法更为明显, 但也受到拟合数据数量的限制。

如表 1 所示, ELM 在 3 个波段的拟合精度都较低, 由

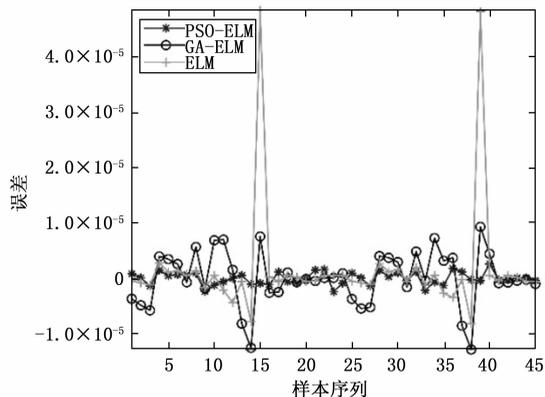


图 8 8~14 μm 数据拟合误差

于随机产生初始参数，容易出现欠拟合现象；GA-ELM 在中短波红外表现较好，但在长波红外范围内性能下降较为明显，且模型较为复杂，在样本数较少时会发生过拟合现象；PSO-ELM 算法鲁棒性好，在 3 个波段都可以较为准确地拟合红外目标模拟器校准数据，在 1~3 μm、3~5 μm、8~14 μm 三个波段，决定系数分别为 0.992 5、0.991 3、0.981 4，平均相对误差分别为 0.124 2%、0.715 7%、0.747 4%。

表 1 评价指标计算结果

波段	拟合方法	决定系数	平均相对误差
1~3 μm	ELM	0.721 3	10.266 6%
	GA-ELM	0.935 1	0.500 6%
	PSO-ELM	0.992 5	0.124 2%
3~5 μm	ELM	0.705 8	11.299 6%
	GA-ELM	0.916 1	1.707 0%
	PSO-ELM	0.991 3	0.715 7%
8~14 μm	ELM	0.566 6	13.721 2%
	GA-ELM	0.850 3	8.709 9%
	PSO-ELM	0.981 4	0.747 1%

通过以上对比，证明了优化初始参数的 ELM 算法在处理非线性数据上的有效性，由于 GA-ELM 和 PSO-ELM 都对 ELM 初始权值和阈值进行优化，但 PSO 算法优化的性能明显优于 GA 算法，可能导致这种现象的原因是两种算法原理的差异，发现基于 PSO-ELM 的算法的数据拟合准确率高于另外两种算法。

3 结束语

针对红外目标模拟器校准数据呈现非线性的特点，本文提出了一种 PSO 优化的 ELM 算法：

1) 利用 PSO 算法搜索 ELM 模型的随机参数，解决了 ELM 模型随机参数影响拟合精度的问题，利用 PSO 算法可得到最优权值和阈值，进而得到最优拟合精度；

2) 将 PSO-ELM 模型应用于红外目标模拟器校准数据，拟合出输入参数（标准黑体辐射源的辐射温度）与输出参

数（辐射照度）之间的非线性关系，进行仿真实验；

3) 选取决定系数 (R^2) 和平均相对误差 (MRE) 作为精度评判标准，对 PSO-ELM 模型性能进行了验证；

4) 通过与 ELM 算法和 GA-ELM 算法进行对比，证明 PSO-ELM 性能优越性。

实验结果显示模型的决定系数及平均相对误差均优于对比的其他建模方法，PSO-ELM 模型在延续 ELM 泛化能力强和学习速率高的基础上，通过 PSO 克服了 ELM 输入权值矩阵与阈值对于预测结果的影响，具有操作简便、预测精准及适用性广泛的优点。结果表明 PSO-ELM 方法在红外目标模拟器校准非线性数据处理方面具有很好的效果。

参考文献：

- [1] 尚超, 王锦春, 张晓兵. 红外焦平面阵列读出电路非均匀性研究 [J]. 红外与激光工程, 2020, 49 (8): 213-220.
- [2] 袁红辉, 陈永平. 非制冷红外探测器读出电路的非均匀性研究 [J]. 物理学报, 2015, 64 (11): 422-429.
- [3] 屈惠明, 陈钱. 红外焦平面阵列二元非线性的非均匀性理论模型 [J]. 电子学报, 2008 (11): 2150-2153.
- [4] 付小宁, 殷世民, 刘上乾. 基于系统非线性的红外焦平面非均匀性校正 [J]. 光子学报, 2002 (10): 1277-1280.
- [5] CHEN NAN, ZHANG JIQING, ZHONG SHENGYOU, et al. Nonuniformity Correction for Variable-Integration-Time Infrared Camera [J]. IEEE Photonics Journal, 2018, 10 (6): 1-11.
- [6] 萧鹏. 红外目标模拟器辐射度测量技术研究 [D]. 哈尔滨: 哈尔滨工业大学, 2007.
- [7] 杨森. 红外目标模拟器辐射测量技术研究 [D]. 哈尔滨: 哈尔滨工业大学, 2018.
- [8] YANG S, LI C W. Hybrid PSO-ASVR-based method for data fitting in the calibration of infrared radiometer [J]. Review of Scientific Instruments, 2016, 87 (6): 063108.
- [9] 翟敏, 张瑞, 王宇. 极限学习机 (ELM) 网络结构调整方法综述 [J]. 西安文理学院学报 (自然科学版), 2014, 17 (1): 1-6.
- [10] 赵虎, 左开伟, 覃永震. 改进人工蜂群算法优化 ELM 分类模型 [J]. 计算机测量与控制, 2016, 24 (10): 251-254.
- [11] 孙伟, 李停, 张明伟. 基于最大-最小蚂蚁系统优化 ELM 的电解槽故障诊断 [J]. 计算机测量与控制, 2015, 23 (10): 3326-3329.
- [12] 夏平凡, 倪志伟, 朱旭辉, 等. 基于双错测度的极限学习机选择性集成方法 [J]. 电子与信息学报, 2020, 42 (11): 2756-2764.
- [13] 杨菊, 袁玉龙, 于化龙. 基于蚁群优化的极限学习机选择性集成学习算法 [J]. 计算机科学, 2016, 43 (10): 266-271.
- [14] 黄广斌. 超限学习机和深度学习的汇聚 [J]. 软件和集成电路, 2019 (9): 32-33.

(下转第 218 页)