

doi:10.3969/j.issn.1001-3539.2024.06.020

基于 WOA-Stacking 集成学习的注塑产品尺寸预测

陈忠杭¹, 王舟挺², 沈加明², 胡燕海¹, 倪德香²

(1. 宁波大学机械工程与力学学院, 浙江宁波 315211; 2. 宁波华美达机械制造有限公司, 浙江宁波 315000)

摘要: 在现有的基于机器学习的注塑产品尺寸预测模型中, 存在单一模型预测精度不高的问题, 为了提高实时监测注塑产品尺寸变化的精度, 提出了一种基于鲸鱼优化算法(WOA)优化 Stacking 集成学习的注塑产品尺寸预测方法。首先, 整合注塑过程收集到的数据, 使用 3σ 准则进行异常值筛选, 再通过随机森林法和互信息法选取关键的特征, 作为后续模型的输入特征; 其次, 在 Stacking 集成学习框架中, 选择 K 近邻、随机森林和轻量级梯度提升机作为基学习器, 选择弹性网络回归作为元学习器, 使用 WOA 优化各个基学习器中的超参数, 构建 WOA-Stacking 集成学习预测模型; 最后, 将所提的模型应用到注塑产品尺寸预测并与其他模型进行对比分析, 以验证本方法的有效性。以第四届工业大数据创新竞赛数据为例, 在包含 3 种集成模型和 3 种单一模型的对比实验中, 选择产品的三维尺寸作为预测目标, 实验结果表明 WOA-Stacking 集成学习模型具有更高的预测精度和拟合能力。

关键词: 注塑; 尺寸预测; 鲸鱼优化算法; Stacking 集成学习; 特征选择

中图分类号: TP181 **文献标识码:** A **文章编号:** 1001-3539(2024)06-0135-07

Injection molding product size prediction based on WOA-Stacking ensemble learning method

CHEN Zhonghang¹, WANG Zhouting², SHEN Jiaming², HU Yanhai¹, NI Dexiang²

(1. School of Mechanical Engineering and Mechanics, Ningbo University, Ningbo 315211, China;

2. Ningbo Hwamda Machinery Manufacturing Co., Ltd., Ningbo 315000, China)

Abstract : In the existing machine learning-based injection molding product size prediction models, there is the problem that the prediction accuracy of a single model is not high. In order to improve the accuracy of real-time monitoring of injection molding product dimensional changes, an injection molding product size prediction method based on whale optimization algorithm (WOA) optimized Stacking ensemble learning was proposed. First, the data collected from the injection molding process were integrated, the outliers were screened using the 3σ criterion, and the key features were selected by random forest and mutual information method as the input features for the subsequent model. Second, in the Stacking ensemble learning framework, K-nearest neighbor, random forest and light gradient boosting machine were selected as the base learners, and elastic net regression was selected as the meta learner, and WOA was used to optimize the hyperparameters in each base learner to construct the WOA-Stacking ensemble learning prediction model. Finally, the proposed model was applied to the injection molding product size prediction, and then other models were compared and analyzed to verify the effectiveness of the present method. Taking the data of the 4th Industrial Big Data Innovation Competition as an example, in the comparison experiment containing three ensemble models and three single models, the three-dimensional size of the products were selected as the prediction target, and the experimental results showed that the WOA-Stacking ensemble learning model had higher prediction accuracy and fitting ability.

Keywords : injection molding ; size prediction ; whale optimization algorithm ; Stacking ensemble learning ; feature selection

注塑过程中的许多因素会对产品尺寸产生影响^[1]。同时, 人工检测需要专业的操作人员, 这不仅增加了人力成本, 还存在尺寸测量效率低下的问

基金项目: 国家自然科学基金项目(51705263)

通信作者: 胡燕海, 博士, 教授, 主要研究方向为光机电一体化、制造业信息化

收稿日期: 2024-04-11

引用格式: 陈忠杭, 王舟挺, 沈加明, 等. 基于 WOA-Stacking 集成学习的注塑产品尺寸预测[J]. 工程塑料应用, 2024, 52(6): 135-141.

CHEN Zhonghang, WANG Zhouting, SHEN Jiaming, et al. Injection molding product size prediction based on WOA-Stacking ensemble learning method[J]. Engineering Plastics Application, 2024, 52(6): 135-141.

题^[2]。因此,准确预测注塑产品尺寸对于注塑产品的质量控制、成本控制和生产效率具有重要意义。

现有的注塑产品质量预测方法主要有机理模型^[3]、数值模拟^[4]和机器学习^[5]等,其中,机器学习方法得到了大多数学者的关注。基于机器学习的产品质量预测方法是利用机器学习算法对大量数据进行学习,从而建立模型来预测注塑产品的质量特性^[6]。刘永兴等^[7]通过轻量级梯度提升机框架设计了基于加工过程数据及参数的注塑产品尺寸预测模型,实现对超规尺寸的高精度预测。Ke等^[8]采用随机梯度下降和带动量的随机梯度下降对人工神经网络模型进行优化,实现训练模型超参数的优化,提高了注塑产品的宽度测试精度。Farahani等^[9]从模内传感器和机器数据源获得各种过程数据,比较了十种不同的机器学习算法,发现了多元线性回归模型训练误差小,具有最佳性能。这些方法大多数只使用一种机器学习来预测注塑产品的质量,仍然存在单一模型受自身结构的限制、预测效果无法突破自身上限的问题。而集成学习通过结合多个模型的特点,降低了过拟合的风险,提高了模型对新数据的泛化能力。

在集成模型预测方法中,宋建等^[10]把极端梯度提升树、轻量级梯度提升树、核岭回归作为基学习器,弹性网络回归作为元学习器,构建Stacking集成学习框架,发现预测精度较单一模型有大幅提高。Koo等^[11]使用机器学习算法开发单一模型,包括决策树、随机森林(RF)、逻辑回归、贝叶斯网络和人工神经网络,并开发了装袋算法与提升算法结合的集成模型,将集成模型的性能与单个模型进行比较,发现集成模型的预测精度优于单个模型。这些方法采用的集成学习框架并没有进一步寻找最优的基学习器超参数,从而将使基学习器的预测误差变大,进而影响模型的准确性。

综上所述,笔者提出一种基于鲸鱼优化算法(WOA)优化Stacking集成学习的方法,实现对注塑产品尺寸的预测。首先,将获得的注塑过程数据进行预处理,再使用RF和互信息法对重要特征进行提取;其次,Stacking集成学习的基学习器选用轻量级梯度提升机算法(LightGBM),RF,K近邻(KNN),元学习器选用弹性网络回归,使用WOA对各个基学习器进行超参数调优;最后,使用Stacking集成学习的元学习器进行训练和验证。

1 特征选择

1.1 数据描述

笔者采用的数据来源于第四届工业大数据创新竞赛(由富士康工业互联网股份有限公司发布),分成4类数据如下。

(1)传感器高频数据:每一模次包含采样时间、模内压力与模内温度等24个传感器数据,采样频率为20 Hz与50 Hz两种,总计16 600组数据。

(2)成型机状态数据:试模过程收集的数据,包括试模一次的周期时间、温度均值与锁模压力等86种参数,总计16 600组。

(3)机台工艺设定数据:注塑机初始设定参数,包括合模压力、合模速度与合模终点等81种参数,总计295组。

(4)产品测量尺寸:每一模次对应的三维尺寸,记为size1, size2和size3,分别对应产品的长、宽和高,总计16 600组。

1.2 数据预处理

首先,提取每一模次中的模内压力、模内温度、冷水温度等传感器数据的最大值、最小值、标准差、均值以及中值以充分表现每一模次中对应传感器的数据特征,并将机台工艺设定数据填充到对应模次的区间中。其次,将存在大量缺失值和重复值的特征进行删除,采用 3σ 准则进行异常值筛选,存在少量缺失值和异常值的特征采取相应特征的均值进行填充。 3σ 准则规定了在正态分布中,约99.73%的数据值落在3个标准差范围内。采用 3σ 准则进行异常值筛选,其表达式见式(1)。

$$|x_i - \mu| \geq 3\sigma \quad (1)$$

式中: x_i 表示样本中第*i*个观测值; μ 表示*x*的均值; σ 表示*x*的标准差。

将超出 $(\mu - 3\sigma, \mu + 3\sigma)$ 区间范围的值视为异常值,并对存在异常值的特征采取对应特征的均值进行填充。然后,将各个特征的数据进行Min-Max归一化处理,即将数据映射到[0, 1]的范围之间,以消除不同特征之间的量纲差异,其表达式见式(2)。

$$x_{\text{new}} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

式中: x_{new} 表示归一化处理后的值; $x_{\min}$ 表示特征中的最小值; $x_{\max}$ 表示特征中的最大值。

以锁模压力(EL_CLAMP_PRESS)为例,异常值处理结果如图1所示,两条横线代表 3σ 准则在该特征中筛选的上限与下限。




图1 锁模压力的异常值处理

Fig. 1 Outlier processing of clamping pressure

最后,获得16 600组数据,每组数据共计212个特征变量,对数据进行随机切分,分成13 280组训练集和3 320组测试集,并使用产品测量尺寸中的三维尺寸作为目标变量。

1.3 关键特征的选择

注塑过程中收集到的数据包含大量的特征,部分特征可能是冗余的或者噪声过多。提取关键特征的目标是为模型提供更有意义、更有区分性的输入,从而使模型更容易理解数据并做出准确的预测。对于注塑过程得到的高维数据,使用特征降维的方法可以有效地降低冗余信息对模型预测精度的影响^[12]。笔者主要将RF和互信息两种方法结合以实现关键特征的提取。

RF是由多个决策树组成的集成模型。每个决策树使用随机抽样的特征进行训练,增加了模型的

多样性;其次,通过特征重要性分数的计算,RF可以识别出对整体模型性能最为关键的特征^[13]。将各个特征重要度进行排序,保留重要度高的特征,作为后续使用的特征。各个特征的贡献度表达式见式(3)。

$$I_f^{\text{RF}} = \frac{1}{N} \sum_{i=1}^N w_i \cdot I_f^i \quad (3)$$

式中: I_f^{RF} 表示特征 f 的总体重要度; w_i 表示第 i 棵树的权重; I_f^i 表示特征 f 在一棵决策树中的基尼指数。

互信息可以用于度量两个随机变量之间的非线性关系,以捕捉到变量之间任何形式的相互依赖关系。计算RF保留后的特征间的互信息值,若存在互信息较高的特征,便去除其中一个特征,减少特征间的冗余信息。互信息计算公式见式(4)。

$$I(X; Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \left(\frac{p(x, y)}{p(x) \cdot p(y)} \right) \quad (4)$$

式中: $I(X; Y)$ 表示特征 X 与特征 Y 间的互信息; $p(x, y)$ 表示 X 与 Y 同时取值 x 和 y 的联合概率; $p(x)$ 和 $p(y)$ 分别表示 X 与 Y 的边缘概率。

首先,使用RF计算各个特征变量与目标变量间的重要度,选取重要度最高的前20个特征。然后,计算特征间的互信息值,若存在互信息值高于0.9的情况,删除其中一个特征,以减少冗余数据,最终获得3组特征变量。保留3组特征中的共同特征,结果见表1。从表1可以看出,关键特征主要为压力和温度。模内温度和模内压力是注塑过程中非常重要的参数,直接影响着熔融塑料的流动性和产品的成型质量。因此,这些特征的统计量(均值、标准差等)可以提供关于温度和压力稳定性的信息,从而间接地反映产品尺寸的变化。

表1 特征选择结果

Tab. 1 Feature selection results

Feature name	Meaning	Feature name	Meaning
Pack_time_2	Keep pressure for two periods of time	IJ_median	Median value of nozzle injection pressure
MouldTemp2_max	Maximum value of mould temperature machine temperature sensor 2	MouldTemp12_mean	Average value of mould core temperature sensor 12
MouldTemp2_mean	Average value of mould temperature machine temperature sensor 2	Sensor1_median	Median value of in-mould pressure sensor 1
spcTime	System time at end of cycle	Sensor3_max	Maximum value of in-mould pressure sensor 3
MouldTemp10_mean	Average value of mould core temperature sensor 10	Sensor6_mean	Average value of in-mould temperature sensor 6
MouldTemp13_mean	Average value of mould core temperature sensor 13		

2 WOA优化Stacking集成学习预测方法

2.1 WOA

WOA是一种启发式优化算法,其基本思想是

模拟鲸鱼在搜索食物时的行为,其中包括迁徙、觅食和社交行为等^[14],以下对WOA的基本流程进行介绍。

2.1.1 包围猎物

由于最优位置在搜索空间中的位置是未知的,鲸鱼优化算法假设当前的最佳候选解是目标猎物或接近最优解。在设定最佳候选解之后,其余个体将尝试向最佳位置移动并更新其位置。位置更新公式见式(5)和式(6)。

$$D = |CX^*(t) - X(t)| \quad (5)$$

$$X(t+1) = X^*(t) - AD \quad (6)$$

式中: D 表示当前个体与最佳候选解的距离; t 表示当前迭代次数; A 和 C 表示系数向量; $X^*(t)$ 表示当前最优候选解的位置向量; $X(t)$ 表示当前个体的位置向量。

系数向量 A 和 C 由式(7)、式(8)、式(9)求得。

$$A = 2ar_1 - a \quad (7)$$

$$C = 2r_2 \quad (8)$$

$$a = 2 - \frac{2t}{T_{\max}} \quad (9)$$

式中: r_1 和 r_2 表示 $[0, 1]$ 间的随机向量; $T_{\max}$ 表示最大迭代次数; a 表示线性收敛因子,从2线性递减到0。

2.1.2 气泡网捕食

鲸鱼能识别猎物的位置并以螺旋移动的方式靠近它们,位置更新公式见式(10)和式(11)。

$$X(t+1) = X^*(t) + D_p e^{bl} \cos(2\pi l) \quad (10)$$

$$D_p = |X^*(t) - X(t)| \quad (11)$$

式中: D_p 表示当前个体与猎物位置间的距离; b 表示螺旋参数; l 表示 $[-1, 1]$ 间的随机数。

鲸鱼螺旋移动接近猎物的同时,还需要缩小包围圈。设定有50%的概率选择收缩包围机制和选择螺旋模型,其表达式见式(12)。

$$X(t+1) = \begin{cases} X^*(t) - AD, & p < 0.5 \\ X^*(t) + D_p e^{bl} \cos(2\pi l), & p \geq 0.5 \end{cases} \quad (12)$$

式中: p 表示选择两种模式的概率,介于区间 $(0, 1)$ 间。

随着迭代次数的增加,参数 a 将减小,系数向量 A 是 $[-a, a]$ 间的随机值。当 $|A| < 1$ 时,个体的下一个位置将是自身位置和猎物位置间的任意位置。

2.1.3 搜索猎物

在寻找新的猎物中,其数学模型见式(13)和式(14)。

$$D = |CX_{\text{rand}} - X(t)| \quad (13)$$

$$X(t+1) = X_{\text{rand}} - AD \quad (14)$$

式中: X_{rand} 表示随机产生的个体位置向量。

当 $|A| \geq 1$ 时,随机生成新的个体位置,更新所有个体的位置,以寻找最佳解,从而加强该算法的全局搜索能力。

2.2 Stacking集成学习

Stacking集成学习模型通过结合多个模型的优势,从而提高整体模型的性能和泛化能力^[15]。第一层包含多个基学习器,每个基学习器对应一种模型,将多个基学习器的预测结果合并成新的数据集,输入到第二层的元学习器中,通过元学习器进行训练,获得最终的预测结果。假设存在 J 个基学习器,Stacking集成学习整体框架如图2所示。




图2 Stacking集成学习整体框架

Fig. 2 Overall framework of Stacking ensemble learning

Stacking集成学习模型如图3所示。首先,将原始数据划分为训练集和测试集,再将训练集数据通过交叉验证分成 K 个子集。对于每一个子集,将该子集作为验证集,剩余的 $K-1$ 个子集合并为训练集,进行模型训练,并生成该子集对应的预测值,重复这个过程直到每个子集生成相应的预测值。其次,将基学习器的预测值合并成一个新的训练集,




图3 Stacking集成学习模型

Fig. 3 Stacking ensemble learning model

把合并后的训练集作为元学习器的训练集,并将基学习器中的 K 列测试集取平均值,将其作为元学习器的测试集。最后,由于存在 J 个基学习器,最终将在元学习器中生成 J 个训练集和 J 个测试集,进行模

型训练,得到最终的预测结果。

2.3 WOA-Stacking 集成学习模型

笔者提出的基于WOA-Stacking集成学习的注塑产品尺寸预测方法整体流程如图4所示。




图4 注塑产品尺寸预测方法整体流程图

Fig. 4 Overall flow chart of injection molding product size prediction method

基于WOA-Stacking集成学习的注塑产品尺寸预测的步骤如下。

(1)收集并整合注塑过程得到数据,处理数据中的缺失值和异常值,并进行Min-Max归一化处理。

(2)对处理后的数据进行特征选取,使用RF提取重要度高的特征,再使用互信息法去除互信息值较高的特征,减少冗余特征,以获得最优特征。

(3)将数据集划分为训练集和测试集,输入到Stacking集成学习的基学习器,并使用WOA对Stacking集成学习的每个基学习器进行超参数调优,以获得最优的基学习器参数,最后将基学习器训练后的数据输入到元学习器中,得到预测结果。

3 实验结果与分析

3.1 评价指标

所选用的评分指标为平均绝对误差(MAE)、均方根误差(RMSE)、决定系数(R^2),计算公式见式(15)、式(16)、式(17)。

$$E_M = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (15)$$

$$E_R = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (16)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (17)$$

式中: E_M 和 E_R 分别表示MAE和RMSE; n 表示预测集样本总数; y_i 表示第 i 个样本的实际值; $\hat{y}_i$ 表示第 i 个样本的预测值; $\bar{y}$ 表示预测集样本的均值。

3.2 模型的建立与训练

在Stacking集成学习中,基学习器的性能和多样性直接影响最终Stacking模型的性能,而元学习器负责结合基学习器的输出,生成最终的模型预测。KNN对于局部关系的拟合能力强,RF对于复杂的非线性关系有良好的性能,而LightGBM在处理大规模数据和高维特征时通常效果显著,三者相结合使得Stacking模型获得更好的预测效果,因此将使用三者作为Stacking模型的基学习器,后续作为单一模型进行比对。弹性网络回归是一种同时结合L1和L2正则化的线性回归方法,有利于防止模型过拟合,因此将其作为Stacking模型的元学习器。

其中,KNN是一种基于实例的学习方法,优化的超参数有 k 值选择和距离参数;RF是一种基于集

成的决策树方法,优化的超参数有决策树个数、决策树最大深度、节点可分的最小样本数、叶子节点含有的最少样本和最大叶子节点数;LightGBM 是一种基于梯度提升的树模型,优化的超参数有学习率、迭代次数、树模型最大深度、叶子节点个数和特征随机采样率。将表 1 中的 11 个变量作为特征变量,分别将产品测量尺寸中的 size1, size2 和 size3 作为目标变量,使用 WOA 算法对 Stacking 集成学习模型中各个基学习器的超参数进行优化。

3.3 特征选择的有效性

为了证明本文特征选择方法的有效性,以 size1 为目标变量,使用 RF 回归算法对本文特征选择方法、RF 特征选择、Pearson 特征选择和原始特征的评价指标进行对比。RF 特征选择方法设置为选取重要度最高的 20 个特征, Pearson 特征选择方法设置为选取相关度最高的 40 个特征,结果见表 2。更低的 MAE 和 MSE 表明模型对真实数据的拟合更为精准,预测结果更接近实际观测值,反映了模型在捕捉目标变量方面的卓越性能;更接近于 1 的 R^2 表示模型更好地解释了目标变量的方差,对观测数据的变化有更好的拟合度。从表 2 可以看出,本文特征选择方法更能提取出关键特征,从而提升尺寸预测的精度。

表 2 特征选择方法结果对比

Tab. 2 Comparison of feature selection results			
Feature selection method	MAE/mm	RMSE/mm	R^2
Method of this article	0.016 1	0.021 9	0.727 3
RF	0.016 5	0.022 7	0.706 9
Pearson	0.017 1	0.023 3	0.692 7
Original features	0.017 4	0.023 9	0.675 7

3.4 模型结果对比分析

为了验证本文的 WOA-Stacking 集成学习算法的有效性,将 WOA-Stacking 模型、经过贝叶斯优化(BO)调参的 Stacking 模型、未经过优化调参的 Stacking 模型和其余单一模型(RF, LightGBM 和 KNN)的评价指标进行对比,结果见表 3。

从表 3 可以看出,未经过优化调参的 Stacking 模型预测精度低于 BO-Stacking 模型。而 WOA-Stacking 模型在 3 个尺寸上的 MAE 较 BO-Stacking 模型分别降低了 7.69%, 6.80% 和 6.25%; RMSE 较 BO-Stacking 模型分别降低了 7.61%, 6.19% 和 5.92%; R^2 较 BO-Stacking 模型分别提高了 3.96%, 1.82% 和 3.90%。因此,经过 WOA 算法优化后的 Stacking 集成学习具有更高的预测精度,证明了

WOA 算法的有效性。

在单一模型中,LightGBM 模型的精度最高。WOA-Stacking 模型在 3 个尺寸上的 MAE 较 LightGBM 模型分别降低了 14.29%, 13.29% 和 15.49%; RMSE 较 LightGBM 模型分别降低了 12.92%, 12.92% 和 13.59%; R^2 较 LightGBM 模型分别提高了 7.73%, 4.30% 和 9.66%。因此,WOA-Stacking 模型优于其余 3 种单一模型,证明了 WOA-Stacking 模型具有更高的准确性和稳定性。

在算法时间方面,WOA-Stacking 模型在 3 个尺寸上的算法速度较 BO-Stacking 模型和 Stacking 模型均有所提高。由于 WOA-Stacking 模型将 3 种单一模型的算法融合使用,与单一模型对比,该算法在速度上不具备优势,但在实际应用中不会造成影响。

表 3 模型结果对比

Tab. 3 Comparison of model results					
Target variable	Model category	MAE/mm	RMSE/mm	R^2	Time/s
Size1	WOA-Stacking	0.013 2	0.018 2	0.810 9	1.065 5
	BO-Stacking	0.014 3	0.019 7	0.780 0	1.299 8
	Stacking	0.015 3	0.021 1	0.748 4	1.554 4
	RF	0.016 5	0.022 7	0.706 9	0.491 9
	LightGBM	0.015 4	0.020 9	0.752 7	0.313 2
	KNN	0.016 8	0.022 7	0.707 3	0.569 0
Size2	WOA-Stacking	0.013 7	0.018 2	0.882 2	1.003 7
	BO-Stacking	0.014 7	0.019 4	0.866 4	1.260 3
	Stacking	0.015 1	0.020 1	0.858 2	1.486 4
	RF	0.016 8	0.021 9	0.833 1	0.591 7
	LightGBM	0.015 8	0.020 9	0.845 8	0.308 7
	KNN	0.016 3	0.021 7	0.833 8	0.582 7
Size3	WOA-Stacking	0.012 0	0.015 9	0.803 7	0.928 5
	BO-Stacking	0.012 8	0.016 9	0.773 5	1.234 2
	Stacking	0.013 8	0.018 0	0.744 3	1.509 6
	RF	0.014 9	0.019 5	0.700 4	0.409 3
	LightGBM	0.014 2	0.018 4	0.732 9	0.378 9
	KNN	0.016 4	0.021 2	0.678 9	0.522 0

选取全部测试集数据,WOA-Stacking 模型在 3 个尺寸上的预测结果如图 5 所示。从图 5 可以看出,WOA-Stacking 模型的预测趋势和实际尺寸的趋势基本一致。可见,WOA-Stacking 模型通过融合不同的单一模型,成功地利用了不同模型之间的互补性和差异性,从而提高了对实际尺寸变化的拟合能力。

4 结论

提出了一种 WOA 算法优化 Stacking 集成学习的模型,以实现注塑产品尺寸的预测,主要结论




图5 WOA-Stacking模型预测结果

Fig. 5 Prediction results of WOA-Stacking model

如下。

(1)通过 3σ 准则筛选注塑过程数据中的异常值,再通过RF、互信息法两种特征筛选方式有效地提取了影响注塑尺寸的重要特征,降低了冗余信息的影响,提高了模型的预测能力。

(2)使用Stacking集成学习结合了不同基学习器的优点,相较于单一模型,具有更高的预测精度;使用WOA算法对Stacking集成学习的基学习器进行超参数调优从而获得性能最优的基学习器,相较于BO-Stacking模型和未经过优化的Stacking模型,具有更高的预测精度。以第四届工业大数据创新竞赛为例,WOA-Stacking集成学习相较于其余模型,平均绝对误差、均方根误差均有降低,决定系数均有提高,验证了设计的WOA-Stacking模型的有效性,具有一定的工程应用价值。

参考文献

[1] AMINABADI S S, TABATABAI P, STEINER A, et al. Industry 4.0 in-line AI quality control of plastic injection molded parts[J]. *Polymers*, 2022, 14(17):3 551–3 573.

- [2] GIM J, TURNG L S. A review of current advancements in high surface quality injection molding: Measurement, influencing factors, prediction, and control[J]. *Polymer Testing*, 2022, 115. DOI:10.1016/j.polymertesting.2022.107718.
- [3] 徐雨,张集海.可注塑成型天然橡胶组合物硫化机理[J]. *高分子材料科学与工程*, 2022, 38(5):58–61, 68.
XU Yu, ZHANG Jihai. Vulcanization mechanism of natural rubber compositions for injection molding[J]. *Polymer Materials Science & Engineering*, 2022, 38(5):58–61, 68.
- [4] 季宁,张卫星,于洋洋,等.基于径向基函数神经网络和多岛遗传算法的注射成型质量控制与预测[J]. *工程塑料应用*, 2020, 48(4): 62–68.
JI Ning, ZHANG Weixing, YU Yangyang, et al. Quality control and prediction of injection molding based on RBF neural network and MIGA[J]. *Engineering Plastics Application*, 2020, 48(4):62–68.
- [5] 王雅哲,马其华.机器学习在复合材料领域中的应用进展[J]. *工程塑料应用*, 2023, 51(9):167–174.
WANG Yazhe, MA Qihua. Progress in application of machine learning in field of composite materials[J]. *Engineering Plastics Application*, 2023, 51(9):167–174.
- [6] PÁRIZS R D, TÖRÖK D, AGEYEVA T, et al. Machine learning in injection molding: An industry 4.0 method of quality prediction[J]. *Sensors*, 2022, 22(7):2 704–2 721.
- [7] 刘永兴,唐小琦,钟靖龙,等.基于轻量级梯度提升机的非对称风险注塑成形产品尺寸预测模型[J]. *中国机械工程*, 2022, 33(8): 965–969.
LIU Yongxing, TANG Xiaoqi, ZHONG Jinglong, et al. Asymmetric risk injection molding product size prediction model based on LightGBM[J]. *China Mechanical Engineering*, 2022, 33(8): 965–969.
- [8] KE K-C, HUANG M-S. Enhancement of multilayer perceptron model training accuracy through the optimization of hyperparameters: A case study of the quality prediction of injection-molded parts[J]. *The International Journal of Advanced Manufacturing Technology*, 2022, 118:2 247–2 263.
- [9] FARAHANI S, XU B, FILIPI Z, et al. A machine learning approach to quality monitoring of injection molding process using regression models[J]. *International Journal of Computer Integrated Manufacturing*, 2021, 34(11):1 223–1 236.
- [10] 宋建,王文龙,李东,等.基于Stacking集成学习的注塑件尺寸预测方法[J]. *华南理工大学学报(自然科学版)*, 2022, 50(6):19–26.
SONG Jian, WANG Wenlong, LI Dong, et al. Injection molding part size prediction method based on Stacking ensemble learning [J]. *Journal of South China University of Technology(Natural Science Edition)*, 2022, 50(6):19–26.
- [11] KOO K, CHOI K, YOO D. Double ensemble technique for improving the weight defect prediction of injection molding in smart factories[J]. *IEEE Access*, 2023, 11:113 605–113 622.

(下转第163页)