

# 基于改进 PSO 神经网络的 微米木纤维切削参数优化\*

齐红<sup>1</sup>, 任洪娥<sup>1</sup>, 贾鹤鸣<sup>2</sup>, 袁世庆<sup>1</sup>

- (1. 东北林业大学信息与计算机工程学院, 中国 哈尔滨 150040;  
2. 东北林业大学机电工程学院, 中国 哈尔滨 150040)

**摘要:** 针对使用传统加工技术切削后的工件无法达到精密要求的问题, 为了从工艺流程角度提升微米木纤维的加工精度和切削效果, 提出了一种基于改进粒子群算法和 BP 神经网络的优化算法, 以实现微米木纤维的精密切削加工。采用误差反向传播算法实现切削参数间复杂关系的最佳结构选择, 通过改进的粒子群优化算法 (PSO) 解决了 BP 网络自身的局部极小值收敛的缺陷, 给出了科学合理的切削参数输出。通过不同树种的微米木纤维切削参数仿真优化实验, 验证了算法的准确性、训练精度和有效性。研究表明: 提出的改进优化算法可以预测出待加工木材的切削参数, 且具有较高的训练精度。

**关键词:** 木纤维切削; 切削参数优化; BP 神经网络; 粒子群优化算法

**中图分类号:** U445.72    **文献标志码:** A    **文章编号:** 0529-6579 (2018) 02-0116-07

## Optimization study of cutting parameters of micron wood fiber based on improved PSO neural network

QI Hong<sup>1</sup>, REN Honge<sup>1</sup>, JIA Heming<sup>2</sup>, YUAN Shiqing<sup>1</sup>

- (1. Information and Computer Engineering College, Northeast Forestry University,  
Harbin 150040, China;  
2. College of Mechanical and Electrical Engineering, Northeast Forestry University,  
Harbin 150040, China)

**Abstract:** In order to improve the process of micron wood fiber cutting, an improved particle swarm algorithm and BP neural network based on the combination of optimization algorithm is proposed to achieve the precision machining of micron wood fiber. The error back propagation algorithm is used to achieve the best structure selection of the complex relationship between cutting parameters. The improved particle swarm optimization algorithm (PSO) solves the defect of local minimum convergence of BP network, and gives a scientific and reasonable output of cutting parameters. The precision and effectiveness of the precision training of the algorithm are verified by the simulation and optimization experiments of the cutting parameters of different tree species. The research shows that the improved optimization algorithm proposed in this paper can predict the cutting parameters of the wood to be processed and has a high training precision.

\* 收稿日期: 2017-05-30

基金项目: 国家自然科学基金 (31370566); 黑龙江省自然科学基金重点项目 (ZD201203); 黑龙江省研究生教育创新工程项目 (JGXM-HLJ-2016014)

作者简介: 齐红 (1978 年生), 女; 研究方向: 林业信息工程; E-mail: qhown@sohu.com

通信作者: 任洪娥 (1962 年生), 女; 研究方向: 数字图像处理; E-mail: renhonge163@163.com

**Key words:** wood fiber cutting; cutting parameter optimization; BP neural network; particle swarm optimization algorithm

随着微米木纤维的应用领域不断地扩大,其加工精度要求也越来越高,推动了加工方式由传统粗犷型向现代精密控制型的转化。木材切削是一个多方面因素综合作用的复杂过程,而且微米级加工属于微观加工的范畴。对于这样的微米级的加工过程来说,切削参数的选择至关重要<sup>[1-2]</sup>。

长期以来,日本名古屋大学的木村志郎教授都在致力于微米木纤维加工工艺的研究,并且已经利用切削的方式成功得到微米木纤维。德国 Hombak 公司拥有先进的微米纤维加工技术,他们设计的刀具设备结构非常复杂,可以加工出微米薄片。德国的 Maier 公司也成功地将残余废旧木材加工成厚度达到微米级别的刨花和纤维。德国的微米木纤维加工工艺代表了世界最先进水平,相关的工业生产设备完全实现了数控化与自动化功能。2013 年,国内第一条微米木纤维加工生产线在浙江慈溪落成。它根据木纤维的化学结构特点,利用高温高压下的物理化学反应制备微米木纤维<sup>[3]</sup>。东北林业大学林业与木工机械工程技术中心设计出了木纤维精密型切削加工实验设备,并已成功加工出纤薄木纤维<sup>[4]</sup>。但国内外相关研究多是对微米木纤维的制备方法和实验设备方面进行研究,没有针对切削过程进行优化,无法从工艺流程角度提升微米木纤维的加工精度和切削效果。

本文将人工神经网络理论的误差反向传播算法(BP)应用到微米木纤维切削参数的智能选择过程中。BP 神经网络对非线性函数的拟合能力很强大,经过对不同树种切削样本的训练学习,BP 网络能够自动迭代获得准确反映切削参数间复杂关系的最佳结构(连接权和偏置值),训练好的网络会对新的输入给出科学合理的切削参数输出。同时,针对 BP 网络自身的局部极小值收敛的缺陷,采用改进的粒子群算法对 BP 神经网络中的权值和阈值进行优化,得到具有最小网络误差的 BP 神经网络结构,以提高网络的学习效率和收敛速度。最后,利用仿真实验验证了改进算法的优越性和有效性,达到了从工艺流程角度提升微米木纤维的加工精度和切削效果的目的。

## 1 BP 神经网络

### 1.1 BP 神经网络中误差的反向传播过程原理

BP 神经网络<sup>[5-6]</sup>是一种按照误差逆向传播算

法训练的多层前馈神经网络,如图 1 所示。对于基本的 BP 神经网络,常采用 S 型函数作为激励函数,如公式(1):

$$\varphi(x) = \psi(x) = f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

式中, $\varphi$  表示隐含层中的激励函数; $\psi$  表示输出层的激励函数。




图 1 BP 网络结构

Fig. 1 BP network structure

### 1.2 误差的反向传播过程

在 BP 神经网络中误差的反向传播过程为:首先由输出层开始逐层计算各层神经元的输出误差,然后根据误差梯度下降法来调节各层的权值和阈值,使修改后的网络的最终输出能接近期望值。设样本  $p$  的二次型误差准则函数为  $E_p$ :

$$E_p = \frac{1}{2} \sum_{k=1}^L (T_k - o_k)^2 \quad (2)$$

式中, $o_k$  表示第  $k$  个节点的输出; $T_k$  表示第  $k$  个节点的预测输出。则系统对所有训练样本的总误差准则函数为:

$$E = \frac{1}{2P} \sum_{p=1}^P \sum_{k=1}^L (T_k^p - o_k^p)^2 \quad (3)$$

式中, $o_k^p$  表示  $p$  第个样本第  $k$  个节点的输出; $T_k^p$  表示第  $p$  个样本第  $k$  个节点的预测输出。根据上述提到的误差梯度下降法依次修正输出层权值的修正量  $\Delta w_k$  和隐含层权值的修正量  $\Delta v_j$ ,权值的调整量与误差的梯度下降成正比,即:

$$\begin{cases} \Delta w_k = -\eta \frac{\partial E}{\partial w_k} \\ \Delta v_j = -\eta \frac{\partial E}{\partial v_j} \end{cases} \quad (4)$$

式中, 负号表示梯度下降。输出层权值调整公式:

$$\begin{aligned} \Delta w_{ki} &= -\eta \frac{\partial E}{\partial w_{ki}} = -\eta \frac{\partial E}{\partial \text{net}_k} \frac{\partial \text{net}_k}{\partial w_{ki}} = \\ &= -\eta \frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial \text{net}_k} \frac{\partial \text{net}_k}{\partial w_{ki}} \end{aligned} \quad (5)$$

隐含层权值调整公式:

$$\begin{aligned} \Delta v_{ij} &= -\eta \frac{\partial E}{\partial v_{ij}} = -\eta \frac{\partial E}{\partial \text{net}_i} \frac{\partial \text{net}_i}{\partial v_{ij}} = \\ &= -\eta \frac{\partial E}{\partial y_i} \frac{\partial y_i}{\partial \text{net}_i} \frac{\partial \text{net}_i}{\partial v_{ij}} \end{aligned} \quad (6)$$

因

$$\begin{cases} \frac{\partial \text{net}_k}{\partial w_{ki}} = y_i \\ \frac{\partial \text{net}_i}{\partial v_{ij}} = x_j \\ \frac{\partial E}{\partial o_k} = -(T_k - o_k) \\ \frac{\partial E}{\partial y_i} = -\sum_{k=1}^L (T_k - o_k) f'(\text{net}_k) w_{ki} \\ \frac{\partial o_k}{\partial \text{net}_k} = f'(\text{net}_k) = o_k(1 - o_k) \\ f'(\text{net}_i) = y_i(1 - y_i) \end{cases} \quad (7)$$

可得输出层权值调整量:

$$\Delta w_k = \eta o_k (T_k - o_k) (1 - o_k) y_i \quad (8)$$

隐含层权值调整量为:

$$\begin{aligned} \Delta v_j &= \eta \left( \sum_{i=1}^L (T_k - o_k) o_k (1 - o_k) w_k \right) \\ &= y_i (1 - y_i) x_j \end{aligned} \quad (9)$$

第  $N+1$  次输入样本时的权值为:

$$\begin{cases} w_k^{N+1} = w_k^N + \Delta w_k \\ v_j^{N+1} = v_j^N + \Delta v_j \end{cases} \quad (10)$$

BP 神经网络算法采用非线性规划中的最速梯度下降法, 按照误差函数的负梯度方向修改权值, 通过不断迭代求解误差函数的最小值。但是该算法也存在学习效率低, 收敛速度慢和易陷入局部极小值等缺点<sup>[7]</sup>。因此, 需要通过对 BP 神经网络参数进行优化, 使得到的结果趋于全局最优, 算法流程如图 2 所示。

## 2 PSO 算法优化 BP 网络的新方法

### 2.1 粒子群算法简介

粒子群优化 (particle swarm optimization, PSO) 算法是模拟鸟类觅食行为而实现复杂社会行为而设计的进化计算方法<sup>[8]</sup>, 该算法数学简化模型如下: 设在维搜索空间中, 存在一个含有  $M$  个粒子的群

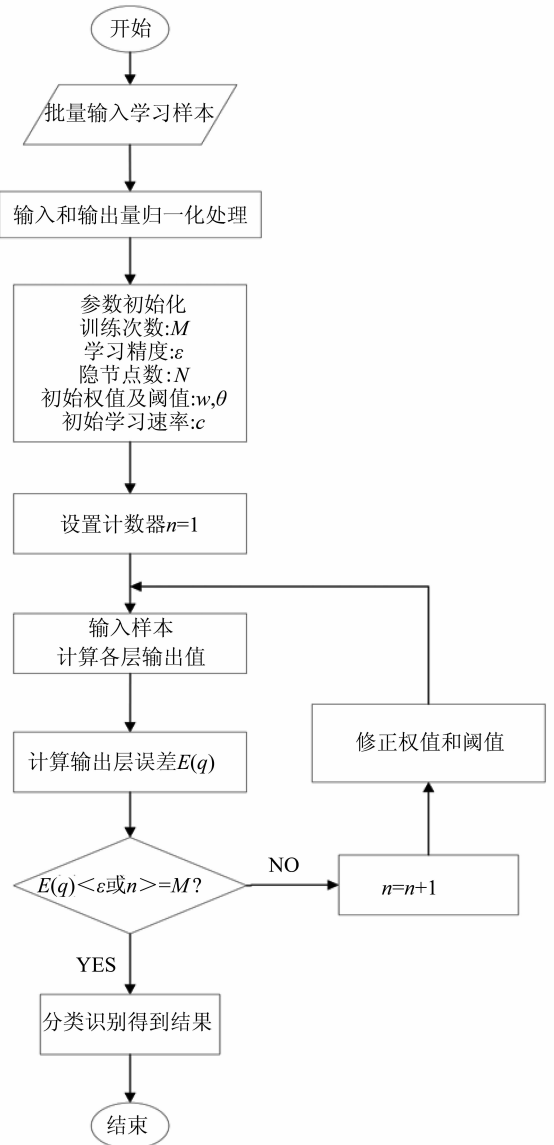


图 2 BP 算法程序流程图

Fig. 2 The topology structure of BP neural network

体, 其中每个粒子的空间位置均为优化问题的一个可能解, 并且该空间位置会根据自身经历和全局粒子信息而更新。设第  $i$  个粒子的空间位置为  $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{in})$ ,  $i = 1, 2, \dots, M$ 。将其代入全局寻优的目标函数并计算出相应的适应值可作为衡量  $\mathbf{X}_i$  的优劣。设第  $i$  个粒子所“飞行”的历史最佳位置为  $\mathbf{P}_i = (p_{i1}, p_{i2}, \dots, p_{in})$ ,  $i = 1, 2, \dots, M$ ; 在整个种群中, 存在一个位置最佳的粒子, 将其用  $\mathbf{P}_g$  表示。则群体中所有粒子经历过的历史最佳位置为  $\mathbf{P}_g = (p_{g1}, p_{g2}, \dots, p_{gn})$ ,  $g = 1, 2, \dots, M$ 。此外, 设  $i$  第个粒子具有的飞行速度  $\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{in})$ ,  $i = 1, 2, \dots, M$ 。其中, 每一个粒子第  $d$  维 ( $1 \leq d \leq n$ ) 的速度和位置采用式 (11) 表示。

$$\begin{cases} v_{id}^{(t+1)} = uv_{id}^{(t)} + c_1 r_1 (p_{id} - x_{id}^{(t)}) + c_2 r_2 (p_{gd} - x_{id}^{(t)}) \\ x_{id}^{(t+1)} = x_{id}^{(t)} + v_{id}^{(t+1)} \\ D_{\max} \geq v_{id}^{(t+1)} \geq -D_{\max} \end{cases} \quad (11)$$

式中,  $r_1, r_2$  为 0 到 1 之间的随机数;  $c_1, c_2$  为每个粒子与群体之间的学习因子<sup>[9]</sup>, 表示粒子的个体最优值和群体最佳粒子位置的吸引程度, 通常选取为 2;  $u$  为惯性权重, 用于调节算法的局部和全局寻优能力;  $D_{\max}$  为粒子每次“飞行”的最大速度。与其他优化算法相比, PSO 能够实现局部与全局的信息共享, 因此具有较佳的收敛性能和全局寻优能力, 并且其过程简单, 比遗传算法和进化算法更容易实现<sup>[10-14]</sup>。

## 2.2 基于改进的 PSO - BP 神经网络的切削参数优化方法

对于 BP 神经网络的隐含层节点数一般采用逐步构造法或者修剪法这类凑试法进行试验确定。由于此过程需要不断更改隐含层节点个数, 与之对应的初始权值和阈值也需改变, BP 神经网络的学习效率和收敛性会因此而受到影响。为了减小这种影响, 通过构造不同的神经网络结构, 对每个网络结构同时生成  $m$  个不同初始权值和阈值, 并采用粒子群对 BP 神经网络中的权值和阈值进行优化, 得到具有最小网络误差的 BP 神经网络结构。

设具有不同初始权值和阈值的网络  $T(1, 2, \dots, m)$ , 均采用式 (1) 至式 (11) 进行初次训练。然后将全部训练后的样本分为  $n_1$  个训练样本和  $n_2$  个检验样本, 按公式 (12) 计算得到训练误差  $E_1$  和检验误差  $E_2$  :

$$\begin{cases} E_1 = \frac{1}{n} \sum_{p_1=1}^{n_1} (O_{p_1} - T_{p_1})^2 \\ E_2 = \frac{1}{n} \sum_{p_2=1}^{n_2} (O_{p_2} - T_{p_2})^2 \end{cases} \quad (12)$$

其中:  $O_{p_1}$  和  $T_{p_1}$  分别为训练样本  $p_1$  的网络实际输出和期望输出;  $O_{p_2}$  和  $T_{p_2}$  分别为检验样本  $p_2$  的网络实际输出和期望输出。

将 PSO 算法的速度迭代公式 (11) 中的第一个等式改写为以下形式:

$$v_{id}^{(t+1)} - uv_{id}^{(t)} = c_1 r_1 (p_{id} - x_{id}^{(t)}) + c_2 r_2 (p_{gd} - x_{id}^{(t)}) \quad (13)$$

根据 (13) 式, 相邻两代粒子速度的改变量取决于粒子当前位置与其历史最佳位置和群体粒子历史最佳位置的变化。因此, 若把网络的权值视作 PSO 算法中粒子的速度, 则在网络训练过程中, 相

继两次权值的改变可视作粒子的速度的改变。因而, 类比公式 (12) 网络的权值改变量还可以按式 (13) - (14) 计算<sup>[15]</sup>。其中:

$$\begin{cases} \Delta w_{ki} = c_1 r_1 [w_{ki}(b) - w_{ki}] + \\ c_2 r_2 [w_{ki}(g) - w_{ki}] \\ \Delta w_{ij} = c'_1 r'_1 [w_{ij}(b) - w_{ij}] + \\ c'_2 r'_2 [w_{ij}(g) - w_{ij}] \end{cases} \quad (14)$$

式中,  $w_k(b)$  和  $w_j(b)$  分别为第  $T$  个神经网络历史上具有最小检验误差  $E_2$  时的隐含层与输出层的权值, 及输入层与隐含层的权值;  $w_k(g)$  和  $w_g(b)$  为所有神经网络中历史上具有最小检验误差  $E_2$  时的隐含层与输出层的权值, 及输入层与隐含层的权值;  $c_1, c_2$  和  $c'_1, c'_2$  为每个神经网络与所有神经网络之间的学习因子;  $r_1, r_2$  和  $r'_1, r'_2$  为 0 到 1 之间的随机数。在每一次训练过程中既要考虑到 BP 神经网络中梯度下降法的更新过程, 也要利用 PSO 算法寻优规则进行阈值更新, 从而得到具有最小检验误差的神经网络。将式 (14) 带入上述基本 BP 神经网络权值调整公式 (10) 得到基于 PSO 算法 BP 神经网络权值调整公式:

$$\begin{cases} w_i^{N+1} = w_i^N + \eta (T_k - o_k) y_i + \\ c_1 r_1 (w_i^{(b)} - w_i) + w_i(g) - w_i \\ v_j^{N+1} = v_j^N + \eta \left[ \sum_{k=1}^L (T_k - o_k) o_k (1 - o_k) w_k \right] \\ y_i (1 - y_i) x_j + c'_1 r'_1 (w_{ij}(b) - w_{ij}) + \\ c'_2 r'_2 (w_{ij}(g) - w_{ki}) \end{cases} \quad (15)$$

设置训练停止条件为: 当满足  $\max(E_1, E_2) \leq \varepsilon$  或者达到迭代上限时停止训练, 最终得到的权值和阈值为最终 BP 神经网络权值。

## 2.3 基于 PSO 优化 BP 神经网络的切削参数选择

将 PSO 优化的 BP 神经网络模型应用于木纤维切削参数智能选择, 需要根据实际问题进行 BP 神经网络设计和 PSO 算法参数设计。

切削参数的影响因素有: 气干密度、断面硬度、切削深度、机床进给范围、机床转速范围等。本文根据这些影响因素建立 PSO - BP 神经网络优化算法, 预测得到最佳的切削速度、进给速度和切削角度。本文根据实际影响因素的个数。确定输入层节点数为 9 个, 输出层节点数为 3 个。隐含层数量对神经网络的影响较大, 增加其数量时可以提高神经网络精度, 但同时也会增加训练复杂度和训练时间<sup>[16-17]</sup>。对于大多数 BP 神经网络均采用只有一个隐含层结构, 因此本文设隐含层数量为 1。

本文采用模型计算值与实验值的相关系数和百分误差进行模型质量评价以及模型预测能力比较<sup>[18]</sup>, 如公式 (16) 所示:

$$\left\{ \begin{aligned} E_p &= \frac{\left[ \frac{1}{n} \sum_{i=1}^n (Y_c - Y_i)^2 \right]^2}{Y_A} \\ R &= \frac{\sum_{i=1}^n (Y_c - Y_A)^2}{\left[ \sum_{i=1}^n (Y_c - Y_i)^2 + \sum_{i=1}^n (Y_c - Y_A)^2 \right]} \end{aligned} \right. \quad (16)$$

式中,  $Y_c$  和  $Y_i$  分别为模型计算值和实测值,  $Y_A$  为样本集和预测集实测值的平均值,  $n$  为样本集和预测值的样本数。运用上式对某一范围的隐含层节点数进行遍历, 找到满足相关系数最大和误差最小的隐含层节点数。试验得到当隐含层节点数为 15 时, 相关系数最大和误差最小。因此, 基于 BP 神经网络的切削参数智能选择结构图, 如图 3 所示。




图 3 基于 BP 神经网络的切削参数智能选择结构图

Fig. 3 Intelligent choice of cutting parameters structure map based on BP neural network

PSO 算法中速度更新公式的惯性权重具有平衡局部与全局搜索能力的作用。若  $u$  较小, 可以增加

收敛速度, 但容易陷入局部最优; 若  $u$  较大, 可得到趋于全局最优的解, 但迭代次数增加。为动态调整  $u$  的大小, 采用式 (17) 使惯性权重随迭代过程而逐渐变化:

$$u' = u_{\min} + \left( \frac{M_{\max} - M}{M_{\max}} \right) \times (u_{\max} - u_{\min}) \quad (17)$$

式中,  $M_{\max}$  为最大迭代次数;  $M$  为当前迭代次数;  $u_{\max}$  为最大惯性权重, 为 0.9;  $u_{\min}$  为最小惯性权重, 为 0.1;  $n$  为指数因子, 为 1.2。PSO 算法设置初始粒子个数为 100, 采用检验误差作为适应度函数, 并且当检验误差满足精度要求或者迭代次数达到预设最大值时, 训练结束并输出结果。

#### 2.4 基于 PSO - BP 神经网络的切削参数选择实验

采用以上 PSO - BP 神经网络结构, 将木材气干密度  $A_1$ 、顺纹抗压强度  $A_2$ 、抗弯强度  $A_3$ 、顺纹剪切强度  $A_4$ 、断面硬度  $A_5$ 、切削深度  $A_6$ 、刀具刃口圆角半径  $A_7$  作为输入参数, 将切削速度  $O_1$ 、进给速度  $O_2$  和切削角度  $O_3$  作为输出参数。根据文献 [4] 获取 14 种木材的网络训练样本和测试样本, 如表 1 所示 (部分节选)。由于数据具有不同的量级, 需先对数据进行归一化处理。随机选取 4 个样本作为检测样本, 其余的作为训练样本, 按照上述 PSO - BP 算法编写 MATLAB 代码, 检测结果如表 2 - 4 所示。

采用 BP 神经网络训练得到的结果与改进 PSO - BP 网络训练结果进行比较, 如表 5 所示。由表 5 可知, 采用改进后的 PSO - BP 神经网络对切削参数进行训练, 得出的结果与传统 BP 网络相比结果更为准确, 具有更高的预测精度。结合表 4 的数据, 可以保证输出参数的合理性; 另外从迭代次数上看, 针对 3 个基本参数改进的优化算法可以更快的完成预测训练, 更快的实现精确加工的切削目标。

表 1 微米木纤维切削加工实验数据

Table 1 Micron wood fiber cutting experimental data

样本	$A_1 /$ ( $g \cdot cm^{-3}$ )	$A_2 /$ (MPa)	$A_3 /$ (MPa)	$A_4 /$ (MPa)	$A_5 /$ (MPa)	$A_6 /$ $\mu m$	$A_7 /$ $\mu m$	$O_1 /$ ( $m \cdot s^{-1}$ )	$O_2 /$ ( $m \cdot s^{-1}$ )	$O_3$
水杉 2	0.342	29.6	54.6	3.8	24.9	40	5	23.84	0.097 5	24'
紫椴 1	0.458	33.8	63.6	7.8	20.6	90	5	22.76	0.017 1	26'
马尾松 2	0.592	62.5	111.2	7.7	50.7	60	10	22.84	0.011 4	27'
刺槐 1	0.792	53.9	126.8	13.1	68.5	80	10	21.68	0.014 5	29'

表 2 切削速度训练结果及误差

Table 2 Training results and error of cutting speed

$m \cdot s^{-1}$

样本	期望	实际	切削
	切削速度	切削速度	速度误差
水杉 1	23.56	23.531 1	-0.028 9
紫椴 1	22.76	22.768 9	-0.008 9
马尾松 2	22.84	22.815 9	-0.024 1
刺槐 1	21.68	21.681 1	0.001 1

表 3 进给速度训练结果及误差

Table 3 Feed speed training results and errors

$m \cdot s^{-1}$

样本	期望	实际	进给
	进给速度	进给速度	速度误差
水杉 1	$1.37 \times 10^{-2}$	$1.374 4 \times 10^{-2}$	$4.4 \times 10^{-5}$
紫椴 1	$1.71 \times 10^{-2}$	$1.701 9 \times 10^{-2}$	$-8.1 \times 10^{-5}$
马尾松 2	$1.14 \times 10^{-2}$	$1.144 1 \times 10^{-2}$	$4.1 \times 10^{-5}$
刺槐 1	$1.45 \times 10^{-2}$	$1.446 8 \times 10^{-2}$	$-3.2 \times 10^{-5}$

表 4 切削角度训练结果及误差

Table 4 Training results and error of cutting angle

样本	期望	实际	切削
	切削角度	切削角度	角度误差
水杉 2	25°20'	25°21'	1'
紫椴 1	26°45'	26°43'	2'
马尾松 2	27°05'	27°4'	1'
刺槐 1	29°0'	28°58'	2'

表 5 BP 和 PSO - BP 算法输出误差对比

Table 5 BP and PSO - BP algorithm output error comparison

$m \cdot s^{-1}$

网络模型	迭代次数	均方误差	训练样本各
			项输出平均误差
PSO - BP	15	$2.35 \times 10^{-4}$	①切削速度: 0.015 97
	13	$1.57 \times 10^{-5}$	②进给速度: $4.95 \times 10^{-5}$
	12	$1.62 \times 10^{-4}$	③切削角度: 1.5'
BP	49	$2.89 \times 10^{-3}$	①切削速度: 0.071 1
	81	$2.3 \times 10^{-3}$	②进给速度: $2.54 \times 10^{-4}$
	112	$4.75 \times 10^{-3}$	③切削角度: 14.85'

### 3 总 结

本文章提出了一种采用 PSO - BP 神经网络算法，并进行了微米木纤维切削参数的选择。主要结论如下：1) 对网络中隐含层节点数进行了最佳性能评估，选取最佳的节点数。隐含节点数为 15 时，相关系数最大，误差最小；2) 通过动态调整 PSO

算法中惯性权重来平衡全局与局部搜索能力；3) 以实验加工所得的数据作为训练样本，训练后的网络将以自学习的方式预测出待加工木材的切削参数。研究实验结果表明，该方法具有较高的训练精度，能够得到合理准确的切削参数。

### 参考文献：

[1] SARKAR A, PANDEY P. River water quality modelling using artificial neural network technique [J]. Aquatic Procedia, 2015, 4:1070 - 1077.

[2] LEE K Y, CHA Y T, PARK J H. Short - term load forecasting using an artificial neural network [J]. IEEE Transactions on Power Systems, 1992, 7(1):124 - 132.

[3] 宋爽. 微米木纤维切削加工参数智能选择方法研究 [D]. 哈尔滨:东北林业大学, 2015:21 - 35.

SONG S. Methods of micron wood fiber cutting parameters [D]. Herbin: Northeast Forestry University, 2015: 21 - 35.

[4] 杨春梅. 微米木纤维的形成机理及模拟加工 [D]. 哈尔滨:东北林业大学, 2003:24 - 36.

YANG C M. Formation mechanism and simulation processing of micron wood fiber [D]. Herbin: Northeast Forestry University, 2003:24 - 36.

[5] 马锐. 神经网络原理 [M]. 北京:机械工业出版社, 2014:24 - 33.

[6] LI J, CHENG J H, SHI J Y, et al. Brief introduction of back propagation (BP) neural network algorithm and its improvement [J]. 2012, 169: 553 - 558.

[7] GAO Q, JIN Y, HOU Y L, et al. Modeling and control for mine sweeping plough electro-hydraulic servo system of certain mine-clearing vehicle [J]. Journal of Central South University of Technology, 2012, 18 (3): 755 - 759.

[8] DA Y, XIURUN G. An improved PSO-based ANN with simulated annealing technique [J]. Neuro Computing, 2005, 63: 527 - 533.

[9] 潘峰. 粒子群优化算法与多目标优化 [M]. 北京:北京理工大学出版社, 2013:20 - 36.

[10] ISMAIL A, JENG D S, ZHANG L L. An optimised product-unit neural network with a novel PSO-BP hybrid training algorithm: applications to load-deformation analysis of axially loaded piles [J]. Engineering Applications of Artificial Intelligence, 2013, 26 (10): 2305 - 2314.

[11] 王永杰, 白艳萍. 基于主成分分析的 PSO - BP 算法在 GDP 和 CPI 预测中的应用 [J]. 重庆理工大学学报, 2017, 31(4): 150 - 154.

WANG Y J, BAI Y P. Application of PSO-BP algorithm based on principal component analysis prediction of GDP

- and GPI[J]. *Journal of Chongqing University of Technology*, 2017,31(4):150-154.
- [12] 田景芝,杜晓昕,郑永杰,等. 基于 PSO-BP 神经网络的加氢脱硫柴油硫含量的预测研究[J]. *石油化工*, 2017,46(1):62-67.  
TIAN J Z, Du X X, ZHENG Y J, et al. Prediction of sulfur content in hydrodesulfurization diesel oil based on PSO-BP neural network [J]. *Petrochemical Industry*, 2017,46(1):62-67.
- [13] 陈子豪,龙华,曹伟. 基于改进型 PSO-BP 神经网络算法的水质评价[J]. *信息技术*,2017,8(1):11-15.  
CHEN Z H ,LONG H, CAO W. Water quality evaluation based on improved PSO-BP neural network algorithm[J]. *Information Technology*, 2017,8(1):11-15.
- [14] 李海斌,翟秋柱,张友,等. PSO-BP 神经网络在隧道围岩变形预测中的应用[J]. *路基工程*,2017,5(1):164-169.  
LI H B ,ZHAI Q Z ,ZHANG Y. Application of PSO-BP neural network to prediction of deformation of tunnel surrounding rock [J]. *Subgrade Engineering*,2017,5(1):164-169.
- [15] 李祚泳,汪嘉杨,郭淳. PSO 算法优化 BP 网络的新方法及仿真实验[J]. *电子学报*, 2008, 36(11):2224-2228.  
LI Z Y ,WANG J Y ,GUO C. A new method of optimizing BP network by PSO algorithm and simulation experiment [J]. *Electronic Journal*, 2008, 36(11):2224-2228.
- [16] SHEN H Y. Determining the number of BP neural network hidden layer units[J]. *Journal of Tianjin University of Technology*, 2008,1(1):9-13.
- [17] CHEN C P. A rapid supervised learning neural network for function interpolation and approximation [J]. *IEEE Transactions on Neural Networks*, 1996, 7(5):1220-1230.
- [18] 高大文,王鹏,蔡臻超. 人工神经网络中隐含层节点与训练次数的优化[J]. *哈尔滨工业大学学报*, 2003, 35(2):207-209.  
GAO D W ,WANG P, CAI Z C. Optimization of hidden nodes and training times in artificial neural network[J]. *Journal of Harbin Institute of Technology*, 2003, 35(2):207-209.