

DOI:10.16356/j.1005-2615.2021.03.020

基于神经网络的荧光油膜厚度与灰度研究

钱泓江, 董秀成, 徐椰焱, 蒋金洋, 陈桂芳

(西华大学电气与电子信息学院, 成都 610039)

摘要: 在全局摩擦测量中,薄油膜技术可以很好地表征表面摩擦的分布情况。用特定波长的紫外线照射添加了荧光显色分子的不同厚度的油膜,油膜将发出不同的亮度。利用该原理通过检测受激发的荧光油膜灰度值可解算出相应油膜的厚度。本次采用BP神经网络及极限学习机(Extreme learning machine, ELM)神经网络搭建模型完成了荧光油膜厚度与灰度关系的预测,运用Hopfield神经网络完成了相应参数的辨识。实验表明,ELM神经网络模型、BP神经网络模型及插值法模型的预测误差分别为5.150%、5.485%和5.935%。通过Hopfield神经网络辨识,光源功率、光距和曝光系数等影响因素的参数误差率控制在1%左右,达到实际工程运用的要求。与传统插值法相比,通过神经网络可获得更高的精度,为荧光油膜灰度与厚度研究提供了一种可行的方法。

关键词: 神经网络; 荧光油膜; 数据预测; 参数辨识

中图分类号: V19

文献标志码: A

文章编号: 1005-2615(2021)03-0470-07

Fluorescence Oil Film Thickness and Gray Level Identification Based on Neural Network

QIAN Hongjiang, DONG Xiucheng, XU Yeting, JIANG Jinyang, CHEN Guifang

(College of Electrical and Electronic Information, Xihua University, Chengdu 610039, China)

Abstract: In global friction measurement, thin oil film technique can well represent the distribution of surface friction. Irradiated with ultraviolet light of a specific wavelength, the oil film with different thickness of the fluorescent color molecules will emit different brightness. Using this principle, the thickness of the oil film can be calculated by detecting the gray value of the excited fluorescent oil film. In this paper, BP neural network and extreme learning machine (ELM) neural network are used to build models to complete the prediction of the relationship between the fluorescence oil film thickness and gray level, and Hopfield neural network is used to complete the identification of the corresponding parameters. The experimental results show that the prediction errors of ELM neural network model, BP neural network model and interpolation model are 5.150%, 5.485% and 5.935%, respectively. Through Hopfield neural network identification, the parameter error rates of the influence factors such as light source power, optical distance and exposure coefficient are controlled at about 1%, which meets the requirements of practical engineering application. Compared with the traditional interpolation method, the higher precision can be obtained by using the neural network, which provides a feasible method for the study of the gray and thickness of the fluorescent oil film.

Key words: neural network; fluorescent oil film; data forecasting; system identification

基金项目: 国家自然科学基金(11872069)资助项目;四川省科技厅重点(2018JY0463)资助项目;教育部“春晖计划”科研(Z2017076)资助项目;四川省高校科研创新团队——机器视觉与智能控制(18TD0024)资助项目;四威高科-西华大学产学研联合实验室(2016-YF04-00044-JH)资助项目;“西华杯”大学生创新创业(2020140)资助项目。

收稿日期: 2020-08-16; **修订日期:** 2020-12-12

通信作者: 董秀成,男,教授, E-mail: 956312605@qq.com。

引用格式: 钱泓江,董秀成,徐椰焱,等. 基于神经网络的荧光油膜厚度与灰度研究[J]. 南京航空航天大学学报, 2021, 53(3): 470-476. QIAN Hongjiang, DONG Xiucheng, XU Yeting, et al. Fluorescence oil film thickness and gray level identification based on neural network[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2021, 53(3): 470-476.

利用荧光油膜在激光照射下的显色反应,由荧光油膜灰度表征出油膜厚度这一关键因素,进而通过得到油膜厚度解算该处的摩阻分布。早在1977年,由Tanner^[1]提出通过油膜的激光干涉来测量表面摩阻,为摩阻的简化测量提供了坚实的基础。1993年,Monson等^[2]对油膜干涉法进行完善,油膜干涉理论发展成熟。而1999年,Brown等^[3]精确建立了在流体表面摩擦应力作用下的油膜演化方程,形象地表征出了油膜厚度随时间的变化率与其自身体积力、摩阻等因素的关系。对使用油膜进行全局摩阻的直接测量提供了可能性。在2008年,由Liu等^[4]提出用荧光油膜的灰度成像来表征油膜厚度这一新方法,建立了荧光油膜灰度与厚度的线性模型,该模型提供了理论基础,但还无法直接用于工程测量中。2011年,李鹏等^[5]将荧光油膜灰度与厚度线性方程引入相对表面剪切力模型,得出相对剪切力与成像平面灰度分布间的映射模型,为进行全局剪切力直接测量方法的研究和建立求解模型提供了有利的基础。2012年,李鹏^[6]提供了较为简便的数据采集方法,他通过用盖玻片和载玻片等高透光光学玻璃构成斜面进行荧光油膜灰度、厚度标定数据的采集,并初步验证了该线性关系的正确性。

在标定过程中,一般选择插值法或数据拟合的方式来处理数据使其平滑。传统的插值法或者数据拟合的方式在一般厚度(如毫米级)的条件下比较实用,但是在面对高精度(如微米级)时,则需要进行算法改进来达到精度要求,其改进的过程较为繁琐,也存在着一定的困难,而两者都有各自的缺点,比如数据拟合方式,由于该方法不一定通过所有数据点,在精度方面也存在一定的局限性;传统插值法在靠近数据两端点插值时,会存在“龙格现象”^[7],为了避免该问题,则采用分段插值形式。

本次采用神经网络对荧光油膜建立模型,针对神经网络对单输入、单输出模型有较好预测的特点,与传统插值法结果进行对比,验证了通过神经网络建立预测模型,有精度更高、预测更准确的优势。

1 实验理论分析

1.1 插值法原理

本次采用一元全区插值法进行荧光油膜灰度与厚度关系的模型建立,其数学模型表示为

$$z = \sum_{i=k}^{k+7} y_i \prod_{\substack{j=k \\ j \neq i}}^{k+7} [(t - x_j)/(x_i - x_j)] \quad (1)$$

式中: x_i 从属于 n 个结点, x_j 为不同于 x_i 的其他结点。通过7次拉格朗日插值计算求得插值点 t 处的函数近似值 z ,且插值点 t 在该 n 个结点中($n=8$)选

取满足

$$\begin{aligned} x_k < x_{k+1} < x_{k+2} < x_{k+3} < t < \\ x_{k+4} < x_{k+5} < x_{k+6} < x_{k+7} \end{aligned} \quad (2)$$

当插值点 t 位于区间外时,则属特殊情况,将取该端的 $n/2$ 个结点进行插值计算。

1.2 BP神经网络

BP神经网络为多层前馈网络,遵循误差反向传播训练机制,围绕梯度下降法中心思想展开,采用梯度搜索方法^[8],最终目标是使实际输出值与期望输出值的误差均方值达到最小。

BP网络结构如图1、2所示。图中 k 为迭代次数, $u(k)$ 及 $y(k)$ 为网络的输入。 $y(k)$ 为受控对象实际输出, $y_n(k)$ 为网络的输出。参考文献[9]的方法,将受控对象实际输出 $y(k)$ 及输入 $u(k)$ 的值作为整个网络的输入,并将系统输出与网络输出的误差目标函数作为神经网络调参标准,从而搭建网络。




图1 BP神经网络逼近的结构

Fig.1 Structure of BP neural network approximation




图2 用于逼近的BP网络

Fig.2 BP network for approximation

前向传播是网络的输出运算过程,隐层神经元的输入过程实际为所有输入的加权函数求和过程,令隐层神经个数为 q ,则有

$$x_j = \sum_{i=1}^q w_{ij} x_i \quad (3)$$

式中: w_{ij} 为网络层间连接权值; x_j 为限层结点; x_i 为输入层结点。

取 $y_n(k) = x_k$,则网络的输出与预想输出的误差为

$$e(k) = y(k) - y_n(k) \quad (4)$$

误差性能指标函数为

$$E = \frac{1}{2} e(k)^2 \quad (5)$$

逆向传播通过 δ 学习算法,对各层间的权值进

行调整。输出层与隐层的连接权值计算为

$$\Delta w_{j_2} = -\eta \frac{\partial E}{\partial w_{j_2}} = \eta \cdot e(k) \cdot \frac{\partial x_k}{\partial w_{j_2}} = \eta \cdot e(k) \cdot x'_j \quad (6)$$

式中 x'_j 为激发函数。 $k+1$ 时刻网络的权值为

$$w_{j_2}(k+1) = w_{j_2}(k) + \Delta w_{j_2} \quad (7)$$

隐层及输入层连接权值计算为

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = \eta \cdot e(k) \times \frac{\partial y_n}{\partial w_{ij}} \quad (8)$$

式(8)中的权值梯度为

$$\frac{\partial y_n}{\partial w_{ij}} = \frac{\partial y_n}{\partial x'_j} \times \frac{\partial x'_j}{\partial x_j} \times \frac{\partial x_j}{\partial w_{ij}} = w_{j_2} \times \frac{\partial x'_j}{\partial x_j} \cdot x_i = w_{j_2} \times x'_j(1-x'_j) \times x_i \quad (9)$$

$k+1$ 时刻网络权值为

$$w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij} \quad (10)$$

当上一轮的权值对本次权值产生了影响,就需加入约束因子 α , 此时的权值有

$$w_{j_2}(k+1) = w_{j_2}(k) + \Delta w_{j_2} + \alpha(w_{j_2}(k) - w_{j_2}(k-1)) \quad (11)$$

$$w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij} + \alpha(w_{ij}(k) - w_{ij}(k-1)) \quad (12)$$

式中: η 为学习速率, α 为约束因子, $\eta \in [0, 1]$, $\alpha \in [0, 1]$ 。雅可比矩阵(输入输出灵敏度信息)算法表达式为

$$\frac{\partial y(k)}{\partial u(k)} \approx \frac{\partial y_n(k)}{\partial u(k)} = \frac{\partial y_n(k)}{\partial x'_j} \times \frac{\partial x'_j}{\partial x_j} \times \frac{\partial x_j}{\partial x(1)} = \sum_j w_{j_2} x'_j(1-x'_j) w_{1j} \quad (13)$$

1.3 ELM 机器学习算法辨识原理

极限学习机(Extreme learning machine, ELM)神经网络较BP神经网络具有更高的精度和运算速度^[10]。令有 N 个任意样本 (X_i, T_i) , 其中 $X_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbb{R}^n$, $T_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \mathbb{R}^m$, 则对于有 P 个隐层结点的单隐层神经网络为

$$\sum_{i=1}^P \beta_i g(W_i \cdot X_j + b_i) = o_j \quad j=1, \dots, N \quad (14)$$

式中: $g(x)$ 为激活函数, W_i, β_i 分别为输入、输出权重, b_i 为偏置。该网络目标函数为

$$\sum_{j=1}^N \|o_j - t_j\| = 0 \quad (15)$$

则可得矩阵形式

$$H\beta = K \quad (16)$$

式中: H 为隐层输出, β 为输出权重, K 为期望值。训练过程中得到

$$\|H(\hat{W}_i, \hat{b}_i) \hat{\beta}_i - K\| = \min \|H(W_i, b_i) \beta_i - K\| \quad (17)$$

可得损失目标函数

$$E = \sum_{j=1}^N \left(\sum_{i=1}^P \beta_i g(W_i \cdot X_j + b_i) - t_j \right)^2 \quad (18)$$

1.4 Hopfield 神经网络参数辨识原理

假定用于参数辨识的约束函数与Hopfield网络约束函数相等,对其状态方程矩阵进行分解变换可得网络的权值矩阵 W 和神经元外输入矩阵 I , 将其代入网络状态方程式进行运算,收敛状态可得到较稳定的辨识参数结果。令一个系统的状态方程为

$$\dot{x} = Ax + Bu \quad (19)$$

式中: A, B 为待辨识的参数矩阵, 取 $P = [A_{11} \ A_{12} \ A_{21} \ A_{22} \ B_{21} \ B_{22}]^T$,

$x = [x_1 \ x_2]^T$, 令 x 为状态矢量, u 为控制输入, 则其参数辨识过程就是对向量 p 的求解过程。设可调系统为

$$\dot{x}_p = \theta_1 x + \theta_2 u \quad (20)$$

式中: $\theta_1 = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}$, $\theta_2 = \begin{bmatrix} b_1 \\ b_2 \end{bmatrix}$, 取 $V =$

$[a_{11} \ a_{12} \ a_{21} \ a_{22} \ b_{21} \ b_{22}]^T$, 则可得到状态偏差方程

$$\dot{e} = (A - \theta_1)x + (B - \theta_2)u \quad (21)$$

定义基于状态偏差变化率的系统参数辨识函数为

$$E = \frac{1}{2} \dot{e}^T \dot{e} \quad (22)$$

$$\dot{e}^T \dot{e} = [\dot{x} - \theta_1 x - \theta_2 u]^T [\dot{x} - \theta_1 x - \theta_2 u] \quad (23)$$

$$E = \frac{1}{2} [\dot{x} - \theta_1 x - \theta_2 u]^T [\dot{x} - \theta_1 x - \theta_2 u] \quad (24)$$

Hopfield网络约束函数趋于收敛的过程,就是估计矩阵 θ_1 和 θ_2 接近实际矩阵 A 和 B 的过程^[11]。网络第 i 个神经元的动态微分方程满足

$$\begin{cases} C_i \frac{du_i}{dt} = \sum_{j=1}^n w_{ij} v_j - \frac{u_i}{R_i} + I_i \\ v_i = g(u_i) \end{cases} \quad (25)$$

式中: $g(u_i) = \rho \frac{1 - e^{-\lambda u}}{1 + e^{-\lambda u}}$, $\rho > 0$; C_i 为调整系数; R_i 为网络收敛因子。

令 $R_i \rightarrow \infty$, 并取 $C_i = 1$, 则状态方程可以转换为

$$\frac{du_i}{dt} = \sum_{j=1}^n w_{ij} v_j + I_i \quad (26)$$

Hopfield网络的约束函数为

$$E_N = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} v_i v_j + \sum_{i=1}^n \frac{1}{R_i} \int_0^{v_i} g_i^{-1}(v) dv - \sum_{i=1}^n I_i v_i \quad (27)$$

由于 $R_i \rightarrow \infty$, 取Hopfield网络的输出等于待辨识参数, 则

$$E_N = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} v_i v_j - \sum_{i=1}^n I_i v_i \quad (28)$$

由式(26)和式(28)可以看出,有

$$\frac{\partial E_N}{\partial v_i} = -\sum_{j=1}^n w_{ij} v_j - I_i \quad (29)$$

取参数辨识的约束函数与 Hopfield 网络约束函数相等^[12-13],即 $E = E_N$,则由式(29)可得

$$\frac{\partial E}{\partial v_i} = -\sum_{j=1}^n w_{ij} v_j - I_i \quad (30)$$

通过 $E = E_1 + E_2$,可以换算为

$$\frac{dE}{dV} = \frac{dE_1}{dV} + \frac{dE_2}{dV} = -WV - I \quad (31)$$

$$\frac{dE}{dV} = \begin{bmatrix} \frac{\partial E_1}{\partial v_1} \\ \vdots \\ \frac{\partial E_1}{\partial v_6} \end{bmatrix} + \begin{bmatrix} \frac{\partial E_2}{\partial v_1} \\ \vdots \\ \frac{\partial E_2}{\partial v_6} \end{bmatrix} \quad (32)$$

通过式(32)解出权值 W 和 I 。

$$W = - \begin{bmatrix} x_1^2 & x_1 x_2 & 0 & 0 & x_1 u & 0 \\ x_2 x_1 & x_2^2 & 0 & 0 & x_2 u & 0 \\ 0 & 0 & x_1^2 & x_1 x_2 & 0 & x_1 u \\ 0 & 0 & x_2 x_1 & x_2^2 & 0 & x_2 u \\ ux_1 & ux_2 & 0 & 0 & u^2 & 0 \\ 0 & 0 & ux_1 & ux_2 & 0 & u^2 \end{bmatrix} \quad (33)$$

$$I = [x_1 \dot{x}_1 \quad x_2 \dot{x}_1 \quad x_1 \dot{x}_2 \quad x_2 \dot{x}_2 \quad u \dot{x}_1 \quad u \dot{x}_2]^T \quad (34)$$

将式(33,34)的 W 和 I 代入式(26),可得到稳定的 u_i ,最终辨识结果的输出为

$$F = g(u_1) \quad G = g(u_2) \quad (35)$$

2 实验结果与讨论

2.1 荧光油膜标定过程

荧光油膜的标定过程是一个数据实时采集的过程,本次通过搭建载玻片斜面的方法进行油膜灰

度与厚度相关信息的采集^[6],为了方便像素点的读取和像素单位的转换,对相机采集的荧光油膜灰度图进行了网格化处理,如图3、4所示。图4中间的红色线条则表示本次的荧光油膜灰度与厚度数据采集部分,且该网格 x 、 y 轴像素间隔均为 16 像素。




图3 荧光油膜灰度图

Fig.3 Grayscale of fluorescent oil film




图4 油膜网格图

Fig.4 Oil film grid

由盖破片和载玻片构成的斜面所采集的数据并不是直接为荧光油膜灰度与厚度的关系数据,而是灰度与横坐标 x 长度的关系,还需进行三角变换处理,如图5所示。可以得到

$$h = x \cdot \tan k \quad (36)$$

采集的初始数据经几何变换处理,如表1、2所示。




图5 斜面三角变换

Fig.5 Transformation of slope trigonometric

表1 荧光油膜灰度及厚度初始数据

Table 1 Initial grayscale and thickness of fluorescence oil film										mm
序号	1	2	3	4	5	6	7	8	9	10
油膜灰度值	32	34	36	40	41	44	47	52	54	57
油膜厚度值	0.000 00	0.005 53	0.006 64	0.007 14	0.010 51	0.014 29	0.021 43	0.026 55	0.028 57	0.033 19
序号	11	12	13	14	15	16	17	18	19	20
油膜灰度值	59	62	65	67	71	72	74	77	80	82
油膜厚度值	0.038 16	0.042 68	0.049 23	0.050 01	0.062 50	0.063 05	0.071 44	0.078 58	0.096 79	0.100 01
序号	21	22	23	24	25	26	27	28	29	30
油膜灰度值	84	86	88	90	92	93	95	97	99	100
油膜厚度值	0.114 3	0.128 59	0.148 78	0.157 16	0.171 46	0.185 73	0.200 02	0.274 89	0.285 74	0.300 03

2.2 神经网络预测

2.2.1 BP神经网络预测

将标定实验得到荧光油膜灰度与厚度初始数

据(表1)作为神经网络的训练数据来源,神经网络设置的结构为1-4-4-1-1,网络的初始权值取随机值,其训练过程如图6所示。网络的训练次数为

表2 荧光油膜灰度-厚度测试数据

Table 2 Test data of grayscale and of thickness of fluorescence oil film

序号	1	2	3	4	5	6	7	8	9	10
油膜灰度值	33	35	43	58	68	79	85	87	96	101
油膜厚度值	0.003 87	0.006 08	0.012 72	0.035 95	0.057 15	0.085 72	0.121 44	0.142 87	0.228 60	0.347 35

500次,训练的神经网络、结果误差图分别如图7、8所示,实验中可以通过不断调整训练次数、最小误差以及权值等参数来使神经网络模型达到最优值。




图6 训练过程图

Fig.6 Training process diagram




图7 神经网络训练

Fig.7 Neural network training




图8 误差曲线

Fig.8 Error curves

由表3中的数据可以直观看出,ELM神经网络的误差低达5.150%,而传统插值法的误差最大,

将训练好的模型通过表2中的测试数据来进行预测,其预测结果如图9所示。




图9 BP神经网络预测结果

Fig.9 Prediction results of BP neural network

2.2.2 ELM神经网络预测

ELM网络较BP网络具有运算速度快的优势,且精度较高,训练模型的预测结果如图10所示。




图10 ELM神经网络预测结果

Fig.10 Prediction results of ELM neural network

2.2.3 对比分析

绘制BP神经网络、ELM网络及传统插值法预测曲线,如图11所示,然后将预测值与真实荧光油膜厚度值进行比较便可以得到预测误差,分析神经网络的预测精度。各算法预测数据结果如表3所示。

为5.935%,故通过神经网络建立预测模型具有一定的优势,且无需分析模型理论结构;与此同时,BP神经网络的误差为5.485%,相较ELM网络的




图 11 数据预测对比

Fig.11 Comparison of data prediction

误差较高,故 ELM 神经网络在模型预测方面比 BP 神经网络占据一定优势,且运算速度快;经实验分析,通过神经网络建立预测模型,较传统插值法的精度有一定的提高。

2.3 Hopfield 神经网络参数辨识

Hopfield 神经网络进行模型的参数辨识,需要根据经验公式或者手册给出初定的参数值^[13]。引用 Liu^[4]提出的数学模型,有

$$I_{(x,y)} = aI_{ex(x,y)}h_{(x,y)} \quad (37)$$

式中: $I_{(x,y)}$ 为荧光亮度(灰度值); $I_{ex(x,y)}$ 为初始光强; $h_{(x,y)}$ 为荧光油膜的厚度; a 为荧光效率等参数。因为影响油膜灰度值的因素不止油膜本身的厚度因素,还有周围环境因素以及油膜的自身特性,如浓度,所以对该线性模型做变换,可以得到

$$h = (n_1 + n_2 + n_3 + \dots)I + (m_1 + m_2 + \dots) \quad (38)$$

因影响因素可能为非线性系统和常数,所以 n_i, m_j 系数定义为影响因素的权重系数,根据经验

式,可以得到假定影响因素参数,如表 4 所示。

表 4 影响因素的假定权重参数值
Table 4 Assumed weight parameter values of influencing factors

影响因素	符号	类型	假定权重初始值
功率	W	非线性	0.13
光距	R	非线性	0.21
曝光系数	T	常数	33.3

通过 Hopfield 神经网络参数辨识,可得以下辨识结果,如图 12~14 所示。




图 12 紫外光源功率参数辨识

Fig.12 Power parameter identification of UV light source




图 13 紫外光源距离参数辨识

Fig.13 Distance parameter identification of UV light source

通过 Hopfield 神经网络所辨识的结果参数如

表 3 神经网络与插值法预测数据及其误差比较

Table 3 Comparison of prediction data and error of neural network and interpolation method

测试灰度	真实厚度/mm	BP 预测厚度/mm	ELM 预测厚度/mm	插值预测厚度/mm	BP 误差/%	ELM 误差/%	插值误差/%
33	0.003 87	0.003 91	0.003 62	0.003 39	1.033	6.460	12.40
35	0.006 08	0.004 83	0.006 63	0.006 75	20.56	9.046	11.02
43	0.012 72	0.011 90	0.012 12	0.013 81	6.447	4.171	8.569
58	0.035 95	0.034 52	0.035 54	0.035 67	3.978	1.140	0.779
68	0.057 15	0.054 71	0.053 29	0.053 59	4.270	6.750	6.229
79	0.085 72	0.088 16	0.090 43	0.092 02	2.846	5.495	7.350
85	0.121 44	0.117 21	0.118 99	0.120 90	3.483	2.070	0.445
87	0.142 87	0.140 96	0.131 86	0.139 26	1.337	7.706	2.527
96	0.228 60	0.240 36	0.233 49	0.233 67	2.783	2.139	2.218
101	0.347 35	0.319 17	0.324 68	0.320 23	8.113	6.527	7.808
平均误差/%	—	—	—	—	5.485	5.150	5.935




图14 曝光系数参数辨识

Fig.14 Identification of exposure coefficient parameters

表5所示。

表5 辨识后的参数值

Table 5 Parameter value after identification

影响因素	初始权重	辨识后的权重	误差百分比/%
功率	0.13	0.128 9	0.85
光距	0.21	0.207 8	1.05
曝光系数	33.3	33.129 6	0.51

通过 Hopfield 神经网络进行参数辨识,能够很好地找出功率、光距和曝光系数等参数对荧光油膜灰度成像的影响程度,且辨识结果误差范围在1%左右,达到实际工程应用的标准。

3 结 论

经过实验分析论证,ELM神经网络模型、BP神经网络模型及插值法模型的预测误差分别为5.150%、5.485%和5.935%。通过神经网络搭建模型较传统插值法精度有所提高;而ELM神经网络具备比BP神经网络运算速度快、精度更高的优势。利用Hopfield神经网络进行参数辨识,其辨识得到参数的误差均控制在1%左右,后续可以继续调整Hopfield神经网络的参数,使误差率达到期望的效果。与传统插值法进行对比,利用神经网络搭建模型可以获得更高的精度,为后续荧光油膜灰度与厚度研究提供了一种可行的方法。

References:

[1] TANNER L. A skin friction meter, using the viscosity balance principle, suitable for use with flat/curved metal surfaces[J]. *Phys E: Scientific Instr*, 1977, 10: 278-284.

[2] MONSON D J, MATREE G G. Boundary-layer transition and global skin friction measurement with an oil-fringe imaging technique[J]. *Society of Automotive Engineers*, 1993, 102: 1829-1843.

[3] BROWN J L, NAUGHTON J W. The thin oil film equation[M]. Washington DC: NASA_AMES Research Center, 1999.

[4] LIU Tianshu, MONTEFORT J. Global luminescent oil-friction meter[J]. *AIAA Journal*, 2008, 46(2):

476-485.

- [5] 李鹏,明晓.风力机叶片的全局表面摩擦力测量的荧光油膜法[J].*南京航空航天大学学报*,2011,43(5): 581-585.
- LI Peng, MING Xiao. Fluorescent oil film method for global surface friction measurement of wind turbine blades[J]. *Journal of Nanjing University of Aeronautics & Astronautics*, 2011,43(5): 581-585.
- [6] 李鹏.全局表面摩擦应力直接测量技术研究[D].南京:南京航空航天大学,2012.
- LI Peng. Research on direct measurement technology of global surface friction stress[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2012.
- [7] 张雨浓,李名鸣,陈锦浩,等.龙格现象难题破解之系数与阶次双确定方法[J].*计算机工程与应用*,2013,49(3): 44-49.
- ZHANG Yunong, LI Mingming, CHEN Jinhao, et al. Double determination of coefficient and order for solving the Runge problem[J]. *Computer Science and Technology*, 2013,49(3): 44-49.
- [8] 刘冰心,王宁,张冬.基于BP神经网络的智能电网配电系统改进算法的研究[J].*现代电子技术*,2012,35(21): 143-144,148.
- LIU Bingxin, WANG Ning, ZHANG Dong. Research on improved algorithm of smart grid distribution system based on BP neural network[J]. *Modern Electronic Technology*, 2012, 35(21): 143-144,148.
- [9] 霍冠良,宁志华.基于BP神经网络的含褶皱复合材料强度预测[J].*南京航空航天大学学报*,2020,52(3): 460-467.
- HUO Guanliang, NING Zhihua. BP neural network for strength prediction of folded composites[J]. *Journal of Nanjing University of Aeronautics & Astronautics*,2020,52(3): 460-467.
- [10] ZHAI J, SHAO Q, WANG X. Architecture selection of ELM networks based on sensitivity of hidden nodes[J]. *Neural Processing Letters*, 2016, 44(2): 471-489.
- [11] 卓新建,章祥荪,徐宗本.关于Hopfield-型神经网络收敛性和求能量函数极小解的可靠性的研究[J].*系统科学与数学*,2001(2): 152-162.
- ZHUO Xinjian, ZHANG Xiangsun, XU Zongben. Research on convergence of Hopfield-type neural networks and reliability of minimum solutions of energy functions[J]. *Systems Science and Mathematics*, 2001(2): 152-162.
- [12] 章毅,周明天,王平安.关于神经网络的能量函数[J].*计算机研究与发展*,1999,36(7): 794-799.
- ZHANG Yi, ZHOU Mingtian, WANG Pingan. On the energy function of neural networks[J]. *Computer Research and Development*, 1999, 36(7): 794-799.
- [13] 郎世城.基于Hopfield神经网络的船舶电网故障诊断研究[D].重庆:重庆交通大学,2019.
- LANG Shicheng. Research on ship power grid fault diagnosis based on Hopfield neural network[D]. Chongqing: Chongqing Jiaotong University, 2019.
- [14] 孙跃,谭晶晶,唐春森.IGBT机理建模及其基于神经