

引用格式: 廉红珍, 陆春月. 基于数据驱动的 Al-Cu 合金多目标性能模型预测[J]. 航空材料学报, 2026, 46(3): 47-55.
LIAN Hongzhen, LU Chunyue. Data-driven multi-objective property model prediction in Al-Cu alloys[J]. Journal of Aeronautical Materials, 2026, 46(3): 47-55.

基于数据驱动的 Al-Cu 合金多目标性能模型预测

廉红珍^{1*}, 陆春月^{2*}

(1. 太原城市职业技术学院 机电工程系, 太原 030027; 2. 中北大学 机械工程学院, 太原 030051)

摘要: 铸造铝合金因其优异的力学性能广泛应用于航空航天、汽车等领域, 但传统合金设计面临成分空间庞大、试错实验成本高和成分与性能之间非线性关系难以预测的问题。本工作提出一种反向传播神经网络、主成分分析和遗传算法相结合的机器学习模型, 用于铸造铝合金的多目标性能预测。该模型通过反向传播神经网络非线性映射建立合金成分与性能的关系、主成分分析降维、遗传算法优化网络参数, 从而提升预测精度和训练效率。结果表明, 优化后的模型均方误差、决定系数和平均绝对误差分别为 36.28、0.91 和 2.44, 在极限抗拉强度、屈服强度和断后伸长率的实验验证中, 预测值与实验值控制在 $\pm 5\%$ 误差范围内, 具有较高预测精度, 证明该模型具有高效性与可靠性。

关键词: 铸造铝合金; 主成分分析; 反向传播神经网络; 遗传算法; 力学性能

doi: 10.11868/j.issn.1005-5053.2025.000023

CSTR: 32420.14.j.issn.1005-5053.2025.000023

中图分类号: V252.2

文献标识码: A

文章编号: 1005-5053(2026)03-0047-09

Data-driven multi-objective property model prediction in Al-Cu alloys

LIAN Hongzhen^{1*}, LU Chunyue^{2*}

(1. Department of Mechanical and Electrical Engineering, Taiyuan City Vocational College, Taiyuan 030027, China; 2. Mechanical Engineering College, North University of China, Taiyuan 030051, China)

Abstract: Cast aluminum alloys are widely used in aerospace, automotive and other industries due to their excellent mechanical properties. However, traditional alloy design faces challenges such as vast composition space, high costs of trial-and-error experiments and difficulty in predicting the nonlinear relationship between composition and properties. This paper proposes a machine learning model that combines backpropagation neural networks, principal component analysis, and genetic algorithms for multi-objective property prediction of cast aluminum alloys. The model establishes the relationship between alloy composition and properties through the nonlinear mapping of backpropagation neural networks, reduces dimensionality *via* principal component analysis, and optimizes network parameters using genetic algorithms—thereby improving prediction accuracy and training efficiency. The results show that the optimized model has mean squared error of 36.28, correlation coefficient of 0.91, and mean absolute error of 2.44. In the experimental verification of ultimate strength, yield strength, and elongation after fracture, the error between experimental values and predicted values is controlled within the range of $\pm 5\%$. This high prediction accuracy demonstrates the efficiency and reliability of the proposed model.

Key words: cast aluminum alloy; principal component analysis; backpropagation neural network; genetic algorithm; mechanical property

铸造铝合金因其具有优异的比强度, 已成为航空航天、汽车、船舶等工业领域的重要结构材料^[1-5]。这类铝合金不仅在高应力环境下具有优异的屈服

强度、极限抗拉强度、断后伸长率等力学性能, 还能通过适当的热处理^[6-7]、热变形^[8]和合金元素调整^[9-10], 进一步改善其综合性能。随着对轻量化与

高性能材料需求的增长,铸造铝合金的开发和优化已成为材料科学的研究热点。然而,由于铝合金性能受成分配比、热处理工艺及微观结构等多重因素影响,传统的实验和理论计算方法难以在多变量条件下准确预测其性能。为了提高研发效率,减少实验成本,数据驱动的智能预测模型逐渐成为研究的关键方向。

当前,基于神经网络的铝合金性能预测模型已被广泛应用。例如,李晓强等^[11]提出的径向基函数(radial basis function, RBF)神经网络在7050铝合金锻造力学性能预测中的应用显示出高收敛性和高精度,预测误差不超过6%,并且相较于反向传播(backpropagation, BP)神经网络, RBF模型预测精度显著提高。魏萌等^[12]利用BP神经网络对汽车用铝合金的锻造性能进行预测,结果表明极限抗拉强度和磨损体积的平均相对误差分别为3.86%和3.67%,显示出较高的预测精度。崔鑫等^[13]引入粒子群算法(particle swarm optimization, PSO)优化BP神经网络,建立PSO-BP模型,对5083铝合金的流变应力进行精确预测,结果表明PSO-BP模型的预测误差小于BP模型的50%,收敛速度是BP模型的10倍以上。除神经网络模型外,机器学习的其他算法也在铝合金性能预测中得到应用。例如,王硕等^[14]在对6000系铝合金导电率和强度预测中,采用支持向量机(support vector machine, SVM)、随机森林(random forest, RF)、深度神经网络(deep neural network, DNN)等5种机器学习算法,发现DNN模型表现出最佳预测效果,其预测精度和泛化能力均显著优于其他模型。此外,李婷^[15]利用RF、极端树(extreme tree, ET)、Bagging、Adaboost等集成学习方法,构建铝合金极限抗拉强度预测模型,结果表明RF模型具有最佳预测能力,决定系数 R^2 达到0.89,平均绝对误差(mean absolute error, MAE)为40.33。

在合金成分优化方面,研究人员通过机器学习和材料基因组工程技术,优化铝合金成分。例如,张普^[16]基于Kriging模型和高效全局优化(efficient global optimization, EGO)算法,通过4次迭代优化出力学性能优良的2xxx系铝合金,经过铸造、固溶及时效处理,极限抗拉强度达到367 MPa,当Cu、Mg、Mn、Y、Ti元素成分范围分别为4.0%(质量分数,下同)~4.5%、0.2%~1.3%、0.4%~1.0%、0%~0.025%和0.1%~0.13%时,该合金具有较好的极限抗拉强度。定巍等^[17]通过半监督学习模型对铝合金成分-屈服强度和成分-抗腐蚀性能

数据进行扩充,并采用得到的完整数据集进行有监督学习,结果表明模型预测的性能数据与真实数据相差不超过10%,该模型具备较高的可靠性和实用性。

在多种机器学习方法中,BP神经网络因其强大的非线性映射能力,尤其适用于处理高维度复杂数据问题,已被广泛应用于材料性能预测^[18-19]。然而,传统BP神经网络在训练过程中存在明显弊端,极易陷入局部最优解,并且对初始权值和阈值极为敏感,这会直接降低模型预测精度,严重限制收敛速率。面对铸造铝合金多变量的性能影响因素,该方法难以准确预测可靠结果。

为有效解决传统BP神经网络存在的问题,本工作提出一种基于主成分分析(principal component analysis, PCA)降维和遗传算法(genetic algorithm, GA)优化的BP神经网络模型。PCA作为常用的数据降维方法^[20],能够在保留数据主要特征的基础上,大幅削减输入维度,去除铝合金成分配比、微观结构等多维特征中的冗余信息,为BP神经网络提供更为精炼的数据。GA模拟生物进化机制,能够在全局范围内搜索最优解,避免陷入局部最优困境^[21]。将PCA、GA与BP神经网络有机结合^[22],既能优化神经网络的初始参数,又能显著提升模型的全局搜索能力与泛化能力。该模型旨在精准预测铸造铝合金极限抗拉强度、屈服强度等关键力学性能,为铸造铝合金的开发与优化提供高效且准确的预测工具,助力相关工业领域在材料研发与应用层面实现突破。

1 预测方法

1.1 数据收集与处理

1.1.1 数据收集

数据收集是模型构建和性能预测的关键环节,其质量直接关乎模型的可靠性与预测的准确性。本工作铸造铝合金的实验数据主要源自公开的材料数据库和已发表的文献,共75组数据。从数据分布来看,主要以Al-Cu-Mg合金为主。数据集涵盖14种铝合金化学成分的输入特征,以及与之对应的极限抗拉强度(ultimate tensile strength, UTS)、屈服强度(yield strength, YS)和断后伸长率(elongation after fracture, EL)3种拉伸性能指标的输出标签,合金化学成分如表1所示。

1.1.2 数据预处理

为了提高数据质量,保证模型的准确性以及

表1 Al-Cu-Mg 合金化学成分范围(质量分数/%)
Table 1 Chemical composition range of Al-Cu-Mg alloys(mass fraction/%)

Cu	Mg	Sc	Zr	Ag	Si	Ti	Fe	Cr	Ni	Mn	Zn	Li	Al
0-6.5	0-2.5	0-0.62	0-0.41	0-0.4	0-0.07	0-0.26	0-0.09	0-0.8	0-1.5	0-0.62	0-0.01	0-1.13	Bal.

预测效率,需要对收集的数据进行预处理。首先需要对数据中噪声数据(异常值)进行清除;其次为了避免某些特征因数值较大而在训练过程中对模型产生不必要的影响,本工作使用标准化处理,将不同特征的取值范围缩小到相同尺度,如式(1)所示:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中: x 和 x' 分别是原始特征和归一化的特征; x_{\max} 和 x_{\min} 分别表示原始特征的上下限。

1.1.3 特征筛选

为了从原始数据中挑选出对模型预测最有用的特征,去除冗余、无关或噪声特征,本工作使用主成分分析来实现输入特征的筛选。主成分分析是一种广泛用于数据降维的统计技术,尤其在高维数据中有重要应用^[23]。其核心思想是通过线性变换,将原始数据投影到一个新的坐标系中,使得投影后数据尽可能保留原始数据的方差。这种降维方法不仅能够简化数据结构,还能在一定程度上消除噪声、减少冗余信息,从而使后续分析更加高效。通常,保留累计方差达到 90% 或 95% 的主成分能在减少信息损失的前提下,大幅降低数据维度^[24]。数据预处理和 PCA 共同作用,可以有效提高模型的效率和准确性,从而在复杂数据集中表现出稳定性和鲁棒性。

1.2 遗传算法优化反向传播神经网络

为了实现铸造铝合金的多目标输出预测(包括极限抗拉强度、屈服强度和断后伸长率),选择搭建反向传播神经网络回归模型,通过在输出层设置多个神经元,分别预测每个目标值。在训练过程中,结合每个目标的损失函数,使用梯度下降方法更新网络权重。最终,网络能够同时优化多个目标回归任务的预测结果。

反向传播神经网络是一种常见的多层前馈神经网络,通过反向传播算法对权重和偏置进行迭代优化。对于输出特征多的回归问题,损失函数可以定义为均方误差(mean squared error, MSE),其表达式为式(2)^[25-26]:

$$\text{MSE}(\theta) = \frac{1}{n} \sum (y_i - \hat{y}_i)^2 \quad (2)$$

式中: y_i 是第 i 个样本真实值; \hat{y}_i 是 BP 神经网络预测值; θ 代表网络的参数集合; n 是样本数量。BP 神经网络通过误差函数计算输出误差,并通过梯度下降法逐层传播误差,从而更新网络中权重和偏置,更新公式为式(3)和式(4)^[25-26]:

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} - \eta \frac{\partial L(\theta)}{\partial w_{ij}^{(t)}} \quad (3)$$

$$b_j^{(t+1)} = b_j^{(t)} - \eta \frac{\partial L(\theta)}{\partial b_j^{(t)}} \quad (4)$$

式中: $w_{ij}^{(t+1)}$ 和 $w_{ij}^{(t)}$ 分别是第 $(t+1)$ 次和第 t 次迭代连接第 i 个和第 j 个神经元的权重; $b_j^{(t+1)}$ 和 $b_j^{(t)}$ 分别是第 $(t+1)$ 次和第 t 次迭代第 j 层的偏置项; η 是学习率; $L(\theta)$ 是 BP 神经网络的损失函数。然而,传统的 BP 算法易于陷入局部最优解,且对初始权重和学习率较为敏感。为了解决这些问题,将 BP 神经网络与遗传算法相结合,能够有效提高网络的全局搜索能力^[12,27]。

遗传算法是一种模拟自然选择和遗传机制的优化算法,其核心思想是通过选择、交叉、变异等操作产生具有优良特性的下一代个体。在 BP 神经网络中,遗传算法可以用于优化神经网络的初始权重、偏置参数、学习率等超参数。具体流程:首先,利用遗传算法生成不同个体(神经网络结构或参数设置)的初始种群,通过适应度函数(均方误差或绝对误差)评价每个个体的性能;然后,通过选择操作保留适应度较高的个体,进行交叉和变异操作生成新的个体。经过多代进化后,遗传算法可以找到较优的网络结构和参数组合,从而避免 BP 神经网络陷入局部最优解。

BP 神经网络与遗传算法结合具有多项优势^[28-30]。首先,遗传算法的全局搜索能力能够弥补 BP 神经网络梯度下降法在复杂问题中的局部优化缺陷;其次,遗传算法可以同时优化多个超参数,如学习率、神经元数量、网络层数等,提高模型整体表现;最后,遗传算法作为一种无梯度优化方法,可以在 BP 神经网络遇到非连续或复杂误差面时,依然保持较强的优化能力。因此,BP 神经网络与遗传算法结合为复杂非线性系统的建模与优化提供有效的解决方案。

2 结果与讨论

2.1 输入特征对输出标签的影响

PCA 在数据处理中具有重要作用,它通过转换原始特征到一个新的正交坐标系(主成分),有效减少数据冗余并消除特征之间的共线性问题。同时,PCA 能够去除高维数据的噪声和无关信息,提高数据质量。通过仅保留方差较大的主成分,PCA 不仅降低噪声影响,还能在降维过程中提高数据整体质量。此外,PCA 通过减少特征数量、限制模型自由度,有效降低过拟合风险,从而提升模型的泛化能力,特别是在数据集较小且特征维度较高的情况下,PCA 的优势尤为突出。

为保证最大程度降低数据维度且不减少信息损失,本工作保留累计方差达到 95% 的主成分,即由原来的 14 个输入特征通过降维最终映射为 8 个输入特征,如图 1 所示。




图 1 主成分分析后特征方差比重图

Fig. 1 Diagram of feature variance proportion after PCA

在模型中虽然使用主成分分析保留数据的大部分方差信息,但是将原始特征转换为新的主成分并不具有直接的物理意义,而且还难以直观理解它们对预测标签的影响。因此,选择采用沙普利可加解释(shapley additive explanations, SHAP)分析来评估输入特征的重要性和影响力。SHAP 分析可以为所有特征计算出一个平均的重要性得分,通过对所有样本的 SHAP 值进行汇总或平均,可以得到每个特征的全局重要性排名。这一结果可以发现哪些特征在模型中对预测结果具有重要影响,从而整体认识模型。

在图 2(a-1)~(c-1)中,特征变量和目标性能之间的关系不是简单的直线关系,而且不同特征之间还会相互影响。图 2(a-2)~(c-2)所示为特征重要性分数,进一步对各元素特征的贡献权重进行量化。综合分析图 2 可知:Al 元素以 6.5902 的最高

得分,成为影响极限抗拉强度的核心关键因素,其细微变动都可能对极限抗拉强度产生显著影响。Sc、Mn 元素的重要性得分亦相对较高,相较之下,Ni、Li、Zn 元素对 UTS 的影响几乎可忽略不计。对于屈服强度来说,Cu、Al、Mg 元素是影响 YS 的重要因素,而 Ni、Li、Zn 元素的重要性得分近乎为零,对屈服强度的影响微乎其微。对于断后伸长率,Al 元素是影响 EL 的关键特征。Sc、Zr 元素的重要性得分相对较低,分别为 0.1532 和 0.1443,对断后伸长率存在一定程度的影响。与极限抗拉强度和屈服强度情况类似,Ni、Li、Zn 元素对断后伸长率的影响十分微弱。

2.2 BP 神经网络实现性能预测

BP 神经网络建模过程中,首先对原始数据进行 PCA 降维处理,选取累积方差达到 95% 的前 8 个主成分。这些主成分既保留数据中的主要信息,减少冗余和噪声,又有效降低模型复杂度,为后续建模提供简化而充分的输入特征。

在铝合金性能预测中,为实现精准预测铝合金极限抗拉强度、屈服强度以及断后伸长率这些多目标,选用 BP 神经网络模型与随机森林模型。这两种模型能够有效捕捉数据中的非线性关系,筛选出最适配铝合金性能预测的最佳模型。经过反复训练,获得训练集与预测集中极限抗拉强度、屈服强度以及断后伸长率真实值与预测值对比结果,如图 3~图 5 所示。无论训练集还是测试集,随机森林和经 PCA 降维的 BP 神经网络对铝合金 UTS、YS 和 EL 的预测值,均与真实值的波动趋势高度贴合,偏差较小。在训练集中,未经 PCA 降维的 BP 神经网络出现部分样本的明显偏差;对于测试集,未经 PCA 降维的 BP 神经网络与真实值偏差进一步增大。因此,PCA 降维既简化了 BP 神经网络的复杂度,也提升了其在训练集和测试集的预测精度。

在模型构建完成后,采用 MSE、平均绝对误差(mean absolute error, MAE)、 R^2 等评估指标来衡量模型的预测性能,得到结果见表 2。

通过对比 BP 神经网络模型和随机森林的训练结果,经 PCA 降维的 BP 神经网络在评估指标上均表现出更优异的性能。在筛选铝合金性能预测模型时,表 2 中 MSE 越小,预测精度越高;MAE 越小,预测值越接近真实值; R^2 越接近 1,拟合精度越高。随机森林、经 PCA 降维和未经 PCA 降维的 BP 神经网络 MSE 分别为 217.51、180.21 和 189.07,其中,经 PCA 降维的 BP 神经网络 MSE 最小,预测精度最高。随机森林、经 PCA 降维和未经 PCA

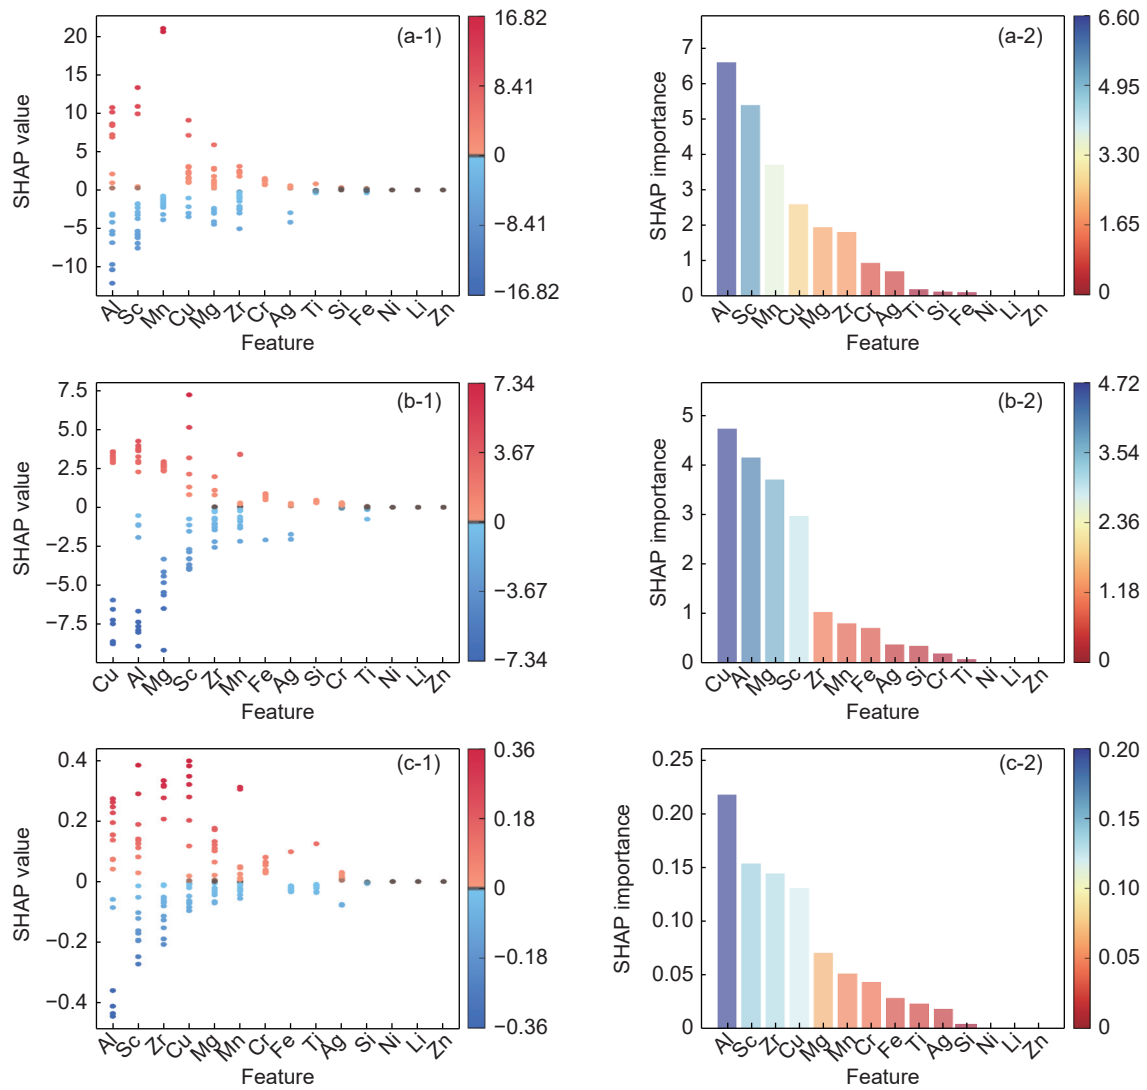


图 2 不同输入特征对输出标签的 SHAP 值分析 (a)极限抗拉强度; (b)屈服强度; (c)断后伸长率; (1)SHAP 值; (2)重要性分析

Fig. 2 SHAP value analysis of the output labels with different input features (a) UTS; (b) YS; (c) EL; (1) SHAP values; (2) importance analysis

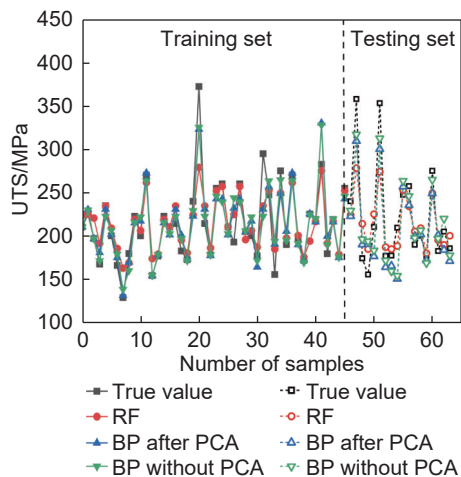


图 3 极限抗拉强度真实值与预测值对比

Fig. 3 Comparison between true and predicted values of UTS

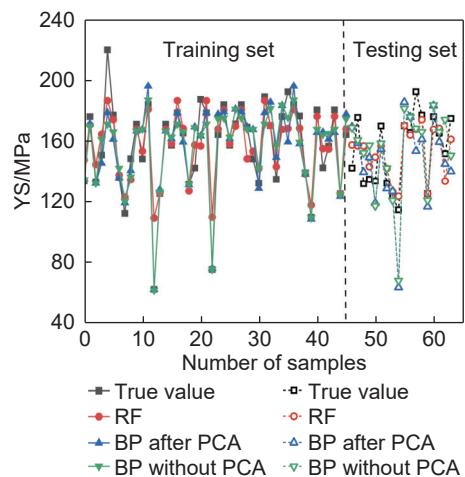


图 4 屈服强度真实值与预测值对比

Fig. 4 Comparison between true and predicted values of YS

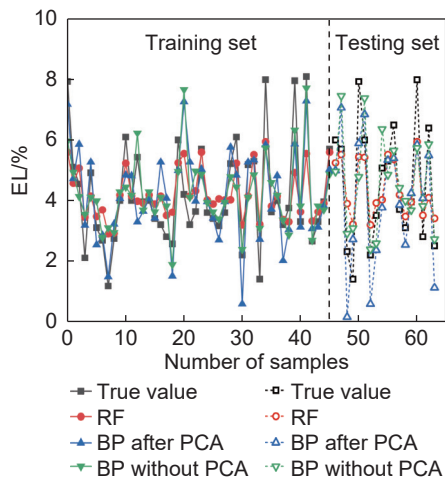


图 5 断后伸长率真实值与预测值对比

Fig. 5 Comparison between true and predicted values of EL

表 2 不同预测模型评估指标结果

Table 2 Results of evaluation indicators in different predicted models

Predicted model	MSE	MAE	R^2
RF	217.51	7.83	0.71
BP after PCA	180.21	7.66	0.73
BP without PCA	189.07	7.65	0.72
GA and BP	36.28	2.44	0.91

降维的 BP 神经网络的 MAE 分别为 7.83、7.66 和 7.65, 其中, 未经 PCA 降维的 BP 神经网络的 MAE 最小, 经 PCA 降维的 MAE 与之相近, 二者均优于随机森林。随机森林、经 PCA 降维和未经 PCA 降维的 BP 神经网络的 R^2 分别为 0.71、0.73 和 0.72, 其中, 经 PCA 降维的 BP 神经网络的 R^2 最接近 1, 拟合效果最好。综合对比, 经 PCA 降维的 BP 神经网络在评估指标上表现出色, 整体预测性能最佳, 是铝合金性能预测的优选模型。

通过对上述评估指标的综合分析, 可以确认 PCA 与 BP 神经网络相结合, 模型预测精度和泛化能力得到有效提升, 尤其在多目标任务预测中展现较强的适应性和优越性。这表明经 PCA 降维的 BP 神经网络模型不仅有效减少冗余特征, 而且在实际应用中高效、精准地预测力学性能。

2.3 遗传算法实现全局优化

采用 PCA 对数据集进行降维后, 在后续模型训练过程会出现过拟合风险, 而且模型总体预测精度并未达到最佳。因此, 引入 GA 对 BP 神经网络进行全局优化, 构建 PCA-BP-GA 模型, 得到结果如图 6~图 8 所示。由图可知, 在训练集中, 该模型预测值与真实值的变化趋势高度吻合, 二者偏差始终




图 6 优化后极限抗拉强度真实值与预测值对比

Fig. 6 Comparison between true and predicted values of UTS after optimization

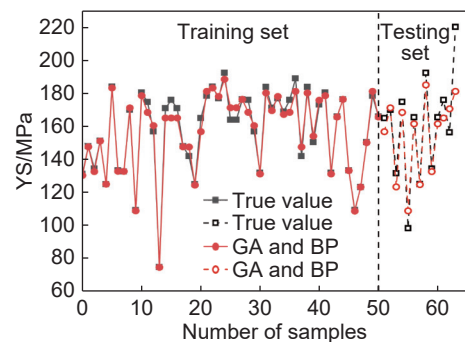


图 7 优化后屈服强度真实值与预测值对比

Fig. 7 Comparison between true and predicted values of YS after optimization




图 8 优化后断后伸长率真实值与预测值对比

Fig. 8 Comparison between true and predicted values of EL after optimization

维持在较小范围内。对于 UTS、YS 和 EL, 该模型的预测结果均能准确符合真实值的特征规律, 这表明遗传算法的全局寻优能力有助于 BP 神经网络充分学习数据的特征关联, 使模型在训练阶段实现良好的拟合效果。对于测试集, PCA-BP-GA 模型的预测值虽然存在小幅波动, 但与真实值变化规律保持一致, 未出现过拟合所导致的显著偏离。即使在部分样本的指标波动区间, 预测值也能稳定跟随真实值的变化趋势, 体现出较优的泛化能力。综上所述

述, PCA-BP-GA 模型不仅解决 PCA 降维后 BP 模型的过拟合风险, 同时在训练集拟合精度与测试集泛化稳定性方面均表现出更优异的性能, 验证了遗传算法对 BP 神经网络全局优化能力的作用, 为铝合金多性能指标的精准和稳定预测提供有效支撑。

传统的 BP 神经网络在训练过程中容易陷入局部最优解, 而遗传算法能够有效跳出局部极值点, 使模型搜索到更优的解。通过对比表 2 中各项评

估指标, 采用遗传算法全局优化后的神经网络, 不仅提升了回归预测的精度, 还增强了网络的泛化能力。

2.4 实验验证

通过上述数据预处理方法以及训练模型的优化算法, 整个模型的超参数及预测精度达到最佳状态。根据合金成分范围, 采用本工作构建的模型对表 3 所示的合金成分进行预测^[31-32], 并与实验值对比得到图 9 所示的结果。

表 3 用于验证模型的合金成分(质量分数/%)

Table 3 Alloy composition of verification model (mass fraction/%)

Model	Cu	Mg	Mn	Sc	Zr	Cr	Al
1 ^{#[31]}	4	1.5	0	0.5	0.2	0	Bal.
2 ^{#[31]}	4	1.5	0	0.2	0	0	Bal.
3 ^{#[31]}	4	1.5	0	0.3	0.1	0	Bal.
4 ^{#[31]}	4	1.5	0	0.3	0.2	0	Bal.
5 ^{#[32]}	6.5	0	0.5	0	0	0.6	Bal.

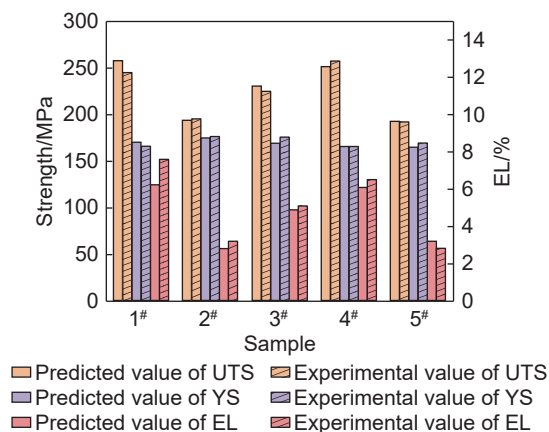


图 9 Al-Cu 铸态合金力学性能预测值与实验值对比

Fig. 9 Comparison between predicted and experimental values of the mechanical property in Al-Cu as-cast alloys

通过对比验证, 预测值与实验值始终保持在 $\pm 5\%$ 误差范围内, 由此得到此模型对于 Al-Cu 铸态合金力学性能具有较高预测精度。

3 结论

(1) 构建基于 BP 神经网络结合主成分分析和遗传算法优化的铸态铝合金力学性能预测模型。预测结果表明, 遗传算法与 BP 神经网络相结合的模型能够准确预测铸造铝合金的极限抗拉强度、屈服强度、断后伸长率等力学性能, 相比于传统的 BP 神经网络模型, 遗传算法的引入有效提升模型收敛速率和预测精度。通过实验对比验证, 模型预

测值与实验值误差在 $\pm 5\%$ 范围内。

(2) 遗传算法与 BP 神经网络相结合的模型克服 BP 神经网络陷入局部最优的缺点, 并在处理高维非线性问题中展现优势。该模型不仅为铸造铝合金的力学性能预测提供可靠工具, 还为未来材料设计和优化提供理论和实践依据。

参考文献:

- [1] AKHTAR N, AKHTAR W, WU S J. Melting and casting of lithium containing aluminium alloys[J]. *International Journal of Cast Metals Research*, 2015, 28(1): 1-8.
- [2] 王一唱, 袁灵洋, 杨磊, 等. Al-Zn 系高强铸造铝合金强韧化研究现状与展望[J]. *稀有金属材料与工程*, 2023, 52(11): 3954-3970.
WANG Y C, YUAN L Y, YANG L, et al. Strengthening-toughening of high-strength Al-Zn cast aluminum alloys: research progress and prospects[J]. *Rare Metal Materials and Engineering*, 2023, 52(11): 3954-3970.
- [3] NIU G D, WANG Y, ZHU L J, et al. Fluidity of casting Al-Si series alloys for automotive light-weighting: a systematic review[J]. *Materials Science and Technology*, 2022, 38(13): 902-911.
- [4] 何玄, 宋鹏, 孔德昊, 等. 机器学习技术在航空材料领域的应用[J]. *航空材料学报*, 2025, 45(3): 85-104.
HE X, SONG P, KONG D H, et al. Application of machine learning technology in field of aviation materials[J]. *Journal of Aeronautical Materials*, 2025, 45(3): 85-104.

- [5] 邢清源, 臧金鑫, 陈军洲, 等. 超高强铝合金研究进展与发展趋势[J]. *航空材料学报*, 2024, 44(2): 60-71.
XING Q Y, ZANG J X, CHEN J Z, et al. Research progress and development tendency of ultra-high strength aluminum alloys[J]. *Journal of Aeronautical Materials*, 2024, 44(2): 60-71.
- [6] ABOULKHAIR N T, MASKERY I, TUCK C, et al. The microstructure and mechanical properties of selectively laser melted AlSi10Mg: the effect of a conventional T6-like heat treatment[J]. *Materials Science and Engineering: A*, 2016, 667: 139-146.
- [7] MA K K, WEN H M, HU T, et al. Mechanical behavior and strengthening mechanisms in ultrafine grain precipitation-strengthened aluminum alloy[J]. *Acta Materialia*, 2014, 62: 141-155.
- [8] 张思平, 曹海龙, 吴锡伟, 等. 航空装备用 2014 铝合金高温变形行为研究[J]. *铝加工*, 2025(1): 42-46.
ZHANG S P, CAO H L, WU X W, et al. Research on high temperature deformation behavior of 2014 aluminium alloy for aviation equipment[J]. *Aluminium Fabrication*, 2025(1): 42-46.
- [9] YANG Z W, CHEN C, LI D, et al. An additively manufactured heat-resistant Al-Ce-Sc-Zr alloy: microstructure, mechanical properties and thermal stability[J]. *Materials Science and Engineering: A*, 2023, 872: 144965.
- [10] TUAN N Q. Effects of substituting ytterbium for scandium on the microstructure and properties of Al-Sc and Al-Mg-Sc alloys[D]. Braga: Universidade do Minho (Portugal), 2014.
- [11] 李晓强, 杜长林, 王俊, 等. 锻造 7050 铝合金力学性能的 RBF 神经网络预测模型[J]. *航天制造技术*, 2021(3): 15-18.
LI X Q, DU C L, WANG J, et al. Prediction of mechanical properties of forged 7050 aluminum alloy based on RBF neural network[J]. *Aerospace Manufacturing Technology*, 2021(3): 15-18.
- [12] 魏萌, 肖凌. 基于 BP 神经网络的铝合金锻造性能预测[J]. *热加工工艺*, 2021, 50(21): 105-107.
WEI M, XIAO L. Prediction of forging performance of aluminum alloy based on BP neural network[J]. *Hot Working Technology*, 2021, 50(21): 105-107.
- [13] 崔鑫, 张建平, 张能辉. 基于 PSO-BP 模型的 5083 铝合金力学性能预测[J]. *锻压技术*, 2019, 44(6): 183-187.
CUI X, ZHANG J P, ZHANG N H. Prediction of mechanical properties for 5083 aluminum alloy based on PSO-BP model[J]. *Forging & Stamping Technology*, 2019, 44(6): 183-187.
- [14] 王硕, 王俊升, 梁婷婷, 等. 高强、高导铝合金研发的机器学习策略[J]. *材料热处理学报*, 2023, 44(11): 27-34.
WANG S, WANG J S, LIANG T T, et al. Development of high-strength, high-conductivity aluminum alloys: a machine learning strategy[J]. *Transactions of Materials and Heat Treatment*, 2023, 44(11): 27-34.
- [15] 李婷. 基于不同机器学习算法的铝合金性能预测[J]. *有色设备*, 2023, 37(4): 66-71.
LI T. Prediction of aluminum alloy properties based on different machine learning algorithms[J]. *Nonferrous Metallurgical Equipment*, 2023, 37(4): 66-71.
- [16] 张普. 基于机器学习的 2xxx 系铝合金成分优化及组织与性能研究[D]. 成都: 西南交通大学, 2023.
ZHANG P. Study on machine learning-based composition optimization and microstructures and properties of 2xxx series aluminum alloys[D]. Chengdu: Southwest Jiaotong University, 2023.
- [17] 定巍, 苗以升, 张坛, 等. 基于半监督模型的铝合金性能预测与成分设计[J]. *邢台职业技术学院学报*, 2023, 40(5): 46-53.
DING W, MIAO Y S, ZHANG T, et al. The performance prediction and composition design of aluminum alloy based on semi-supervised model[J]. *Journal of Xingtai Polytechnic College*, 2023, 40(5): 46-53.
- [18] HART G L, MUELLER T, TOHER C, et al. Machine learning for alloys[J]. *Nature Reviews Materials*, 2021, 6(8): 730-755.
- [19] LIANG T T, WANG J S, XUE C P, et al. Design of high strength and electrically conductive aluminium alloys by machine learning[J]. *Materials Science and Technology*, 2022, 38(2): 116-129.
- [20] BUNDELA A S, RAHUL M R. Application of machine learning algorithms with and without principal component analysis for the design of new multiphase high entropy alloys[J]. *Metallurgical and Materials Transactions A*, 2022, 53(10): 3512-3519.
- [21] 魏雨晨, 李旭东, 刘治国, 等. 基于 GA-BP 神经网络的航空铝合金预腐蚀疲劳寿命预测[J]. *环境技术*, 2022, 40(5): 178-182.
WEI Y C, LI X D, LIU Z G, et al. Prediction of pre-corrosion fatigue life of aviation aluminum alloy based on GA-BP neural network[J]. *Environmental Technology*, 2022, 40(5): 178-182.
- [22] 丁凤娟, 贾向东, 洪腾蛟, 等. 基于 GA-BP 和 PSO-BP 神经网络的 6061 铝合金板材流变应力预测模型[J]. *稀有金属材料与工程*, 2020, 49(6): 1840-1853.
DING F J, JIA X D, HONG T J, et al. Flow stress prediction model of 6061 aluminum alloy sheet based on GA-BP and PSO-BP neural networks[J]. *Rare Metal Materials and Engineering*, 2020, 49(6): 1840-1853.
- [23] 王荣桥, 蒋康河, 胡殿印, 等. 基于主成分分析的镍基单晶高温疲劳寿命模型[J]. *航空动力学报*, 2016, 31(6): 1359-1367.

- WANG R Q, JIANG K H, HU D Y, et al. High temperature fatigue life model for single crystal nickel superalloy based on principal component analysis[J]. *Journal of Aerospace Power*, 2016, 31(6): 1359-1367.
- [24] 陈奎, 张天云, 郑小平, 等. 主成分分析法的改进及其在工程材料综合评价中的应用[J]. *机械工程材料*, 2013, 37(7): 90-93.
- CHEN K, ZHANG T Y, ZHENG X P, et al. Improvement of principal component analysis and its application in engineering materials comprehensive evaluation[J]. *Materials for Mechanical Engineering*, 2013, 37(7): 90-93.
- [25] 胡倩倩, 韩啸, 刘吉辉, 等. 基于 GA-BP 神经网络的 LF 精炼过程合金加入量预测模型[J]. *冶金自动化*, 2025, 49(1): 32-41.
- HU Q Q, HAN X, LIU J H, et al. Prediction model of alloy addition amount in LF refining process based on GA-BP neural network[J]. *Metallurgical Industry Automation*, 2025, 49(1): 32-41.
- [26] 秦一梅. 软计算技术在 TiAl 合金显微硬度的预测研究[D]. 西安: 陕西科技大学, 2018.
- QIN Y M. Prediction on micro-hardness of TiAl alloy based on soft computing[D]. Xi'an: Shaanxi University of Science and Technology, 2018.
- [27] 张浩, 王国文, 曾凡宜, 等. 基于 BP 神经网络的 6082 铝合金固溶时效处理后的晶粒尺寸预测[J]. *锻压技术*, 2023, 48(3): 227-235.
- ZHANG H, WANG G W, ZENG F Y, et al. Grain size prediction of 6082 aluminum alloy after solution and aging treatment based on BP neural network[J]. *Forging & Stamping Technology*, 2023, 48(3): 227-235.
- [28] MA Z, JI H C, HUANG X M, et al. Research on high temperature stamping forming performance and process parameters optimization of 7075 aluminum alloy[J]. *Materials*, 2021, 14(19): 5485.
- [29] 梅益, 孙全龙, 喻丽华, 等. 基于 GA-ELM 的铝合金压铸件晶粒尺寸预测[J]. *金属学报*, 2017, 53(9): 1125-1132.
- MEI Y, SUN Q L, YU L H, et al. Grain size prediction of aluminum alloy dies castings based on GA-ELM[J]. *Acta Metallurgica Sinica*, 2017, 53(9): 1125-1132.
- [30] LI B, DU Y, ZHENG Z S, et al. Manipulation of mechanical properties of 7xxx aluminum alloy via a hybrid approach of machine learning and key experiments[J]. *Journal of Materials Research and Technology*, 2022, 19: 2483-2496.
- [31] 侯丽娜. 微合金化对 Al-Cu-Mg 合金组织及性能的影响[D]. 沈阳: 沈阳工业大学, 2010.
- HOU L N. The effects of minor alloying on the microstructure and mechanical properties of Al-Cu-Mg alloy[D]. Shenyang: Shenyang University of Technology, 2010.
- [32] 潘利文, 陈永斌, 周勇, 等. Cr 对 Al-Cu-Mn 合金显微组织及力学性能的影响[J]. *广西大学学报(自然科学版)*, 2024, 49(4): 835-846.
- PAN L W, CHEN Y B, ZHOU Y, et al. Effects of Cr on microstructure and mechanical properties of Al-Cu-Mn alloy[J]. *Journal of Guangxi University(Natural Science Edition)*, 2024, 49(4): 835-846.

收稿日期: 2025-02-20; 录用日期: 2025-03-31

基金项目: 国家科技部创新方法专项(2020IM020700)

通讯作者: 廉红珍(1968—), 女, 博士, 副教授, 研究方向为机械设计及机电液一体化, 联系地址: 山西省太原市尖草坪区九丰路 6 号太原城市职业技术学院(030027), E-mail: 543354783@qq.com; 陆春月(1979—), 女, 博士, 副教授, 研究方向为智能设计与制造, 联系地址: 山西省太原市尖草坪区学院路 3 号中北大学(030051), E-mail: luchunyue@nuc.edu.cn

(本文责编: 陈 卉)