

基于多策略-交通拥堵优化-支持向量回归算法的 重组竹参数及质量的双向预测

张佳薇¹, 刘志浩¹, 刘吉宇², 丁禹程^{2*}

(1. 东北林业大学 控制与信息工程学院, 哈尔滨 150040; 2. 东北林业大学 机电工程学院, 哈尔滨 150040)

摘 要: 针对重组竹热压成型过程中工艺参数多因素耦合、依赖经验调参且试错成本高的问题, 亟需建立工艺参数与质量指标之间的定量映射关系, 并进一步实现面向目标性能的参数反推。为此, 提出一种基于多策略 (multi-strategy, MS) 交通拥堵优化算法 (traffic jam optimization, TJO) 优化的支持向量回归 (support vector regression, SVR) 方法——MS-TJO-SVR, 用于构建重组竹工艺参数与质量指标的双向预测模型。正向预测以密度、含水率、施胶量和保压时间为工艺参数输入, 以静曲强度、水平抗剪强度、吸水宽度膨胀率和吸水厚度膨胀率为质量指标输出; 反向预测以质量指标为输入, 反推相应工艺参数。通过 MS-TJO 对 SVR 关键超参数进行联合寻优, 提高模型对非线性关系的表征能力与预测稳定性。结果表明, 所构建的 MS-TJO-SVR 在正向与反向预测任务中均具有较高的拟合精度和较小的预测误差, 且在与传统 SVR 及其他优化 SVR 方法的对比中表现出更优的综合性能。研究结果可为重组竹热压成型参数优化与质量预测提供有效的建模工具与方法参考。

关键词: 重组竹; 工艺参数; 双向预测; 质量指标; 支持向量回归; 参数优化; 多策略优化; 交通拥堵优化算法

中图分类号: TS652; S781.9

文献标识码: A

DOI: 10.7525/j.issn.1006-8023.2026.03.009

Bidirectional Prediction of Process Parameters and Quality Indicators of Reconstituted Bamboo Based on Multi-Strategy Traffic Jam Optimization and Support Vector Regression

ZHANG Jiawei¹, LIU Zhihao¹, LIU Jiyu², DING Yucheng^{2*}

(1. College of Control and Information Engineering, Northeast Forestry University, Harbin 150040, China; 2. College of Mechanical and Electrical Engineering, Northeast Forestry University, Harbin 150040, China)

Abstract: In the hot-press molding process of reconstituted bamboo, the coupling of multiple process parameters, reliance on empirical parameter adjustment, and high trial-and-error costs make it necessary to establish a quantitative mapping relationship between process parameters and quality indicators, and further realize reverse prediction of parameters for target performance. To address this issue, a support vector regression (SVR) method optimized by a multi-strategy (MS) traffic jam optimization (TJO) algorithm, namely MS-TJO-SVR, is proposed to develop a bidirectional prediction model for the process parameters and quality indicators of reconstituted bamboo. In the forward prediction, density, moisture content, adhesive content, and pressure holding time are used as input process parameters, while modulus of rupture, horizontal shear strength, water absorption width swelling rate, and water absorption thickness swelling rate are used as output quality indicators. In the reverse prediction, the quality indicators are used as inputs to predict the corresponding process parameters. By jointly optimizing the key hyperparameters of SVR, MS-TJO enhances the model's abil-

收稿日期: 2026-01-03

基金项目: 国家竹产业研究院委托研发项目 (2025YJY07)。

第一作者简介: 张佳薇, 博士, 教授。研究方向为林业物联网和智能检测。E-mail: zjw@nefu.edu.cn

*** 通信作者:** 丁禹程, 博士, 讲师。研究方向为林业智能装备与检测。E-mail: 18646656293@163.com

引文格式: 张佳薇, 刘志浩, 刘吉宇, 等. 基于多策略-交通拥堵优化-支持向量回归算法的重组竹参数及质量的双向预测[J]. 森林工程, 2026, 42(3): 530-544.

ZHANG J W, LIU Z H, LIU J Y, et al. Bidirectional prediction of process parameters and quality indicators of reconstituted bamboo based on multi-strategy traffic jam optimization and support vector regression[J]. Forest Engineering, 2026, 42(3): 530-544.

ity to characterize nonlinear relationships and improves prediction stability. The results indicate that MS-TJO-SVR achieves high fitting accuracy and low prediction error in both forward and reverse prediction tasks, and outperforms traditional SVR and other optimized SVR methods in overall performance. This study provides an effective modeling tool and methodological reference for process parameter optimization and quality prediction in the hot-press molding of reconstituted bamboo.

Keywords: Reconstituted bamboo; process parameters; bidirectional prediction; quality indicators; support vector regression; parameter optimization; multi-strategy optimization; traffic jam optimization algorithm

0 引言

随着绿色建材与可再生资源需求的增长,竹材凭借生长周期短、比强度高及可再生供给能力强等优势,被认为是木材的潜在替代材料,并在建筑与工程领域受到广泛关注^[1-2]。为提升材料一致性与工程适用性,重组竹通过纤维化重组、施胶与热压成型等工艺实现结构重组与性能均化,其制造过程与最终性能对工艺路径与压制条件高度敏感^[3-4]。热压成型作为关键环节,涉及压实致密化、传热传质与胶黏剂固化等多物理过程耦合,工艺参数(如密度、含水率、施胶量和保压时间等)存在显著耦合关系,并共同影响材料力学性能与吸水尺寸稳定性^[5-7]。已有研究表明,热压参数及树脂体系等因素会改变竹束板的传热行为、孔隙结构与界面结合质量,从而影响弯曲强度、抗剪强度与吸水厚度膨胀等指标^[8-10]。然而实际生产中工艺参数仍常依赖经验设定,导致性能波动与返工成本增加;传统“试错式”优化周期长、效率低,难以满足快速响应与精准控制需求^[11]。此外,现有研究多停留在单因素或局部参数组合层面,对多参数耦合条件下质量指标的定量预测及面向目标性能的工艺参数反推仍缺乏统一、高效的建模框架。

针对上述问题,有必要采用数据驱动方法对工艺参数与质量指标之间的复杂关联进行建模。机器学习在分析非线性映射方面具有优势,可用于实现质量预测与参数优化。支持向量回归(support vector regression, SVR)基于结构风险最小化原则,在小样本、非线性回归问题中具有较好的泛化能力,适用于复杂工艺过程性能预测^[12-13]。但SVR对惩罚系数、核参数及不敏感区等超参数较为敏感,选参不当易导致欠拟合或过拟合,从而降低模型稳定性与预测精度^[14-15]。因此,引入智能优化算法对SVR超参数进行自适应寻优已成为提升预测性能的有效手段。杜京义等^[16]将遗传算法(genetic algorithm, GA)用于SVR参数选取,通过群体搜索实现惩罚系数与核参数的全局寻优,从而降低人工调参不确定性,并提升预测稳定性。Kavousi-Fard等^[17]提出了一种改进的萤

火虫算法与SVR结合的混合框架,该框架自适应地确定关键参数并应用于短期负荷预测,验证了其在精度上的优势。Gu等^[18]则针对 ν -SVR提出了一种增量学习策略(ν -参数),能够在数据逐步到达的场景中实现在线更新,兼顾了训练效率和泛化能力。王昕等^[19]提出了概率神经网络-主成分分析-分散搜索优化支持向量回归组合模型(probabilistic neural network-principal component analysis-scatter search-support vector regression, PNN-PCA-SS-SVR)组合模型,该模型通过PCA进行降维以减少冗余信息,同时结合SS-SVR提升回归能力,成功应用于光伏功率短期预测,并取得了良好的预测效果。李崎勇等^[20]采用改进的鲸鱼算法(improved whale optimization algorithm, IWOA)来优化SVR的参数,并将其应用于光伏最大功率点跟踪,该方法在精度和动态响应方面优于传统方法。徐佳宁等^[21]则构建了一种改进的SVR模型,用于锂电池剩余寿命(remaining useful life, RUL)的预测,结合模型改进与参数优化,提升了预测的精度和稳定性,验证了该方法在复杂退化过程建模中的应用潜力。

面向竹基热压过程,丁禹程^[22]提出了工艺参数-质量指标的双向预测框架,为目标性能驱动的工艺反推与过程控制提供了有益探索,但其超参数寻优策略在全局搜索覆盖与收敛精度方面仍有提升空间。当工况变化或数据噪声较大时,寻优过程可能出现搜索不充分或收敛于次优解的情况,从而影响模型预测稳定性与工艺反推精度。为此,本研究以交通阻塞优化算法(traffic jam optimizer, TJO)为基础^[23],融合差分进化(differential evolution, DE)策略^[24]、混沌-随机对称初始化策略(chaotic-random symmetric initialization strategy, CRSIS)^[25]与导向学习改进策略(guided learning strategy, GLS)^[26],形成多策略(multi-strategy, MS)协同的MS-TJO算法,并用于SVR超参数联合寻优,构建重组竹热压工艺参数与质量指标的双向预测模型。该模型可实现由工艺参数预测性能指标以及由目标性能反推工艺参数的统一建模,为重组竹热压参数优化与质量预测提供方法支撑。

1 多策略-交通拥堵优化-支持向量回归 (MS-TJO-SVR) 双向预测方法

1.1 TJO 算法

交通拥堵优化算法(TJO)是一种模拟交通拥堵疏导过程的群体智能优化算法。其灵感来源于交通管理中“自动驾驶-自我调节-强制引导”的三阶段干预策略,通过模拟驾驶员行为从无序探索到有序收敛的演化过程,实现对解空间的全局搜索与局部开发。算法主要包括种群初始化、自动驾驶阶段、自我调节阶段、强制引导阶段以及边界处理与种群更新5个核心步骤,以下将逐一阐述。

1.1.1 种群初始化

TJO算法的初始化过程采用随机生成策略。假设优化问题的维度为 d ,变量下界为 $\mathbf{l}=[l_1, l_2, \dots, l_d]$,上界为 $\mathbf{u}=[u_1, u_2, \dots, u_d]$ 。设种群大小为 N ,最大迭代次数为 T 。记第 i 个个体在初始化时刻的位置信息为 $\mathbf{x}_i=[x_{i1}, x_{i2}, \dots, x_{id}]$,其中, $i=1, 2, \dots, N; j=1, 2, \dots, d$,表示第 j 个维度(第 j 个决策变量)。第 i 个个体的初始位置 $\mathbf{x}_i$ 可通过公式生成,该公式为

$$x_{ij} = r_1 \cdot (u_j - l_j) + l_j \quad (1)$$

式中, r_1 为从 $[0, 1]$ 区间均匀分布的随机数。

1.1.2 自动驾驶阶段(autonomous)

此阶段模拟无交通指挥时驾驶员按自身意愿行驶的过程。个体根据历史最优位置和全局最优位置的加权组合确定最佳行驶方向,并加入随机扰动模拟驾驶偏离。设 $\mathbf{x}_i^t$ 为第 t 次迭代时第 i 个个体的位置向量($t=1, 2, \dots, T$),则其更新形式为

$$\mathbf{x}_i^t = \mathbf{x}_i^{t-1} + \delta \cdot (r_2 \cdot (\mathbf{u} - \mathbf{l}) + \mathbf{l}) \quad (2)$$

式中: δ 为违章程度系数,控制随机扰动的强度; r_2 为随机数; $\mathbf{x}_i^{t-1}$ 为加权得到的最优参考位置向量,计算公式为

$$\mathbf{x}_i^{t-1} = (1 - \lambda) \mathbf{s}_i + \lambda \mathbf{x}_{\text{best}} \quad (3)$$

式中: $\mathbf{s}_i$ 为个体历史最优位置; $\mathbf{x}_{\text{best}}$ 为全局历史最优位置; $\lambda = t/T$ 为迭代比例因子; $\delta = \alpha(1 - \lambda)e^{-\lambda} \sin(r_3) \cos(r_4)$ 为违章程度系数, r_3 和 r_4 为随机数。

$$\alpha = 1.5 - (t - 1)/(T - 1) \quad (4)$$

1.1.3 自我调节阶段(self-regulation)

此阶段模拟驾驶员在意识到拥堵后自主调整行为的过程。个体根据当前经验或随机尝试新方向为

$$\mathbf{x}_i^t = \begin{cases} \mathbf{x}_i^{t-1} + \alpha \sin r_5 \cdot (\mathbf{x}_r^t - \mathbf{x}_i^t), & R > 0.5 \\ \mathbf{x}_i^{t-1} + \alpha \sin r_6 \cdot (\mathbf{x}_i^{t-1} - \mathbf{x}_i^t), & R \leq 0.5 \end{cases} \quad (5)$$

式中: $\mathbf{x}_r^t$ 为从第一阶段中随机选择的个体位置; R, r_5, r_6 为随机数,用于控制个体调整行为的强度。

1.1.4 强制引导阶段(enforce)

此阶段模拟交警介入指挥,所有驾驶员按统一最优方向行驶的过程,公式为

$$\mathbf{x}_i^t = \mathbf{x}_i^{t-1} + \beta \sin r_7 \cdot (\mathbf{x}_i^{t-1} - \mathbf{x}_i^t) \quad (6)$$

式中: $\beta = 0.5 + (t - 1)/(T - 1)$,为线性调节因子; r_7 为随机数。

1.1.5 边界处理及种群更新

为处理越界解,本算法采用边界约束策略

$$\mathbf{x}_{ij}^{\text{new}} = \begin{cases} u_j, & x_{ij}^{\text{new}} > u_j \\ l_j, & x_{ij}^{\text{new}} < l_j \\ x_{ij}^{\text{new}}, & \text{其他} \end{cases} \quad (7)$$

更新种群规则为

$$\mathbf{x}_i^{t+1} = \begin{cases} \mathbf{x}_i^{\text{new}}, & F(\mathbf{x}_i^{\text{new}}) < F(\mathbf{x}_i^t) \\ \mathbf{x}_i^t, & \text{否则} \end{cases} \quad (8)$$

算法在达到最大迭代次数 T 后停止,输出全局最优解 $\mathbf{x}_{\text{best}}$ 。

1.2 MS-TJO 算法

尽管TJO具有一定寻优能力,但在复杂非线性问题中仍存在初始种群质量不高、全局搜索能力不足及易陷入局部最优等问题,因此有必要对其进行多策略改进。

1.2.1 差分进化策略

为了提高全局搜索能力并抑制早熟收敛,本研究将差分进化(DE)中的变异和交叉操作,随机性地融入TJO迭代过程中。每代对个体的更新规则是独立选择的:以50%的概率采用TJO更新,否则执行DE更新。通过这种随机混合的机制,2种搜索策略可以在同代中并行执行,从而增强搜索多样性,减少早熟收敛的风险。

个体更新策略具体实现如下。

对第 i 个个体,生成随机数 $R \sim U(0, 1)$ 。

1)当 $R < 0.5$ 时,执行原始TJO更新

包括自动驾驶、自我调节和强制引导3个阶段,保持原TJO算法的完整搜索逻辑。

2)当 $R \geq 0.5$ 时,执行DE更新

变异操作。采用改进的DE/rand/1变异策略,融入当前最优解信息,以平衡探索与开发,其公式为

$$\mathbf{v}_i = \mathbf{x}_i + 0.5 \cdot (\mathbf{x}_{\text{best}} - \mathbf{x}_i) + 0.5 \cdot (\mathbf{x}_{r1} - \mathbf{x}_{r2}) \quad (9)$$

式中: $\mathbf{x}_{r1}$ 和 $\mathbf{x}_{r2}$ 为从当前种群中随机选择的2个不同个体; $\mathbf{x}_{\text{best}}$ 为当前全局最优解。

交叉操作。采用两项交叉策略,确保子代个体能同时继承父代与变异个体的优良特性,其公式为

$$\mathbf{u}_{i,j} = \begin{cases} \mathbf{v}_{i,j}, & \text{if rand} \leq 0.5 \text{ 或 } j = j_{\text{rand}} \\ \mathbf{x}_{i,j}, & \text{其他} \end{cases} \quad (10)$$

式中, j_{rand} 为随机选择的维度索引,保证至少有一个维

度来自变异向量。

1.2.2 混沌-随机对称初始化策略

为了提高初始种群的质量和多样性,本研究设计了一种混沌-随机对称初始化策略(chaotic-random symmetric initialization strategy, CRSIS)。该策略通过使用混沌映射代替传统的随机初始化,并结合自适应的随机反向学习机制,来构建具有良好遍历性和探索性的初始种群。

1)混沌映射初始化

采用具有优良遍历特性的 Logistic 混沌映射生成主体初始种群,其公式为

$$\mathbf{x}_{k+1} = \mu \cdot \mathbf{x}_k \cdot (1 - \mathbf{x}_k), \mu = 4. \quad (11)$$

式中,初始值 $\mathbf{x}_0$ 为(0,1)区间内的随机数。将混沌序列映射至搜索空间,其公式为

$$\mathbf{P}_{\text{chaos}}^{(i)} = \mathbf{l}_{bj} + (\mathbf{u}_{bj} - \mathbf{l}_{bj}) \odot \mathbf{x}^{(i)}. \quad (12)$$

式中: $\odot$ 表示逐元素乘法; $\mathbf{l}_{bj}$ 为搜索空间下界; $\mathbf{u}_{bj}$ 为搜索空间上界。混沌序列的遍历特性确保初始解在搜索空间中分布更均匀。

2)自适应随机反向学习

为充分利用搜索空间的对称性并引入可控随机性,提出自适应随机反向学习机制(adaptive randomized opposition-based learning, AROBL),公式为

$$\mathbf{P}_{\text{AROBL}}^{(i)} = \mathbf{l}_{bj} + \mathbf{u}_{bj} - \mathbf{r} \odot \mathbf{P}_{\text{chaos}}^{(i)} \quad (13)$$

式中, $\mathbf{r} \in [0, 1]^d$ 为动态随机系数向量,其元素按如下方式生成,公式为

$$r_j = 0.5 \cdot (1 + \sin(2\pi \cdot \xi + \phi_j)). \quad (14)$$

式中: ξ 和 ϕ_j 均为[0,1]区间内的随机数; r_j 表示动态随机系数,通过正弦函数生成,用于调节搜索中的随机扰动,确保扰动的可控性和适应性。该设计使得反向学习不再是固定对称,而是具有自适应随机偏移特性,既保持了反向学习的基本思想,又引入了探索性随机扰动。

3)精英竞争选择

将混沌初始化种群 $\mathbf{P}_{\text{chaos}}$ 与自适应随机反向学习种群 $\mathbf{P}_{\text{AROBL}}$ 合并,得到规模为 $2N$ 的候选种群 $\mathbf{P}_{\text{candidate}}$ 。计算所有候选个体的适应度值后,采用精英保留策略筛选前 N 个最优个体构成最终初始种群。

1.2.3 导向学习改进策略

为了进一步提高算法的收敛精度和个体质量,本研究引入了一种导向学习策略(guided learning strategy, GLS)作为增强机制。该策略通过分析种群在各个维度上的分布情况,自适应地选择全局探索或局部开发策略,在个体级别上与原有的TJO-DE机制进行竞争优化。

导向学习的核心在于动态感知种群在各维度的收

敛状态。本研究采用个体历史最优位置FlockMemoryX在各维度上的标准差作为收敛度指标,公式为

$$V_0^{(j)} = \text{std}(\text{FlockMemoryX}(j)) / (\mathbf{u}_{bj} - \mathbf{l}_{bj}). \quad (15)$$

式中, $V_0^{(j)}$ 表示第 d 维的标准化分散度,其值越大,表明种群在该维度上越分散,需要进行全局探索,其值越小则表明种群在该维度上越集中,适合进行局部精细搜索。

基于收敛度指标 V_0 ,对每个维度独立选择更新策略。设定阈值参数 $A = 0.3$,迭代进度因子 $\eta = 1 - t/T$ 。

当 $V_0^{(j)} > A$ 且随机数小于 0.7η 时,该维度处于分散状态且处于算法前期,采用全局探索策略,公式为

$$\mathbf{x}_{\text{GLS}}^{(ij)} = \mathbf{l}_{bj} + \text{rand} \cdot (\mathbf{u}_{bj} - \mathbf{l}_{bj}). \quad (16)$$

式中, $\text{rand} \sim U(0, 1)$ 为均匀分布随机数。

当 $V_0^{(j)} > A$ 但随机数不小于 0.7η 时,该维度处于分散状态但已进入算法中后期,围绕个体历史最优进行探索,公式为

$$\mathbf{x}_{\text{GLS}}^{(ij)} = \text{FlockMemoryX}^{(ij)} + R_1 \cdot (2 \cdot \text{rand} - 1). \quad (17)$$

式中, $R_1 = 0.2(\mathbf{u}_{bj} - \mathbf{l}_{bj})\eta$,为动态搜索范围。

当 $V_0^{(j)} \leq A$ 时,该维度已趋于集中,采用导向局部开发策略,在全局最优解附近进行精细搜索

$$\mathbf{x}_{\text{GLS}}^{(ij)} = \mathbf{x}_{\text{best}}^{(j)} + \tan(\pi(\text{rand} - 0.5)) \cdot R_2 \cdot \eta. \quad (18)$$

式中: $R_2 = 0.1(\mathbf{u}_{bj} - \mathbf{l}_{bj})$,为搜索范围; $\tan$ 函数产生的非线性扰动保证了搜索的多样性。

导向学习策略以个体竞争的方式与主算法融合。每代迭代先生成一组导向学习候选种群 $\mathbf{x}_{\text{GLS}}$,随后逐个比较个体适应度:若 $\mathbf{x}_{\text{GLS}}$ 中对应个体优于原个体,则进行替换。该竞争机制在保留原策略优势个体的同时,引入导向学习的潜在改进,从而实现2种策略的互补融合。

1.2.4 时间复杂度分析

设定算法的种群规模为 N 、问题维度为 d ,最大迭代次数为 T 。原始TJO算法的计算主要包括初始化、个体更新和适应度评估,因此其整体时间复杂度为 $O(NdT)$ 。

在此基础上,本研究引入了3种改进机制,其对复杂度的贡献为:1)CRSIS初始化—混沌映射和自适应随机反向学习各自生成 N 个个体并进行精英筛选,其复杂度为 $O(Nd)$,相较于迭代主过程可忽略不计;2)DE融合策略—个体以50%的概率选择TJO或DE更新,单次更新的复杂度为 $O(d)$,因此不改变总体量级,仅是调整了更新策略的比例;3)导向学习机制—为每个个体生成GLS候选解,生成过程为 $O(d)$,并增加了一次适应度评估,用于个体之间的竞争选择。

因此,改进算法的总时间复杂度为 $O(NdT)$,与原

始算法保持相同数量级。

1.3 MS-TJO-SVR预测模型构建流程与评价指标

在监督回归任务中,设训练数据集为 $D = \{(\mathbf{x}_i, \mathbf{y}_i) | i = 1, 2, \dots, n\}$, 其中 $\mathbf{x}_i$ 与 $\mathbf{y}_i$ 分别表示第 i 个样本的输入变量与输出响应, n 为样本总量。支持向量回归(SVR)的基本思想是将输入 $\mathbf{x}_i$ 通过非线性映射 $\phi(\cdot)$ 投影至高维特征空间,使得在该特征空间中可以采用线性模型刻画输入与输出之间的关系,并据此完成回归拟合。在此框架下,回归函数可表示为

$$f(\mathbf{x}) = \omega^T \varphi(\mathbf{x}) + b. \quad (19)$$

式中: $f(\mathbf{x})$ 为回归函数; ω 为权重向量; b 为偏置项。依据结构风险最小化(SRM)思想,SVR的求解可转化为正则化风险最小化问题

$$\min \frac{1}{2} \|\omega\|^2 + c \sum_{i=1}^n L(f(\mathbf{x}_i), \mathbf{y}_i). \quad (20)$$

式中: $L(\cdot)$ 为损失函数; c 为惩罚因子。

通过核函数可将训练样本隐式映射至高维特征空间,从而增强模型对非线性关系的表征能力。本研究

选用高斯径向基核函数(Radial basis function, RBF)作为SVR的核函数

$$K_{\text{RBF}}(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2\right). \quad (21)$$

式中, γ 为核函数系数。因此,基于核函数的SVR表达式为

$$f(\mathbf{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(\mathbf{x}, \mathbf{x}_i) + b. \quad (22)$$

由式(21)和式(22)可知,SVR的预测性能对超参数设置较为敏感,其中惩罚因子 c 与核函数系数 γ 对模型的拟合能力与泛化性能影响显著。为避免经验选参带来的不确定性,本研究引入MS-TJO对SVR的超参数进行自动寻优。具体而言,将MS-TJO个体位置编码为 $\theta = [c, \gamma]$, 以验证误差MSE作为适应度函数进行迭代搜索,获得最优参数 θ^* , 并据此构建MS-TJO-SVR预测模型。模型最终在验证集上采用决定系数(R^2)、各评价指标决定系数 R^2 的算术平均值(平均 R^2)、平均绝对误差(mean absolute error, MAE)和均方误差(mean squared error, MSE)进行综合评价,整体流程见图1。




图1 MS-TJO-SVR算法流程

Fig. 1 Flowchart of the MS-TJO-SVR algorithm

2 材料与方法

2.1 原材料与试验设备

本研究所使用纤维化竹单板(fibrillated bamboo veneer)由安徽竹迹新材料科技有限公司提供,规格为

210 cm×15 cm×0.75 cm;其气干密度约为0.51 g/cm³,平均相对含水率为9.9%。所用胶黏剂为酚醛树脂,来源于太尔胶黏剂(广东)有限公司;经稀释后,树脂固含量为21%,黏度为188 cP, pH为10.22。

小型试验热压机(BL-6170-B型,东莞市宝轮精密

检测仪器有限公司);电热鼓风恒温干燥箱(DHG-9055A型,天津市泰斯特仪器有限公司),控温范围RT+10~300℃,恒温波动度±1℃;精密裁板锯(MJ90型,沈阳宝山木工设备厂);微机控制电子万能试验机(EUT5000型,深圳市兰博三思材料检测有限公司);恒温水槽,精度1℃;千分尺,精度0.01 mm。

2.2 工艺流程与质量指标计算方法

本研究重组竹试样按“竹束制备—浸胶干燥—组

坯热压成型”工艺制备。胶黏剂为酚醛树脂,干燥采用烘箱烘干;热压温度与压力恒定(140℃、7 MPa),重点对施胶量、含水率、成型密度和保压时间等变量进行分组控制。具体步骤为:竹单板纤维化后裁剪成尺寸一致的竹束;竹束浸渍酚醛树脂并烘干至规定状态(调控施胶量与含水率);按既定方式组坯并在140℃、7 MPa下热压成型(调控密度与保压时间);冷却养护后按标准取样,见图2。




图2 工艺流程图

Fig. 2 Schematic diagram of the process flow

重组竹试样的质量评价依据国家标准 GB/T 40247—2021《重组竹》。评价指标分为两类,力学性能与吸水尺寸稳定性。本研究从力学性能中选取静曲强度和水平抗剪强度,从吸水尺寸稳定性中选取吸水厚度膨胀率和吸水宽度膨胀率作为质量指标;各项测试均按标准规定的方法与条件进行。

1) 静曲强度计算公式为

$$\sigma_b = \frac{3F_{\max} l_1}{2BH^2} \quad (23)$$

式中: σ_b 为静曲强度,MPa; $F_{\max}$ 为最大载荷,N; l_1 为跨距,mm; B 为试件宽度,mm; H 为试件厚度,mm。

2) 水平抗剪强度计算公式为

$$\tau = \frac{3F}{4BH} \quad (24)$$

式中: τ 为水平抗剪强度,MPa; F 为最大载荷,N。

3) 吸水厚度膨胀率与吸水宽度膨胀率的计算公式分别为

$$T_s = \frac{H_2 - H_1}{H_1} \times 100\% \quad (25)$$

$$W_s = \frac{B_2 - B_1}{B_1} \times 100\% \quad (26)$$

式中: T_s 为吸水厚度膨胀率,%; W_s 为吸水宽度膨胀率,%; H_1 、 H_2 分别为浸水前后厚度,mm; B_1 、 B_2 分别为浸水前后宽度,mm。

2.3 试验方案构建与数据采集

鉴于重组竹工业试验成本高、周期长,全因子试验难以兼顾效率与经济性。为在有限试验次数下系统评估工艺参数对质量的影响,本研究采用四因素三水平的田口正交试验设计,以分析各因素主效应并为参数优化提供依据。结合前期工艺经验与文献,选取密度、竹束含水率(浸胶烘干后的二次干燥含水率)、施胶量和保压时间4个关键因素,密度分别为0.95、1.10、1.25 g/cm³;含水率分别为6%、11%、16%;施胶量分别为13%、15%、17%;保压时间分别为9、11、13 min,结果见表1。

表 1 重组竹热压成型试验结果表
Tab. 1 Results of hot-pressing forming experiments for reconstituted bamboo

序号 No.	密度/(g·cm ⁻³) Density	含水率/% Moisture	施胶量/% Adhesive	保压时间/min Pressing holding time	静曲强度/MPa Static bending strength	水平抗剪强度/Pa Horizontal shear strength	吸水宽度膨胀率/% Water absorption width swelling	吸水厚度膨胀率/% Water absorption thickness swelling
1	0.95	6	13	9	250.62	18.78	3.19	10.82
2	0.95	11	15	11	273.28	19.64	1.43	10.13
3	0.95	16	17	13	280.64	23.68	0.97	9.43
4	1.10	6	15	13	297.00	22.86	2.82	8.73
5	1.10	11	17	9	288.71	24.04	2.35	7.80
6	1.10	16	13	11	294.60	21.26	2.65	8.92
7	1.25	6	17	11	326.45	28.06	1.38	8.10
8	1.25	11	13	13	338.08	25.79	1.38	8.91
9	1.25	16	15	9	328.81	25.46	1.39	8.38

2.4 归一化处理与数据划分

由于工艺参数与质量指标存在单位不一致、取值跨度大的特点,直接输入模型易引发尺度偏置,影响超参数搜索与预测稳定性。为此,本研究在建模前对数据进行极值归一化,将各变量缩放至[-1,1]区间,计算公式为

$$x' = 2 \cdot \frac{x - x_{\min}}{x_{\max} - x_{\min}} - 1。$$
 (27)

式中, $x_{\min}$ 与 $x_{\max}$ 为变量最小值与最大值。

预测值随后通过逆变换恢复原始量纲以进行对比。归一化参数在训练集上确定,并同样作用于验证与测试数据。本研究在正交试验设计框架下获取数据,并在试验过程中形成多组有效样本,汇总构建建模数据集。数据集按照70%、30%划分为训练集与验证集,其中验证集为75组样本。完成数据处理与划分后,建模与试验环节均在统一计算平台上完成,硬件环境为13th Gen

Intel(R) Core(TM) i7-13700 5.0 GHz和16 GB RAM。

3 双向预测结果与模型性能分析

3.1 正向模型结果及分析

在正向预测任务中,选择密度、含水率、施胶量和保压时间作为模型的输入变量,吸水厚度膨胀率、吸水宽度膨胀率、静曲强度和水平抗剪强度作为输出响应,建立了一个用于预测重组竹成型质量的模型。为提升SVR建模效果,采用MS-TJO对SVR关键参数进行寻优,获得最优参数组合并据此完成正向预测模型的构建。模型性能基于验证集75组样本进行验证,通过比较预测结果与实测数据评估其准确性。

正向模型的预测结果见表2。由表2可知,在正向预测任务中模型的平均 R^2 达到0.978 2,表明MS-TJO-SVR具有较高的拟合精度,能够有效表征工艺参数与性能指标之间的非线性关系。

表 2 MS-TJO-SVR正向预测结果
Tab. 2 Forward prediction results of the MS-TJO-SVR model

指标 Indicator	决定系数 R^2	平均决定系数 Mean R^2	平均绝对误差 MAE	均方误差 MSE	运行时间/s Running time
静曲强度 Static bending strength	0.987 4	0.978 2	5.679 1	49.673 6	84.97
水平抗剪强度 Horizontal shear strength	0.972 8		0.850 7	0.947 1	
吸水宽度膨胀率 Water absorption width swelling	0.982 5		0.354 3	0.154 4	
吸水厚度膨胀率 Water absorption thickness swelling	0.970 2		1.124 8	1.509 8	

图3展示了模型对关键性能指标的预测值与实测值对比。图3(a)和图3(b)分别为静曲强度与水平抗剪强度,预测与实测偏差较小,表明模型对力学性能指

标具有良好的预测效果;图3(c)和图3(d)对应吸水宽度膨胀率与吸水厚度膨胀率,二者整体一致性较好,说明模型能够较准确表征吸水膨胀特性。




图3 验证集正向预测结果对比分析

Fig. 3 Comparative analysis of forward prediction results on the validation set

图4给出了MS-TJO-SVR在各性能指标上的相对误差分布。可以观察到,误差总体围绕零基线对称波动,未出现持续同向偏离,表明模型不存在明显系统性偏差。对于力学性能指标,见图4(a)和图4(b),误差分布集中、波动幅度小,说明模型对静曲强度与水平抗剪强度具有稳定的预测表现;对于吸水尺寸稳定性指标,见图4(c)和图4(d),误差离散度主要集中在零附近,未呈现明显的系统性偏离,表明模型对该类指标同样具备一定的预测可用性与鲁棒性。

3.2 正向模型对比结果及分析

为对比MS-TJO-SVR的性能,本研究在相同训练样本条件下,分别构建PSO-SVR与基础SVR的正向预测模型。PSO-SVR是通过粒子群优化算法(particle swarm optimization, PSO)优化支持向量回归(SVR)模

型的超参数,从而提升模型的预测性能。各方法的预测结果及计算效率汇总见表3。对比可见,MS-TJO-SVR的预测相对误差更低,拟合效果更优。

图5对不同模型在重组竹参数与质量的正向预测进行了综合对照。从整体分布看,MS-TJO-SVR在相关性与标准差两方面与参考点匹配度最高,说明其输出的离散程度更贴近实测数据,同时保持更强的一致性,反映出模型在正向映射下对误差波动的抑制能力更突出。相比之下,PSO-SVR与传统SVR虽能获得一定相关水平,但标准差偏离参考范围更明显,其预测结果更易出现幅度波动,整体精度与稳定性仍逊于MS-TJO-SVR。综合而言,MS-TJO-SVR在正向预测任务中的总体优势,可为热压成型过程的参数-质量关系建模提供更可靠的支撑。




图 4 验证集正向预测结果相对误差分布

Fig. 4 Relative error distribution of forward prediction results on the validation set

表 3 不同算法正向预测性能的对比分析

Tab. 3 Comparative analysis of forward prediction performance using different algorithms

算法 Algorithm	指标 Indicator	决定系数 R^2	平均决定系数 Mean R^2	平均绝对误差 MAE	均方误差 MSE	运行时间/s Running time
MS-TJO-SVR	静曲强度 Static bending	0.987 4	0.978 2	5.679 1	49.673 6	84.97
	水平抗剪强度 Horizontal shear strength	0.972 8		0.850 7	0.947 1	
	吸水宽度膨胀率 Water absorption width swelling	0.982 5		0.354 3	0.154 4	
	吸水厚度膨胀率 Water absorption thickness swelling	0.970 2		1.124 8	1.509 8	
PSO-SVR	静曲强度 Static bending	0.948 9	0.877 0	12.328 3	207.256 1	88.76
	水平抗剪强度 Horizontal shear strength	0.873 9		1.744 0	3.868 5	
	吸水宽度膨胀率 Water absorption width swelling	0.806 9		0.886 9	0.956 1	
	吸水厚度膨胀率 Water absorption thickness swelling	0.878 3		1.911 5	4.139 8	
SVR	静曲强度 Static bending	0.875 0	0.778 4	18.167 5	601.708 3	47.86
	水平抗剪强度 Horizontal shear strength	0.769 3		2.122 2	6.393 6	
	吸水宽度膨胀率 Water absorption width swelling	0.726 3		0.901 5	1.088 5	
	吸水厚度膨胀率 Water absorption thickness swelling	0.743 2		2.210 6	7.020 7	




图 5 不同算法正向预测对比

Fig. 5 Comparison of forward prediction performance of different algorithms

3.3 反向模型结果及分析

在反向预测任务中,选择吸水厚度膨胀率、吸水宽度膨胀率、静曲强度和水平抗剪强度作为输入特征,密度、含水率、施胶量和保压时间作为输出变量,构建了反向预测模型。为获得更优的SVR建模性能,采用

MS-TJO 对其关键参数进行全局寻优,从而确定最优参数组合并完成反向模型的建立。预测结果汇总见表4。反向预测模型的平均 R^2 达到0.979 7,说明该模型具备较高的拟合精度与非线性关系刻画能力;同时,从整体预测表现来看,其效果优于正向预测模型。

表 4 MS-TJO-SVR 反向预测结果

Tab. 4 Reverse prediction results of the MS-TJO-SVR model

指标 Indicator	决定系数 R^2	平均决定系数 Mean R^2	平均绝对误差 MAE	均方误差 MSE	运行时间/s Running time
密度 Density	0.978 7	0.979 7	0.056 2	0.012 7	88.34
含水率 Moisture content	0.991 7		1.158 8	1.856 2	
施胶量 Adhesive content	0.976 3		0.504 7	0.409 2	
保压时间 Pressure-holding time	0.971 9		0.478 5	0.338 1	

图6给出了MS-TJO-SVR反向预测中各工艺参数的预测值与实测值对比。密度图6(a)与含水率图6(b)的散点整体贴近对角线分布,说明预测结果与实际值一致性较好;施胶量图6(c)同样呈现较高吻合度,

偏差较小;保压时间图6(d)的预测点更为集中,进一步验证了该模型在参数反演过程中的预测精度和可靠性。




图6 验证集反向预测结果对比分析

Fig. 6 Comparative analysis of reverse prediction results on the validation set

图7展示了MS-TJO-SVR反向预测的相对误差分布。总体而言,各指标误差均围绕零基线波动,且幅度较小,表明模型对不同参数的偏差控制较为稳定。图7(c)误差分布最为集中,预测一致性最佳;图7(a)与图7(d)误差离散度略大,但仍主要聚集在零附近;图7(b)波动相对更明显、分布更分散,提示该指标的预测稳定性仍有进一步提升空间,可能与其受噪声或非线性影响更强有关。

3.4 反向模型对比结果及分析

不同算法的预测性能与计算效率对比见表5。结果表明,MS-TJO-SVR综合表现最佳:其平均 R^2 为0.9797,拟合与预测能力较强,且误差更小、偏差控制更优;同时运行时间为88.34s,计算效率较高。总体

来看,该模型在精度与耗时之间取得较好平衡,可为重组竹工艺参数与质量预测及生产过程的质量控制与优化提供支持。

图8为反向预测结果,即在反推关键参数的场景下比较各模型表现。MS-TJO-SVR在多数参数上同时实现较高相关系数与更合理的标准差水平,其点位更集中于参考点附近,表明该模型在处理反向推断时依然能保持结果稳定。相对而言,PSO-SVR与传统SVR在部分参数上具备可比表现,但其整体相关性提升与标准差匹配程度不够均衡,说明对逆向映射中的不确定性与参数耦合刻画仍存在不足。综合而言,MS-TJO-SVR在反向预测中更能在低误差约束下重构参数变化规律,体现出更强的逆问题适应性与综合预测能力。




图 7 验证集反向预测结果相对误差分布

Fig. 7 Relative error distribution of reverse prediction results on the validation set

表 5 不同算法反向预测性能的对比分析

Tab. 5 Comparative analysis of reverse prediction performance using different algorithms

算法 Algorithm	指标 Indicator	决定系数 R^2	平均决定系数 Mean R^2	平均绝对误差 MAE	均方误差 MSE	运行时间/s Running time
MS-TJO-SVR	密度 Density	0.978 7	0.979 7	0.056 2	0.012 7	88.34
	含水率 Moisture content	0.991 7		1.158 8	1.856 2	
	施胶量 Adhesive content	0.976 3		0.504 7	0.409 2	
	保压时间 Pressure-holding time	0.971 9		0.478 5	0.338 1	
PSO-SVR	密度 Density	0.890 1	0.922 7	0.079 8	0.012 8	91.89
	含水率 Moisture content	0.944 7		1.807 9	3.830 1	
	施胶量 Adhesive content	0.926 6		0.803 5	0.7783	
	保压时间 Pressure-holding time	0.929 3		0.787 0	0.727 3	
SVR	密度 Density	0.883 6	0.760 8	0.092 0	0.017 3	37.60
	含水率 Moisture content	0.741 4		2.941 7	5.299 1	
	施胶量 Adhesive content	0.729 7		1.144 2	2.109 4	
	保压时间 Pressure-holding time	0.688 3		1.242 2	2.632 9	




图 8 不同算法反向预测对比

Fig. 8 Comparison of reverse prediction performance of different algorithms

4 结论

1) 针对工艺参数与质量指标之间存在的复杂非线性关系,提出了一种基于 MS-TJO 优化的 SVR 双向预测方法。通过对 SVR 超参数进行自适应寻优,构建统一的正向预测与反向反演模型,实现工艺参数与质量指标之间的双向映射。

2) 预测结果表明,所建立的 MS-TJO-SVR 模型在正向与反向任务中均表现出较高的预测精度与稳定性,能够有效表征多参数耦合条件下的非线性特征。多项评价指标显示,模型预测结果与实测值保持良好一致性,体现出较强的建模能力与泛化性能。

3) 对比传统 SVR 与 PSO-SVR 模型的结果,MS-TJO-SVR 在正向与反向预测中均表现最佳,其点位更接近参考点,标准差与实测值更一致且相关性更高,体现出更高的预测精度与稳定性,表明该模型在正向预测与工艺反推场景下均展现出良好的适用性。研究结

果为重组竹热压工艺参数优化与质量预测提供了可靠的建模思路,也为类似工程材料成型过程的智能预测与反演分析提供参考。

参 考 文 献

- [1] 于文吉,江泽慧,叶克林. 竹材特性研究及其进展[J]. 世界林业研究,2002(2):50-55.
YU W J, JIANG Z H, YE K L. Characteristics research of bamboo and its development[J]. World Forestry Research, 2002(2):50-55.
- [2] 张建,汪奎宏,李琴,等. 我国竹材利用率现状分析与建议[J]. 林业机械与木工设备,2006(8):7-10.
ZHANG J, WANG K H, LI Q, et al. Status analysis and suggestions for bamboo utilization rate in China [J]. Forestry Machinery & Woodworking Equipment, 2006(8):7-10.
- [3] 秦莉,于文吉. 重组竹研究现状与展望[J]. 世界林业研究,2009,22(6):55-59.

- QIN L, YU W J. Status and prospects of reconstituted bamboo lumber [J]. *World Forestry Research*, 2009, 22 (6): 55-59.
- [4] 于文吉. 我国重组竹产业发展现状与趋势分析[J]. *木材工业*, 2012, 26(1): 11-14.
- YU W J. Current status and future development of bamboo scrimber industry in China [J]. *China Wood Industry*, 2012, 26(1): 11-14.
- [5] 胡南, 李贤军, 吴义强, 等. 室外用重组竹及重组竹木复合材生产工艺初探[J]. *林业机械与木工设备*, 2011, 39(11): 17-18, 21.
- HU N, LI X J, WU Y Q, et al. Preliminary study on the production technology of the reconsolidated bamboo and reconsolidated bamboo-wood composite panels for outdoor use [J]. *Forestry Machinery & Woodworking Equipment*, 2011, 39(11): 17-18, 21.
- [6] 左迎峰, 吴义强, 肖俊华, 等. 重组竹制备工艺对力学性能的影响[J]. *西南林业大学学报(自然科学)*, 2016, 36(2): 132-136.
- ZUO Y F, WU Y Q, XIAO J H, et al. Effect of preparation technology on mechanical properties of reconstituted bamboo [J]. *Journal of Southwest Forestry University (Natural Sciences)*, 2016, 36(2): 132-136.
- [7] 张亚慧, 马红霞, 孟凡丹, 等. 浸胶方式对竹基纤维复合材料性能的影响[J]. *林产工业*, 2017, 44(9): 24-27.
- ZHANG Y H, MA H X, MENG F D, et al. Effects of impregnating methods on the properties of bamboo-based fiber composites [J]. *China Forest Products Industry*, 2017, 44(9): 24-27.
- [8] 任一萍, 刘红征, 郭文静, 等. 热处理温度对重组竹性能的影响[J]. *木材工业*, 2018, 32(6): 1-4.
- REN Y P, LIU H Z, GUO W J, et al. Effect of thermal treatment temperatures on properties of bamboo scrimber [J]. *China Wood Industry*, 2018, 32(6): 1-4.
- [9] 许杨, 刘倩, 孙子健, 等. 高密度重组竹的物理力学性能研究[J]. *林产工业*, 2024, 61(6): 20-26.
- XU Y, LIU Q, SUN Z J, et al. Study on the physical and mechanical properties of high-density bamboo scrimbers [J]. *China Forest Products Industry*, 2024, 61(6): 20-26.
- [10] 李豪, 马鑫茹, 夏林, 等. 慈竹基重组竹材物理力学性能研究[J]. *工业建筑*, 2025, 55(2): 1-9.
- LI H, MA X R, XIA L, et al. Research on physical and mechanical properties of bambusa emeiensis bamboo scrimber [J]. *Industrial Construction*, 2025, 55(2): 1-9.
- [11] 李权, 杨明杰, 陈林碧, 等. 工艺参数对竹重组材性能的影响[J]. *福建林学院学报*, 2011, 31(2): 189-192.
- LI Q, YANG M J, CHEN L B, et al. Effect of technological parameter on performance of recombined bamboo materials [J]. *Journal of Fujian College of Forestry*, 2011, 31(2): 189-192.
- [12] BRERETON R G, LLOYD G R. Support vector machines for classification and regression [J]. *Analyst*, 2010, 135(2): 230-267.
- [13] XU S, AN X, QIAO X D, et al. Multi-output least-squares support vector regression machines [J]. *Pattern Recognition Letters*, 2013, 34(9): 1078-1084.
- [14] SÁNCHEZ A V D. Advanced support vector machines and kernel methods [J]. *Neurocomputing*, 2003, 55(1/2): 5-20.
- [15] PENG X J. TSVR: An efficient twin support vector machine for regression [J]. *Neural Networks*, 2009, 23(3): 365-372.
- [16] 杜京义, 侯媛彬. 基于遗传算法的支持向量回归机参数选取[J]. *系统工程与电子技术*, 2006, 28(9): 1430-1433.
- DU J Y, HOU Y B. Parameters selection of support vector regression by genetic algorithms [J]. *Systems Engineering and Electronics*, 2006, 28(9): 1430-1433.
- [17] KAVOUSHI-FARD A, SAMET H, MARZBANI F. A new hybrid modified firefly algorithm and support vector regression model for accurate short term load forecasting [J]. *Expert Systems with Applications*, 2014, 41(13): 6047-6056.
- [18] GU B, SHENG S V, WANG Z, et al. Incremental learning for ν -support vector regression [J]. *Neural Networks*, 2015, 67: 140-150.
- [19] 王昕, 黄柯, 郑益慧, 等. 基于PNN/PCA/SS-SVR的光伏发电功率短期预测方法[J]. *电力系统自动化*, 2016, 40(17): 156-162.
- WANG X, HUANG K, ZHENG Y H, et al. Short-term forecasting method of photovoltaic output power based on PNN/PCA/SS-SVR [J]. *Automation of Electric Power Systems*, 2016, 40(17): 156-162.
- [20] 李崎勇, 张伟斌, 赵新哲, 等. 改进鲸鱼算法优化支持向量回归的光伏最大功率点跟踪[J]. *电工技术学报*, 2021, 36(9): 1771-1781.
- LI J Y, ZHANG W B, ZHAO X Z, et al. Global maximum power point tracking for PV array based on support vector regression optimized by improved whale algorithm [J]. *Transactions of China Electrotechnical Society*, 2021, 36(9): 1771-1781.

- [21] 徐佳宁,倪裕隆,朱春波. 基于改进支持向量回归的锂电池剩余寿命预测[J]. 电工技术学报, 2021, 36(17): 3693–3704.
- XU J N, NI Y L, ZHU C B. Remaining useful life prediction for lithium-ion batteries based on improved support vector regression[J]. Transactions of China Electrotechnical Society, 2021, 36(17): 3693–3704.
- [22] 丁禹程. 重组竹热压温度自抗扰控制及工艺参数质量双向预测研究[D]. 哈尔滨:东北林业大学, 2024.
- DING Y C. Research on active disturbance rejection control of hot-pressing temperature and bidirectional prediction of process parameters and quality for reconstituted bamboo[D]. Harbin: Northeast Forestry University, 2024.
- [23] WANG J P, SHANG Z Y. Traffic jam optimizer: A novel swarm-based metaheuristic algorithm for solving global optimization problems[J]. Applied Mathematical Modelling, 2026, 150(PB): 116410.
- [24] QIN K A, HUANG L V, SUGANTHAN N P. Differential evolution algorithm with strategy adaptation for global numerical optimization[J]. IEEE transactions on evolutionary computation, 2009, 13(2): 398–417.
- [25] ADEWUMI O A, ARASOMWAN M A. An improved particle swarm optimiser based on swarm success rate for global optimisation problems[J]. Journal of Experimental & Theoretical Artificial Intelligence, 2016, 28(3): 441–483.
- [26] JIA H M, LU C H. Guided learning strategy: A novel update mechanism for metaheuristic algorithms design and improvement[J]. Knowledge-Based Systems, 2024, 286: 111402.