

基于 DPSO-BP 神经网络的 V 形自由折弯成形角度和回弹预测

占少伟¹, 龚俊杰¹, 韦源源¹, 王金荣², 陈扬东²

(1. 扬州大学 机械工程学院, 江苏 扬州 225000; 2. 江苏亚威机床股份有限公司, 江苏 扬州 225200)

摘要: 采用基于 DPSO 算法优化 BP 神经网络 (DPSO-BP) 的机器学习算法建模, 提出一种考虑材料参数和几何参数的 V 形自由折弯成形角度和回弹的预测方法。该方法主要引入非线性惯性权重改进粒子群 (PSO) 算法, 进一步优化神经网络的初始权值和阈值, 构建神经网络预测模型。以不同批号的 SUS304 不锈钢板料为研究对象, 通过设计正交试验得到 45 个训练样本数据, 验证所建立的预测模型的准确性。结果表明: 采用 DPSO-BP 神经网络模型预测的成形角和回弹角的平均误差分别为 0.150° 和 0.120°, 与未优化的 PSO-BP 神经网络模型相比, 预测的成形角和回弹角的平均误差明显减小, 且计算耗时由 14.0 min 大幅缩短至 0.8 min, 同时实现了高预测精度和高计算效率。

关键词: 回弹; V 形自由折弯; BP 神经网络; PSO 算法; 回弹角

DOI: 10.13330/j.issn.1000-3940.2023.08.021

中图分类号: TG386

文献标志码: A

文章编号: 1000-3940 (2023) 08-0151-07

Prediction on V-shaped free bending angle and springback based on DPSO-BP neural network

Zhan Shaowei¹, Gong Junjie¹, Wei Yuanyuan¹, Wang Jinrong², Chen Yangdong²

(1. College of Mechanical Engineering, Yangzhou University, Yangzhou 225000, China;

2. Jiangsu Yawei Machine Tool Co., Ltd., Yangzhou 225200, China)

Abstract: A prediction method about V-shaped free bending angle and springback considering material parameters and geometric parameters was proposed, according to the machine learning algorithm modelling based on the BP neural network optimized by the DPSO algorithm (DPSO-BP). The method mainly introduced the nonlinear inertia weight to improve particle swarm (PSO) algorithm, further optimized the initial weight and threshold of the neural network, and constructed the neural network prediction model. Then, the different batches of SUS304 stainless steel sheets was taken as the research object, 45 training sample data were obtained by designing orthogonal experiment, and the accuracy of the constructed prediction model was verified. The results show that the average errors of the forming angle and the springback angle predicted by the DPSO-BP neural network model are 0.150° and 0.120°, respectively. Compared with the PSO-BP neural network model before optimization, the average errors of the forming angle and the springback angle are significantly reduced, and the calculation time is greatly shortened from 14.0 min to 0.8 min, achieving high prediction accuracy and high calculation efficiency at the same time.

Key words: springback; V-shaped free bending; BP neural network; PSO algorithm; springback angle

随着折弯成形技术的快速发展, 对折弯成形件的成形精度要求越来越高。V 形自由折弯成形可在较少模具的情况下加工多种角度的折弯零件, 具有较好的灵活性, 因此, 被广泛应用于汽车、家电、农机和航空等领域。在钣金折弯成形后, 残余应力使得钣金发生弹性变形, 产生无法避免的回弹现象,

进而影响着折弯成形精度。零件的回弹受变形过程和卸载过程的双重影响, 且涉及几何、材料和接触等非线性问题, 使得回弹的机理极其复杂。

对于回弹预测和控制问题, 国内外学者主要从理论模型、有限元仿真模拟和近似模型进行研究。Leu D K 等^[1]基于基本弯曲理论, 提出了一种考虑厚度比、厚向异性系数和应变硬化指数的 V 形弯曲回弹计算简化方法。Li H Z 等^[2]提出了一种考虑塑性应变与塑性应变强化的理论模型, 以纯铝箔为对象, 通过对比理论模型计算结果与实际折弯试验, 验证了理论模型的准确性。Jiang Z Q 等^[3]以钛合金管为研究对象, 从折弯角度、材料的屈服极限、加工硬化系数、

收稿日期: 2022-11-07; 修订日期: 2023-02-08

基金项目: 江苏省自然科学基金青年基金项目 (BK20190869)

作者简介: 占少伟 (1999-), 男, 硕士研究生

E-mail: zhansw0506@163.com

通信作者: 龚俊杰 (1969-), 男, 博士, 教授

E-mail: gjunj@126.com

加工硬化指数、杨氏模量和板材壁厚等方面分析了各因素对折弯回弹的影响。王飞等^[4]针对板材的成形和回弹过程进行了有限元仿真试验,分析了弹性模量、硬化指数、板料厚度、下模开口宽度、上模圆角半径和润滑条件对折弯回弹的影响。Trzepieciński T 等^[5]采用 ABAQUS 建立了 V 形自由折弯成形的有限元模型,研究了各向异性钢板的回弹,并试验证明了有限元模拟的可靠性。高云亮等^[6]采用 ABAQUS 建立了 M 形支架节的有限元模型,研究了支架节的高度变化与结构设计波高比值参数对回弹的影响。Teimouri R 等^[7]采用人工神经网络的方法研究了材料厚度、材料轧制方向及冲头尖端弯曲半径这 3 个因素对 CK67 薄钢板在 V 形弯曲成形中回弹量的影响。刘晓宇等^[8]采用 BP 神经网络建模,实现了 W 形微弯曲回弹预测。

对于回弹问题,基于解析法的理论回弹模型由于推导简化,无法满足高精度的要求。而采用有限元模拟进行研究,在合理设置材料参数等情况下有着较高的成形精度,但需要较长的模拟计算时间。为了实现钣金 V 形自由折弯成形角度和回弹的快速预测,本文以不同批号的不锈钢板料为研究对象,设计正交试验并进行真实折弯试验,获得神经网络的训练样本数据,构建基于 DPSO-BP 神经网络的 V 形自由折弯成形角度和回弹预测模型,最终通过试验验证了模型的有效性。

1 V 形自由折弯成形回弹

V 形自由折弯成形过程如图 1 所示,虚线代表上模和板料的初始状态,通过上模匀速下压至给定深度后,卸载完成折弯全过程。板料 V 形折弯成形的加载和卸载过程满足如图 2 所示的应力、应变曲线。当上模向下压时,应力和应变沿着 $O \rightarrow A \rightarrow B$ 路径达到最大;卸载后,应力沿着 $B \rightarrow D'$ 路径降为 0,此时板料保持塑性应变 ε_e ,与最大应变 ε_{\max} 相比,减少了 $\Delta\varepsilon$ 的弹性应变变量^[9],进而导致板料出现如图 3 所示的回弹现象。图 1~图 3 中, V 为下模开口宽度, r 为上模圆角半径, t 为板料厚度, D 为上模下压量, R_{eL} 为屈服强度, ε 为应变, σ 为应力, α 为卸载后的成形角, α_0 为卸载前的角度, $\Delta\alpha$ 为回弹角。

2 样本数据获取

2.1 材料力学试验

由于材料性能对 V 形折弯回弹具有明显影响,




图 1 V 形自由折弯成形示意图

Fig. 1 Schematic diagram of V-shaped free bending




图 2 折弯加载-卸载过程的应力、应变

Fig. 2 Stress and strain during bending loading-unloading process




图 3 板料折弯回弹

Fig. 3 Springback of sheet bending

且不同批号的不锈钢板料的性能有所差异,首先进行力学性能测试。按照 GB/T 228.1—2021^[10]对 3 种不同批号的不锈钢材料进行拉伸试样设计,并在电子万能材料试验机上进行拉伸试验,试验结果如表 1 所示。由表 1 可知,不同批号的不锈钢板料的弹性模量和屈服强度均存在一定的差异性,进而影响折弯回弹预测的精度。管志平等^[11]通过平均冲击值法 (Mean Impact Value, MIV) 对回弹的影响因素进行了分析,发现弹性模量与屈服强度对回弹的影响程度大于硬化指数。并且,不同批号的不锈钢的硬化指数范围很小,为 0.4238~0.4287,故构建神经网络预测模型时可忽略该参数。以屈服强度与弹性模量之比 R_{eL}/E 代表材料性能^[12],作为输入层参数。

表 1 不同批号 SUS304 不锈钢力学性能
Table 1 Mechanical properties of SUS304 stainless steel with different batches

编号	弹性模量 E/GPa	屈服强度 R_{eL}/MPa	硬化指数	泊松比	R_{eL}/E
1	194.5	296.81	0.4287	0.293	1.53×10^{-3}
2	196.1	279.45	0.4241	0.298	1.43×10^{-3}
3	192.6	285.39	0.4238	0.293	1.48×10^{-3}

2.2 设计正交试验

在 V 形自由折弯成形过程中，影响回弹的参数有很多，如：上模圆角半径 r 、摩擦条件、下模圆角半径、上模下压量 D 等。根据实际工程条件和试验分析，本文选取 5 个最重要的影响参数设计正交试验：屈服强度与弹性模量之比 R_{eL}/E 、板料厚度 t 、上模圆角半径 r 、下模开口宽度 V 、上模下压量 D （其他为固定的模具参数，如上模角度和下模角度为 85° ，下模圆角半径为 1 mm ）。具体各因素的水平参数取值如下。

- (1) 屈服强度与弹性模量之比 R_{eL}/E : 1.43×10^{-3} 、 1.48×10^{-3} 、 1.53×10^{-3} 。
- (2) 板料厚度 t : 1.0、1.5 和 2.0 mm。
- (3) 上模圆角半径 r : 0.8、1.0 和 1.2 mm。
- (4) 下模开口宽度 V : 8、12 和 20 mm。
- (5) 上模下压量 D : $V=8\text{ mm}$ 时， D 取为 1.53、1.97、2.40、2.84 和 3.13 mm； $V=12\text{ mm}$ 时， D 取为 2.29、2.95、3.60、4.26 和 4.78 mm； $V=20\text{ mm}$ 时， D 取为 3.82、4.91、6.00、7.09 和 8.17 mm。

由于上模下压量对折弯成形角度的影响极大，进而影响回弹角，为保证后续建立的 BP 神经网络模型的准确性，对其他 4 个因素建立 $L_9(3^4)$ 正交试验，设置上模下压量因素具有 5 个水平，结合 9 组正交试验得到 45 个试验样本数据，具体的试验方案与结果见表 2。表 2 中的正交试验结果是通过在江苏亚威机床股份有限公司进行真实折弯试验所得。现场折弯试验如图 4 所示，采用尼康高速相机拍摄折弯试验全过程，连接计算机并导入 Image Pro plus 软件处理，取出卸载前与卸载后的两帧图像，识别板料边缘并测量得到卸载前和卸载后的板料角度，进而得到成形角 α 和回弹角 $\Delta\alpha$ 。软件处理后得到的试验 5 中板料卸载前和卸载后的角度测量结果如图 5 所示。

表 2 正交试验方案与结果
Table 2 Schemes and results of orthogonal experiments

试验 序号	R_{eL}/E	t/mm	r/mm	V/mm	D/mm	成形角 $\alpha/(^\circ)$	回弹角 $\Delta\alpha/(^\circ)$
1	1.43×10^{-3}	1.0	1.0	8	1.53	140.71	3.53
2	1.43×10^{-3}	1.0	1.0	8	1.97	127.33	3.81
3	1.43×10^{-3}	1.0	1.0	8	2.40	114.59	4.12
4	1.43×10^{-3}	1.0	1.0	8	2.84	98.93	4.46
5	1.43×10^{-3}	1.0	1.0	8	3.13	91.93	4.53
6	1.43×10^{-3}	1.5	0.8	12	2.29	139.4	3.48
7	1.43×10^{-3}	1.5	0.8	12	2.95	126.6	3.59
8	1.43×10^{-3}	1.5	0.8	12	3.60	114.13	4.17
9	1.43×10^{-3}	1.5	0.8	12	4.26	98.54	4.49
10	1.43×10^{-3}	1.5	0.8	12	4.78	91.97	4.55
11	1.43×10^{-3}	2.0	1.2	20	3.82	140.13	3.95
12	1.43×10^{-3}	2.0	1.2	20	4.91	126.87	4.18
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
44	1.53×10^{-3}	2.0	0.8	8	2.84	98.48	4.01
45	1.53×10^{-3}	2.0	0.8	8	3.13	91.91	4.24




图 4 现场折弯试验图
Fig. 4 Bending experiment diagram in situation

3 DPSO-BP 神经网络预测模型

3.1 BP 神经网络

误差反向传播神经网络（Back Propagation Neural Network, BPNN）是一种误差反向传播算法训练的多层前馈网络^[13]。其学习规则是基于最速下降法，通过反向传播不断调整网络的权值和阈值，最终使得网络误差最小。Hornik K 等^[14]已经证明，具有反向传播算法的 3 层前馈神经网络可以拟合任何目标精度的非线性函数。本文利用 MATLAB 构建 BP 神经网络预测模型，对函数（式（1））进行逼近，BP 神经网络结构如图 6 所示。




图 5 试验 5 的板料卸载前 (a) 和卸载后 (b) 的角度

Fig. 5 Angles before (a) and after (b) unloading of sheet in experiment 5

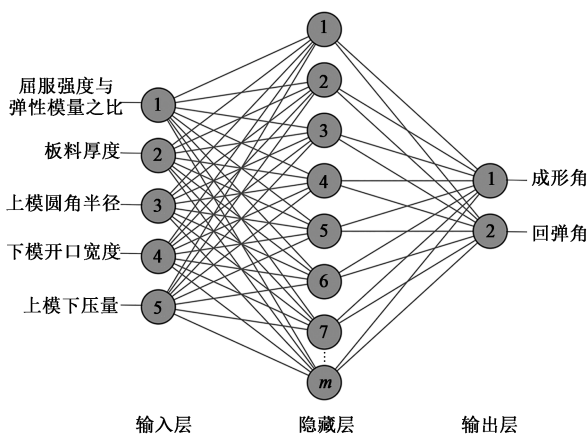


图 6 BP 神经网络结构图

Fig. 6 Diagram of BP neural network structure

$$(\alpha, \Delta\alpha) = f(R_{eL}/E, t, r, V, D) \quad (1)$$

由图 6 可知, 该模型为一个 5- m -2 的 3 层 BP 神经网络模型。其中输入层的这 5 个神经元分别为屈服强度与弹性模量之比、板料厚度、上模圆角半径、下模开口宽度、上模下压量这 5 个影响因素; 输出层的 2 个神经元, 分别为 V 形自由折弯的成形角和回弹角。隐藏层有 m 个神经元, m 的取值通过式 (2) 确定。

$$m = \sqrt{n + l} + a \quad (2)$$

式中: n 为输入层的神经元数, 本文取 $n=5$; l 为输出层的神经元数, 本文取 $l=2$; a 为 1~10 之间的常数。

初步确定神经网络结构后, 使用 MATLAB 软件编程建立并训练 BP 神经网络模型, 进一步确定最佳隐藏层数。合理选择隐藏层数和划分样本数据能够避免过拟合现象, 即神经网络预测模型在训练样

本时表现过于优越但是在验证数据集和测试数据集时表现不佳。采用 fitnet 函数建立神经网络, 网络性能使用均方误差性能函数衡量。设置网络训练目标最小目标误差为 1×10^{-3} , 最大训练次数为 100, 学习速率为 0.01。对隐藏层传递函数、输出层传递函数及训练函数分别为 tansig 函数、purelin 函数和 trainlm 函数。dividerand 函数将样本数据分为训练集和验证集。对由式 (2) 取得的 10 个不同的 m 值建立神经网络模型并训练, BP 神经网络在不同隐藏层神经元数下所有样本的均方误差如图 7 所示。观察可知, 当隐藏层神经元数为 9 时, BP 神经网络模型的均方误差达到最小值, 当隐藏层神经元数超过 9 后, 均方误差逐渐增大, 故后续构建的神经网络隐藏层神经元数为 9。




图 7 不同隐藏层神经元数时的均方误差

Fig. 7 Mean square errors of different neuron numbers for hidden layer

3.2 PSO 算法和 DPSO 算法

粒子群算法 (Particle Swarm Optimization, PSO) 是对鸟类捕食行为进行研究而诞生的一种优化算法。

PSO 算法利用群体中个体之间的信息共享, 使群体能够快速在求解空间进行探测, 从而找到最优解。PSO 算法首先初始化为一群随机粒子, 在寻找最优解的迭代过程中, 粒子通过跟踪两个“极值”的方式更新自身位置和速度。粒子 i 的第 k 次迭代更新方式^[15]如下:

$$v_i^{k+1} = wv_i^k + c_1r_1(p_{\text{best},i}^k - x_i^k) + c_2r_2(g_{\text{best}}^k - x_i^k) \quad (3)$$

$$x_i^{k+1} = x_i^k + v_i^{k+1} \quad (4)$$

式中: x_i^k 为第 k 代粒子 i 的位置; x_i^{k+1} 为第 $(k+1)$ 代粒子 i 的位置; v_i^k 为第 k 代粒子 i 的速度; v_i^{k+1} 为第 $(k+1)$ 代粒子 i 的速度; $p_{\text{best},i}^k$ 为第 k 代粒子 i 的最优位置; g_{best}^k 为第 k 代粒子的全局最优解; r_1 、 r_2 为 $[0, 1]$ 间的随机数; w 为惯性权重; c_1 、 c_2 为学习因子, 通常取 $c_1 = c_2$ 。

PSO 算法可通过给定确切的初始权值和阈值优化 BP 神经网络, 提高模型的预测精度。但直接使用基本 PSO 算法优化会明显导致计算效率下降^[16], 为此需要对基本 PSO 算法进行改进。本文主要对惯性权重参数 w 进行改进。当寻找最优解的迭代过程中, 较小的惯性权重有利于全局搜索, 但可能错过最优解; 而较大的惯性权重有利于局部搜索, 但容易得到局部最优。为平衡算法的全局搜索能力以及局部搜索能力, 将惯性权重改进为非线性权重^[17], 其表达式为:

$$w = w_{\max} - (w_{\max} - w_{\min}) \tan\left(\frac{k}{k_{\max}} \times \frac{\pi}{4}\right) \quad (5)$$

式中: w_{\max} 、 w_{\min} 分别为最大惯性权重和最小惯性权重, 通常分别取 0.9 和 0.4; k_{\max} 为最大迭代次数。

由式 (5) 可知, 刚开始迭代次数 k 较小, w 接近于最大惯性权重 w_{\max} , 算法的全局搜索能力强; 随着迭代次数 k 的增大, w 非线性递减至 w_{\min} 附近, 提高了算法的局部搜索和收敛能力。因此, 改进后的动态 DPSO 算法有着更好的搜索能力和收敛速度。

3.3 构建 DPSO-BP 神经网络预测模型

DPSO-BP 神经网络预测模型的具体构建流程如图 8 所示, 主要步骤如下:

- (1) 确定 BP 神经网络结构;
- (2) 根据神经网络结构确定粒子群维度 Q :

$$Q = (n + 1)m + (m + 1)l \quad (6)$$

- (3) 设置适应度函数并初始化粒子参数;

(4) 利用 DPSO 算法优化 BP 神经网络的权值和阈值, 带入 BP 神经网络进行训练。

通过试验已发现最佳隐藏层神经元个数为 9,

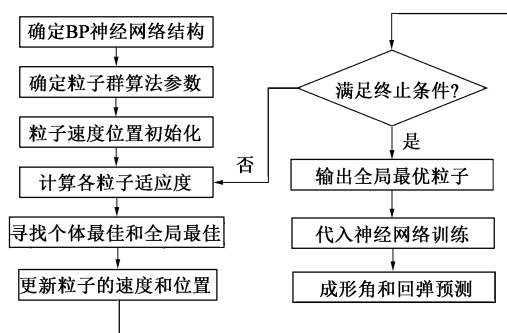


图 8 DPSO-BP 神经网络模型的算法流程

Fig. 8 Algorithm flow of DPSO-BP neural network model

故本文建立的 BP 神经网络模型结构为 5-9-2。由式 (6) 得到粒子群维度为 74。设置适应度函数 $F = \frac{1}{1+L}$, 其中, L 为均方误差之和。设置 DPSO 算法超参数: 粒子数为 40, 学习因子 $c_1 = c_2 = 1.5$, 最大惯性权重和最小惯性权重分别取 0.9 和 0.4。

构建 DPSO-BP 神经网络预测模型, 并使用正交试验所得样本数据进行训练。训练过程如图 9 所示, 当训练次数达到 14 次时网络停止训练, 训练集的均方误差达到设定目标误差 0.001, 且验证集的均方误差在第 13 次训练时达到最小, 为 0.00216。表明该网络能够在短时间内达到目标误差精度, 并且具有较好的泛化能力。对于 BP 神经网络模型, 相关系数 R 值越接近 1, 则网络的训练精度越高。图 10 为该神经网络的网络训练值, 在训练集和验证集上相关系数 R 分别为 0.99874 和 0.99529, 表明模型在训练集和验证集上的训练精度均较高, 未出现过拟合现象。




图 9 BP 神经网络训练过程中均方误差变化曲线

Fig. 9 Variation curves of mean square error during training process for BP neural network

3.4 不同预测模型的对比与评估

为验证模型的有效性, 另做折弯试验得到 5 个

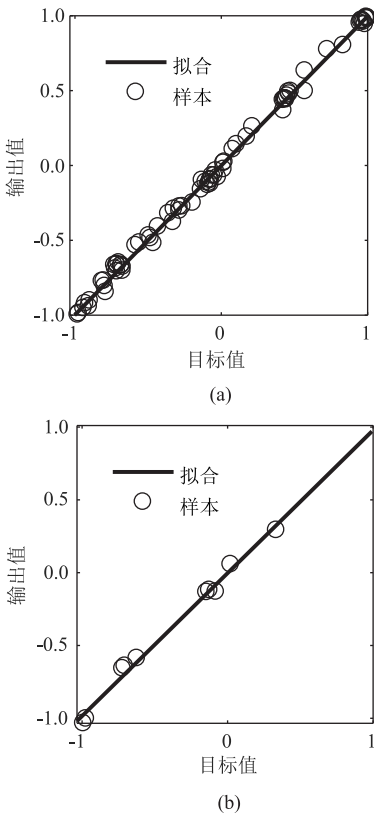


图 10 神经网络的训练值
(a) 训练集 (b) 验证集
Fig. 10 Network training values for neural network
(a) Training sets (b) Verification sets

测试样本数据（表 3），对用 BP 神经网络模型、PSO-BP 神经网络模型以及 DPSO-BP 神经网络模型进行预测精度评估。3 种神经网络预测模型的预测结果及其误差分别如表 4~表 6 所示，预测成形角和回弹角的平均误差及计算所用时间如图 11 所示。

表 3 试验测试样本
Table 3 Experimental test samples

试验序号	R_{eL}/E	t/mm	r/mm	V/mm	D/mm
1'	1.43×10^{-3}	1.0	0.8	8	1.53
2'	1.43×10^{-3}	1.5	1.0	12	2.95
3'	1.48×10^{-3}	1.5	1.0	8	3.13
4'	1.48×10^{-3}	2.0	1.2	12	4.85
5'	1.53×10^{-3}	1.5	0.8	20	4.91

由图 11 可知，BP 神经网络模型在测试集上预测的成形角和回弹角的平均误差为 0.396° 和 0.356° ，而训练和测试的总计算耗时为 0.5 min。与 BP 神经网络模型相比，采用 PSO-BP 神经网络模型预测的成形角和回弹角的平均误差分别减小至

表 4 BP 神经网络模型预测成形角和回弹角及误差（°）
Table 4 Forming angles, springback angles and errors predicted by BP neural network model（°）

试验 序号	预测值		试验值		绝对误差	
	成形角	回弹角	成形角	回弹角	成形角	回弹角
1'	140.77	3.94	140.12	3.39	0.65	0.55
2'	127.24	4.15	126.93	3.86	0.31	0.29
3'	92.03	4.00	92.30	4.22	-0.27	-0.22
4'	92.67	5.00	91.96	4.35	0.71	0.65
5'	127.82	4.79	127.86	4.72	-0.04	0.07

表 5 PSO-BP 神经网络模型预测成形角和回弹角及误差（°）
Table 5 Forming angles, springback angles and errors predicted by PSO-BP neural network model（°）

试验 序号	预测值		试验值		绝对误差	
	成形角	回弹角	成形角	回弹角	成形角	回弹角
1'	140.46	3.69	140.12	3.39	0.34	0.30
2'	127.08	4.00	126.93	3.86	0.15	0.14
3'	92.02	3.97	92.30	4.22	-0.28	-0.25
4'	92.45	4.78	91.96	4.35	0.49	0.43
5'	127.70	4.63	127.86	4.72	-0.16	-0.09

表 6 DPSO-BP 神经网络模型预测成形角和回弹角及误差（°）

试验 序号	预测值		试验值		绝对误差	
	成形角	回弹角	成形角	回弹角	成形角	回弹角
1'	140.38	3.64	140.12	3.39	0.26	0.25
2'	126.80	3.76	126.93	3.86	-0.13	-0.10
3'	92.24	4.20	92.30	4.22	-0.06	-0.02
4'	92.15	4.50	91.96	4.35	0.19	0.15
5'	127.75	4.64	127.86	4.72	-0.11	-0.08




图 11 不同预测模型的成形角和回弹角平均误差及计算时间对比
Fig. 11 Comparison of average errors for forming angle and springback angle and calculation time by different prediction models

0.284°和0.242°, 但计算效率明显下降, 总计算耗时为14.0 min。将粒子群算法中惯性权重 w 改进为非线性惯性权重的DPSO算法提高了算法的搜索能力, 同时加快了算法的收敛速度。与PSO-BP神经网络模型相比, 采用DPSO-BP神经网络模型预测的成形角和回弹角平均误差分别减小至0.150°和0.120°, 总计算耗时大幅缩短至0.8 min。

因此, 本文提出的基于DPSO-BP神经网络预测模型具有高预测精度和良好的计算效率。由于本文试验得到的训练样本仅有45个, 故出现个别预测误差较大的现象, 后续积累更多的试验样本数据可进一步提高神经网络预测模型的预测精度。

4 结语

本文通过引用非线性惯性权重法改进PSO算法, 构建了基于DPSO-BP神经网络算法的预测模型。该模型以屈服强度与弹性模量之比 R_{eL}/E 、板料厚度 t 、上模圆角半径 r 、下模开口宽度 V 和上模下压量 D 为输入, V形自由折弯成形角和回弹角为输出。以不同批号的不锈钢板料为研究对象, 使用正交试验得到的45个样本数据对所建模型进行训练, 并试验验证。结果表明: 采用DPSO-BP神经网络模型预测的成形角和回弹角平均误差分别为0.150°和0.120°, 与未优化的PSO-BP神经网络模型相比, 成形角和回弹角的平均误差明显减小, 且计算耗时由14.0 min缩短至0.8 min, 同时实现了高预测精度和高计算效率。

参考文献:

- [1] Leu D K, Zhuang Z W. Springback prediction of the vee bending process for high-strength steel sheets [J]. Journal of Mechanical Science and Technology, 2016, 30 (3): 1077-1084.
- [2] Li H Z, Dong X H, Shen Y, et al. Size effect on springback behavior due to plastic strain gradient hardening in microbending process of pure aluminum foils [J]. Materials Science and Engineering: A, 2010, 527 (16-17): 4497-4504.
- [3] Jiang Z Q, Yang H, Zhan M, et al. Coupling effects of material properties and the bending angle on the springback angle of a titanium alloy tube during numerically controlled bending [J]. Materials & Design, 2010, 31 (4): 2001-2010.
- [4] 王飞, 游有鹏. 钣金 V 形折弯回弹影响因素的有限元分析 [J]. 沈阳工业大学学报, 2012, 34 (5): 526-529, 535.
Wang F, You Y P. Finite element analysis on influencing factors of springback in sheet metal V-bending [J]. Journal of Shenyang University of Technology, 2012, 34 (5): 526-529, 535.
- [5] Trzepieciński T, Lemu H G. Prediction of springback in V-die air bending process by using finite element method [A]. Proceedings of Matec Web of Conferences [C]. Shanghai, 2017.
- [6] 高云亮, 缪卫东, 冯昭伟, 等. M 型 Ti-Ni 合金血管支架的结构设计对性能的影响 [J]. 稀有金属, 2017, 41 (8): 936-942.
Gao Y L, Miao W D, Feng Z W, et al. Influence of structural design of M type Ti-Ni alloy vascular stents on performance [J]. Chinese Journal of Rare Metals, 2017, 41 (8): 936-942.
- [7] Teimouri R, Baseri H, Rahmani B, et al. Modeling and optimization of spring-back in bending process using multiple regression analysis and neural computation [J]. International Journal of Material Forming, 2014, 7 (2): 167-178.
- [8] 刘晓宇, 陆小龙, 黄茜, 等. 基于 BP 神经网络的 W 形微弯曲回弹预测 [J]. 机械设计, 2019, 36 (10): 14-17.
Liu X Y, Lu X L, Huang X, et al. Prediction of the micro W-bending's springback based on the BP neural network [J]. Journal of Machine Design, 2019, 36 (10): 14-17.
- [9] 陈光耀, 李恒, 贺子芮, 等. 基于机器学习的管材弯曲回弹有效预测与补偿 [J]. 中国机械工程, 2020, 31 (22): 2745-2752.
Chen G Y, Li H, He Z R, et al. Effective prediction and compensation of springbacks for tube bending using machine learning approach [J]. China Mechanical Engineering, 2020, 31 (22): 2745-2752.
- [10] GB/T 228.1—2021, 金属材料 拉伸试验 第1部分: 室温试验方法 [S].
GB/T 228.1—2021, Metallic materials—Tensile testing—Part 1: Method of test at room temperature [S].
- [11] 管志平, 李金钊, 韦钦洋, 等. 基于 BPNN 神经网络的板材 V 型折弯回弹预测模型 [J]. 塑性工程学报, 2022, 29 (8): 1-10.
Guan Z P, Li J Z, Wei Q Y, et al. Prediction model of V-shaped bending springback of sheet metal based on BPNN neural network [J]. Journal of Plasticity Engineering, 2022, 29 (8): 1-10.
- [12] Fu Z M, Mo J H. Springback prediction of high-strength sheet metal under air bending forming and tool design based on GA-BPNN [J]. The International Journal of Advanced Manufacturing Technology, 2011, 53 (5): 473-483.
- [13] 闻新, 周露, 李翔, 等. MATLAB 神经网络仿真与应用 [M]. 北京: 科学出版社, 2003.
Wen X, Zhou L, Li X, et al. MATLAB Neural Network Simulation and Application [M]. Beijing: Science Press, 2003.
- [14] Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators [J]. Neural Networks, 1989, 2 (5): 359-366.
- [15] Shi Y H, Eberhart R C. A modified particle swarm optimizer [A]. Proceedings of the IEEE International Conference on Evolutionary Computation [C]. Anchorage, 1998.
- [16] 张炎亮, 齐聪, 程燕培. 基于 DPSO-BP 的机械转子故障诊断 [J]. 机床与液压, 2022, 50 (19): 194-199.
Zhang Y L, Qi C, Cheng Y P. Fault diagnosis of mechanical rotor based on DPSO-BP [J]. Machine Tool & Hydraulics, 2022, 50 (19): 194-199.
- [17] Bansal J C, Singh P K, Saraswat M, et al. Inertia weight strategies in particle swarm optimization [A]. Proceedings of the Third World Congress on Nature and Biologically Inspired Computing [C]. Salamanca, 2011.