

管材成形

## 基于 GRA 的 PSO-BP 神经网络斜轧穿孔管形预测

王清华<sup>1</sup>, 加世滢<sup>1</sup>, 胡建华<sup>2</sup>, 双远华<sup>2</sup>, 赵铁琳<sup>3</sup>

(1. 太原科技大学 电子信息工程学院, 山西 太原 030024; 2. 太原科技大学 材料科学与工程学院, 山西 太原 030024;  
3. 太原重工股份有限公司技术中心, 山西 太原 030024)

**摘要:** 针对斜轧穿孔中无缝钢管管形计算复杂且精度不高的缺陷, 提出了基于灰色关联度分析 (GRA) 的 PSO-BP 神经网络管形预测模型。由于轧制过程中影响管形的因素较多, 通过灰色关联度分析对工艺参数进行了相关性分析, 选择相关度较高的影响因素作为输入; 并使用粒子群优化算法对 BP 神经网络进行优化, 确定了最佳的神经网络结构, 构建了无缝钢管的斜轧穿孔管形预测模型。最后, 应用现场数据对该模型进行了训练和测试, 并将其与 BP 神经网络和传统数学模型进行了对比分析。研究表明: 该预测模型的精度较高、可靠性较好, 为提高无缝钢管的生产质量奠定了基础。

**关键词:** 斜轧穿孔; 管形预测; 灰色关联度分析; 粒子群优化算法; BP 神经网络

**DOI:** 10.13330/j.issn.1000-3940.2022.08.014

**中图分类号:** TP183

**文献标志码:** A

**文章编号:** 1000-3940 (2022) 08-0088-07

## Prediction of pipe shape in cross-rolled piercing by PSO-BP neural network based on GRA

Wang Qinghua<sup>1</sup>, Jia Shiying<sup>1</sup>, Hu Jianhua<sup>2</sup>, Shuang Yuanhua<sup>2</sup>, Zhao Tielin<sup>3</sup>

(1. School of Electronic and Information Engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China;  
2. School of Materials Science and Engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China;  
3. Technical Center of Taiyuan Heavy Industry Co., Ltd., Taiyuan 030024, China)

**Abstract:** For the defects of complicated calculation and low precision for pipe shape of seamless steel pipe in cross-rolled piercing, a pipe shape prediction model of PSO-BP neural network based on grey relational analysis was proposed. Since there were many factors affecting the pipe shape during the rolling process, the correlation analysis of the process parameters was carried out by the gray correlation analysis, and the influencing factors with higher correlation were selected as the input. Then, the BP neural network was optimized by particle swarm optimization algorithm, the optimal neural network structure was determined, and the pipe shape prediction model of cross-rolled piercing for seamless steel pipe was constructed. Finally, the model was trained and tested by field data and was compared with BP neural network and traditional mathematical models. The research results show that the prediction model has higher accuracy and better reliability, which lays a foundation for improving the production quality of seamless steel pipes.

**Key words:** cross-rolled piercing; pipe shape prediction; grey relational analysis; particle swarm optimization algorithm; BP neural network

管坯穿孔是热轧无缝钢管生产中最重要变形工序之一, 它将实心坯料穿成空心毛管。穿孔后的毛管质量直接影响下道工序的工艺能否正常执行以及最终的产品质量<sup>[1]</sup>, 尺寸精度 (包括壁厚和外径等) 为衡量毛管质量的重要指标。穿孔工艺调整不合理会导致毛管产生螺旋状导致壁厚不均<sup>[2]</sup>。文献

[3] 依据轧制过程中的变形机理建立了毛管外径和壁厚的计算模型。而工艺参数对毛管质量的影响主要靠调整试凑的方法来完成<sup>[4]</sup>。

人工神经网络是一种多输入、多输出, 具有非线性适应性信息处理能力的系统, 在轧制领域的预测仿真中得到了广泛的应用。文献 [5] 提出了基于灰色关联度分析 (Grey Relational Analysis, GRA) 的极限学习机 (Extreme Learning Machine, ELM) 热轧薄板的轧制力预测模型, 能够快速、准确地预测轧制力, 满足在线预测的要求。文献 [6] 利用三维有限元分析和 BP 神经网络的方法对轧制力进行预测, 提高了预测精度。文献 [7] 应用长时间

收稿日期: 2021-07-07; 修订日期: 2021-10-10

基金项目: 山西省科技重大专项 (20191102009)

作者简介: 王清华 (1980-), 女, 博士, 讲师

E-mail: 2002043@tyust.edu.cn

通信作者: 加世滢 (1996-), 女, 硕士研究生

E-mail: 13103421357@163.com

学习和短时间学习的神经网络在线学习功能建立模型, 并对热轧过程的轧制力进行预测。文献 [8] 建立了粒子群优化算法 (Particle Swarm Optimization, PSO) 和 BP 神经网络混合训练的神经网络预测模型, 对板带热轧过程中的横向厚度分布进行预测, 经验证该模型的预测精度较高。上述的神经网络建模主要应用于板带材的轧制过程, 而利用神经网络对管材领域的轧制力、质量参数建模的研究较少。文献 [9] 应用实测的工艺参数与其对应的毛管精度参数, 建立了模拟穿孔机生产的网络模型, 预测了毛管质量偏差及合理的工艺参数。文献 [10] 应用步进子时段 MICR 算法, 结合现场采集的数据建立了预测毛管质量的数学模型。文献 [11] 通过灰色关联度分析确定了影响轧制力的主要因素, 提出了结合机理计算与 BP 神经网络预测的轧制力机理模型, 提高了轧制力模型的预测精度。

本文针对二辊斜轧穿孔工艺, 结合某无缝钢管厂的生产数据, 进行灰色关联度分析, 筛选出影响管形的主要工艺参数; 利用粒子群优化算法优化 BP 神经网络参数, 建立管形预测模型, 并改善预测模型的性能, 得到的 PSO-BP 神经网络预测模型相较于 BP 神经网络以及传统计算方法, 其学习速度快、精度高、可靠性好, 能够满足生产应用要求。

## 1 穿孔毛管管形的传统数学模型

斜轧穿孔是无缝钢管生产中金属变形的第 1 道工序, 毛管的几何尺寸主要由外径和壁厚决定。穿孔时轧件的变形量较大, 根据变形区的几何关系并考虑弹跳公式, 毛管外径  $d_0$  和壁厚  $S_0$  的计算公式分别如式 (1) 和式 (2) 所示<sup>[3]</sup>。

$$d_0 = \sqrt{\left(\frac{D+b}{2}\right)^2 + (L_p - y)^2 \tan^2 \beta} - \frac{D}{2} + (L_p - y) \tan \alpha_2 \cos \beta + \frac{l}{2} + \square d \quad (1)$$

$$S_0 = \sqrt{\left(\frac{D+b}{2}\right)^2 + (L_p - y)^2 \tan^2 \beta} - \frac{D}{2} + (L_p - y) \tan \alpha_2 - \frac{\delta_n}{2} + \square S \quad (2)$$

式中:  $D$  为轧辊直径, mm;  $b$  为轧辊间距,  $b = (1 - \delta)d_z$ ;  $\delta$  为压缩带处压缩量, 结合经验数据取  $\delta = 15.5\%$ ;  $d_z$  为管坯直径, mm;  $L_p$  为顶头圆弧部分长度, mm;  $y$  为前伸量, mm;  $\beta$  为送进角, ( $^\circ$ );  $\alpha_2$  为轧辊出口锥角, ( $^\circ$ );  $l$  为导板间距, mm;  $\delta_n$  为顶头直径, mm;

$\square d$  和  $\square S$  分别为外径和壁厚的弹跳值, mm。

由上述的机理模型分析可知, 在计算外径和壁厚时均需要考虑穿孔机自身的刚度和弹跳值, 而弹跳值是由经验得出的, 必然会产生误差; 此外, 坯料的孔型设计、轧辊的加工与装配精度、顶头的加工精度等均会影响穿孔毛管的壁厚精度。

## 2 模型预测变量的选择

无缝钢管的壁厚精度和外径尺寸与轧制过程中的孔型、工艺参数、设备运行情况等多个因素有关, 可以设定和检测的参数很多, 如果将这些检测量均作为模型的输入, 势必会造成不必要的信息冗余, 使模型的结构复杂、性能降低, 最终影响其在线应用。

灰色关联度分析对样本数据的大小与分布规律没有严格要求, 通过对事物的发展趋势进行分析, 在更高层次上实现对事物之间、因素之间的理解, 关联度越高, 表现越优异<sup>[12]</sup>。为了建立准确的穿孔管形预测模型, 首先需要影响管形的因素进行分析, 避免建模中信息不全或冗余, 因此, 将主要工艺参数作为输入变量, 确保参数选择的合理性, 并采取灰色关联度分析对斜轧穿孔管形的 11 个输入变量即坯料直径、坯料长度、出钢温度、入口锥角、出口锥角、轧辊间距、导板间距、前伸量、轧辊转速、顶头直径、送进角与毛管的外径和壁厚进行了相关性分析。

灰色关联度分析的核心为计算关联度, 计算步骤为:

(1) 确定分析序列。设参考序列有两组, 分别为壁厚序列  $X_{01} = [x_{01}(1), x_{01}(2), \dots, x_{01}(k), \dots, x_{01}(n)]$ 、外径序列  $X_{02} = [x_{02}(1), x_{02}(2), \dots, x_{02}(k), \dots, x_{02}(n)]$ , 其中  $x_{01}(k)$  为第  $k$  组壁厚数据,  $x_{02}(k)$  为第  $k$  组外径数据,  $k=1, 2, \dots, n$ ,  $n$  为数据组数; 比较序列为  $X_i = [x_i(1), x_i(2), \dots, x_i(k), \dots, x_i(n)]$ ,  $i$  为主要工艺参数的数量,  $i=1, 2, \dots, 11$ , 其中  $x_i(k)$  为第  $i$  个相关工艺参数的第  $k$  组数据。

(2) 对输入变量进行无量纲化处理。由于这些工艺参数的性质不相同, 在进行灰色关联度分析之前, 需要先进行处理, 使之转化为数量级大体相近的无量纲数据。本文选用均值化方法来处理参考序列和比较序列, 使得原数列中各数据归一化至 1 的量级附近, 处理后得到的壁厚、外径序列和比较序列为  $Y_{01}$ 、 $Y_{02}$  和  $Y_i$ 。

(3) 计算壁厚和外径的关联度系数  $\zeta_{01i}(k)$  和  $\zeta_{02i}(k)$ :

$$\zeta_{01i}(k) = \frac{\min_i \min_k |y_{01}(k) - y_i(k)| + \xi \max_i \max_k |y_{01}(k) - y_i(k)|}{|y_{01}(k) - y_i(k)| + \xi \max_i \max_k |y_{01}(k) - y_i(k)|} \quad (3)$$

$$\zeta_{02i}(k) = \frac{\min_i \min_k |y_{02}(k) - y_i(k)| + \xi \max_i \max_k |y_{02}(k) - y_i(k)|}{|y_{02}(k) - y_i(k)| + \xi \max_i \max_k |y_{02}(k) - y_i(k)|} \quad (4)$$

式中:  $y_{01}(k)$ 、 $y_{02}(k)$  和  $y_i$  分别为无量纲化处理后的第  $k$  组壁厚数据、外径数据和第  $i$  个相关工艺参数的第  $k$  组数据;  $\xi$  为分辨系数, 在  $[0, 1]$  范围之内, 本文取  $\xi=0.5$ 。

(4) 计算  $Y_{01}$  和  $Y_i$  及  $Y_{02}$  和  $Y_i$  的关联度  $\gamma_{01i}$  和  $\gamma_{02i}$ , 表达式为:

$$\gamma_{01i} = \frac{1}{n} \sum_{k=1}^n \zeta_{01i}(k) \quad (5)$$

$$\gamma_{02i} = \frac{1}{n} \sum_{k=1}^n \zeta_{02i}(k) \quad (6)$$

(5) 根据灰色关联度排序。

$\gamma_{01i}$  和  $\gamma_{02i}$  反映了参考序列  $X_{01}$  和  $X_{02}$  与第  $i$  个影响因素的比较序列  $X_i$  的相关度,  $\gamma_{01i}$  和  $\gamma_{02i}$  值越大, 表示  $X_i$  对壁厚或外径的影响程度越大。结合实际采集数据, 得出影响穿孔后毛管壁厚和外径的工艺参数的关联度如表 1 所示。

表 1 影响穿孔毛管尺寸的工艺参数的关联度

Table 1 Correlation degrees of process parameters affecting pipe sizes after piercing

工艺参数	壁厚		外径	
	关联度	影响程度排序	关联度	影响程度排序
坯料直径	0.8453	1	0.9758	2
顶头直径	0.8165	4	0.9318	4
坯料长度	0.5980	8	0.6017	6
出钢温度	0.6070	7	0.5584	8
入口锥角	0.5966	9	0.5487	9
出口锥角	0.5966	10	0.5487	10
送进角	0.6118	6	0.5640	7
轧辊间距	0.8446	3	0.9761	1
导板间距	0.8451	2	0.9644	3
前伸量	0.6359	5	0.6981	5
轧辊转速	0.5666	11	0.5238	11

由表 1 的排序结果并结合生产工艺以及现场实际可以得出, 在 11 个工艺参数中, 前伸量、轧辊间距、导板间距、坯料直径、顶头直径这 5 个工艺参数与穿孔毛管的壁厚和外径均有较大的关联度, 作为斜轧穿孔管形预测模型的输入变量, 输出变量为穿孔毛管的壁厚和外径。

### 3 PSO-BP 神经网络预测模型

#### 3.1 BP 神经网络结构确定

人工神经网络是自适应模型, 可从数据中学习并进行归纳, 用来建立从输入至输出的映射关系<sup>[13]</sup>。BP 神经网络是一种误差反向传播神经网络, 由输入层、隐藏层和输出层组成, 包含信号的正向传播和反向传播两个部分<sup>[14-15]</sup>。正向传播时信号从输入层经隐藏层至输出层, 当预测输出和期望输出的误差较大时, 进入误差的反向传播阶段, 按照误差梯度下降的方式修正各层的权值、偏置, 通过不断地调整各层权值进行网络学习, 减小输出误差<sup>[16]</sup>。BP 神经网络结构如图 1 所示。




图 1 BP 神经网络结构图

Fig. 1 Structure diagram of BP neural network

此处输入变量为前伸量、轧辊间距、导板间距、坯料直径、顶头直径 5 个工艺参数, 输出变量为外径和壁厚, 由上述灰色关联度分析得到。

根据输入、输出变量可以确定输入层和输出层的神经元的数量。因此, 确定隐藏层的神经元数量为 BP 神经网络重要的任务之一, 通常使用调整试凑法来确定。本文采用经验公式来确定隐藏层神经元的数量, 尝试不同数量的神经元, 采用不同的网络模型, 用相关系数  $R$  判断网络的性能, 目标为最大化相关系数, 以获得具有最佳泛化能力的网络。

$$m = \sqrt{a + e} + c \quad (7)$$

式中:  $m$  为隐藏层神经元的数量;  $a$  和  $e$  分别为输入层和输出层神经元的数量;  $c$  为调节常数,  $c=1\sim 10$ 。

BP 神经网络中存在许多成熟的反向传播训练算法, 如梯度下降算法、拟牛顿优化、共轭梯度算法、



随机逼近、Levenberg-Marquardt 优化等<sup>[17]</sup>，可以通过比较相关系数得到最佳的训练算法。表 2 列出了隐藏层含有不同数量神经元时的相关系数。

表 2 隐藏层含有不同数量神经元时的相关系数

Table 2 Correlation coefficients of hidden layer with different numbers of neuron

隐藏层神经元数量/个	壁厚预测的相关系数		外径预测的相关系数	
	训练集	测试集	训练集	测试集
4	99.276	99.323	99.980	99.989
5	99.394	99.460	99.982	99.988
6	99.355	98.246	99.983	99.981
7	99.280	99.458	99.982	99.980
8	99.267	99.559	99.983	99.984
9	99.176	99.176	99.984	99.979
10	99.491	99.597	99.983	99.988
11	99.200	99.435	99.981	99.970

降低误差除了可以调节隐藏层神经元的数量，也可以增加隐藏层的数量，但增加隐藏层的数量会使得网络复杂化，增加训练时间，甚至出现过拟合现象，且本文对多层隐藏层进行实验分析，发现增加隐藏层数量未提高网络精度，所以，本文选择单隐藏层 BP 神经网络<sup>[18]</sup>。由表 2 可知，当隐藏层取 10 个神经元时，外径和壁厚训练集和测试集的相关系数均为最佳，基于这一分析，构建 5-10-2 为神经网络的最优结构。

本文中构建的 BP 神经网络结构及所用的函数如表 3 所示。

表 3 神经网络结构及算法

Table 3 Neural network structure and algorithm

BP 神经网络	网络设置
训练算法	Levenberg-Marquardt
学习算法	动量梯度下降算法、偏差学习算法
传递函数	Tan、Sigmoid 函数
性能函数	MSE
输入层神经元数量/个	5
隐藏层数量/个	1
隐藏层神经元数量/个	10
输出层神经元数量/个	2

### 3.2 PSO-BP 神经网络

神经网络中存在欠拟合或过拟合问题，除了学习速率、动量和隐藏层参数对网络性能有影响以外，初始权重和偏置的选择对于避免局部极小点和提高

网络收敛速度也均有一定程度的影响。因此，一些学者使用粒子群优化算法以获得更好的网络参数，从而抑制过拟合或欠拟合问题。粒子群优化算法是一种基于种群信息在全局搜索空间中寻找最优解的优化算法<sup>[19]</sup>，以误差作为适应度函数，通过更新粒子的位置和速度来搜索最优粒子<sup>[20]</sup>。本文采用 PSO 算法优化 BP 神经网络的初始权重和偏置，可加快收敛速度，提高模型的准确性、鲁棒性、收敛性。采用 PSO-BP 神经网络的训练步骤如下。

步骤 1：数据预处理。不同的输入变量工艺参数具有不同的量纲，影响神经网络的训练过程以及精度。因此，在训练之前需要将输入变量工艺参数归一化处理至  $[-1, 1]$  之间。

步骤 2：初始化粒子群算法的参数。

步骤 3：确定适应度函数。选择 BP 神经网络的均方误差  $MSE$  作为粒子群的适应度函数<sup>[13]</sup>：

$$MSE = \frac{1}{g} \sum_{j=1}^g (y_j - \hat{y}_j)^2 \quad (8)$$

式中： $g$  为训练集的样本数量； $j$  为训练集的样本序号； $y_j$  为神经网络输出的实际值； $\hat{y}_j$  为神经网络输出的预测值。

通过计算粒子群的适应度函数来评估粒子的好坏，同时得到初始化粒子群的全局最优位置  $g_{best}$  和个体最优位置  $p_{best}$ ，即全局最优解和个体最优解。

步骤 4：更新粒子速度和位置。

$t$  次迭代的粒子速度  $v(t)$ 、位置  $x(t)$  用式 (9)~式 (10) 更新：

$$v(t+1) = \omega v(t) + c_1 r_1 (p_{best}(t) - x(t)) + c_2 r_2 (g_{best}(t) - x(t)) \quad (9)$$

$$x(t+1) = x(t) + v(t+1) \quad (10)$$

式中： $p_{best}(t)$  为  $t$  次迭代时的个体最优解； $g_{best}(t)$  为  $t$  次迭代时的全局最优解； $\omega$  为惯性权重； $c_1$  和  $c_2$  为学习因子； $r_1$  和  $r_2$  为  $[0, 1]$  之间的随机数； $t$  为当前迭代的次数； $v(t+1)$  为第  $(t+1)$  次迭代的粒子速度； $x(t+1)$  为第  $(t+1)$  次迭代的粒子位置。

步骤 5：迭代计算输出最优粒子。将最大迭代次数和最小均方误差作为判断条件，当迭代次数达到上限、均方误差小于给定值时，确定迭代是否停止；否则，返回步骤 4。

步骤 6：PSO-BP 神经网络模型训练。将采用 PSO 算法得到的权值和偏置，输入数据训练 BP 神经网络模型，训练流程如图 2 所示。

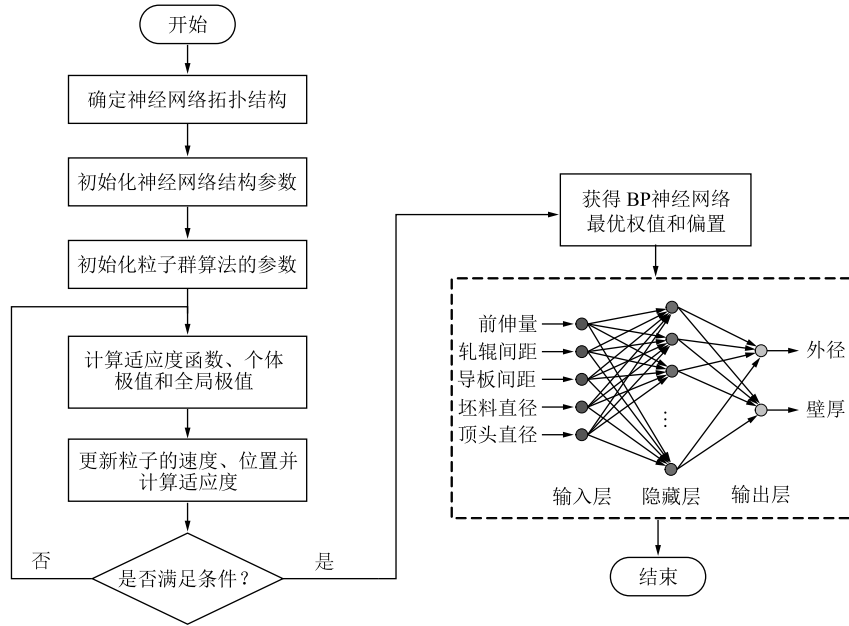


图 2 PSO-BP 神经网络训练流程图

Fig. 2 Flow chart of training for PSO-BP neural network

## 4 实验验证

### 4.1 实验建立

结合国内某钢管生产厂的生产数据,采集材料为 304L 不锈钢的 190 组数据,将其应用于 PSO-BP 神经网络模型中,训练样本为 175 组,测试样本为 15 组。

神经网络中隐藏层传递函数采用 Trainlm, 输入层传递函数采用 Logsig, 输出层传递函数采用 Purelin。模型最大训练次数为 200 次, 训练目标为 0.0005, 学习率为 0.01。PSO 算法中设定粒子数为 50, 粒子的最大速度为 1; 最大惯性权重为 0.9, 最小惯性权重为 0.4, 较大的惯性权重在迭代初期有利于算法的全局搜索, 较小的惯性权重在迭代后期有利于算法的局部搜索; 学习因子  $c_1=c_2=2$ ; 维数为 82; 目标函数为 PSO-BP 神经网络输出的预测值与实际值的均方误差。

### 4.2 实验分析

性能度量可以反映模型预测值和实际值之间的拟合程度。为了评估预测精度, 采用以下性能指标。

(1) 相对误差:

$$RE = \frac{|\hat{y}_h - y_h|}{y_h}$$

(2) 平均绝对误差:

$$MAE = \frac{1}{q} \sum_{h=1}^q |y_h - \hat{y}_h|$$

(3) 平均绝对百分比误差:

$$MAPE = \frac{1}{q} \sum_{h=1}^q \left| \frac{y_h - \hat{y}_h}{y_h} \right|$$

(4) 均方根误差:

$$RMSE = \sqrt{\frac{1}{q} \sum_{h=1}^q (y_h - \hat{y}_h)^2}$$

(5) 决定系数:

$$R^2 = 1 - \frac{\sum_{h=1}^q (y_h - \hat{y}_h)^2}{\sum_{h=1}^q (y_h - \bar{y}_h)^2}$$

式中:  $q$  为测试集样本总数;  $h$  为测试集样本序号;  $y_h$  和  $\hat{y}_h$  分别为神经网络输出的实际值和预测值;  $\bar{y}_h$  为神经网络输出的实际值的平均值。

$RE$ 、 $MAE$ 、 $MAPE$  和  $RMSE$  用于评价模型预测值与实际值之间的误差。决定系数  $R^2$  表示预测值与实际值之间的一致性, 反映了输入变量对输出变量的综合影响,  $R^2$  越接近于 1, 表明模型的预测值越接近于实际值。

为了进一步验证基于 GRA 的 PSO-BP 神经网络的有效性, 利用传统数学模型、BP 神经网络分别对外径和壁厚进行预测, 并将仿真结果进行比较, 对比结果如图 3 所示, 相对误差如图 4 所示, 其他性能指标结果如表 4 和表 5 所示。

由图 3 可以看出, PSO-BP 神经网络的预测结果较 BP 神经网络和传统数学模型的预测结果更接近于实际值。




图 3 不同模型壁厚 (a) 和外径 (b) 的预测结果与实际值对比

Fig. 3 Comparison between predicted results and actual values of wall thickness (a) and outer diameter (b) for different models




图 4 不同模型壁厚 (a) 和外径 (b) 的预测相对误差图

Fig. 4 Relative error diagrams of prediction on wall thickness (a) and outer diameter (b) for different models

表 4 不同模型壁厚预测的性能指标

Table 4 Performance indexes of wall thickness predictions for different models

模型	MAE	MAPE	RMSE	$R^2$
传统数学模型	1.6999	0.1588	1.8883	0.6129
BP 神经网络	0.4393	0.0459	0.5251	0.9701
PSO-BP 神经网络	0.3391	0.0337	0.4403	0.9790

表 5 不同模型外径预测的性能指标

Table 5 Performance indexes of outer diameter predictions for different models

模型	MAE	MAPE	RMSE	$R^2$
传统数学模型	5.9067	0.0335	8.0843	0.9750
BP 神经网络	0.6112	0.0041	0.8313	0.9897
PSO-BP 神经网络	0.5331	0.0034	0.7612	0.9899

如图 4 所示,传统数学模型对壁厚预测的最大相对误差为 20.75%,最小相对误差为 8.06%;对

外径预测的最大相对误差为 6.91%,最小相对误差为 0.80%。BP 神经网络对壁厚预测的最大相对误差为 11.11%,最小相对误差为 1.04%;对外径预测的最大相对误差为 1.1100%,最小相对误差为 0.0309%。PSO-BP 神经网络对壁厚预测的最大相对误差为 9.60%,最小相对误差为 0.10%;对外径预测的最大相对误差为 0.87%,最小相对误差为 0.01%;

## 5 结论

(1) 针对二辊斜轧穿孔过程中无缝钢管管形预测的问题,结合现场采集的数据,利用灰色关联度分析,通过关联度对比得出了对外径和壁厚的影响较大的关键参数:前伸量、导板间距、轧辊间距、坯料直径、顶头直径。

(2) 基于 MAE (平均绝对误差)、MAPE (平均绝对百分比误差)、RMSE (均方根误差)、 $R^2$  (决

定系数)分析,采用 PSO-BP 神经网络建立的二辊斜轧穿孔管形预测模型的性能优于 BP 神经网络和传统数学模型,表明该模型的性能比较稳定,可以在生产进行前用来预测毛管的质量,指导生产顺利进行。

#### 参考文献:

- [1] 李群,高秀华. 钢管生产 [M]. 北京:冶金工业出版社,2008.
- Li Q, Gao X H. Steel Pipe Production [M]. Beijing: Metallurgical Industrial Press, 2008.
- [2] 张进,朱宝禄,韩建新,等. 连轧钢管的壁厚不均原因分析 [J]. 钢管, 2013, 42 (1): 55-58.
- Zhang J, Zhu B L, Han J X, et al. Research on wall thickness inhomogeneity of steel pipe as rolled with mandrel mill [J]. Steel Pipe, 2013, 42 (1): 55-58.
- [3] 李连诗. 钢管塑性变形原理 (上册) [M]. 北京:冶金工业出版社,1985.
- Li L S. Plastic Deformation Principle of Steel Pipe (Volume I) [M]. Beijing: Metallurgical Industry Press, 1985.
- [4] 双远华,李国祯. 钢管斜轧理论及生产过程的数值模拟 [M]. 北京:冶金工业出版社,2001.
- Shuang Y H, Li G Z. Numerical Simulation of Steel Pipe Slant Rolling Theory and Production Process [M]. Beijing: Metallurgical Industry Press, 2001.
- [5] 曹卫华,李熙,吴敏,等. 基于极限学习机的热轧薄板轧制力预测模型 [J]. 信息与控制, 2014, 43 (3): 270-275.
- Cao W H, Li X, Wu M, et al. A rolling force prediction model for hot rolled sheets based on extreme learning machine [J]. Information and Control, 2014, 43 (3): 270-275.
- [6] Bagheripoor M, Bisadi H. Application of artificial neural networks for the prediction of roll force and roll torque in hot strip rolling process [J]. Applied Mathematical Modelling, 2013, 37 (7): 4593-4607.
- [7] Son J S, Lee D M, Kim I S, et al. A study on on-line learning neural network for prediction for rolling force in hot-rolling mill [J]. Journal of Materials Processing Technology, 2005, 164-165: 1612-1617.
- [8] 高山凤,刘鸿飞,郝安民,等. 热轧板带横向厚度分布的预测与控制 [J]. 哈尔滨工业大学学报, 2016, 48 (1): 180-183.
- Gao S F, Liu H F, Xi A M, et al. Prediction and control of thickness transverse distribution in hot rolling strip [J]. Journal of Harbin Institute of Technology, 2016, 48 (1): 180-183.
- [9] 双远华,赖明道. 人工神经网络在预测斜轧穿孔毛管偏差中的应用 [J]. 中国有色金属学报, 2001, (5): 862-866.
- Shuang Y H, Lai M D. Application of artificial neural networks on predicting deviation of tube in cross piercing process [J]. The Chinese Journal of Nonferrous Metals, 2001, (5): 862-866.
- [10] 肖冬,潘孝礼,毛志忠,等. 基于步进子时段 MICR 方法的毛管质量预报 [J]. 仪器仪表学报, 2007, 28 (12): 2190-2196.
- Xiao D, Pan X L, Mao Z Z, et al. Quality prediction of tube hollow based on step-by-step staged MICR [J]. Chinese Journal of Scientific Instrument, 2007, 28 (12): 2190-2196.
- [11] 陈鑫,朱明杰,吴敏,等. 结合机理计算与神经网络预测的无缝钢管轧制力建模 [J]. 冶金自动化, 2015, 39 (4): 32-37.
- Chen X, Zhu M J, Wu M, et al. Rolling force modeling for seamless steel pipe combining mechanism model and neural network prediction [J]. Metallurgical Industry Automation, 2015, 39 (4): 32-37.
- [12] 魏子茹,卢延辉,王鹏宇,等. 基于 CRITIC 法的灰色关联理论在无人驾驶车辆测试评价中的应用 [J]. 机械工程学报, 2021, 57 (12): 99-108.
- Wei Z R, Lu Y H, Wang P Y, et al. Application of grey correlation theory based on CRITIC method in autonomous vehicles test and evaluation [J]. Journal of Mechanical Engineering, 2021, 57 (12): 99-108.
- [13] Larkiola J, Myllykoski P, Korhonen A S, et al. The role of neural networks in the optimisation of rolling processes [J]. Journal of Materials Processing Technology, 1998, 80-81: 16-23.
- [14] Sun W, Xu Y F. Financial security evaluation of the electric power industry in China based on a back propagation neural network optimized by genetic algorithm [J]. Energy, 2016, 101: 366-379.
- [15] 夏维,刘新学,范阳涛,等. 基于混合遗传 BP 神经网络的城市系统作战能力评估 [J]. 系统工程与电子技术, 2017, 39 (1): 107-113.
- Xia W, Liu X X, Fan Y T, et al. Combat capability evaluation of city system based on mix-genetic algorithm BP neural network [J]. Systems Engineering and Electronics, 2017, 39 (1): 107-113.
- [16] Wang J L, Shi P, Jiang P, et al. Application of BP neural network algorithm in traditional hydrological model for flood forecasting [J]. Water, 2017, 9 (1): 48.
- [17] Yang Y Y, Linkens D A, Talamantes-silva J. Roll load prediction-Data collection, analysis and neural network modelling [J]. Journal of Materials Processing Technology, 2004, 152 (3): 304-315.
- [18] Chen K, Yang S J, Batur C. Effect of multi-hidden-layer structure on performance of BP neural network; Probe [A]. Proceedings of 2012 8th International Conference on Natural Computation [C]. IEEE, 2012.
- [19] Khan S U, Yang S Y, Wang L Y, et al. A modified particle swarm optimization algorithm for global optimizations of inverse problems [J]. IEEE Transactions on Magnetics, 2016, 52 (3): 1-4.
- [20] 毛志翔,鲁世红,李正芳,等. 电加热渐进成形工艺参数优化及成形温度预测 [J]. 热加工工艺, 2019, 48 (19): 100-103.
- Mao Z X, Lu S H, Li Z F, et al. Optimization of process parameters and prediction of forming temperature for electro-heating incremental forming [J]. Hot Working Technology, 2019, 48 (19): 100-103.