

基于 BP 神经网络的紫外光源自适应固化控制研究

郑明明¹, 王 军^{1,2}, 董兴法¹, 石绍鹏¹

¹苏州科技大学电子与信息工程学院, 江苏 苏州 215009;

²中国科学院长春光学精密机械与物理研究所, 长春 130033

摘要: 为解决紫外光动态固化技术中的固化不充分或反固化反应等问题, 提出一种基于 BP 算法的 LED 紫外光源多参数自适应控制方法。利用神经网络优异的非线性逼近能力, 并结合优化后的 BP 算法构建一个 3 输入 2 输出的网络预测模型。通过与多元线性回归和多元非线性回归模型的对比显示, BP 神经网络算法有更高的拟合度。最后将 57 组数据导入训练好的模型进行验证。实验表明: 该 BP 神经网络模型预测结果较好, 且稳健性强。2 输出参数预测值误差分别为 1.86% 和 2.35%, 可灵活应用于多种紫外光固化场合。

关键词: 紫外光; 固化技术; 自适应调光; BP 神经网络

中图分类号: TN247 文献标识码: A doi: 10.14016/j.cnki.jgzz.2021.03.058

Research on adaptive curing control of ultraviolet light driver based on BP neural network

ZHENG Mingming¹, WANG Jun^{1,2}, DONG Xingfa¹, SHI Shaopeng¹

¹Suzhou University of Science and Technology, Suzhou Jiangsu 215009, China;

²Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China

Abstract: In order to solve the problem of insufficient curing or anti curing reaction in UV dynamic curing technology, a multi-parameter adaptive control method of LED UV light source based on the BP algorithm is proposed. A 3-input-2-output network prediction model is built based on the excellent non-linear approximation ability of the neural network and the optimized BP algorithm. Compared with the multiple linear regression model and multiple non-linear regression model, BP neural network algorithm has a higher fitting degree. Finally, 57 groups of data are imported into the trained model for verification. The experimental results show that the BP neural network model has good prediction results and strong robustness. The two output parameters' prediction errors are 1.86% and 2.35% respectively, which can be flexibly applied to a variety of UV curing occasions.

Key words: ultraviolet light; curing technology; adaptive dimming; BP neural network

1 引言

紫外光固化技术是通过紫外光照射 UV 油墨或 UV 胶体, 在光引发剂的作用下, 使胶体中的化学键聚合而干燥结膜, 广泛应用于油墨固化、印刷等行业^[1]。

固化本质上是一个复杂的化学过程, 固化效果受多种因素影响, 可视多元非线性动态模型。传统的紫外光源多为高压汞灯, 由于开关机操作费时、寿命短及工作温度高等原因, 导致其在实际应用中受到了诸多限制。而相比于 LED 光源, 其具有的发光光谱纯度高 (尤其是集中在用于固化涂料最敏感的 365 nm 附近一段的窄光谱)、随开随关、节能、环保、寿命长等优点^[2-4], 都是传统汞灯光源无法比拟的。

文献[5]中采用 BP 神经网络算法, 将车流量、环境光强等参数作为神经网络的输入, 调光量作为神经网络输出, 实现了对隧道内的灯光精确控制, 进而达

收稿日期: 2020-09-16

基金项目: “十三五”江苏省重点学科项目 (No.20168765); 江苏省研究生科研创新项目 (No.KYCX17_2060); 江苏省研究生工作站项目

作者简介: 郑明明 (1994-), 男, 硕士研究生。研究方向: 光电信息处理技术。E-mail: zhengmingming110@163.com

通讯作者: 王军 (1979-), 男, 博士, 副教授。研究方向: 光电测控技术与仪器。E-mail: wjyhl@126.com

<http://www.laserjournal.cn>

到节能和隧道照明优化效果。文献[6]中研究设计的LED自适应驱动电源系统,把神经网络与PID算法进行结合,通过实时采集光源系统的温度、环境光照强度、驱动LED光源发光强度的电流值作为输入参数,利用神经网络优异的非线性逼近能力,得到系统的调光反馈量,有效改善了在复杂控制环境下系统的稳定性。

基于以上分析,提出一种BP(Back Propagation, BP)神经网络算法^[7]对紫外光进行自适应调控,以满足不同需求的固化要求。考虑到现有市场上的LED紫外固化光源,其调光机制多为有级调光,且随着光源产品的使用时间增加,LED光源寿命也会受到影响,不能准确提供指定光强以及精确的曝光时间^[8],加上工作人员很难根据实际生产情况来手动精确调节光源发光强度。因此,为满足各种实际生产需求,且同时能有效提高产品的固化反应程度是本研究的关键。这对于新型LED固化光源的研发和拓展性应用研究提供了可行性方法分析及实验依据。

2 自适应调光系统

2.1 系统整体框架设计

在紫外光固化控制系统中,固化效果往往和紫外光照度值、环境温度以及曝光时间有着复杂的非线性关系,采用简单的线性回归模型具有一定的局限性。而BP神经网络具有很好的非线性拟合预测能力,不需要计算各参数之间的隐含关系公式就可以对曝光能量进行预测。

图1给出了光源自适应控制结构框图,图中的主决策控制器部分为本固化控制系统的核心部分,通过传感器实时采集紫外光照度值、固化环境温度及传送带速度(传送带速度决定了固化的曝光时间)发送到主控制器,作为系统的输入量并由BP神经网络算法处理后输出调光量和固化所吸收的能量,最后由光源驱动系统接收来自主控制器的调光量完成固化所要求的能量进行调节。

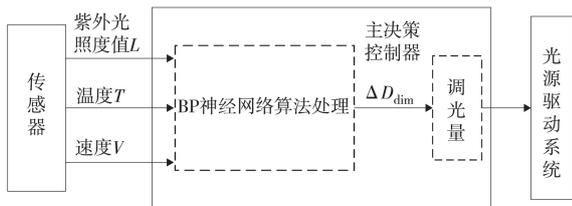


图1 自适应紫外光固化控制结构框图

2.2 LED光源驱动调光原理

采用数字PWM调光方式来调节流过LED的实际有效电流值,通过神经网络的输出值来得到相应的

PWM调光系数。对于开关电源的恒流主要是通过两个高频开关MOS管循环开通与关断的原理,在上端MOS管导通期间,输入电流为电感充电,当其关断期间,下端MOS管导通期间,电感放电,两个时间间隔内,电流流经负载为负载供电^[9]。数字PWM调光具体方法是在LED的回路中串入一个MOS管,然后以不同占空比的PWM信号加载到MOS管栅极,进而可以调节LED光源光强,所调节的实际有效电流为:

$$I_e = D_{dim} \times I_{max} \quad (1)$$

式(1)中: $D_{dim} = \frac{T_{on}}{T_{on} + T_{off}}$ 光源调光系数; T_{on} 是MOS

管导通时间; T_{off} 是MOS管关断时间; I_{max} 是最大输出电流。

3 BP神经网络自适应模型建立

3.1 神经网络模型构造及其算法

设计的神经网络由一个输入层、一个隐含层、一个输出层构成。输入信号采用二维输入,即传感器采集到的数据值与数据值的变化值作为输入信号,这样能够有效地减少信号在获取和传输过程中带来的滞后性^[10],能够使网络的输出值更满足自适应控制需求。如图2所示。

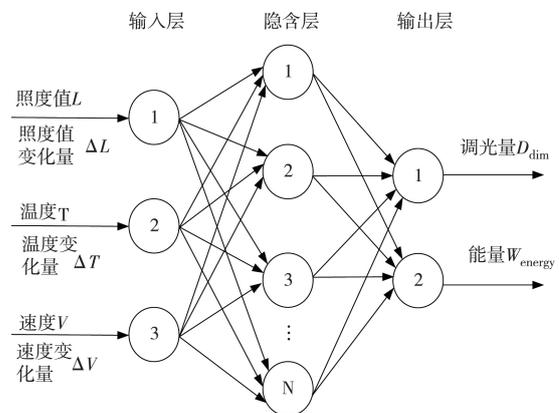


图2 三层神经网络拓扑图

1) 输入层的输入量:

$$O_i^{in} = x(i) \quad i = 1, 2, 3 \quad (2)$$

式(2)中: $x(i)$ 为第 i 个输入参数。

2) 隐含层的输入、输出:

$$\begin{cases} net_j^{in}(k) = \sum_{i=1}^3 w_{ij}^{in} o_i^{in} \\ o_j^{in}(k) = f[net_j^{in}(k)] \end{cases} \quad j = 1, 2, \dots, N \quad (3)$$

式(3)中: w_{ij}^{in} 为输入层与隐含层之间的节点连接权值; $f(x)$ 为隐含层激活函数。

3) 输出层的输入、期望输出为:

$$\begin{cases} net_l^{out}(k) = \sum_{j=1}^N w_{jl}^{out} o_j^{in}(k) \\ o_l^{out}(k) = g[net_l^{out}(k)] \end{cases} \quad l = 1, 2 \quad (4)$$

式(4)中: w_{jl}^{out} 为隐含层与输出层之间的节点连接权值; $g(x)$ 为输出层激活函数。

4) 取输出节点均方误差函数:

$$E(k) = \frac{1}{2} [r_{in}(k) - y_{out}(k)]^2 \quad (5)$$

式(5)中: $r_{in}(k)$ 表示期望值; $y_{out}(k)$ 表示预测值。

3.2 BP 算法优化

在传统的算法基础上添加动量因子^[11]后的权值计算公式:

$$\Delta w_{ij}^{out}(k) = -\eta \frac{\partial E(k)}{\partial w_{ij}^{out}(k)} + \alpha \Delta w_{ij}^{out}(k-1) \quad (6)$$

式(6)中: η 为学习率; E 为均方差; α 为动量因子,且 $\alpha \in (0, 1)$ 。于是:

$$\begin{cases} \Delta w_{ij}^{out}(k) = \alpha \Delta w_{ij}^{out}(k-1) + \eta \delta_l^{out} O_j^{in}(k) \\ \delta_l^{out} = E(k) \operatorname{sgn} \left[\frac{\partial y_{out}(k)}{\partial \Delta o_l^{out}(k)} \right] g' [net_l^{out}(k)] \end{cases} \quad (7)$$

由于 $\frac{\partial y_{out}(k)}{\partial o_l^{out}(k)}$ 未知,此处可以使用阶跃函数 sgn

$\left[\frac{\partial y_{out}(k)}{\partial \Delta o_l^{out}(k)} \right]$ 近似代替,且还要通过改变学习率 η 来

消除近似代替产生的计算不精确问题。

经以上分析,网络输出层的权值计算公式为:

$$\begin{cases} \Delta w_{ij}^{out}(k) = \alpha \Delta w_{ij}^{out}(k-1) + \eta \delta_l^{out} O_j^{in}(k) \\ \delta_l^{out} = E(k) \operatorname{sgn} \left[\frac{\partial y_{out}(k)}{\partial \Delta o_l^{out}(k)} \right] g' [net_l^{out}(k)] \end{cases} \quad (8)$$

同理,可得隐含层权值计算公式。

隐含层的神经元个数一般可由式(9)来初步确定:

$$N = \sqrt{m+n} + a \quad (9)$$

式(9)中: m 和 n 分别为输入层及输出层神经元的个数, a 取 $[1, 10]$ 。

4 实验及结果分析

4.1 系统硬件实物搭建

实验搭建的测试平台由系统板和 LED 阵列式光源等构成,而系统板主要由主决策控制器和光源驱动模块组成。主控制器接收传感器测得的数据并进行相应的算法处理,光源驱动模块接收来自主控制器的调光量以调节光源强度,如图3所示。

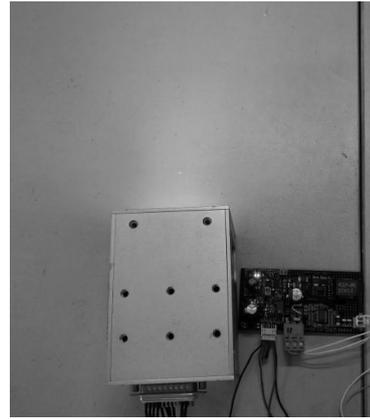


图3 紫外光源测试实物图

4.2 样本数据处理

固化效果的优劣往往是依据专业人员的丰富经验来判定,固化效果好的产品其固化过程所吸收的紫外光能量值是介于一定的小范围内。可见,鉴别过程的主观性占很大比重,但可以通过检测仪器来测量固化过程所测得的能量,近似视为产品固化过程吸收的能量,通过这种方式,可将固化反应程度进行量化。从收集到的357组已固化的产品数据中(所收集到的数据均在同一高度下测得),随机选取300组数据作为训练样本,再取余下的57组数据检验神经网络的学习结果,部分训练样本数据,见表1所示。

表1 部分自适应BP神经网络训练样本

照度/ ($\text{mw} \cdot \text{cm}^{-2}$)	温度/ ($^{\circ}\text{C}$)	速度/ ($\text{cm} \cdot \text{s}^{-1}$)	调光系数/ %	能量/ mJ
363	27.4	9.4	35.3	3 721
375	28.1	9.5	36.2	3 635
532	26.2	14.3	64.5	3 657
295	31.6	8.7	22.5	3 390
228	25.5	7.2	10.2	3 157
672	26.9	16.5	85.2	3 932
535	29.6	13.7	64.3	4 036
688	29.9	15.3	86.3	3 993
650	28.7	16.4	82.4	3 961
393	33.7	10.5	38.3	3 742
621	35.3	15.2	78.3	4 137
525	32.1	13.7	63.5	3 832
475	38.6	11.6	52.6	4 093
466	37.5	12.2	51.2	3 966
632	39.5	15.9	80.3	3 820
593	42.3	15.3	74.6	3 875
580	45.6	15.0	71.5	3 866
710	44.3	17.8	94.2	4 008
659	40.5	17.1	85.2	3 739
485	43.6	12.6	54.8	3 986

由表1所示,样本的输入或输出数据之间存在差异,在训练过程中,为了避免高数值数据特征掩盖低数值数据特征,忽略了低数值数据特征影响^[12]。为此,需要对所采集到的样本数据进行归一化处理,具体公式为:

$$x = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

式(10)中: x_i 为未归一化的样本数据, x_{\max} 和 x_{\min} 为输入、输出数据中的最大值和最小值。

4.3 隐含层神经元数目寻优

上式(9)给出了初步确定神经元数目 $N \in [3, 13]$,最终确定隐含层神经元个数才能使神经网络性能达到最优。为此,对 N 所有可能的取值采用“三分法”^[13]进行实验,以均方差为评价指标,不同神经元数目的实验训练结果如图4所示。

图4中,MSE1表示所吸收能量的均方误差,MSE2表示调光系数的均方误差。通过观察可知,隐含层节点数对均方误差的影响走势呈不规则的抛物线模型,整体变化趋势上呈现抛物线变化。当选取隐含层神经元节点数 $N=8$ 时,MSE1有最小均方误差为4.0%;取 $N=9$ 时,MSE2有最小误差为4.2%。考虑到网络的训练时间及固化性能主要以能量来衡量,故设计的BP神经网络模型 N 取8。

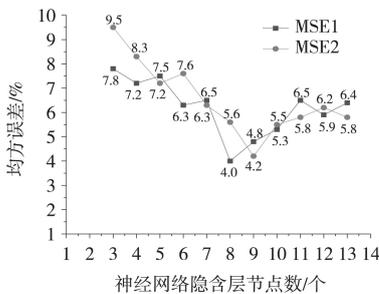


图4 隐含层神经元个数对网络性能影响

4.4 样本数据预测结果分析

为了验证所建立的BP神经网络模型的必要性和准确性,引入多元线性回归模型^[14]和多元非线性回归模型^[15]进行对比,再将300组数据作为验证样本来评估预测值和真实值的拟合程度,计算三种模型的拟合度系数 R^2 。

$$R^2 = \left| 1 - \frac{\sum_{i=1}^{300} (y_i - y_i^*)^2}{\sum_{i=1}^{300} (y_i - \bar{y})^2} \right| \quad (11)$$

式(11)中: y_i 为真实值; \bar{y} 为平均值; y_i^* 为预测

值。

通过计算得到BP神经网络模型与上述2种模型的拟合度系数,结果见表2所示。

表2 三种模型的拟合度系数对比

建模方法	拟合度
BP神经网络	0.857
多元线性回归	0.536
多元非线性回归	0.751

式(11)表明, R^2 的值越接近1,所建立模型的拟合度更贴近真实情况。由表2可以看出,BP神经网络模型较多元线性模型和多元非线性模型的拟合度更优越。

由以上分析,BP神经网络模型最终确定选择3-8-2单隐含层结构。将检验样本数据导入到已经训练完成的BP神经网络模型进行最优固化效果预测,把归一化后的样本数据带入训练函数,输出为调光系数和能量,并将两组数据反归一化。部分检验结果如表3所示。

表3 样本期望值与预测值比较

照度/ ($\text{mw} \cdot \text{cm}^{-2}$)	温度/ ($^{\circ}\text{C}$)	速度/ ($\text{cm} \cdot \text{s}^{-1}$)	调光系数 期望值/ %	调光系数 真实值/ %	能量期 望值/ mJ	能量真 实值/ mJ
402	29.3	10.2	39.8	41.7	3 872	4 022
597	30.2	14.6	72.1	73.8	4 089	4 242
325	35.6	8.7	27.2	28.3	3 736	3 605
636	37.8	15.6	80.9	77.2	4 033	4 179
459	33.4	12.3	50.6	52.6	3 657	3 785
572	42.7	14.8	68.4	66.8	3 795	3 871
337	38.2	7.9	28.8	30.0	4 166	4 310
658	32.5	15.7	84.8	88.3	4 028	4 160
...
580	35.3	11.5	75.6	73.6	3 972	3 865
445	33.6		82.3	85.6	4 032	4 185

为了更直观地体现该BP神经网络的性能,计算期望值与预测值误差,如图5所示。RE1表示完全固化所吸收能量的期望值与预测值误差,RE2表示调光系数的期望值与预测值误差。从图中可以看出,训练完成的BP神经网络模型预测效果较好。其中RE1最小误差为1.86%,最大误差为3.88%;RE2最小误差为2.35%,最大误差为4.82%,说明该预测模型是有意义的。

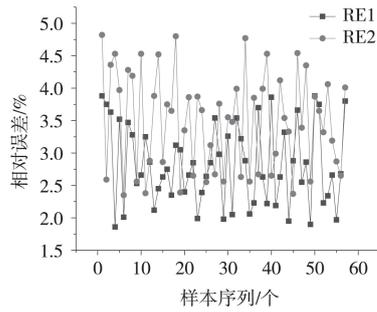


图5 期望值与预测值相对误差

5 结论

以往在紫外光固化过程中,调光一般通过手动调节,且为有级调光,其过程主观性太强。提出一种用优化后的BP算法和神经网络结合的方法,控制系统根据影响固化效果参数情况进行自适应调节光源强度,构建的基于BP神经网络算法的LED紫外光源自适应固化控制模型,其调光策略具有实时性,能够根据当前光源照度值、固化环境温度及曝光时间的变化进行实时跟踪与调节。结果表明:搭建的BP神经网络预测模型最小误差为1.86%和2.35%,该方法简便了繁琐的手动调光操作,提高了调光准确度。为了进一步提高固化控制精度,可在现有的基础上收集更多的样本数据,扩大训练样本容量,使BP神经网络具有更强的鲁棒性与自适应性。

参考文献

- [1] 孔晓慧,白廷柱,杨雅丽.紫外光固化LED线光源的光学系统设计及仿真[J].光学学报,2013,33(02):187-192.
- [2] 赵欢,许文海,芦永军.LED阵列型紫外光固化光源系统[J].光电子·激光,2007,18(11):1314-1316.
- [3] 廖刚,陈小媛,蒋福春,等.用于固化的高光密度紫外LED大功率光源的设计[J].中国照明电器,2017(12):11-15.
- [4] 向昌明.紫外光LED固化光学系统设计[D].广州:华南理工大学,2017.
- [5] Sun Shujun, Li Bo, Zou Nianyu. LED tunnel lighting control based on ZigBee [C] // 2018 15th China International Forum on Solid State Lighting: International Forum on Wide Bandgap Semiconductors China (SSLChina: IFWS), 2018.
- [6] 李莎.大功率LED自调节驱动电源研究[D].长春:长春工业大学,2018.
- [7] Liu Hongwei, Guo Kai, Zhang Zanyun, et al. High-Power LED Photoelectrothermal Analysis Based on Backpropagation Artificial Neural Networks [J]. IEEE Transactions on Electron Devices, 2017, 64(7): 2867-2873.
- [8] 姜华.阵列光源自动化检测与控制系统研究[D].苏州:苏州科技大学,2018.
- [9] 李志博,王辉,王磊,等.一种大功率低噪声的智能可调LED驱动设计方法[J].液晶与显示,2018,33(09):778-786.
- [10] 曲宇宁,常青,葛宇,等.模糊PID控制在智能路灯控制系统的应用研究[J].电源技术,2018,42(03):431-433.
- [11] 齐晓慧,李杰,韩帅涛.基于BP神经网络的自适应自抗扰控制及仿真[J].兵工学报,2013,34(06):776-782.
- [12] 刘欢.基于视觉舒适度LED背光亮度自适应控制系统研究[D].天津:天津工业大学,2018.
- [13] 王嵘冰,徐红艳,李波,等.BP神经网络隐含层节点数确定方法研究[J].计算机技术与发展,2018,28(04):31-35.
- [14] 瞿海斌.基于PLS的建模方法[J].浙江大学学报(工学版),1999(05):19-22.
- [15] 孙凤林.偏最小二乘回归法非线性建模及其递推算法的研究[D].广州:华南理工大学,2010.