

基于机器学习的0Cr17Ni4Cu4Nb不锈钢流变应力预测研究

赵礼栋¹, 张又铭², 张继林³, 窦建明^{4*}, 姚家宝³

(1. 兰州工业学院计算机与人工智能学院, 甘肃 兰州 730050; 2. 大连交通大学机车车辆工程学院, 辽宁 大连 116000; 3. 兰州工业学院机电工程学院, 甘肃 兰州 730050; 4. 兰州交通大学机电工程学院, 甘肃 兰州 730070)

摘要:以0Cr17Ni4Cu4Nb不锈钢为例, 提出一种基于粒子群优化BP神经网络预测流变应力的新模型。以常温下的准静态(0.001 s^{-1})压缩试验数据、四种温度(25、350、500、300 °C)和六种应变率(750、1 500、2 000、2 600、3 500、4 500 s^{-1})的冲击试验数据为基础, 构建了0Cr17Ni4Cu4Nb不锈钢流变应力的随机森林预测模型、粒子群优化随机森林预测模型、Back Propagation(BP)神经网络预测模型以及粒子群优化BP神经网络预测模型, 采用统计学的决定系数(R^2)、平均绝对误差(MAE)、均方差(MSE)和均方误差平方根(RMSE)四个指标分析评价上述四种模型, 得出四种模型预测的综合性能依次是粒子群优化BP神经网络模型、BP神经网络模型、粒子群优化随机森林模型、随机森林模型。粒子群优化BP神经网络模型决定系数 $R^2=0.999\ 7$ 、平均绝对误差 $MAE=1.577\ 3$ 、均方差 $MSE=5.505\ 3$ 和均方误差平方根 $RMSE=2.346\ 3$, 该模型能够很好预测0Cr17Ni4Cu4Nb不锈钢流变应力。

关键词:0Cr17Ni4Cu4Nb 不锈钢; 流变应力; 预测模型; 机器学习; 粒子群优化BP神经网络

中图分类号: TG142.7, TP301.6

文献标志码: A

文章编号: 1004-7638(2023)04-0196-09

DOI: 10.7513/j.issn.1004-7638.2023.04.028

开放科学(资源服务)标识码(OSID):



听
语
音
与
作
者
互
动
聊
科
研

Research on prediction accuracy of the flow stress of 0Cr17Ni4Cu4Nb stainless steel based on machine learning

Zhao Lidong¹, Zhang Youming², Zhang Jilin³, Dou Jianming^{4*}, Yao Jiabao³

(1. School of Computer and Artificial Intelligence, Lanzhou Institute of Technology, Lanzhou 730050, Gansu, China; 2. School of Locomotive and Vehicle Engineering, Dalian Jiaotong University, Dalian 116000, Liaoning, China; 3. School of Electrical and Mechanical Engineering, Lanzhou Institute of Technology, Lanzhou 730050, Gansu, China; 4. College of Electrical and Mechanical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, Gansu, China)

Abstract: A new model for predicting rheological stresses based on particle swarm optimization BP neural network is proposed for 0Cr17Ni4Cu4Nb stainless steel as an example. Based on the quasi-static (0.001 s^{-1}) compression testing data at room temperature and the impact testing data at four temperatures (25, 350, 500 and 300 °C) and six strain rates (750, 1 500, 2 000, 2 600, 3 500 and 4 500 s^{-1}), a random forest prediction model for rheological stress of 0Cr17Ni4Cu4Nb stainless steel, a Particle Swarm Optimized Random Forest prediction model, a Back Propagation (BP) neural network, and a Particle

收稿日期: 2022-11-16

基金项目: 甘肃省青年科技基金计划项目(21JR7RA351); 甘肃省自然科学基金(20JR5RA376); 甘肃省重点人才项目(甘组通字[2022]77号); 国家级大学生创新创业训练计划项目(202211807007); 兰州交通大学甘肃省重点实验室开放课题(2022051)。

作者简介: 赵礼栋, 1977年出生, 男, 硕士, 副教授, 主要从事计算机软件编程、硬件调试以及模型建立研究, E-mail: 40241324@qq.com; *通讯作者: 窦建明, 1985年出生, 男, 博士, 副教授, 主要从事智能制造、切削过程状态监测与故障诊断研究, E-mail: lgy_116@163.com。

Swarm Optimized BP neural network are constructed. Four indicators including the statistical coefficient of determination (R^2), mean absolute error (MAE), mean square error (MSE) and root mean square error (RMSE) are used to analyze and evaluate the four models mentioned above. The comprehensive performance of the prediction models is in sequence of particle swarm optimization BP neural network model, BP neural network model, particle swarm optimization random forest model, and the random forest model. The coefficient of determination $R^2=0.9997$, mean absolute error $MAE=1.5773$, mean squared error $MSE=5.5053$ and root mean squared error $RMSE=2.3463$ are determined for the particle swarm optimized BP neural network model, which can predict the rheological stress of 0Cr17Ni4Cu4Nb stainless steel very well.

Key words: 0Cr17Ni4Cu4Nb stainless steel, rheological stress, prediction model, machine learning, particle swarm optimization BP neural network

0 引言

马氏体沉淀硬化不锈钢 0Cr17Ni4Cu4Nb 具有强度高、韧性好、耐腐蚀和耐氧化等优良的特性,可作为汽轮机叶片、仪器仪表结构件和泵零件等,广泛用于航空航天、核电工业以及重要的行业^[1-5]。这些零部件无论在加工成形阶段,还是在服役过程中,都会承受复杂的变形,具体体现在流动变形应力与应变、应变率和温度之间的关系^[6-9],即材料的本构模型。它们之间的关系是复杂且高度非线性的,通过传统方法构建本构模型,工作量大且很难保证流变应力的预测精度,因此急需寻求一种精度高的本构模型^[10-12]。

目前计算机技术应用于科学研究当中,特别是机器学习的神经网络,具有自学习、自组织和非线性适应性的能力和处理复杂非线性关系的特点,能够解决传统回归方法的缺点,用来表征材料的流变应力行为^[13-16]。丁军^[10]等人提出一种基于改进遗传算法选择算子的优化人工神经网络预测 304 不锈钢在复杂服役环境下流变应力的新模型,并对比决策树、线性回归和未改进遗传神经网络模型计算的 MAE 和 R^2 ,改进遗传神经网络模型最佳。周峰^[14]等人研究 Ti-22Al-24BNb-0.5Y 合金流变行为,通过正交试验分析应变速率、变形温度和应变变量对该合金流变应力的影响,并基于 BP 神经网络构建合金高温本构关系模型,表明该预测模型可作为 Ti₂Al-Nb 基合金塑性成形过程有限元模拟的本构关系。王天祥^[16]等人研究变形温度为 600~950℃,应变速率为 0.001~10 s⁻¹ 条件下 Ti60 合金的流变应力行为,并建立人工神经网络 (ANN) 本构模型,能准确地描述并预测该合金的流变应力行为。An Zhen^[17]等人利用 Gleeble-3800 热模拟试验机,在应变速率 0.001~1 s⁻¹ 以及变形温度 750~950℃ 范围内对

Ti-555211 合金进行等温恒应变速率压缩试验,基于人工神经网络的方法建立了 Ti-55521 合金热变形本构模型,表明该模型能很好地预测该合金的本构关系。Wang Chunhui^[18]等人通过 BSTMUF601 高温合金在 1 253 K 和 1 368 K 不同载荷下的蠕变试验研究了蠕变行为,基于 BP 神经网络建立该高温合金蠕变本构模型,表明 BP 神经网络方法对该材料蠕变本构模型参数识别和预测方面的优势。何龙^[19]等人采用 Gleeble-3500 热模拟试验机对 GH5188 高温合金试样进行热压缩试验,研究其在应变速率为 0.001~0.1 s⁻¹ 和变形温度在 1 000~1 150℃ 时的热变形行为,建立了基于 BP 神经网络的本构模型,并验证了所建本构模型的可靠性,表明该模型能准确地预测 GH5188 高温合金的高温流变应力。邱仟^[20]等人采用 Gleeble-3800 型热模拟试验机对 SP700 钛合金在变形温度 700~950℃、应变速率 0.001~1 s⁻¹ 条件下进行等温恒应变速率压缩试验,研究其高温流动行为,同时根据试验数据构建出 BP 神经网络本构关系模型,表明该本构模型对合金流动应力的预测精度较高。雷锦文^[21]等人使用 Gleeble-3800 对锻态 Ti6242s 钛合金在温度 950~1 010℃、应变速率 0.01~10 s⁻¹ 的条件下进行了 75% 变形量的热压缩模拟试验,基于试验取得的真应力-真应变曲线,分别使用人工神经网络 (ANN) 和 Arrhenius 方程建立该合金本构模型,研究其热变形行为,研究表明 Arrhenius 本构模型精度远低于 ANN 本构模型。综上所述,神经网络本构模型具有预测精度高、稳定性好的优点,应该大范围推广。

国内外学者对马氏体沉淀硬化不锈钢 0Cr17Ni4Cu4Nb 高温流变行为和本构关系进行的研究还很有限。因此,笔者以动静态冲击试验数据为基础,采用随机森林、粒子群优化随机森林、BP (Back Propagation) 神经网络以及粒子群优化

BP神经网络原理,构建相应的流动应力预测模型,对比分析四种模型预测的综合性能。

1 计算方法及原理

1.1 随机森林

随机森林(random forest, RF)是利用多棵树对样本进行训练并预测的一种分类器^[22],其本质是Bagging算法和random subspace算法相结合^[23-26]。它采用Bootstrap重抽样方法,对数据样本进行随机抽出 n 个子样本,建立决策树模型,并从每个子样本的所有特征中随机选取 m (预定义的数字)个特征用于分割每个节点,形成一片随机森林。随机森林找到每棵树的最佳分割点,剩余部分类似决策树,最终预测结果为所有决策树输出结果的平均值,其结构如图1所示。




图1 随机森林结构

Fig. 1 Random forest structure

1.2 BP神经网络

BP(Back Propagation)神经网络是一种按误差逆传播训练的多层前馈网络,具备并行计算和自适应学习能力,能够实现高度复杂非线性关系的映射^[13,27-28]。它采用梯度下降法的数学思想,使用梯度搜索技术,降低设定的最小值(实际值和期望值的误差均方差)。BP神经网络由输入层、隐含层和输出层三个部分组成,其结构如图2所示^[12,17,21]。

1.3 粒子群优化随机森林和BP神经网络

粒子群优化算法是典型的群体智能优化算法^[29-31]。计算模型依据只有速度和位置,没有质量的粒子模拟鸟群觅食方式。通常通过随机的粒子不断迭代搜索,使种群整体上适应更好的方向,最终获得最优解^[32-34]。

随机森林中各初始参数对模型影响比较大,它通常采用人工经验选择,这样增加了预测的不确定性,同时决策树棵数或剪枝阈值的选取缺乏理论依据^[23]。BP神经网络的初始权值和阈值是随机设置的,有可能这些参数设置不当,会导致网络收敛过慢和陷入局部最优^[35]。基于上述问题,提出粒子群优化两种模型,粒子群优化算法对随机森林的决策树和BP神经网络的隐含层个数及神经元个数进行计算,它们的流程分别如图3、和图4所示。




图2 BP神经网络结构

Fig. 2 BP neural network structure




图3 基于PSO-RF流程

Fig. 3 Flow chart based on PSO-RF




图4 基于 PSO-BP 神经网络流程

Fig. 4 Flow chart based on PSO-RF neural network

2 不锈钢 0Cr17Ni4Cu4Nb 应力预测模型建立

2.1 数据来源

笔者使用的试验数据来源于文献 [36]。不锈钢 0Cr17Ni4Cu4Nb 的化学成分如表 1 所示。利用高温分离式霍普金森试验装置(AL1000, 北京东方德兴科技有限公司)和万能试验机(UTM5305, 济南科盛试验机设备有限公司)分别做六种应变率(750、1 500、2 000、2 600、3 500、4 500 s⁻¹)和四种温度(25、350、500、300 ℃)下的冲击试验和常温下的准静态(0.001 s⁻¹)压缩试验, 获得材料的应力应变关系。采用机器学习将上述 5 205 组试验数据建模, 预测材料在不同温度、应变率和应变条件下的流变应力。

表 1 不锈钢 0Cr17Ni4Cu4Nb 的化学成分

Table 1 Chemical composition of 0Cr17Ni4Cu4Nb stainless steel %

C	Si	Cr	Ni	Mn	P	S	Cu	Nb	Fe
0.05	0.80	16.25	3.60	0.82	0.03	0.02	3.83	0.28	Bal.

2.2 数据处理

数据处理一般有归一化和标准化两种方式, 其能够消除不同特征的数量级造成的影响。笔者采用 Matlab 数据处理和算法模型计算, 经过数据处理各特征处于同一数量级, 可以进行综合对比评价, 提

高模型的预测精度和效率。使用 mapminmax 函数将数据转化到 [-1, 1] 区间。将 5 205 组试验样本分为 2 000 组训练样本集和 3 205 组测试样本集。训练集用来确定模型的参数选择及评价, 测试集则用来对模型的预测性能进行评估和验证^[10,37]。

2.3 模型评价指标

为了进一步定量分析训练所得模型的准确性, 采用统计学的决定系数(coefficient of determination, R^2)、平均绝对误差(mean absolute error, MAE)、均方差(mean square error, MSE)以及均方误差平方根(root mean square error, $RMSE$)四个衡量评价指标, 其表达式如下^[10,32,37]:

$$R^2 = 1 - \frac{\sum_{j=1}^m (y_j - y_j')^2}{\sum_{j=1}^m (y_j' - \bar{y})^2} \quad (1)$$

$$MAE = \frac{1}{m} \sum_{j=1}^m |y_j' - y_j| \quad (2)$$

$$MSE = \frac{1}{m} \sum_{j=1}^m (y_j' - y_j)^2 \quad (3)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{j=1}^m (y_j' - y_j)^2} \quad (4)$$

其中, y_j' 是第 j 个样本的预测值; y_j 是第 j 个样本的真实值; $\bar{y}$ 是样本真实值的平均值; m 是样本数量。 R^2 越接近 1, 表明模型拟合效果越好; MAE 、 MSE 和 $RMSE$ 越小, 表明模型预测精度越高。

3 结果与讨论

3.1 随机森林及粒子群优化随机森林

回归树的棵数 $ntree$ 和随机特征的数目 $mtry$ 是随机森林回归预测模型的最重要两个参数。 $ntree$ 值决定了训练度和精确度, 其值越大, 模型精度越高; $mtry$ 控制了模型属性的扰动程度, $mtry$ 通常根据经验公式 $mtry = \text{变量数} / 3$ 确定, 根据文献 [37] 取 $ntree \in [5, 60]$, $mtry = 1$, 确定 $ntree$ 值工作量相对较大且结果不一定精确。按照图 1 流程进行计算。当 $ntree$ 间隔 5 取值计算四个指标的结果如表 2 所示。

由表 2 可知, 满足 R^2 最大时, $ntree = 45$; MAE 最小时, $ntree = 30$; MSE 和 $RMSE$ 最小时, 决策树棵树 $ntree = 45$ 。综合选择决策树棵树 $ntree = 45$, 表明模型拟合效果好、精度相对预测高, 但是决策树棵树

ntree 越大,效率越低。为了加快预测效率,并且考虑随机森林自身缺点,按照图 4 流程进行计算,粒子群优化随机森林算法得到决策树棵树 ntree=16,此时的四个指标如表 3 所示。对比表 2 和表 3 可得,随机森林模型的四个指标值都比粒子群优化随机森林的稍微好一点,但相差不大,近似相等,不过粒子群优化随机森林决策树的棵树要比随机森林决策树的棵树少得多,不到 2/5。如果在考虑预测精度相接近的条件下,选择决策树少的比较好,所以粒子群优化随机森林相对比随机森林优越一点。

表 2 随机森林预测能力评价指标

Table 2 Random forest predictive capability evaluation index

ntree	R^2	MAE	MSE	ESE
5	0.947 7	24.407 9	1 069.263 9	32.340 5
10	0.950 0	23.984 6	1 022.440 8	31.250 5
15	0.952 6	23.495 8	969.309 6	30.961 1
20	0.964 5	20.936 4	725.611 7	26.871 0
25	0.962 9	21.189 6	759.266 0	27.431 5
30	0.967 6	19.558 7	661.354 7	25.692 1
35	0.967 2	20.165 0	671.321 8	25.901 2
40	0.966 4	20.231 9	687.360 5	26.186 7
45	0.968 4	19.770 9	645.141 9	25.366 1
50	0.966 7	20.006 2	680.311 2	26.035 1
55	0.966 6	20.137 4	681.869 9	26.101 2
60	0.964 7	20.605 9	721.031 4	26.838 9

表 3 粒子群优化随机森林预测能力评价指标

Table 3 Particle swarm optimization random forest prediction capability evaluation index

ntree	R^2	MAE	MSE	ESE
16	0.967 2	20.020 5	670.948 2	25.899 8

3.2 BP 神经网络及粒子群优化 BP 神经网络

依据图 2BP 神经网络回归算法结构,模型训练的输入层为训练数据中的温度、应变、应变率,模型的输出层为流变应力。此结构中,神经元个数以及隐含层层数未知,首先需反复训练确定最佳神经网络结构,然后才能进行回归预测。采用 Zou^[38] 等人的方法来确定神经网络的隐含层神经元个数和隐含层层数。隐含层神经元节点数的一般参照公式如式 (5) 所示^[14]:

$$n_1 = \sqrt{n+m} + a \quad (5)$$

其中, n_1 为隐含层的神经元节点数; n 为输入层的神经元; m 为输出层的神经元; a 取 1~10 之间的常数。按照公式(5)得 $n_1=3 \sim 12$ 。当隐含层层数为一层时,神经元数量从 3 到 12 依次间隔 2 递增,不同神经元个数训练下的评价指标见表 4。

表 4 不同神经元个数训练下的评价指标

Table 4 Evaluation metrics under different training numbers of neurons

神经元数量	R^2	MAE	MSE	ESE
3	0.977 7	16.544 9	455.939 9	21.352 7
5	0.980 2	15.457 2	404.037 5	20.100 7
7	0.995 1	7.479 4	100.204 2	10.010 2
9	0.996 8	6.039 8	65.481 1	8.092
11	0.998 2	4.422 1	36.896 9	6.074 3
13	0.997 8	4.725 9	45.189 5	6.722 3

由表 4 可知,当神经元数量为 11 个时, R^2 最大, MAE 、 MSE 和 $RMSE$ 都最小。当神经元数量为 11 个时,将隐含层层数依次从 1 层增加到 6 层,研究隐含层层数对神经网络性能的影响,最终确定最优的隐含层层数,不同隐含层个数训练下的评价指标见表 5。

表 5 不同隐含层个数训练下的评价指标

Table 5 Evaluation metrics under different training numbers of implied layers

隐含层层数	R^2	MAE	MSE	ESE
1	0.998 2	4.419 4	36.951 3	6.078 8
2	0.999 3	2.556 9	14.478 0	3.805 0
3	0.999 6	2.089 8	8.959 8	2.993 3
4	0.999 5	2.146 4	10.309 6	3.210 9
5	0.999 5	2.049 8	9.738 8	3.120 7
6	0.999 7	1.577 3	5.542 9	2.354 3

由表 5 可知,当隐含层层数为 6 层时, R^2 最大, MAE 、 MSE 和 $RMSE$ 都最小。综合考虑选择隐含层层数为 6 层,最终神经网络结构为 $3 \times 11 \times 11 \times 11 \times 11 \times 11 \times 11 \times 11 \times 1$ 。由于上述结构通过两个步骤而获得一种结果,且第一步骤是第二步骤的前提,需要经过多次计算,为此提出粒子群优化 BP 神经网络,按照图 4 进行六次,先获得 1~6 层最优神经元结构(神经元节点数为 2~13),然后进行 6 个结构的预测,得到粒子群优化 BP 神经网络训练下的评价指标见表 6。由表 6 可知,当隐含层结构为 $12 \times 12 \times 12 \times 12 \times 12 \times 12$ 时, R^2 最大, MAE 最小;当隐含层结构

12×12×8 时, R^2 最大, MAE 、 MSE 和 $RMSE$ 都最小。由于隐含层结构简单, 计算效率高, 同时 3 层和 6 层的 R^2 相等, 最终粒子群优化神经网络的结构为 3×12×12×8×1。在达到相同的 R^2 时, 粒子群优化 BP 神经网络模型所需要的隐含层层数是 BP 神经网络模型隐含层层数的 1/2。粒子群优化 BP 神经网络模型比 BP 神经网络模型相对好一点。


3.3 不同模型预测结果对比

为了进一步对比分析四种模型的整体预测精度, 将预测值和试验值相关性和平均绝对误差表示如图 5 所示。


表 6 粒子群优化 BP 神经网络训练下的评价指标

Table 6 Evaluation metrics under particle swarm optimization BP neural network training


隐含层结构	R^2	MAE	MSE	ESE
12	0.996 9	5.851 3	63.677	7.979 8
12×12	0.999 5	2.186 3	10.969 1	3.312
12×12×8	0.999 7	1.477 0	5.505 3	2.346 3
9×11×12×12	0.999 7	1.669 5	6.603 9	2.569 8
12×11×10×12×11	0.999 6	1.768 0	7.326 3	2.706 7
12×12×12×12×12×12	0.999 7	1.503 0	5.670 0	2.381 2




(a) 随机森林 (决策树 ntree=45)



(b) 粒子群优化随机森林 (决策树 ntree=16)



(c) BP 神经网络 (神经网络结构为 3×11×11×11×11×11×11×11)



(d) 粒子群优化 BP 神经网络 (神经网络的结构为 3×12×12×8×1)

图 5 不同模型真应力预测和试验值之间的相关性

Fig. 5 Correlation between predicted and experimental values of true stress by different models

从图 5 可以看出, 随机森林预测的 R^2 和 MAE 稍微低于粒子群优化随机森林, 但是从 3.1 分析可知此时前者的决策树 (ntree=45) 远远大于后者的决策树 (ntree=16), 因此在达到相同或者接近的 R^2 和 MAE 时, 粒子群优化随机森林优于随机森林。另外, BP 神经网络和粒子群优化 BP 神经网络预测的 R^2 相等, 但是粒子群优化 BP 神经网络预测的 MAE 稍微高于 BP 神经网络, 同时从 3.2 分析可知此时前者

的隐含层层数是 3 层, 后者的隐含层层数是 6 层, 因此粒子群优化 BP 神经网络优于 BP 神经网络。综合对比四个模型可得 BP 神经网络优于随机森林, 这是由自身特点决定的, 粒子群优化的模型优于粒子群未优化的模型, 其效率高, 这是粒子群自身优点决定。它们预测的综合性能依次是粒子群优化 BP 神经网络模型、BP 神经网络模型、粒子群优化随机森林模型、随机森林模型。

4 结论

1) 当决策树 $n_{tree}=45$ 时, 随机森林预测精度最高, $R^2=0.968\ 4$ 、 $MAE=19.770\ 9$; 粒子群优化随机森林的决策树 $n_{tree}=16$ 时, $R^2=0.967\ 2$ 、 $MAE=20.020\ 5$, 在预测精度相差不大的情况下, 综合考虑, 粒子群优化随机森林的模型要比随机森林的模型优越。

2) 当 BP 神经网络模型和粒子群优化 BP 神经网络预测精度最高($R^2=0.999\ 7$)时, 前者的神经网络

结构为 $3\times 11\times 11\times 11\times 11\times 11\times 11\times 1$, 后者的神经网络结构为 $3\times 12\times 12\times 8\times 1$, 结构简单, 粒子群优化 BP 神经网络模型预测精度达到 BP 神经网络模型精度所需隐含层层数较少。

3) 四种模型预测的综合性能依次是粒子群优化 BP 神经网络模型、BP 神经网络模型、粒子群优化随机森林模型、随机森林模型。

4) 利用粒子群优化 BP 神经网络模型在高温、高应变率和大应变下更好的预测 0Cr17Ni4Cu4Nb 不锈钢流变应力。

参考文献

- [1] Wang Jianxing, Yang Gang, Zhang Zhongmo, *et al.* Effect of ECAP deformation on microstructure and mechanical properties of 0Cr17Ni4Cu4Nb stainless steel[J]. Journal of Plasticity Engineering, 2018, 25(1): 119–124.
(王剑星, 杨钢, 张忠模, 等. ECAP变形对0Cr17Ni4Cu4Nb不锈钢组织与力学性能的影响[J]. 塑性工程学报, 2018, 25(1): 119–124.)
- [2] Wang Jianxing, Yang Gang, Liu Tianmo, *et al.* Effect of Ni content on mechanical properties of 0Cr17Ni4Cu4Nb stainless steel[J]. Transactions of Materials and Heat Treatment, 2010, 31(12): 56–60.
(王剑星, 杨钢, 刘天模, 等. Ni含量对0Cr17Ni4Cu4Nb不锈钢力学性能的影响[J]. 材料热处理学报, 2010, 31(12): 56–60.)
- [3] Wang Hanxiao, Bai Bing, Zhang Changyi, *et al.* Micro-structure and properties analysis of nuclear power stem material 17-4PH stainless steel at different service time[J]. Nuclear Science and Engineering, 2018, 38(2): 318–325.
(王瀚霄, 白冰, 张长义, 等. 核电阀杆材料17-4PH不锈钢服役不同时间的组织性能分析[J]. 核科学与工程, 2018, 38(2): 318–325.)
- [4] Huang Jing, Ma Yuan, Wang Mingjie, *et al.* Investigation and optimization of investment casting 0Cr17Ni4Cu3Nb stainless steel parts aero-engines[J]. Special Casting & Nonferrous Alloys, 2019, 39(2): 159–162.
(黄静, 马原, 王明杰, 等. 精密铸造0Cr17Ni4Cu3Nb不锈钢航空发动机零件[J]. 特种铸造及有色合金, 2019, 39(2): 159–162.)
- [5] Sun Jianxin, Liu Yongsheng, Guo Baofeng, *et al.* Hot deformation behavior and hot processing map of 17-4PH stainless steel for oil fracturing valve box[J]. Journal of Plasticity Engineering, 2022, 29(4): 112–118.
(孙建新, 刘永胜, 郭宝峰, 等. 石油压裂阀箱用17-4PH不锈钢热变形行为及热加工图[J]. 塑性工程学报, 2022, 29(4): 112–118.)
- [6] Zhang Jilin, Jia Haishen, Yi Xiangbin, *et al.* Effect of high temperature and high strain rate on the dynamic mechanical properties of 06Cr19Ni10 austenitic stainless steel[J]. Iron Steel Vanadium Titanium, 2022, 43(1): 145–151.
(张继林, 贾海深, 易湘斌, 等. 高温高应变率对06Cr19Ni10奥氏体不锈钢动态力学性能的影响[J]. 钢铁钒钛, 2022, 43(1): 145–151.)
- [7] Jia Haishen, Zhang Jilin, Yi Xiangbin, *et al.* Experimental study on rheological behavior of 022Cr18Ni14Mo2 stainless steel at high temperature and high strain rate[J]. Journal of Mechanical Strength, 2022, 44(3): 600–606.
(贾海深, 张继林, 易湘斌, 等. 高温、高应变率下022Cr18Ni14Mo2不锈钢流变行为的试验研究[J]. 机械强度, 2022, 44(3): 600–606.)
- [8] Jia Haishen, Luo Wencui, Zhang Jilin, *et al.* Study on dynamic mechanical properties and constitutive model of 022Cr18Ni14Mo2 stainless steel under impact load[J]. Iron Steel Vanadium Titanium, 2022, 43(2): 178–185.
(贾海深, 罗文翠, 张继林, 等. 冲击载荷下022Cr18Ni14Mo2不锈钢动态力学特性及其本构模型研究[J]. 钢铁钒钛, 2022, 43(2): 178–185.)
- [9] Duan Xinmin, Sun Peiqiu, Xu Zhiqiang, *et al.* Study on the integral forming technology of front /rear interfacing for 0Cr17Ni4Cu4Nb[J]. Forging & Stamping Technology, 2016, 41(5): 44–48.
(段新民, 孙培秋, 徐志强, 等. 0Cr17Ni4Cu4Nb前/后接口套圈整体成形技术研究[J]. 锻压技术, 2016, 41(5): 44–48.)

- [10] Ding Jun, Gu Yuchuan, Huang Xia, *et al.* Research on prediction accuracy of flow stress of 304 stainless steel based on artificial neural network optimized by improved genetic algorithm[J]. *Journal of Mechanical Engineering*, 2022, 58(10): 78–86.
(丁军, 古愉川, 黄霞, 等. 基于改进遗传算法优化人工神经网络的304不锈钢流变应力预测准确性研究[J]. *机械工程学报*, 2022, 58(10): 78–86.)
- [11] Zhong Mingjun, Wang Kelu, Lu Shiqiang, *et al.* Study on high temperature deformation behavior and BP neural network constitutive model of MoNb alloy[J]. *Journal of Plasticity Engineering*, 2020, 27(12): 177–182.
(钟明君, 王克鲁, 鲁世强, 等. MoNb合金高温变形行为及BP神经网络本构模型研究[J]. *塑性工程学报*, 2020, 27(12): 177–182.)
- [12] Luo Rui, Cao Yun, Qiu Yu, *et al.* Investigation of constitutive model of as-extruded spray-forming 7055 aluminum alloy based on BP artificial neural network[J]. *Journal of Aeronautical Materials*, 2021, 41(1): 35–44.
(罗锐, 曹赞, 邱宇, 等. 基于BP人工神经网络喷射成形7055铝合金的本构模型[J]. *航空材料学报*, 2021, 41(1): 35–44.)
- [13] Wu Xiongxi. Model of constitutive relationship and processing map for 7050 aluminum alloy based on BP neural network[J]. *Special Casting & Nonferrous Alloys*, 2014, 34(10): 1011–1015.
(吴雄喜. 基于BP神经网络的7050铝合金本构关系模型及加工图[J]. *特种铸造及有色合金*, 2014, 34(10): 1011–1015.)
- [14] Zhou Feng, Wang Kelu, Lu Shiqiang, *et al.* Flow behavior and BP neural network high temperature constitutive model of Ti-22Al-24Nb-0.5Y alloy[J]. *Journal of Materials Engineering*, 2019, 47(8): 141–146.
(周峰, 王克鲁, 鲁世强, 等. Ti-22Al-24Nb-0.5Y合金流变行为及BP神经网络高温本构模型[J]. *材料工程*, 2019, 47(8): 141–146.)
- [15] Zhang Qing, Li Ping, Xue Kemin. Model of constitutive relationship for TB8 alloy based on BP neural network[J]. *Forging & Stamping Technology*, 2010, 35(1): 130–133.
(张青, 李萍, 薛克敏. 基于BP神经网络的TB8合金高温本构关系模型[J]. *锻压技术*, 2010, 35(1): 130–133.)
- [16] Wang Tianxiang, Lu Shiqiang, Wang Kelu, *et al.* Flow stress behavior and artificial neural network constitutive model of Ti60 alloy[J]. *Special Casting & Nonferrous Alloys*, 2020, 40(9): 1019–1023.
(王天祥, 鲁世强, 王克鲁, 等. Ti60合金的流变应力行为及人工神经网络本构模型[J]. *特种铸造及有色合金*, 2020, 40(9): 1019–1023.)
- [17] An Zhen, Li Jinshan, Feng Yong, *et al.* Modeling constitutive relationship of Ti-555211 alloy by artificial neural network during high-temperature deformation[J]. *Rare Metal Materials and Engineering*, 2015, 44(1): 62–66.
- [18] Wang Chunhui, Sun Zhihui, Zhao Jiaqing, *et al.* Creep deformation constitutive model of BSTMUF601 superalloy using BP neural network method[J]. *Rare Metal Materials and Engineering*, 2020, 49(6): 1885–1893.
- [19] He Long, Zhang Ranyang, Zhao Gangyao, *et al.* Constitutive model of GH5188 superalloy based on BP neural network[J]. *Special Casting & Nonferrous Alloys*, 2021, 41(2): 223–226.
(何龙, 张冉阳, 赵刚要, 等. 基于BP神经网络的GH5188高温合金本构模型[J]. *特种铸造及有色合金*, 2021, 41(2): 223–226.)
- [20] Qiu Qian, Wang Kelu, Li Xin, *et al.* Constitutive relationship of SP700 titanium alloy based on BP neural network[J]. *Journal of Plasticity Engineering*, 2021, 28(11): 167–172.
(邱仟, 王克鲁, 李鑫, 等. 基于BP神经网络的SP700钛合金本构关系[J]. *塑性工程学报*, 2021, 28(11): 167–172.)
- [21] Lei Jinwen, Xue Xiangyi, Zhang Siyuan, *et al.* High-precision constitutive model of Ti6242s alloy hot deformation based on artificial neural network[J]. *Rare Metal Materials and Engineering*, 2021, 50(6): 2025–2032.
(雷锦文, 薛祥义, 张思远, 等. 基于人工神经网络的高精度Ti6242s合金热变形本构模型[J]. *稀有金属材料与工程*, 2021, 50(6): 2025–2032.)
- [22] Zhang Pin, Yin Zhenyu, Jin Yinfu, *et al.* A novel hybrid surrogate intelligent model for creep index prediction based on particle swarm optimization and random forest[J]. *Engineering Geology*, 2020, 265: 628–638.
- [23] Wang Jie, Cheng Xuexin, Peng Jinzhu. A weighted random forest model based on particle swarm optimization[J]. *Journal of Zhengzhou University(Natural Science Edition)*, 2018, 50(1): 72–76.
(王杰, 程学新, 彭金柱. 一种基于粒子群算法优化的加权随机森林模型[J]. *郑州大学学报(理学版)*, 2018, 50(1): 72–76.)
- [24] Breiman L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5–32.
- [25] Wang Weitong, Fan Haidong, Liang Chengsi, *et al.* Predictive modeling of NO_x outlet of hedged boiler based on random

- forest[J]. Thermal Power Generation, 2022, 51(4): 96–104.
(王伟同, 范海东, 梁成思, 等. 基于随机森林算法的对冲锅炉出口NO₂排放量预测模型研究[J]. 热力发电, 2022, 51(4): 96–104.)
- [26] Wu Xianguo, Liu Pengcheng, Chen Hongyu, *et al.* Prediction of concrete strength based on random forest[J]. Concrete, 2022, (1): 17–20,24.
(吴贤国, 刘鹏程, 陈虹宇, 等. 基于随机森林的高性能混凝土抗压强度预测[J]. 混凝土, 2022, (1): 17–20,24.)
- [27] Yan Liangming, Shen Jian, Li Zhoubing, *et al.* Modelling for flow stress and processing map of 7055 aluminum alloy based on artificial neural networks[J]. The Chinese Journal of Nonferrous Metals, 2010, 20(7): 1296–1301.
(闫亮明, 沈健, 李周兵, 等. 基于神经网络的7055铝合金流变应力模型和加工图[J]. 中国有色金属学报, 2010, 20(7): 1296–1301.)
- [28] Lv Zhe, He Lile, Lin Yuyang, *et al.* Parameters prediction of BP neural network based on constitutive model of aluminum alloy powder forming[J]. Hot Working Technology, 2022, 51(4): 46–50.
(吕哲, 贺利乐, 林育阳, 等. 基于铝合金粉末成形本构模型的BP神经网络参数预测[J]. 热加工工艺, 2022, 51(4): 46–50.)
- [29] Feng Xi, Li Qing, Quan Wei, *et al.* Overview of multiobjective particle swarm optimization algorithm[J]. Chinese Journal of Engineering, 2021, 43(6): 745–753.
(冯茜, 李擎, 全威, 等. 多目标粒子群优化算法研究综述[J]. 工程科学学报, 2021, 43(6): 745–753.)
- [30] Li Hejian, Xu Xiaowei, Wang Ke, *et al.* Transformer fault diagnosis model based on particle swarm optimization and random forest[J]. Journal of Kunming University of Science and Technology(Natural Sciences), 2021, 46(3): 94–101.
(李鹤健, 徐肖伟, 王科, 等. 基于粒子群优化随机森林的变压器故障诊断模型[J]. 昆明理工大学学报(自然科学版), 2021, 46(3): 94–101.)
- [31] Li Le, Shu Yuechao, Wu Jianpeng, *et al.* A damage prediction model of wet friction elements based on PSO-BP neural network[J]. Transactions of Beijing Institute of Technology, 2022, 42(12): 1246–1255.
(李乐, 舒越超, 吴健鹏, 等. 基于PSO-BP神经网络湿式摩擦元件损伤预测模型[J]. 北京理工大学学报, 2022, 42(12): 1246–1255.)
- [32] Fan Shengxu, Yang Chunxi, Yang Qiliang, *et al.* Prediction model of Panax notoginseng leaf area growth based on particle swarm-optimization random forest algorithm and meteorological data[J]. Chinese Traditional and Herbal Drugs, 2022, 53(10): 3103–3110.
(范升旭, 杨晨曦, 杨启良, 等. 基于粒子群-随机森林算法和气象数据的三七叶面积生长预测模型[J]. 中草药, 2022, 53(10): 3103–3110.)
- [33] Cheng Xuexin. Research on particle swarm optimization weighted random forest algorithm[D]. Zhengzhou: Zhengzhou University, 2017.
(程学新. 粒子群优化加权随机森林算法研究[D]. 郑州: 郑州大学, 2017.)
- [34] Li Chao. Improvement strategies for particle swarm optimization algorithms with applications[D]. Wuxi: Jiangnan University, 2021.
(李超. 粒子群优化算法改进策略及其应用研究[D]. 无锡: 江南大学, 2021.)
- [35] Chang Ruohan, Cai Zhongyi, Cheng Liren, *et al.* Flow stress prediction model and processing map of Mg-Zn-Zr alloy based on GA-BP network[J]. Materials Reports, 2017, 31(6): 136–139,146.
(常若寒, 蔡中义, 程丽任, 等. 基于遗传BP网络的Mg-Sm-Zn-Zr合金应力预测模型及加工图[J]. 材料导报, 2017, 31(6): 136–139,146.)
- [36] Zhang Jilin, Jia Haishen, Yi Xiangbin, *et al.* Dynamic mechanical properties and comparison of two constitutive models for martensitic stainless steel 0Cr17Ni4Cu4Nb[J]. Materials Research Express, 2021, 8(10): 106501.
- [37] Hu Yi, Zhang Lushan, Yuan Fuyin, *et al.* Prediction of concrete strength based on random forest[J]. Construction Technology, 2020, 49(17): 89–94.
(胡毅, 张陆山, 袁福银, 等. 基于随机森林的混凝土强度预测研究[J]. 施工技术, 2020, 49(17): 89–94.)
- [38] Zou Dafang, Wang Zidong, Zhang Leimin, *et al.* Deep field relation neural network for click-through rate prediction[J]. Information Sciences, 2021, 577: 128–139.