

机器学习耦合有限元分析预测板料气弯回弹行为

徐承亮¹, 张祥林², 王大军³

(1. 广州科技贸易职业学院 产业学院, 广东 广州 511442; 2. 华中科技大学 材料成形与模具技术国家重点实验室, 湖北 武汉 430074; 3. 重庆邮电大学 自动化学院, 重庆 400065)

摘要: 采用机器学习神经网络 (NN) 耦合有限元分析 (FEA) 的方法来构建弯曲成形过程的非线性回弹模型, 并且考虑了不同材料、工艺参数和模具几何形状, 可以有效和准确地预测工件的弯曲回弹行为。当模具开口量 $V=11\text{ mm}$ 、板料厚度 $t=3\text{ mm}$ 时, 对于结构钢 HC220 材料, 机器学习 NN 模型的预测值 (Y_{NN}) 与回弹后分析解 (y_{JBP}) 的均方根误差 $RMSE$ 分别为 0.28 和 1.70; 对于双相钢 DP590 材料, Y_{NN} 与 y_{JBP} 的 $RMSE$ 分别为 0.45 和 0.22。采用 NN 模型、回弹后分析解 (y_{JBP}) 和 FEA 方法的 CPU 计算时间分别为 3.1、6.3 和 278 s, NN 模型的 CPU 计算时间最少, 实验结果表明, NN 模型可以在良好的预测精度和高效的求解速度之间达到一个最佳平衡。

关键词: 空气辅助弯曲; 弯曲回弹; 机器学习; 神经网络; 有限元分析

DOI: 10.13330/j.issn.1000-3940.2022.06.015

中图分类号: TG302 **文献标志码:** A **文章编号:** 1000-3940 (2022) 06-0107-06

Springback behavior on sheet metal in gas bending predicted by machine learning coupled with finite element analysis

Xu Chengliang¹, Zhang Xianglin², Wang Dajun³

(1. Industry College, Guangzhou Vocational College of Technology and Business, Guangzhou 511442, China;

2. State Key Laboratory of Material Forming and Die Technology, Huazhong University of Science and Technology, Wuhan 430074, China;

3. College of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: A nonlinear springback model of bending process was constructed by machine learning neural network (NN) coupled finite element analysis (FEA), and considering different materials, process parameters and die geometry shapes, the bending springback behavior of workpiece could be predicted effectively and accurately. When the die opening amount $V=11\text{ mm}$ and the sheet thickness $t=3\text{ mm}$, for structural steel HC220 material, the root mean square errors $RMSE$ of prediction value (Y_{NN}) by machine learning NN model and analytical solution after springback (y_{JBP}) were 0.28 and 1.70 respectively. For dual-phase steel DP590 material, the $RMSE$ values of Y_{NN} and y_{JBP} were 0.45 and 0.22 respectively. The CPU calculation time of NN model, analytical solution after springback (y_{JBP}) and FEA methods were 3.1, 6.3 and 278 s respectively, and the NN model was of less CPU calculation time. The experimental results show that the NN model can achieve an optimal balance between good prediction accuracy and efficient solution speed.

Key words: air-assisted bending; bending springback; machine learning; neural network; finite element analysis

板料弯曲成形是一种应用广泛的基础成形工艺, 如空气辅助弯曲 (气弯)、压痕、弯管等^[1-2]。研究表明, 气弯工艺参数和弯曲行为之间表现出高度复杂的非线性关系, 且开发基于复杂工艺参数构建的非线性模型非常困难^[3]。基于简化的材料特性的有限元分析 (Finite Element Analysis, FEA) 是一种工

程中实际应用的非线性数值模拟方法^[4-6], 但是使用 FEA 方法需要构建复杂的有限元模型, 且调整有限元模拟参数进行计算的过程非常耗时。

机器学习神经网络 (Neural Network, NN) 方法能够克服工程中涉及的非线性和多参数带来的限制, 可以用来替代常规的分析方法^[7-10], NN 方法使用数据来调整模型参数, 但是获取机器学习的数据需要进行各种弯曲实验^[11-13], 而弯曲实验通常会耗费昂贵的时间资源, 因此, 越来越多的研究者将 FEA 方法产生的高质量数据用于机器学习建模。如 Miranda S S 等^[14]利用 FEA 方法和实验数据分析了 NN 方法在弯曲回弹建模中的应用, 并预测了回弹角和冲头位移; Fu Z 等^[15]研究了 NN 方法在弯曲零件上的应用, 利用

收稿日期: 2022-02-16; 修订日期: 2022-05-18

基金项目: 广东省普通高校特色创新项目 (自然科学类) (2018GKTSCX053); 2021 年度广州市基础与应用基础研究项目 (2021-02-08-13-0018); 材料成形与模具技术国家重点实验室基金资助项目 (P2021-016)

作者简介: 徐承亮 (1970-), 男, 硕士, 高级工程师, 副教授

E-mail: 281552074@qq.com

遗传算法优化了 NN 方法的权值,使得预测值与实验值之间的误差最小;Narayanasamy R 和 Padmanabhan P^[16]比较了回归模型和神经网络,根据冲头压下量、速度、几何和材料等数据预测回弹角;Sharad G 等^[17]通过实验数据开发的机器学习和有限元模型,研究了冲头压下量对回弹角的影响。目前的研究大多集中在回弹问题上,但回弹前的弯曲成形过程也是需要考虑的,因为回弹与弯曲零件上的应力分布密切相关。

本文研究的机器学习神经网络 (NN) 方法所需的数据来源于气弯过程的数值模拟,其目的为训练 NN 以预测获得指定弯曲角度所需的冲头位移,通过研究两种不同的材料,生成了较大的数据集,并提高了使用 NN 方法的泛化性能。最后,采用实验方法验证了所研究模型和方法的可靠性。

1 空气辅助弯曲工艺

空气辅助弯曲 (气弯) 工艺为压力机制动器弯曲过程中的一种工艺方法,工件往往具有较长的尺寸,这种弯曲工艺的主要优点为:如果充分控制冲头位移即压下量 Y_p ,则可以使同一套工具 (冲头和模具) 获得不同的弯曲角度,如图 1 所示。主要工艺参数包括:模具开口量 V ,冲头位移即压下量 Y_p ,板料厚度 t 和弯曲角度 α 。




图 1 气弯工艺参数示意图

Fig. 1 Schematic diagram of gas bending process parameters

冲头位移即压下量 Y_p 是决定弯曲和回弹的基本工艺参数,需要加以控制以获得足够精确的弯曲角度,这涉及模具几何结构、板料厚度以及材料性能。现代压力折弯机通常配备有计算机数控技术,可以控制冲头压下量,但仍然需要能够预测成形和回弹的模型,并决定最终的几何形状^[17],从而构建工艺参数之间相互作用的非线性关系。

2 机器学习耦合有限元分析

2.1 机器学习神经网络 (NN) 模型

机器学习神经网络 (NN) 模型包括数据输入

层、网络隐含层以及求解变量的输出层。在本文的应用中,NN 模型包括 3 个输入:模具开口量 V 、板厚度 t 、弯曲角度 α , 1 个输出:冲头位移即压下量 Y_p ,如图 2 所示。由于存在回弹效应,冲头位移即压下量 Y_p 需要考虑弯曲角度 α 不增加或增加两种情况,即不考虑回弹时的压下量 Y_p 或考虑回弹时的压下量 Y_{SB} ,如图 2 所示。




图 2 机器学习神经网络模型原理

Fig. 2 Principle of machine learning neural network model

实验中使用训练集以调整网络隐含层节点的数量,以及节点之间的权重值,这些训练集包括有限元分析 (FEA) 获得的输入集 $(V, t, \alpha)^{Train}$,以及所对应的输出集 Y_p^{Train} ,测试阶段包括评估机器学习神经网络的输出集 Y_p^{Test} 和测试数据集对应的期望输出之间的平均均方误差 MSE ,以评估所开发的机器学习神经网络模型的泛化能力。

2.2 数据集

表 1 为 FEA 研究案例组合的统计数据表,由此产生的模拟结果将作为 NN 模型中的数据集。实验定义了两种不同的材料,即结构钢 HC220 和双相钢 DP590,对于不同的模具开口 V 、板料宽度 b ,输出冲头位移 (压下量) Y_p 的模拟值,对于每个 V 和 t 值,产生冲头压下量 Y_p 和所对应的弯曲角度 α 。通过 FEA 模拟可获得 300 个样本,其中,100 例用作训练集。表 1 统计了这些 FEA 模拟数据样本的最大值、最小值、平均值、标准偏差和方差等。

表 1 FEA 研究案例组合的统计数据结果

Table 1 Statistical data results of case portfolios studied in FEA

输出参数	统计数据				
	最大值	最小值	平均值	标准偏差	方差
模具开口 V/mm	50	10	26.4	3.2	4.3
板料宽度 b/mm	50	15	35.3	1.6	2.5
板料厚度 t/mm	6	0.5	3.2	1.2	1.5
冲头位移 Y_p/mm	16	2	8.7	1.4	1.8
弯曲角度 $\alpha/(\circ)$	178	84	113.2	5.7	8.2

2.3 有限元分析 (FEA)

由于实验中薄板弯曲件的宽度远大于厚度,因

此其弯曲过程即为一个平面应变过程。考虑有限元分析 (FEA) 模型是对称的, 因此, 实验中仅分析实际模型的 1/2, 其模具的几何参数如表 1 所示。实验中使用 ABAQUS 动态显式算法来分析弯曲过程, 采用六面体网格, 边界库仑摩擦因数为 0.15, 冲孔速度为 $20\text{ mm} \cdot \text{s}^{-1}$, 采用弹塑性准则分析不同弯曲条件下的模拟结果。另外, 为方便从数值模拟结果中获取所需结果, 编写了 Python 脚本以提取机

器学习 NN 模型所需的数据集, 例如冲头压下量、弯曲角度以及其他变量。对于回弹后分析解 (y_{JBP}), 在回弹之前的弯曲分析中使用输出数据库来创建新的模型, 并用于训练、测试和验证的数据集。图 3a 为有限元定义的几何和尺寸变量, 图 3b 为弯曲过程中的等效应力分布云图, 在该模型中考虑了适当的边界条件, 并考虑了基于应力、应变和位移的弹性回复。




图 3 有限元模型和分析结果
(a) 有限元定义的几何和尺寸变量 (b) 弯曲过程中的等效应力分布云图

Fig. 3 Finite element model and analysis results
(a) Geometric and dimensional variables defined by finite element (b) Cloud diagram of equivalent stress distribution during bending process

2.4 材料属性

弯曲过程中的材料性能具有重要作用, 会影响最终的几何形状。本文所研究的材料为不同抗拉强度等级的结构钢 HC220 和双相钢 DP590, 结构钢适用于大多数常见的应用情况, 如运输容器、储存贮存器和卷形型材, 双相钢可用于需要高强度材料的场合, 如高压容器、汽车零件或自行车框架, 上述两种材料的主要力学性能如表 2 所示^[18-19]。

表 2 结构钢 HC220 和双相钢 DP590 的力学性能
Table 2 Mechanical properties of structural steel
HC220 and dual-phase steel DP590

参数	结构钢 HC220	双相钢 DP590
弹性模量 E/GPa	210	210
泊松比 ν	0.3	0.3
屈服强度 R_{eL}/MPa	246	393
抗拉强度 R_m/MPa	375	261
伸长率 $A/\%$	35	26

3 结果与讨论

3.1 NN 训练、测试与验证

本文使用 Levenberg-Marquardt 最小化优化算法来调整隐含层的各种组合, 以确定适合当前数据的 NN 结构的大小, 实验开始时对输入值进行归一化

处理, 并测试 NN 学习参数的各种组合。图 4 为训练、测试、验证数据集的标准化学习误差最小化迭代过程, 纵坐标对应 800 次迭代过程中的训练、测试和验证数据集的均方误差 (MSE), 其中迭代 308 次即可以获得最小的 MSE 值, 为 1.1005×10^{-5} 。完成学习训练的条件为基于验证集和测试集的 MSE 值最小, 在训练过程中, 基于训练集的结果对 NN 节点之间的权重进行动态调整, 使 MSE 值最小, 在训练结束之后, 将机器学习 NN 模型的计算结果与有限元分析 (FEA) 数据和回弹后分析解 (y_{JBP}) 进行比较, 以评价机器学习 NN 模型的性能。




图 4 训练、测试、验证数据集的标准化学习均方误差最小化迭代过程
Fig. 4 Minimization iterative process of standardized learning mean square error for training, testing and verifying data sets

3.2 预测冲头压下量与弯曲角度

弯曲过程结束并释放冲头后, 工件将获得最终的弯曲角度, 由于存在弹性变形, 工件将进行一定程度的弹性回复。图 5 为机器学习 NN 模型预测冲头位移即压下量 Y_p 以及弯曲角度 α 的结果, 即冲头位移-弯曲角度曲线, 其中, Y_{sim} 为有限元模拟的数据, Y_{NN} 为机器学习 NN 模型预测的结果, y_{JBP} 为回弹后分析解。如图 5a 和图 5b 所示, 采用结构钢 HC220 和双相钢 DP590 材料, 模具开口量 $V=16\text{ mm}$, 板料厚度 $t=3.0\text{ mm}$, 基于测试

集数据, 可以看出, 较高的冲头压下量对应较小的弯曲角度, 结构钢 HC220 材料和双相钢 DP590 材料的机器学习 NN 模型均能够获得较好的验证精度, 其中, 由冲头压下量误差引起的最大弯曲角误差为 2.6° 、最小弯曲角误差为 0.4° ; $V=40\text{ mm}$ 、 $t=5.0\text{ mm}$ 时, 如图 5c 和 5d 所示, NN 模型预测曲线与结构钢 HC220 和双相钢 DP590 的有限元模拟的曲线非常接近。这些结果表明, 基于 NN 模型求解的结果更接近真实的气弯过程, 并获得了更高的精度。

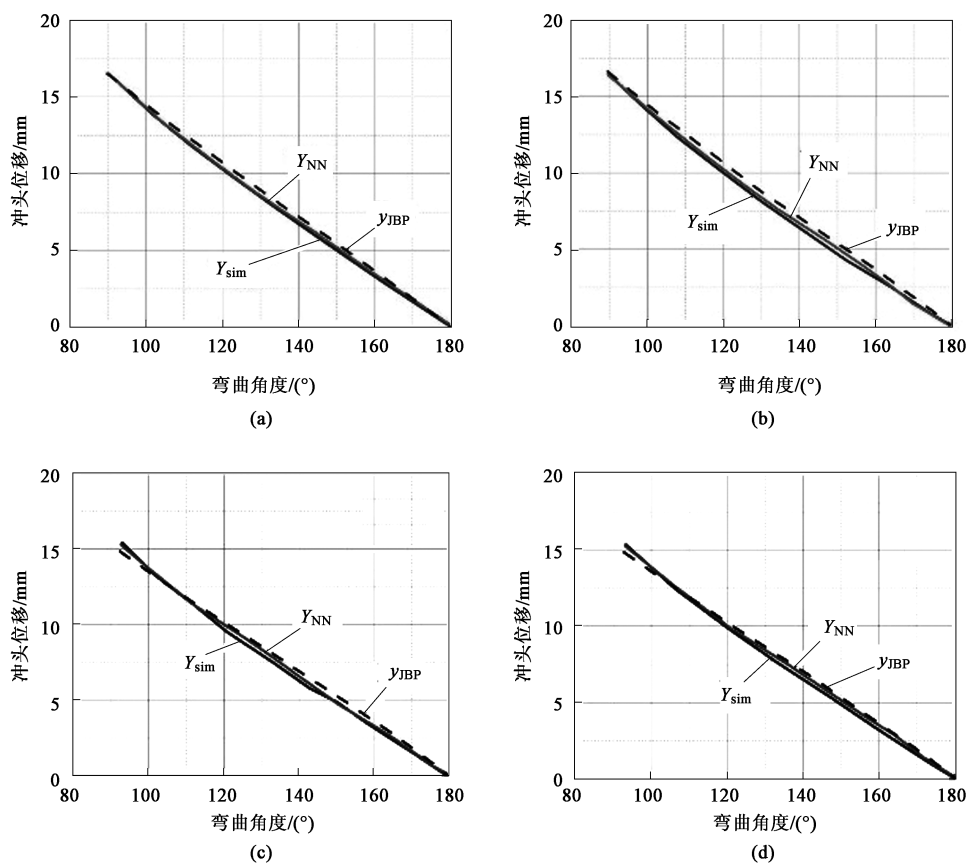


图 5 结构钢 HC220 和双相钢 DP590 材料的冲头位移-弯曲角度曲线

(a) HC220, $V=16\text{ mm}$, $t=3.0\text{ mm}$ (b) DP590, $V=16\text{ mm}$, $t=3.0\text{ mm}$ (c) HC220, $V=40\text{ mm}$, $t=5.0\text{ mm}$
(d) DP590, $V=40\text{ mm}$, $t=5.0\text{ mm}$

Fig. 5 Punch displacement-bending angle curves for structural steel HC220 and dual-phase steel DP590

3.3 实验验证

图 6a 为实验用的气辅折弯机, 每一次弯曲过程都是通过控制数控折弯机的连续冲头压下量并测量每个工件的弯曲角度来完成的, 记录并绘制每次弯曲过程中的冲头位移即压下量与弯曲角度的关系以及冲头释放后的回弹角度。图 6b、图 6c 和图 6d 分别为冲头和坯料的初始接触、弯曲后的零件和回弹后的零件。

对机器学习 NN 模型、有限元模拟和回弹后分

析解 (y_{JBP}) 3 种方法获得的结果进行比较, 以对所提出的机器学习 NN 模型进行评估, 结构钢 HC220 和双相钢 DP590 材料的弯曲角度随冲头压下量的变化曲线分别如图 7a 和图 7b 所示, 其中, $V=11\text{ mm}$, $t=3\text{ mm}$, 冲头圆角半径为 1 mm 。从图 7 中可以看出, 有限元模拟结果 Y_{sim} 、机器学习 NN 模型预测结果 Y_{NN} 的弯曲角度数值和通过实验测试获得的实验值结果吻合较好, 而由回弹后分析解 y_{JBP} 定义的弯




图 6 实验设备、模具和零件
(a) 气辅折弯机 (b) 冲头与坯料的初始接触
(c) 弯曲后的零件 (d) 回弹后的零件
Fig. 6 Experimental equipment, dies and parts
(a) Air-assisted pressure bending machine (b) Initial contact of punch and blank (c) Part after bending (d) Part after springback

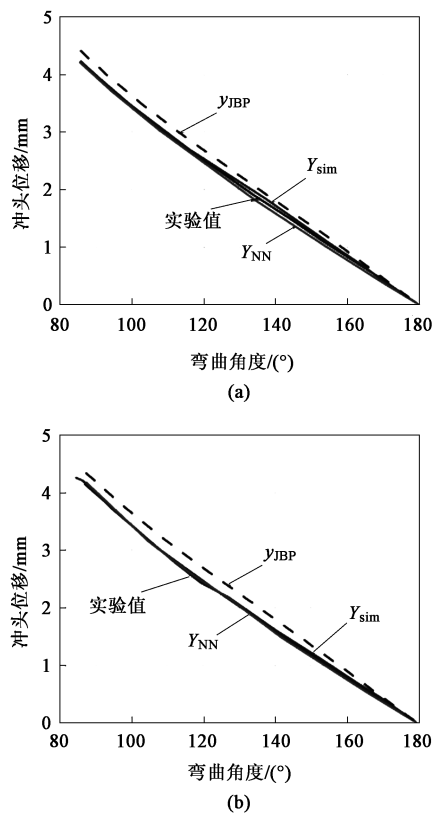


图 7 结构钢 HC220 (a) 和双相钢 DP590 (b) 的冲头位移-弯曲角度曲线
Fig. 7 Punch displacement-bending angle curves for structural steel HC220 (a) and dual-phase steel DP590 (b)

曲回弹曲线明显地偏离了实验和有限元模拟的曲线。另外，实验对这些不同方法的效率及其准确性进行了比较，基于使用的实验曲线和对冲头压下量的预

测，采用均方根误差 $RMSE$ 和 CPU 计算时间比较了不同的方法，对比结果如表 3 所示。

表 3 结构钢 HC220 和双相钢 DP590 材料的 Y_{sim} 、 Y_{NN} 和 y_{JBP} 的均方根误差 $RMSE$ 和 CPU 计算时间的对比
Table 3 Comparisons of root mean square errors $RMSE$ and CPU calculation time of Y_{sim} , Y_{NN} and y_{JBP} for structural steel HC220 and dual-phase steel DP590

方法	CPU 计算 时间/s	均方根误差 $RMSE$	
		结构钢 HC220	双相钢 DP590
有限元模拟 (Y_{sim})	278	0.10	0.18
机器学习神经网络模型(Y_{NN})	3.1	0.28	0.45
回弹后分析解 (y_{JBP})	6.3	1.70	0.22

从表 3 中可以看出：对于结构钢 HC220 材料， Y_{NN} 与 y_{JBP} 的 $RMSE$ 分别为 0.28 和 1.70， Y_{sim} 具有更低的 $RMSE$ 值，为 0.10；对于双相钢 DP590 材料， Y_{NN} 与 y_{JBP} 的 $RMSE$ 分别为 0.45 和 0.22，有限元模拟结果具有更低的 $RMSE$ 值，为 0.18。其中， Y_{NN} 和 y_{JBP} 的 CPU 计算时间分别为 3.1 和 6.3 s，机器学习 NN 方法的 CPU 计算时间最少，而有限元模拟最耗时，CPU 计算时间为 278 s。因此，机器学习 NN 模型在良好的预测精度和高效的求解速度之间达到最佳平衡。

表 4 为弯曲回弹的实验和有限元结果的对比。从表 4 中可以看出，对于结构钢 HC220 材料，实验测量的回弹前后的角度差为 4° ，有限元模拟的回弹前后的角度差为 3.9° ，两者相差 0.1° ；对于双相钢 DP590 材料，实验测量的回弹前后的角度差为 7.9° ，有限元模拟的回弹前后的角度差为 7.1° ，两者相差 0.8° ，结果说明，屈服应力较高的双相钢 DP590 材料具有较大的弯曲回弹倾向。该实验结果表明，有限元建模获得的数值求解结果具有良好的精度，进一步说明了有限元结果数据集用于预测冲头压下量（位移-弯曲角度）的机器学习 NN 模型的可靠性。

表 4 结构钢 HC220 和双相钢 DP590 在实验和数值模拟中获得的回弹角度
Table 4 Springback angles obtained in experiment and numerical simulation of structural steel H220 and dual-phase steel DP590

材料	方法	冲头位 移/mm	弯曲角度/($^{\circ}$)		回弹角 度/($^{\circ}$)
			回弹前	回弹后	
结构钢 HC220	实验	4	85.7	89.7	4.0
	有限元模拟	4	87.7	91.6	3.9
双机钢 DP590	实验	4	85.7	93.6	7.9
	有限元模拟	4	86.1	93.2	7.1

4 结语

本文提出一种根据神经网络 (NN) 耦合有限元分析 (FEA) 的空气辅助弯曲成形工艺的回弹预测方法, 其基于不同的弯曲成形工艺参数的 FEA 模拟来实现数据的获取。本文研究了两种不同强度的结构钢 HC220 和双相钢 DP590 材料的不同板料厚度和模具开口量下的 NN 求解方案。结果表明, 机器学习 NN 模型与有限元模拟以及通过实验获得的结果非常接近, 这表明基于 NN 求解的结果更接近真实的气弯过程, 并获得了更高的精度, 并且机器学习 NN 模型在良好的预测精度和高效的求解速度之间达到最佳平衡。总的来说, 机器学习 NN 模型所获得的结果是有效和准确的, 并且可以结合有限元模拟对气辅弯曲回弹加以控制。

参考文献:

- [1] 宋云鹤, 秦雪娇, 鲍益东. 基于 DKT12 壳单元的板料冲压成形中重力加载变形模拟仿真 [J]. 塑性工程学报, 2020, 27 (11): 65-69.
Song Y H, Qin X J, Bao Y D. Simulation of gravity loading deformation in sheet metal stamping based on dkt12 shell element [J]. Journal of Plasticity Engineering, 2020, 27 (11): 65-69.
- [2] Pacheco J B, Santos A D. A study on the nose radius influence in press brake bending operations by finite element analysis [J]. Key Engineering Materials, 2013, 554-557 (2): 1432-1442.
- [3] 丁立波, 李健东, 李明杰, 等. 高强钢辊弯成形过程中成形力的影响因素研究 [J]. 精密成形工程, 2021, 13 (4): 6-12.
Ding L B, Li J D, Li M J, et al. Study on influencing factors of forming force in roll bending process of high strength steel [J]. Precision Forming Engineering, 2021, 13 (4): 6-12.
- [4] 洪凯骏, 杜晟强, 咎祥. 不同背压方式对静液挤压过程影响的模拟研究 [J]. 精密成形工程, 2019, 11 (2): 17-21.
Hong K J, Du S Q, Min X. Simulation study on the influence of different back pressure on hydrostatic extrusion process [J]. Precision Forming Engineering, 2019, 11 (2): 17-21.
- [5] Nath U, Yadav V, Purohit R. Finite element analysis of AM30 magnesium alloy sheet in the laser bending process [J]. Advances in Materials and Processing Technologies, 2021, (3): 1-13.
- [6] 方刚, 陈祝, 雷丽萍. 非关联本构模型在铝合金板料成形有限元模拟中的应用 [J]. 塑性工程学报, 2021, 28 (6): 8-18.
Fang G, Chen Z, Lei L P. Application of uncorrelated constitutive model in finite element simulation of aluminum alloy sheet forming [J]. Journal of Plasticity Engineering, 2021, 28 (6): 8-18.
- [7] 熊文韬, 谢三山, 黄兆飞, 等. 基于神经网络遗传算法函数寻优与回弹补偿技术的某型汽车前幅拉延成形优化 [J]. 塑性工程学报, 2020, 27 (6): 8-12.
- Xiong W T, Xie S S, Huang Z F, et al. Optimization of drawing forming of front panel of an automobile based on neural network genetic algorithm function optimization and springback compensation technology [J]. Journal of Plasticity Engineering, 2020, 27 (6): 8-12.
- [8] Liu S, Xia Y, Shi Z. Deep learning in sheet metal bending with a novel theory-guided deep neural network [J]. Journal of Automatica Sinica, 2021, 8 (3): 565-581.
- [9] 张新艳, 郭鹏, 余建波. 应用深度强化学习的压边力优化控制 [J]. 哈尔滨工业大学学报, 2020, 52 (7): 9-13.
Zhang X Y, Guo P, Yu J B. Optimal control of blank holder force using deep reinforcement learning [J]. Journal of Harbin Institute of Technology, 2020, 52 (7): 9-13.
- [10] Ingarao G, Di Lorenzo R. Design of complex sheet metal forming processes: a new computer aided progressive approach [J]. International Journal of Material Forming, 2010, 3 (1): 21-24.
- [11] Le T T, Asteris P G, Lemonis M E. Prediction of axial load capacity of rectangular concrete-filled steel tube columns using machine learning techniques [J]. Engineering with Computers, 2021: 1-34.
- [12] 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): 8-13.
Chen G Y, Li H, He Z R, et al. Prediction and compensation of pipe bending springback based on machine learning [J]. China Mechanical Engineering, 2020, 31 (22): 8-13.
- [13] Ly H B, Le T T, Vu H L T, et al. Computational hybrid machine learning based prediction of shear capacity for steel fiber reinforced concrete beams [J]. Sustainability, 2020, 12 (7): 2709-2732.
- [14] Miranda S S, Barbosa M R, Santos A D, et al. Forming and springback prediction in press brake air bending combining finite element analysis and neural networks [J]. The Journal of Strain Analysis for Engineering Design, 2018, 53 (8): 584-601.
- [15] Fu Z, Mo J. 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.
- [16] Narayanasamy R, Padmanabhan P. Comparison of regression and artificial neural network model for the prediction of springback during air bending process of interstitial free steel sheet [J]. Journal of Intelligent Manufacturing, 2012, 23 (3): 357-364.
- [17] Sharad G, Nandedkar V M. Springback in sheet metal U bending-FEA and neural network approach [J]. Pracedia Materials Science, 2014, 6: 835-839.
- [18] El-Zeghayar M, Topper T, Bonnen J, et al. Effective strain-fatigue life of dual phase 590 steel [A]. Proceedings of the 12th International Conference on Fracture [C]. Ottawa, 2009.
- [19] Pham Q T, Kim Y S, Nguyen D T. Application/comparison study of a graphical method of forming limit curve estimation for DP590 steel sheets [J]. Journal of the Korean Society for Precision Engineering, 2019, 36 (9): 883-890.