

木材染色颜料配方预测模型

管雪梅¹, 郭明辉², 曹军¹

1. 东北林业大学机电工程学院, 哈尔滨 150040

2. 东北林业大学, 东北林业大学生物质材料科学与技术教育部重点实验室, 哈尔滨 150040

摘要 木材颜色是决定消费者印象的重要因素, 为了提高木制品的装饰作用和产品价值, 要对木材及木质材料进行着色。将计算机配色的方法用于木材染色中, 能加快染料配方生成的速度并将极大地提高工作效率、节约成本。本文研究了一种运用动态模糊神经网络建立的木材染色颜料配方预测模型, 所谓的“动态”是指模糊神经网络的网络结构不是预先设定的, 而是动态变化的, 即在学习开始前, 没有一条模糊规则, 其模糊规则在学习过程中逐渐增长而形成的。在论述建模方法的基础上, 对算法中的学习规则和参数确定进行了研究。模型为三输入三输出系统, 输出就确定为活性艳红 X-3B、活性黄 X-R、活性蓝 X-R 的浓度值, 输入为色差, 该模型预测相对误差为 0.52%, 训练时间为 128s, 结果比较令人满意。这种方法为木材染色配色提供了一种新的途径, 同时也为其理论在配色系统中的应用提供了新的思路, 具有一定的理论研究价值和实际应用价值。

关键词 计算机配色; 动态模糊神经网络; 预测模型

中图分类号 TP391.4

文献标志码 A

doi 10.3981/j.issn.1000-7857.2013.17.004

Predictive Model of Wood Dyeing Pigment Formula

GUAN Xuemei¹, GUO Minghui², CAO Jun¹

1. College of Mechanical and Electrical Engineering, Northeast Forestry University, Harbin 150040, China

2. Key Laboratory of Bio-based Material Science and Technology of Ministry of Education, Northeast Forestry University, Harbin 150040, China

Abstract Wood color is an important factor determining consumer first impression. In order to improve the decorative role and value of wood products, wood and wood materials need to be coloring. Applying computer color matching method to wood dyeing for speeding up the generation of dyeing formula would greatly improve work efficiency and save costs. A kind of prediction model for wood dyeing pigment formula is built by using Dynamic Fuzzy Neural Network (DFNN). The word "dynamic" refers to the fact that the network structure of fuzzy neural network does not preset, it changes dynamically; that is to say, there is no predeterminate fuzzy rule before learning, its fuzzy rules gradually increase and form during the learning process. The output is concentration values of reactive brilliant red X-3B, reactive yellow X-R, and reactive blue X-R, input is color difference, namely, ΔL , Δa , and Δb . The relative error of the prediction model is 0.52% and its training time is 128s. The results are comparatively satisfactory. The method provides a new way for wood dyeing and color matching and a new idea for the applications of its theories in color matching system; therefore it has certain value for theoretical research and practical applications.

Keywords computer color matching; DFNN; prediction model

0 引言

木材颜色是决定消费者印象的重要因素, 为了提高木制品的装饰作用和产品价值, 要对木材及木质材料进行着色^[1]。木材染色中的一个重要环节是配色, 其对染色后木材的颜色质量至关重要。在此过程中, 普遍以色彩合成与颜色混合理论为基础, 采用人工配色, 其对配色人员的素质要求高, 既费

时又难以适应现代工业生产的要求, 且成本高、准确性差^[2-3]。将计算机配色的方法用于木材染色中, 能加快染料配方生成的速度并将极大地提高工作效率、节约成本^[4]。

现有的计算机染色技术思想是利用库贝尔卡-芒克理论 (Kubelka-Munk) 对测得的颜色相关量进行计算, 对于木材染色这一涉及诸多影响因素的系统来说, 误差较大。近年来, 有

收稿日期: 2012-07-29; 修回日期: 2013-04-03

基金项目: 黑龙江省自然科学基金项目(C201127); 中央高校基本科研业务费专项资金项目(DL11BB24)

作者简介: 管雪梅, 讲师, 研究方向为木材科学与计算机仿真交叉学科, 电子信箱: gxm_maomao1980@163.com

学者提出利用神经网络等智能手段对这一复杂的系统进行研究,取得了一定的成果^[5-7]。本研究将动态模糊神经网络运用到木材染色计算机配色的系统中,取得了一定的成果。

1 动态模糊神经网络介绍

1.1 模型建立

所谓的“动态”是指模糊神经网络的网络结构不是预先设定的,而是动态变化的,即在学习开始前,没有一条模糊规则,其模糊规则在学习过程中逐渐增长而形成的。本文提出的动态模糊神经网络结构如图1所示。其本质意义是代表一




图1 动态模糊神经网络的结构

Fig. 1 Structure of dynamic fuzzy neural network

个基于TSK模型的模糊系统。在图中, x_1, x_2, \dots, x_r 是输入的语言变量, Y 是系统的输出, MF_j 是第*i*个输入变量的第*j*个隶属度函数, R_j 表示第*j*条模糊规则, N_j 是第*j*个归一化节点, ω_j 是第*j*个规则的结果参数或者连接权, u 指系统总的规则数。

各层的含义如下。

(1) 第1层:输入层。节点表示输入的语言变量,输入个数为*r*。

(2) 第2层:隶属函数层。每个节点分别表示一个高斯隶属函数:

$$\mu_j(x_i) = \exp\left[-\frac{(x_i - c_{ij})^2}{\sigma_j^2}\right] \quad i=1, 2, \dots; j=1, 2, \dots, u \quad (1)$$

式中, μ_j 是 x_i 的第*j*个隶属函数, c_{ij} 是该函数的中心, σ_j 是该函数的宽度, u 是隶属函数的个数,也表示系统总的规则数。

(3) 第3层:T-范数层。每个节点分别表示一个可能的模糊规则中的IF部分,反映了模糊规则数。第*j*个规则 R_j 的输出为

$$\Phi_j = \exp\left[-\frac{\sum_{i=1}^r (x_i - c_{ij})^2}{\sigma_j^2}\right] = \exp\left[-\frac{\|X - C_j\|^2}{\sigma_j^2}\right] \quad j=1, 2, \dots, u \quad (2)$$

$C_j = (c_{j1}, c_{j2}, \dots, c_{jr}) \in R^r$ 是第*j*个RBF单元的中心, $X = (x_1, x_2, \dots, x_r) \in R^r$ 。由此可见,该层的每个节点也表示一个RBF单元,即RBF节点数与模糊系统的规则数相等。

(4) 第4层:归一化层。将该层的每个节点称为*N*节点。易知*N*节点数与模糊规则数相等。第*j*个节点 N_j 的输出为

$$\varphi_j = \frac{\Phi_j}{\sum_{k=1}^u \Phi_k} \quad j=1, 2, \dots, u \quad (3)$$

(5) 第5层:输出层。该层节点表示DNFM的输出变量,可以是单输出,也可以多输出。输出为所有输入信号按权值的线性叠加(结构以一个输出为例,更多输出求解方法相同):

$$y(X) = \sum_{k=1}^u \omega_k \varphi_k \quad (4)$$

式中, ω_k 是THEN部分(结果参数)或者第*k*个规则的连接权值,表现为输入量的函数:

$$\omega_k = a_{k0} + a_{k1}x_1 + a_{k2}x_2 + \dots + a_{kr}x_r \quad k=1, 2, \dots, u \quad (5)$$

将式(2)、(3)、(5)代入式(4),可得DNFM的输出变量的详细表达式:

$$y(X) = \frac{\sum_{i=1}^u \left[(a_{i0} + a_{i1}x_1 + a_{i2}x_2 + \dots + a_{ir}x_r) \exp\left(-\frac{\|X - C_i\|^2}{\sigma_i^2}\right) \right]}{\sum_{i=1}^u \exp\left(-\frac{\|X - C_i\|^2}{\sigma_i^2}\right)} \quad (6)$$

1.2 DNFM的学习算法

1.2.1 模糊规则的确定

本文采用分级学习的思想^[8-10],根据DNFM的输出误差 e_i 和高斯函数的覆盖范围 d_{\min} 确定是否产生新规则。对于第*i*个观测数据 (X_i, t_i) , X_i 为DNFM的输入向量, t_i 为期望输出,定义输出误差:

$$\|e_i\| = \|t_i - y_i\| \quad (7)$$

其中 y_i 为式(6)计算的DNFM当前结构下的全部输出。若 $\|e_i\| > k_e$,则考虑增加一条新规则。 k_e 为预先设定的误差指数。

定义覆盖范围为

$$d_i(j) = \|X_i - C_j\| \quad (8)$$

$$d_{\min} = \operatorname{argmin}(d_i(j)) \quad (9)$$

式中, C_j 为当前所有RBF单元的中心向量。若 $d_{\min} > k_d$,则考虑增加一条新规则。 k_d 为预先设定的覆盖范围的有效半径。基于单调递减函数,逐渐减少每个RBF单元的误差指数和有效半径,预设参数 k_e 和 k_d 为

$$k_e = \max[e_{\max} \cdot \beta^i, e_{\min}] \quad (10)$$

$$k_d = \max[d_{\max} \cdot \gamma^i, d_{\min}] \quad (11)$$

式中 e_{\max} 和 e_{\min} 分别为最大误差和DNFM的期望精度, $0 < \lambda < 1$ 为收敛常数; d_{\max} 和 d_{\min} 分别为输入空间的最大、最小长度, $0 < \gamma < 1$ 为衰减常数。这些参数都在学习之前设定^[11-13]。

由于RBF单元的宽度对系统的泛化能力至关重要,宽度太小将不能全面划分输入空间,使系统泛化能力变差;宽度太大又容易陷入饱和,不能产生正确的输出。因此,产生新规则的初始参数按下式确定:

$$C_i = X_i \quad (12)$$

$$\sigma_i = k_s \cdot d_{\min} \quad (13)$$

式中, k_s 为预先设定的重叠因子,且第1条规则的宽度也是预先设定的常数。

综上,只有当 $\|e_i\| > k_e$ 且 $d_{\min} > k_d$ 同时成立时,才产生一条新规则。而对于其他 3 种可能出现的情况,只需调整现有 RBF 单元的宽度和 THEN 部分的权值。

1.2.2 权值的确定

根据上述模糊规则的确定方法,假定共有 n 个观测数据产生了 u 条模糊规则。那么,第 4 层的网络输出可表示为

$$\varphi = \begin{bmatrix} \varphi_{11} & \cdots & \varphi_{1n} \\ \vdots & & \vdots \\ \varphi_{u1} & \cdots & \varphi_{un} \end{bmatrix} \quad (14)$$

则对任意输入 $X_i(x_{1j}, x_{2j}, \dots, x_{nj})$,DNFM 的输出式 (4)可表示为

$$Y = W \times \Psi \quad (15)$$

$$W = (a_{10} \cdots a_{1n} \quad a_{11} \cdots a_{1n} \quad \cdots \quad a_{1r} \cdots a_{1r}) \quad (16)$$

$$\Psi = \begin{bmatrix} \varphi_{11} & \cdots & \varphi_{1n} \\ \vdots & & \vdots \\ \varphi_{u1} & \cdots & \varphi_{un} \\ \varphi_{11} \cdot x_{11} & \cdots & \varphi_{1n} \cdot x_{1n} \\ \vdots & & \vdots \\ \varphi_{u1} \cdot x_{11} & \cdots & \varphi_{un} \cdot x_{1n} \\ \vdots & & \vdots \\ \varphi_{11} \cdot x_{r1} & \cdots & \varphi_{1n} \cdot x_{rm} \\ \vdots & & \vdots \\ \varphi_{u1} \cdot x_{r1} & \cdots & \varphi_{un} \cdot x_{rm} \end{bmatrix} \quad (17)$$

若 DNFM 的理想输出为 $T = (t_1, t_2, \dots, t_n) \in R^n$, 则可采用线性最小二乘法逼近一个最优的权值向量 $W^* \in R^{(r+1) \times n}$, 使误差能量最小。这个最优的权值向量由下式确定:

$$W^* = T(\Psi^T \Psi)^{-1} \Psi^T \quad (18)$$

2 木材染色颜料配方预测模型建立

本研究试材取自黑龙江哈尔滨的杨木单板,厚 0.6mm, 长为 100mm×50mm。染料采用活性艳红 X-3B、活性黄 X-R、活性蓝 X-R, 渗透剂采用 JFC, 采用食盐 (NaCl) 作为均染剂、促染剂, 固色剂为纯碱 (Na₂CO₃), 蒸馏水。在颜色空间的选择上, 本研究采用 Lab 空间作为研究对象。

使用全自动分光光度计分别测量染色前的杨木单板和使用活性艳红、活性黄、活性蓝 3 种染料分别染色处理后的杨木单板的三刺激值, 并计算差值 $\Delta L, \Delta a, \Delta b$, 作为输入, 以染色配方作为输出, 利用动态模糊神经网络建立配方预测模型。

2.1 木材染色中的配色过程

对于木材染色而言, 人们更重视颜色的差别, 而不是色素的差别, 事先测量要染成的单板的颜色 (一般为珍贵材), 然后测得染色材 (杨木单板) 的颜色, 具体的过程如图 2 所示。计算色差, 色差的计算公式为

$$\Delta a = a_i - a \quad \Delta b = b_i - b \quad \Delta L = L_i - L \quad (19)$$

2.2 配色模型的建立

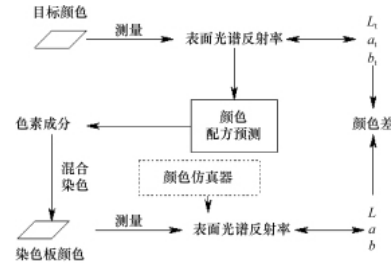


图 2 木材染色的配色过程

Fig. 2 Color matching process for wood dyeing

因为染料事先选好, 那么输出就确定为活性艳红 X-3B、活性黄 X-R、活性蓝 X-R 的浓度值, 输入为色差, 即上边的 $\Delta L, \Delta a, \Delta b$, 那么建立的配色模型如图 3 所示。

2.3 配色模型实现过程




图 3 木材染色配色模型

Fig. 3 Model for wood dyeing and color matching

(1) 数据的准备

将数据经过合适的预处理以后, 分成两组, 一组为训练数据, 另一组为校验数据, 两组数据之间互相独立。本研究将前期染色试验中的 280 组数据作为训练数据, 将试验中 20 组比较成功仿真珍贵材的配色数据作为校验数据。这一分类方法参考文献[14][15]经改进而确定。

(2) 网络参数的选择

DNFM 网络的参数设置并不复杂, 在本研究中最大训练次数为 6000, $d_{\min} = 2, d_{\max} = 40, e_{\min} = 0.5, e_{\max} = 50e_{\min}, \gamma = \left(\frac{d_{\min}}{d_{\max}}\right)^{2.5/200}$,

$$\beta = \left(\frac{e_{\min}}{e_{\max}}\right)^{1/100}, \sigma_{\bar{c}} = 35, k = 2.5, k_w = 1.4, k_c = 0.01。$$

2.4 仿真结果

训练中模糊规则不断变化, 其产生规则如图 4 所示, 训练中产生的均方根误差如图 5 所示, 输出误差和最后的输入结果如表 1 所示。

通过以上仿真结果计算, 对三拼色 (活性艳红、活性黄、




图 4 训练中模糊规则的产生

Fig. 4 Generation of fuzzy rules during the training




图5 训练中的均方根误差

Fig. 5 Root-mean-square errors durin the training

表 1 DNFM 网络输出结果

Table 1 DNFM network output results

样本序号	期望输出			实际输出			相对误差/%
	活性艳红	活性黄	活性蓝	活性艳红	活性黄	活性蓝	
1	0.0501	0.0500	0.0512	0.0502	0.0502	0.0508	0.49
2	0.0499	0.0499	0.1014	0.0501	0.0497	0.1018	0.78
3	0.0501	0.0495	0.1501	0.0500	0.0499	0.1506	0.46
4	0.0499	0.0506	0.2017	0.0501	0.0502	0.2009	0.65
5	0.0507	0.0500	0.2509	0.0510	0.0499	0.2503	0.54
6	0.1014	0.0508	0.2488	0.1009	0.0511	0.2501	0.65
7	0.1021	0.0513	0.3009	0.1017	0.0508	0.3011	0.58
8	0.1037	0.1018	0.0504	0.1021	0.1021	0.0501	0.79
9	0.1008	0.1001	0.1491	0.1005	0.1003	0.1501	0.58
10	0.1062	0.1008	0.2507	0.1057	0.1010	0.2513	0.67
11	0.2008	0.0522	0.2500	0.2012	0.0517	0.2504	0.43
12	0.1996	0.0523	0.3012	0.2004	0.0531	0.3009	0.28
13	0.2015	0.1008	0.0519	0.2014	0.1011	0.0523	0.37
14	0.1997	0.1016	0.1493	0.2001	0.1023	0.1502	0.53
15	0.1988	0.1011	0.2517	0.2013	0.1014	0.2495	0.45
16	0.3016	0.2520	0.1989	0.3002	0.2502	0.2003	0.38
17	0.3002	0.2506	0.2499	0.3007	0.2498	0.2501	0.73
18	0.3020	0.2502	0.3019	0.3017	0.2492	0.3023	0.63
19	0.3032	0.3019	0.0496	0.3021	0.3023	0.0501	0.48
20	0.3002	0.3014	0.2504	0.3001	0.3009	0.2497	0.65
平均相对误差/%							0.52

活性蓝)的仿真相对误差为 0.52%,是在可接受的范围之内,在设定学习训练次数为 6000 情况下,训练时间为 128s,结果比较令人满意。

3 结论

本文研究了一种用于木材染色计算机配色的模糊神经网络模型(DNFM),该网络集模糊推理、神经网络结构和学习算法于一体,构成基于神经网络的模糊推理系统。结果显示 DNFM 的输出能够与木材染色配色样本数据很好地匹配,经训练,DNFM 就能很好的逼近教师数据集合,误差较小,基本符合配色的要求,

这种方法为木材染色配色提供了一新的途径,同时也为

其理论在配色系统中的应用提供了新的思路,具有一定的理论研究价值和实际应用价值。

同时,此研究也存在一定的不足,例如个别样本存在误差较大,此模型只限于三拼色样本,而对于其他样本并不适用,没有考虑木材本身特性进行染色配方预测等问题,需要在今后的研究中进一步研究。

参考文献 (References)

- [1] 孙建. 中国木材工业发展现状、趋势和政策[J]. 中国人造板, 2010, 7(1): 3-7.
Sun Jian. China Wood-based Panels, 2010, 7(1): 3-7.
- [2] 陈玉和, 陆仁书, 李宗然. 泡桐单板染色因素对上染率的影响[J]. 木材工业, 2011, 14(1): 8-11.
Chen Yuhe, Lu Renshu, Li Zongran. China Wood Industry, 2011, 14(1): 8-11.
- [3] 段新芳, 孙芳利, 朱玮, 等. 壳聚糖处理对木材染色的助染效果及其机理的研究[J]. 林业科学, 2011, 39(6): 126-130.
Duan Xinfang, Sun fangli, Zhu Wei, et al. Scientia Silvae Sinicae, 2011, 39(6): 126-130.
- [4] 武林, 于志明. 计算机配色技术应用于木材染色初探 [J]. 中国人造板, 2010, 13(8): 17-20.
Wu Lin, Yu Zhiming. China Wood-based Panels, 2010, 13(8): 17-20.
- [5] Zhang J, Morri A J. Recurrent neuro-fuzzy networks for nonlinear process modeling[J]. IEEE Trans On Neural Networks, 2011, 10(2): 313-326.
- [6] Lee K M, Kwak D H, Kwang H L. Fuzzy inference neural network for fuzzy model tuning [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2010, 26(4): 637-645.
- [7] Kang H R. Kubelka-munk modeling of ink jet ink mixing [J]. Imaging Technology, 2010(17): 76-83.
- [8] Barrosa S A, Rutlegeb D N. Principal component transform partial least squares [C]// A Novel Method to Accelerate Cross-validation in PLS Regression Chemometrics and Intelligent Laboratory Systems, 2009: 245-255.
- [9] Wold S, Sjöström M, Eriksson L. PLS-regression: A basic tool of chemometrics[J]. Chemometrics and Intelligent Laboratory Systems, 2012, 58(4): 109-130.
- [10] Geladi P, Heman W. The father of PLS. chemometrics and intelligent [J]. Laboratory Systems, 2009, 15(1): 7-8.
- [11] Baglio S, Graziani S, Pitrone N. Intelligent measuring systems for distance estimation based on fuzzy data fusion[C]// Instrumentation and Measurement Technology Conference, IMTC-96. Conference Proceedings. Quality Measurements: The Indispensable Bridge between Theory and Reality, IEEE, 1996: 1286-1288.
- [12] Cao S G, Rees N W. Analysis and design for a class of complex control systems Part I: Fuzzy modeling and identification [J]. Automatica, 2009, 33(11): 1017-1028.
- [13] Hecht-Nielsen, Pruitt W O, Aboukhaled A, et al. Crop water requirements[M]. Rome: Irrigation and Drainage Paper Press, 2009.
- [14] Li Y, Rad A B, Peng W. An enhanced training algorithm for multilayer neural networks based on reference out put of hiddenlayer[J]. Neural Computing & Apvlication, 2010, 27(8): 218-225.
- [15] Jackon I R H. Convergence properties of radial basis functions [J]. Constructive Approximation, 2008, 27(4): 243-264.

(责任编辑 岳臣)