

基于改进遗传算法的反向传播神经网络 拟合 LED 光谱模型

高 航, 薛凌云

杭州电子科技大学生命信息与仪器工程学院, 浙江 杭州 310018

摘要 发光二极管(LED)太阳光模拟器的设计需要对 LED 光谱建立精度高且稳定性好的数学模型。针对 LED 光谱数学模型非线性的特点,提出利用一种经改进遗传算法(GA)优化的反向传播(BP)神经网络对 LED 光谱模型进行辨识。通过改进 GA 的算子,提高算法收敛效果和辨识精度,利用改进 GA 对 BP 神经网络初始和权值阈值进行优化,用于建立可靠的 LED 光谱模型。选取不同驱动电流条件下的白色、红色 LED 光谱进行实验验证,实验结果表明该算法拟合的 LED 光谱模型与实际测量光谱分布非常接近,相比其他模型精度更高,普适性更好。

关键词 光学器件; 光谱模型; 反向传播神经网络; 发光二极管; 遗传算法; 曲线拟合

中图分类号 O433.4 **文献标识码** A

doi: 10.3788/LOP54.072302

Back Propagation Neural Network Based on Improved Genetic Algorithm Fitting LED Spectral Model

Gao Hang, Xue Lingyun

*College of Life Information and Instrument Engineering, Hangzhou Dianzi University,
Hangzhou, Zhejiang 310018, China*

Abstract The design of light emitting diode (LED) solar simulator needs to establish a high accuracy mathematical model with good stability for LED spectra. According to the characteristics of nonlinear LED spectrum mathematical model, a back propagation (BP) neural network optimized by improved genetic algorithm (GA) is proposed to identify LED spectral model. By improving the operator of GA, the convergence effect and the identification accuracy is improved. The improved GA is used to optimize the initial weights and thresholds of BP neural network, which is used to establish reliable LED spectral model. Under different driving current conditions, white and red LED are selected as experimental samples to verify the experiment. Experimental results show that the LED spectrum model is very close to the measured spectrum, and it has higher precision and better universality than other models.

Key words optical devices; spectral model; back propagation neural network; light emitting diode; genetic algorithm; curve fitting

OCIS codes 230.3670; 300.6280

1 引言

随着发光二极管(LED)技术的日益发展,凭借其响应时间短、可控性能好、产品类型丰富等优点,LED已逐步成为太阳光模拟器的主流光源^[1]。在LED太阳光模拟器的设计中,需要对LED光谱分布建立等效的数学模型,在此基础上才能完成多种LED合成标准太阳光谱的研究,得到满足性能要求的太阳光模拟器

收稿日期: 2017-02-07; **收到修改稿日期:** 2017-03-08

基金项目: 国家重大科研仪器研制项目(61427808)

作者简介: 高 航(1991—),男,硕士研究生,主要从事LED太阳光模拟器方面的研究。E-mail: gaohang_hdu@163.com

导师简介: 薛凌云(1967—),女,博士,教授,主要从事自动化装置、模式识别等方面的研究。

E-mail: xly@hdu.edu.cn(通信联系人)

配光方案。所以建立一个高精度且高稳定性的 LED 光谱模型对研究 LED 太阳光模拟器十分重要^[2]。

反向传播(BP)神经网络对于非线性模型有很好的非线性映射能力,可以逼近任意非线性曲线,根据这一特点,本文利用改进遗传算法(GA)优化的 BP 神经网络建立稳定可靠的 LED 光谱模型,以提高模型的普适性,减少建模难度。然后通过对实验测得的红色、白色 LED 的光谱分布曲线建立数学模型,验证该算法的可行性和可靠性。

2 LED 光谱模型

2.1 传统模型

过去的研究人员根据 LED 的辐照特性,已提出多种数学模型来准确描述 LED 光谱分布情况。早期高斯函数是研究人员首选的 LED 光谱模型。2005 年潘建根课题组^[3]在高斯模型基础上提出了一种修正高斯模型(M-model):

$$S(\lambda) = \exp[-3.2213(\lambda - \lambda_0)^2 / (\Delta\lambda_0)^2] \times \exp[-0.3 |(\lambda - \lambda_0) / \Delta\lambda_0|], \quad (1)$$

式中 λ 为波长, λ_0 为峰值波长, $\Delta\lambda_0$ 为半峰全宽,单位为 nm^[4]。

2010 年 He 等^[5]提出利用分段函数构造 LED 光谱模型(S-model):

$$\begin{aligned} S(\lambda, \lambda_0, \Delta\lambda) &= [g(\lambda, \lambda_0, \Delta\lambda) + k_1 g(\lambda, \lambda_0, \Delta\lambda)^{k_2}] / (1 + k_1), \\ g(\lambda, \lambda_0, \Delta\lambda) &= \exp[-(\lambda - \lambda_0)^2 / (\Delta\lambda)^2], \\ \Delta\lambda &= \begin{cases} \Delta\lambda_1 (\lambda < \lambda_0) \\ \Delta\lambda_2 (\lambda \geq \lambda_0) \end{cases}, \quad k_i = \begin{cases} k_i^1 (\lambda < \lambda_0) \\ k_i^2 (\lambda \geq \lambda_0) \end{cases} \quad (i = 1, 2), \end{aligned} \quad (2)$$

式中 λ_0 为峰值波长, k_i ($i = 1, 2$) 为光谱形状特征值,左侧光谱半峰全宽 $\Delta\lambda_1 = 2 \int_{380}^{\lambda_0} S(\lambda) d\lambda$,右侧光谱半峰

全宽 $\Delta\lambda_2 = 2 \int_{\lambda_0}^{780} S(\lambda) d\lambda$ 。

2012 年谈茜等^[6]提出由多个高斯函数表征 LED 光谱模型,该模型对于 n ($n \geq 1$) 个波峰的 LED 就选用 $3n$ 个高斯函数表示(G-model):

$$S(\lambda) = \sum_{i=1}^{3n} A_i \exp[a_i (\lambda - \lambda_0 - m_i)^2 / (\Delta\lambda)^2], \quad (3)$$

式中 A_i ($i = 1, 2, \dots, 3n$) 为各高斯函数所占权重, a_i ($i = 1, 2, \dots, 3n$) 为系数, λ_0 为峰值波长, $\Delta\lambda$ 为半峰全宽, m_i ($i = 1, 2, \dots, 3n$) 为光谱峰值波长修正系数, $m_i = 0$ 。

单色 LED 辐照分布是半峰全宽较窄的单峰曲线,常用高斯函数或改进公式表征 LED 光谱数学模型。然而单色 LED 光谱谱线具有高度非线性非对称性的特点,高斯函数或者固定公式等都无法完整地表现 LED 光谱辐照分布。白色 LED 的光谱谱线是双峰曲线,拟合白光 LED 光谱则多选用多个高斯函数或多个固定公式叠加的方法,在拟合过程中也会存在差异。

2.2 GA 优化 BP 神经网络模型

基于 LED 光谱分布非线性的特点,本研究提出利用一种经 GA 优化的 BP 神经网络对 LED 光谱进行拟合。BP 神经网络在训练中各层连接的初始权值和阈值都是随机数,未经优化的随机取数会影响 BP 神经网络的收敛速度,容易陷入局部最优,最终得到的网络结构可能是非最优解。由于 GA 有很好的全局搜索能力,不易陷入局部极小,使 BP 神经网络权值和阈值有更好的寻优搜索空间,将 GA 用于优化 BP 神经网络,可避免初始化权值和阈值的随机取值,提高了 BP 神经网络的泛化能力、网络学习速度和整体逼近能力^[7]。

基于 GA 的 BP 神经网络的算法过程可以分为 3 部分:网络结构确定、GA 优化和网络预测,图 1 为算法流程图,具体算法过程如下:

1) 确定 BP 神经网络的网络结构,包括网络层数、各层的节点数等。

2) 用 GA 对 BP 神经网络的初始化权值和阈值进行优化。选择合适的取值区间进行基因编码。再通过选择、交叉和变异操作搜索到 BP 神经网络的最佳初始权值和阈值。每次局部寻优过程中保留适应度值高的个体,反复迭代,迭代过程中将局部最优解进行比较,找到适应度值最高的全局最优个体。

3) 最终达到迭代次数,将 GA 得到的最优个体赋值给 BP 神经网络的权值和阈值,把实际输入数据导入输入层,在输出层得到期望输出数据^[8]。

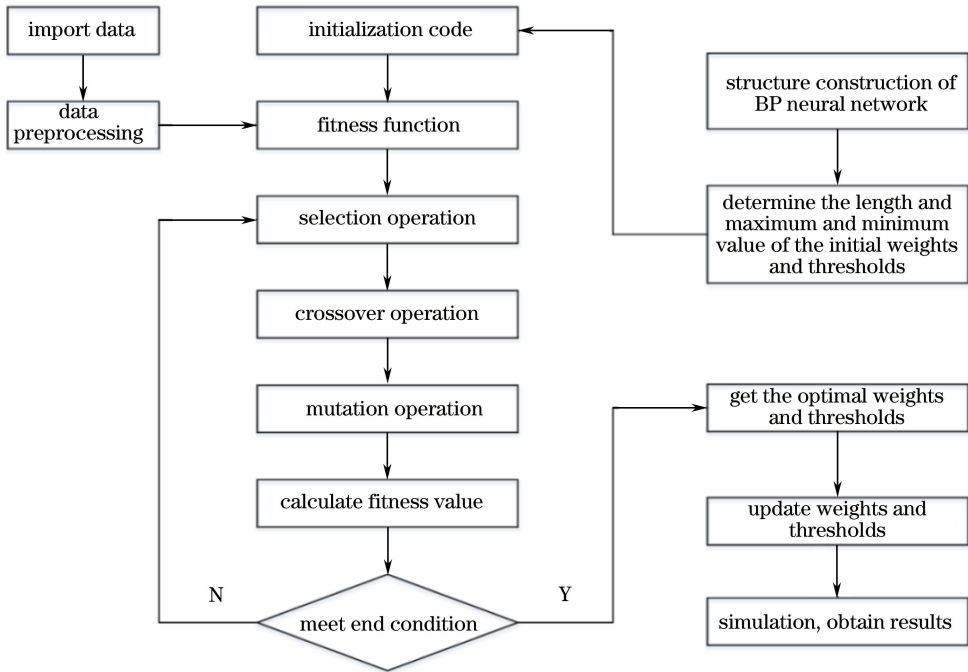


图 1 GA 优化的 BP 神经网络流程图

Fig. 1 Flow chart of BP neural network optimized by GA

3 改进 GA 设计

GA 是一种全局优化方法,但是简单 GA 存在搜索效率低下、陷入局部最优值差等缺点,用其优化 BP 神经网络可能会出现搜索方向偏离全局最优解、收敛速度慢等问题。所以本课题组对 GA 进行改进和优化,以克服简单 GA 存在的缺点。

3.1 基因编码

二进制编码在进行多目标搜索寻优时,其个体编码长,占据大量的计算机内存,计算速度慢,采用浮点数编码可以提高计算精度。改进 GA 种群中每一个个体的编码长度 $D = m \times l + l + l \times n + n$, 其中 m 是输入层节点数, l 是隐含层节点数, n 是输出层节点数。

3.2 适应度函数

GA 的搜索目标是在逐代进化过程中使网络预测的误差最小的权值阈值,则适应度函数的选取是要根据输入数据能计算得到可比较网络误差的非负结果。所以根据 GA 产生的权值阈值相应的神经网络,计算出期望输出与实际输出之间的误差平方和,适应度函数采用误差的倒数,误差越大适应度函数越小,具体如下:

$$f(x) = \frac{1}{\sum_{i=1}^m [y(i) - y_k(i)]^2}, \quad (4)$$

式中 $y(i)$ 是第 i 个输出节点的输出值, $y_k(i)$ 是期望输出值, m 是输出节点数。

3.3 选择算子

提出一种排序选择的方法,将个体适应度值的差别转化为排列次序,个体被选中的概率仅由它在种群中所排的位置所决定。首先,将种群按照适应度值从大到小依次排列,将适应度值最低排在整体末尾 1/4 的个体直接淘汰,保留位于中间 1/2 的个体,把排序在前 1/4 的个体全部复制一遍,直接被选中作为繁殖的父代。把保留下来的中间 1/2 的个体保持从大到小排列次序,组成一个新的种群,进行第二步操作。这样直接淘汰

了适应度低的个体,保证了 GA 的收敛速度,而且保证适应度高的个体可以直接作为父代遗传,减小了概率选择过程中的个体数量,使算法可以更快更好找到最优解。

然后,将上一步中保留下的种群计算出个体的选择概率:

$$\begin{cases} p_k^N = Q^N (1 - q^N)^{k-1} \\ Q^N = \frac{q^N}{1 - (1 - q^N)^{L/2}} \end{cases}, \quad (5)$$

式中 p 是个体的选择概率, q 是最佳个体的选择概率, k 是个体在种群中的排列序号, $k=1, 2, \dots, L/2$, L 为种群个数, N 是当前迭代次数。对于 q 值来说,在种群初期繁殖过程中,个体间差异大,适应度值差别大,最佳的个体应该具有大的选择概率。随着迭代次数的增加,种群间个体的差异会逐步减小,适应度值会接近,此时最佳个体与其他个体间差异不大, q 值应考虑到多样化因素,所以 q 值应该变小。因此提出一种按照迭代次数变化的 q 值:

$$q^N = q_{\max} - (q_{\max} - q_{\min}) \times \frac{N - 1}{M - 1}, \quad (6)$$

式中 q_{\max} 、 q_{\min} 分别是初、末代的最佳个体的选择概率, M 是总迭代次数。

从保留下来的个体组成的新种群中按照概率选择 $L/4$ 个个体作为父代的一部分,与第一步中复制下来的前 $1/4$ 部分一起组成一个个体数量为 $L/2$ 的父代种群。

3.4 交叉算子

采用算术交叉,设父代中进行繁殖的两个个体的某一基因分别是 A 和 B , λ 是 $(0, 1)$ 区间的随机数,交叉操作后产生的新的子代基因分别是 A' 和 B' ,

$$A' = \lambda \times A + (1 - \lambda) \times B, \quad (7)$$

$$B' = (1 - \lambda) \times A + \lambda \times B. \quad (8)$$

每一对父代个体进行两次交叉操作,产生两对子代个体,则数量为 $L/2$ 个个体的父代种群会繁殖出数量为 L 个个体的子代种群,保持了遗传种群的数目稳定。

3.5 变异算子

对于变异算子,种群中的个体适应度值一开始往往差异很大,随着迭代次数的增加,进化逐步趋于稳定,搜索空间会逐步减小,此时如果突然出现适应度值很小的个体会大大影响 GA 的收敛性,所以个体中基因变异的概率应该随着进化次数的增加而减小。同时,要保持前期变异概率较大,后期变异减小幅度较小,不能是线性变化,这样可以很好地提高算法前期的寻优搜索范围,并且防止算法后期过快早熟。则变异算子的概率公式为

$$p_m(N) = p_m(N - 1) - [p_m(N - 1) - 0.5]/M, \quad (9)$$

式中 p_m 是变异概率, N 是当前迭代次数, M 是总迭代次数, $p_m(0)$ 是初始变异概率,其值应该大于 0.5。

当父代个体中某一基因被选择进行变异时,设变异的父代个体为 $s = (v_1, \dots, v_k, \dots, v_t)$, 其中 t 是基因长度, v_k 被选中进行变异,变异区间为 $[a_k, b_k]$, 则变异后产生的子代个体为 $s' = (v_1, \dots, v_{k-1}, v'_k, v_{k+1}, \dots, v_t)$ 。繁殖后期适应度值趋于稳定,寻优搜索基本确定了搜索范围,则基因变异幅度应随着繁殖次数的增加而降低,否则基因突然的大幅度变化会导致适应度值的突变,影响收敛速度。其中 v'_k 的变异规则为

$$v'_k = \begin{cases} v_k + \Delta(N, b_k - v_k), & f_{\text{rand}} = 0 \\ v_k - \Delta(N, b_k - v_k), & f_{\text{rand}} = 1 \end{cases}, \quad (10)$$

式中 f_{rand} 表示随机生成一个 0 或 1 的数, N 是当前迭代次数,函数 $f_{\Delta}(x, y)$ 的值域为 $[0, y]$, 随着 x 的增加, $f_{\Delta}(x, y)$ 接近于 0 的概率增大,则 $f_{\Delta}(x, y)$ 的函数表达式为

$$f_{\Delta}(x, y) = y \times r \times \exp[-\pi(x - 1)^2 y^2 / (M - 1)^2], \quad (11)$$

式中 r 是一个 $[0, 1]$ 区间内的随机数, M 为总迭代次数, λ 是决定变异幅度的一个参数,起着调节局部搜索区域的作用,取值范围为 $[2, 5]$ 。

4 实验验证

4.1 实验平台及数据分析

本实验通过 LED 光谱测试与分析系统进行样本数据采集,该系统由程控恒流源、积分球、光谱仪、控制个人电脑(PC)组成,如图 2 所示,其中光谱仪选用美国海洋光学公司的 HR4000 型光谱仪,其波长测量范围为 380~800 nm,采样间隔为 0.1 nm,利用该光谱仪分别测量驱动电流为 700 mA 的白色 LED 和驱动电流为 20 mA 的红色 LED 的光谱分布,通过 MATLAB 软件进行仿真模拟。




图 2 LED 光谱测试与分析系统结构原理图

Fig. 2 Structure schematic of LED spectrum measurement and analysis system

对于改进 GA 中的参数,迭代次数为 50,种群大小为 40,初、末代最佳个体选择概率分别是 0.9、0.6,初始变异概率为 0.6。LED 光谱模型拟合结果与神经网络结构有关,选用 3 层神经网络,隐含层神经元个数为 60,波长作为网络输入样本,光辐照强度作为网络输出样本,选用训练均方差、网络迭代误差 ϕ 和光谱误差比 θ 评价神经网络拟合效果,网络迭代误差 ϕ 和光谱误差比 θ 为

$$\phi = \sum |y_k(\lambda) - y(\lambda)|, \quad (12)$$

$$\theta = \frac{|y_k(\lambda) - y(\lambda)|}{|y(\lambda)|} \times 100\%, \quad (13)$$

式中 $y_k(\lambda)$ 表示波长 λ 的模型光谱辐照度, $y(\lambda)$ 表示波长 λ 的光谱辐照度测量值。

选用峰值辐照度 T 、峰值波长 W 、半峰全宽 ΔW 以及光谱匹配度 E 来表征模型光谱与实测光谱之间的误差情况。光谱匹配度公式为

$$E = \sqrt{\sum [y_k(\lambda) - y(\lambda)]^2 / n}, \quad (14)$$

式中 n 为光谱采样个数。

4.2 白色 LED 光谱拟合和改进 GA 效果验证

为了验证对 GA 改进的优化效果和改进 GA-BP 神经网络对白色 LED 光谱拟合的有效性,分别用改进 GA-BP 神经网络和 GA-BP 神经网络对白色 LED 光谱进行模型辨识,将两种算法的仿真效果进行比较研究。GA-BP 神经网络中的相关参数设置与改进 GA-BP 神经网络一致。

通过 MATLAB 仿真得到的改进 GA-BP 神经网络和 GA-BP 神经网络对 700 mA 驱动电流下的白色 LED 拟合得到的光谱分布模型如图 3 和图 4 所示,可以看出 GA-BP 神经网络对白光 LED 光谱拟合的误差极大,不能准确模拟出光谱的分布情况,而改进 GA-BP 神经网络可以完整地表征出白光 LED 的光谱分布。

图 5 和图 6 分别是改进 GA-BP 神经网络和 GA-BP 神经网络的训练均方差曲线,当训练次数达到 500 时 GA-BP 神经网络的均方差收敛值大于 10^{-2} ,而改进 GA-BP 神经网络的收敛值接近 10^{-6} ,收敛效果大大优于前者。图 7 是网络迭代误差曲线,改进 GA-BP 神经网络和 GA-BP 神经网络每次迭代的平均误差分别为 6.0802, 6.9744。图 8 是光谱误差比曲线,给出的是 400~500 nm 波长范围内改进 GA-BP 神经网络和 GA-BP 神经网络与实测光谱分布之间的光谱误差比,从图 8 可以看出,改进 GA-BP 神经网络的收敛效果更好,模型稳定,误差总是小于 GA-BP 神经网络,而 GA-BP 网络模型误差波动大,容易发生失真。

为了进一步验证 GA 经过改进之后其性能的优越性,统计改进 GA-BP 神经网络和 GA-BP 神经网络对白色 LED 光谱拟合得到的误差数据,包括主、次峰值辐照度 T_1 、 T_2 ,主、次峰值波长 W_1 、 W_2 ,主、次半峰全宽

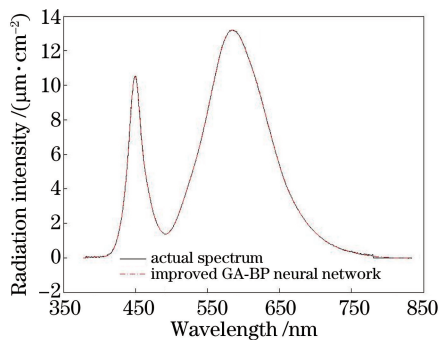


图 3 改进 GA-BP 神经网络拟合的白色 LED 光谱分布

Fig. 3 White LED spectral distribution fitted by improved GA-BP neural network

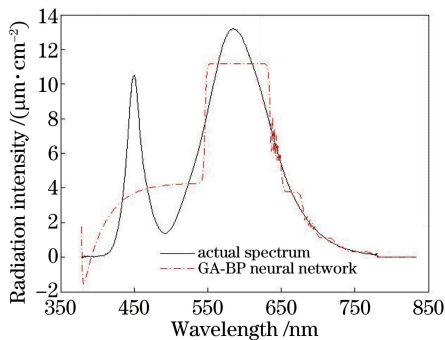


图 4 GA-BP 神经网络拟合的白色 LED 光谱分布

Fig. 4 White LED spectral distribution fitted by GA-BP neural network

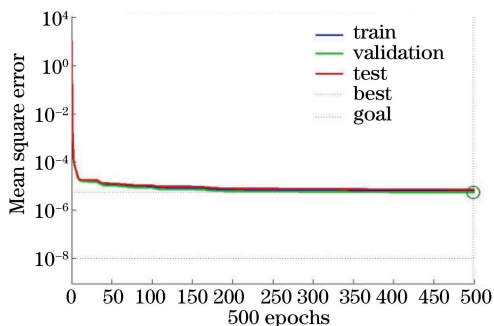


图 5 改进 GA-BP 神经网络训练均方差曲线

Fig. 5 Training mean square error curve of improved GA-BP neural network

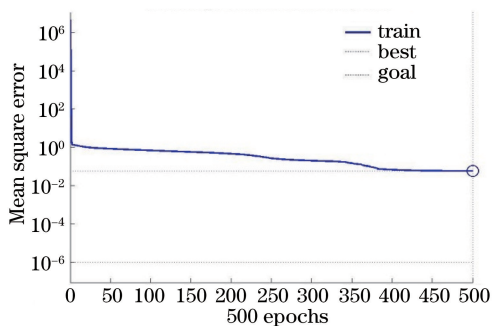


图 6 GA-BP 神经网络训练均方差曲线

Fig. 6 Training mean square error curve of GA-BP neural network

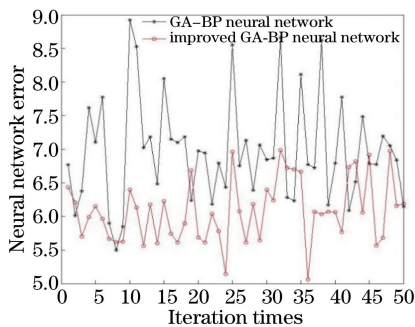


图 7 神经网络迭代误差曲线

Fig. 7 Curves of neural network iteration error

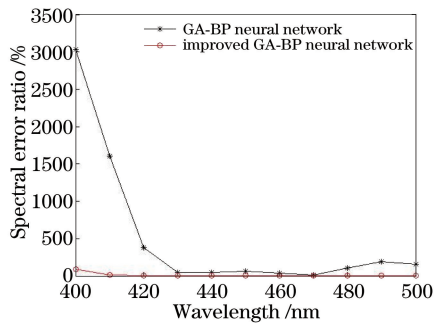


图 8 光谱误差比曲线

Fig. 8 Curves of spectral error ratio

ΔW_1 、 ΔW_2 , 光谱匹配度 E , 如表 1 所示。

表 1 改进 GA-BP 神经网络与 GA-BP 神经网络误差对比

Table 1 Error comparison between improved GA-BP neural network and GA-BP neural network

Item	Measurement	Improved GA-BP neural network		GA-BP neural network	
		Simulation	Error / %	Simulation	Error / %
T_1	13.2078 $\mu\text{m}\cdot\text{cm}^{-2}$	13.2015 $\mu\text{m}\cdot\text{cm}^{-2}$	0.04	11.1940 $\mu\text{m}\cdot\text{cm}^{-2}$	17.99
W_1	584.2932 nm	584.7983 nm	0.08	621.3223 nm	6.34
ΔW_1	101.5598 nm	101.6837 nm	0.12	102.7672 nm	1.19
T_2	10.5175 $\mu\text{m}\cdot\text{cm}^{-2}$	10.5235 $\mu\text{m}\cdot\text{cm}^{-2}$	0.06	—	—
W_2	450.3306 nm	449.6731 nm	0.15	—	—
ΔW_2	24.1927 nm	24.3237 nm	0.54	—	—
E	—	0.1293		1.5909	

改进 GA-BP 神经网络拟合白色 LED 模型与实测光谱之间的误差均小于 1%，光谱匹配度也优于未改进的 GA-BP 神经网络，而后者模型容易发生失真，精度低、收敛差。结果表明改进 GA-BP 神经网络可以表征白色 LED 光谱分布模型，与实测光谱分布非常接近，同时改进后 GA 的寻优搜索效果更好。

4.3 单色 LED 光谱拟合和模型性能分析

将改进 GA-BP 神经网络模型与上文中的 3 个光谱模型分别对 20 mA 驱动电流下的红色 LED 光谱分布进行拟合，对仿真结果进行对比，验证改进 GA-BP 神经网络模型精度和对单色 LED 光谱的拟合效果。改进 GA-BP 神经网络采用 3 层网络结构，隐含层神经元为 60 个，模型得到的输入层权值、隐含层权值和阈值、输出层阈值的部分数值如表 2 所示。

表 2 改进 GA-BP 神经网络权值和阈值

Table 2 Weight and threshold of improved GA-BP neural network

Input layer weight	Hidden layer weight	Hidden layer threshold	Output layer threshold
-168.0184	-0.8207	167.9814	6.9966
170.0674	0.8151	145.1854	/
168.7299	2.3653	-111.3930	/
149.9289	2.2460	96.9053	/
-156.4714	-0.0257	-78.3122	/

图 9、图 10、图 11 和图 12 分别是采用改进 GA-BP 神经网络、M-model、S-model 和 G-model 拟合的红色 LED 光谱分布，可以看出改进 GA-BP 神经网络模型辨识精度明显优于 M-model、S-model 和 G-model。

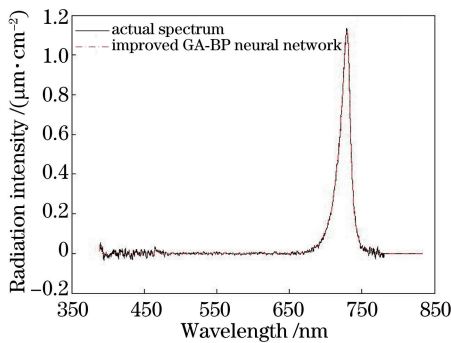


图 9 改进 GA-BP 神经网络拟合的红色 LED 光谱分布

Fig. 9 Red LED spectral distribution fitted by improved GA-BP neural network




图 10 M-model 拟合的红色 LED 光谱分布

Fig. 10 Red LED spectral distribution fitted by M-model




图 11 S-model 拟合的红色 LED 光谱分布

Fig. 11 Red LED spectral distribution fitted by S-model

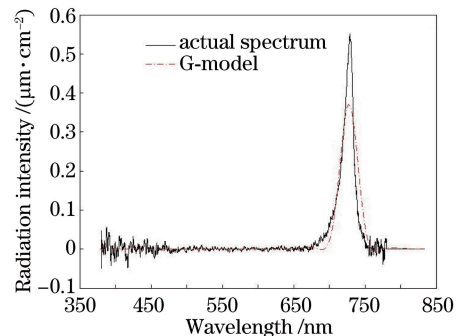


图 12 G-model 拟合的红色 LED 光谱分布

Fig. 12 Red LED spectral distribution fitted by G-model

为了验证改进 GA-BP 神经网络拟合 LED 光谱模型的精度，分别统计改进 GA-BP 神经网络、M-model、S-model 和 G-model 拟合的红色 LED 光谱的模型误差数据，包括峰值辐照度 T 、峰值波长 W 、半峰全宽 ΔW 以及光谱匹配度 E ，如表 3 所示。表 3 中 M' 为实测值， S' 为仿真值， E' 为误差百分比。可看出改进 GA-BP 神经网络模型的各个误差值均小于 2%，光谱匹配度也优于其他 3 个模型，尽管 M-model 和 S-model 的峰值

波长误差小,但是其峰值辐照度和半峰全宽误差均大于 10%,同时 S-model 和 G-model 发生失真,影响拟合精度。

表 3 采用不同光谱模型获得的误差

Table 3 Error obtained using different spectral models

Item	M'	Improved GA-BP neural network		M-model		S-model		G-model	
		S'	$E' / \%$	S'	$E' / \%$	S'	$E' / \%$	S'	$E' / \%$
T	$1.1352 \mu\text{m} \cdot \text{cm}^{-2}$	$1.1203 \mu\text{m} \cdot \text{cm}^{-2}$	1.7	$1 \mu\text{m} \cdot \text{cm}^{-2}$	11.9	$0.9868 \mu\text{m} \cdot \text{cm}^{-2}$	13.1	$0.3702 \mu\text{m} \cdot \text{cm}^{-2}$	67.4
W	728.9652 nm	729.085 nm	0.02	728.9652 nm	0	728.9652 nm	0	727.6455 nm	0.2
ΔW	15.8326 nm	15.7123 nm	0.8	13.4228 nm	15.2	41.8357 nm	164	28.7781 nm	81.8
E	—	0.0082		0.0665		0.1212		0.0292	

选取 700~750 nm 波长范围,计算 4 种模型与实测光谱之间的光谱误差比,误差曲线如图 13 所示。改进 GA-BP 神经网络的光谱误差比最小,而另外 3 个模型不稳定且误差极大。

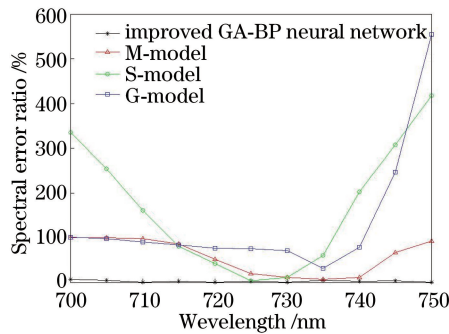


图 13 不同光谱模型与实测光谱的误差比

Fig. 13 Error ratio of different spectral models and measured spectra

通过采用改进 GA-BP 神经网络、M-model、S-model 和 G-model 分别对红色 LED 光谱模型进行辨识,结果表明改进 GA-BP 神经网络的拟合精度最高,误差最小,稳定性最好,性能优于其他 3 个模型,非常接近实测光谱分布,验证了利用改进 GA-BP 神经网络对单色 LED 光谱模型拟合的可行性和可靠性。

5 结 论

对 LED 光谱建立稳定的高精度的数学模型是 LED 太阳光模拟器研究的关键技术,首先对 GA 提出一种改进方法,通过与未改进的 GA 进行实验对比,证明改进 GA 收敛效果更好、更稳定可靠。然后用改进 GA 优化的 BP 神经网络对 LED 光谱分布进行建模,并对在不同驱动电流条件下白色、红色 LED 的光谱分布情况进行实验验证。结果显示该光谱建模拟合的 LED 光谱分布与实际采样的光谱分布已非常接近,能有效地表征单光 LED 和白光 LED 光谱谱线,性能优于过去常用模型,表明该模型具有高精度、全局寻优、普适性好等优点。

参 考 文 献

- [1] Song Pengcheng, Wen Shangsheng, Chen Yingcong. Research on color mixing based on RGBW-LEDs[J]. Acta Optica Sinica, 2015, 35(9): 0923004.
宋鹏程, 文尚胜, 陈颖聪. 基于 RGBW 四色 LED 的混光研究[J]. 光学学报, 2015, 35(9): 0923004.
- [2] Mohan M V A, Pavithran J, Osten K L, et al. Simulation of spectral match and spatial non-uniformity for LED solar simulator[C]. 2014 IEEE Global Humanitarian Technology Conference-South Asia Satellite, 2014: 111-117.
- [3] Shen Haiping, Feng Huajun, Pan Jianguan, et al. LED spectrum mathematical model and its application (English)[C]. China Illuminating Engineering Society, 2005: 83-85.
沈海平, 冯华君, 潘建根, 等. LED 光谱数学模型及其应用(英文)[C]. 中国照明学会, 2005: 83-85.
- [5] He G X, Zheng L H. A model for LED spectra at different drive currents[J]. Chinese Optics Letters, 2010, 8(11):

1090-1094.

- [6] Tan Qian, Rao Feng, Zhang Yonglin, *et al.* LED spectral model characterized by several Gaussian functions [J]. *Chinese Optics*, 2012, 5(5): 493-498.
谈茜, 饶丰, 张永林, 等. 由多个高斯函数表征的发光二极管光谱模型[J]. *中国光学*, 2012, 5(5): 493-498.
- [7] Peng Jiwei, Lü Wenhua, Xing Hongyan, *et al.* Temperature compensation for humidity sensor based on improved GA-BP neural network [J]. *Chinese Journal of Scientific Instrument*, 2013, 34(1): 153-160.
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.
- [8] Chai Yi, Yin Hongpeng, Li Dajie, *et al.* Self-adaptation optimize BP neural network design based on the genetic algorithms [J]. *Journal of Chongqing University (Natural Science Edition)*, 2007, 30(4): 91-96.
柴毅, 尹宏鹏, 李大杰, 等. 基于改进遗传算法的 BP 神经网络自适应优化设计[J]. *重庆大学学报(自然科学版)*, 2007, 30(4): 91-96.