

基于改进 Stacking 集成学习的高强度钢柱 屈曲能力预测

何智成¹, 韩 苙¹, 宋贤海^{*2}, 张桂勇³

(1. 湖南大学 汽车车身先进设计制造国家重点实验室, 长沙 410082;

2. 南昌航空大学 材料科学与工程学院, 南昌 330036;

3. 大连理工大学 工业装备结构分析优化与 CAE 软件全国重点实验室 船舶工程学院, 大连 116024)

摘 要: 由于屈曲强度的形成机制复杂, 影响屈曲强度的因素较多, 目前对屈曲强度的认识还不全面。近年来, 机器学习已初步应用于预测结构屈曲强度等力学性能, 然而基于实验测试的样本数据量小容易造成过拟合, 导致其预测精度低。本文提出一种基于改进 Stacking 算法的 GSSA(Grid Search-Stacking Algorithm)模型, 并对某型号高强度钢柱屈曲强度进行预测, 提升了屈曲强度的预测精度。首先, 基于标准 Stacking 算法通过使用网格搜索算法选择最优基模型组合, 并采用留一交叉验证(LOOCV)法训练基模型, 实现了 GSSA 模型的构建, 有效解决了小样本集训练带来的预测精度低问题; 然后, 为了进一步验证 GSSA 模型的可靠性, 本文采用 Bland-Altman 法对 GSSA 模型进行一致性评价, 结果表明, GSSA 模型具有很好的可靠性; 最后, 采用 SHAP 模型对 GSSA 模型预测的屈曲强度进行了可解释性分析, 实现了其影响因素评价。

关键词: 屈曲强度; Stacking 算法; GSSA 模型; Bland-Altman 法; SHAP 模型

中图分类号: O302

文献标志码: A

文章编号: 1007-4708(2023)04-0585-09

1 引 言

钢结构由于材料强度高、塑性和韧性良好等优点, 在各个领域如机械结构及装备和输电塔结构等方面得到了广泛的应用^[1,2]。目前的钢结构主要有型钢、钢板和钢柱等。然而随着工业的快速发展, 对新型材料和结构的需求不断增加。在新型钢结构的开发中, 钢结构在受压条件下表现出来的不稳定性是在其设计和制造过程中需要考虑的重要因素。屈曲变形是结构失稳的常见原因, 直接关系到材料和结构的可靠性。钢结构的屈曲变形与其屈曲强度有关。然而由于屈曲强度的形成机制复杂, 不同钢结构的屈曲强度受多种因素影响, 目前对屈曲强度的认识还不全面。研究钢结构屈曲强度的方法主要有实验测量和有限元仿真分析两种。这两种方法通常会耗费大量的时间和资源。

国内外学者对钢结构屈曲强度进行了大量研究, 文献[3,4]报道了不同类型钢结构如钢柱和钢

壳等在受压条件下的屈曲问题。研究表明, 钢结构的屈曲行为受许多因素影响, 包括初始几何缺陷、载荷和温度等^[5]。Wang 等^[6]采用实验和数值方法研究了点蚀缺陷对厚壁圆柱钢壳屈曲强度的影响。Haidarali 等^[7]开发了两种有限元模型来研究横向约束冷弯型钢梁中出现的不同形式的屈曲行为。然而, 通过实验和有限元仿真分析方法对钢结构的屈曲行为进行研究通常会耗费大量的时间、人力、物力和财力。另外, 由于影响钢结构屈曲强度的因素较多, 要全面研究其影响机理需要设计大量实验才能完成。

为了加速新型材料和结构的研发, 探究影响其性能的因素, 机器学习越来越广泛地运用于新型材料和结构的设计中。叶红玲等^[8]提出了一种基于 CGTN 网络的深度学习模型实现跨分辨率结构拓扑优化设计来代替传统的拓扑优化设计方法。阎军等^[9]介绍了机器学习算法应用于结构拓扑优化研究的一些重要进展。苏国韶等^[10]提出了基于自适应协方差矩阵进化策略-高斯过程协同优化算法的结构优化方法来降低工程结构优化的计算代价。近年来, 一些研究学者开始基于机器学习模型对钢材料的性能进行研究。Xie 等^[11]建立了一个深度

收稿日期: 2022-01-12; 修改稿收到日期: 2022-02-28.

基金项目: 国家自然科学基金联合基金(U20A20285); 湖南省杰出青年科学基金(2021JJ10016)资助项目.

作者简介: 宋贤海^{*} (1964-), 男, 硕士, 高级工程师
(E-mail: 31011@nchu.edu.cn).

学习模型,以预测工业钢板的力学性能。该模型可以根据工艺参数和原钢成分,在线监测和控制钢材力学性能,并指导生产具有定制力学性能的目标钢板。Yan 等^[12]提出一种基于机器学习的材料性能预测模型,该模型对钢的疲劳强度进行了高精度的预测。Pala 等^[13]采用神经网络研究了冷成型 C 型截面钢的几何参数对扭曲屈曲应力的影响。Le 等^[14]通过遗传算法和粒子群算法对自适应神经模糊推理系统进行优化,构建两个混合模型对高强度钢柱的屈曲强度进行了预测。但是,这些基于机器学习模型对钢材料和结构性能的研究,特别是对钢结构屈曲强度的研究,大多是基于实验测试的小样本数据,容易产生过拟合,导致大多数机器学习模型预测精度低,无法满足工程实际应用的需求。另外,在对钢结构屈曲强度进行预测时考虑的影响因素也不够全面。

针对该问题,本文提出一种基于改进 Stacking 算法的 GSSA(Grid Search-Stacking Algorithm)模型,并用于对 Yu 等^[15]的 57 个实验结果,以及具有 20 个特征(初始几何尺寸和初始缺陷)的高强度钢 Y 型截面柱的屈曲强度进行预测和分析。首先,本文基于标准 Stacking 算法,提出使用网格搜索算法选择最优基模型组合,并通过留一交叉验证(LOOCV)法训练基模型,构建了 GSSA 模型。通过三个回归评价指标,包括决定系数(R^2)、平均绝对误差(MAE)和均方根误差(RMSE)对提出的 GSSA 模型和其他常用的机器学习模型的性能进行对比分析;然后,为了验证模型的可靠性,本文采用 Bland-Altman 法对 GSSA 模型的预测结果与有限元仿真分析、实验测量的结果进行一致性评价;最后,本文引入 SHAP 模型对 GSSA 模型预测的屈曲强度进行了分析和解释。分析结果可为未来高强度钢结构的设计提供指导。

2 新型 Y 型高强度钢柱屈曲数据获取与预处理

2.1 数据获取

本文高强度钢 Y 型截面柱屈曲强度相关数据来自文献^[15]。数据由 Yu 等^[15]对 57 组 3 种不同截面尺寸的 420 MPa Y 型截面柱进行轴向压缩实验测量和计算得到。因此,本研究的数据来源是有效且可靠的。这 57 组数据中,共有两种不同类型的特征,包括初始几何尺寸和初始缺陷。拉伸实验结果表明,组成 Y 型截面柱的等边角钢的杨氏模

量为 210 GPa~211 GPa,屈服强度为 450 MPa~455 MPa,钢板的杨氏模量为 209 GPa~214 GPa,屈服强度为 485 MPa~496 MPa。由于材料的力学性能波动很小,因此,本文不考虑材料的力学性能波动对高强度钢 Y 型截面柱屈曲强度的影响。另外,通过测量和计算发现高强度钢 Y 型截面柱三个截面上残余应力的合力及合力矩近似为零,因此,本文也不考虑残余应力对屈曲强度的影响。最终选取测量得到的包括初始几何尺寸和初始缺陷两大类的 20 个特征和相对应的屈曲强度作为本文研究的数据集,具体情况列入表 1。420 MPa 高强度钢 Y 型截面柱的结构如图 1 所示。




图 1 420 MPa 高强度钢 Y 型截面柱结构

Fig. 1 Structural diagram of 420 MPa high-strength steel Y-section column

表 1 数据集参数含义

Tab. 1 Meaning of parameters in the data set

参数	含义
L	钢柱测量长度
b_a	等边角钢宽度
t_a	等边角钢厚度
b_b	钢板宽度
t_b	钢板厚度
I_x	绕 x 轴转动惯量
I_y	绕 y 轴转动惯量
λ_x	沿 x 轴的长细比
λ_y	沿 y 轴的长细比
u	等边角钢左支腿宽度的偏差
v	等边角钢右支腿宽度的偏差
θ	Y 截面三支角的平均旋转角度
e_{0x}	沿 x 轴的质心偏差
e_{0tx}	顶部沿 x 轴加载偏心量
e_{0bx}	底端沿 x 轴的加载偏心量
e_x/L	沿 x 轴的总偏差比
e_{0y}	沿 y 轴的质心偏差
e_{0ty}	y 轴上端加载偏心
e_{0by}	底端沿 y 轴的加载偏心量
e_y/L	沿 y 轴的总偏差比
N_u	钢柱屈曲强度实验值

2.2 数据预处理

将数据集中的 57 组数据分为两部分,80% 的数据作为训练集,20% 的数据作为测试集。为了保证预测结果的可靠性和提高预测模型的性能,需要对原始数据集进行标准化处理。本文采用 Z-Score 标准化将原始数据集转换为均值为 0,标准差为 1 的正态分布数据集。Z-Score 标准化的计算公式为

$$Z_s = (X - \mu) / \sigma \quad (2)$$

式中 X 为原始数据集中的特征值, μ 和 σ 分别为原始数据集各特征值均值和方差。

3 基于标准 Stacking 算法的 GSSA 模型建模

3.1 标准 Stacking 算法

Stacking 算法最早由 Wolpert^[16] 提出,旨在通过异构算法的差异性进行多层叠加来增强模型预测精度和泛化能力。图 2 为标准 Stacking 算法的结构。在标准 Stacking 算法中,原始数据集划分为训练集和测试集两部分。首先,训练集训练多个基模型,得到的结果作为次级训练集;然后,用测试集测试这些基模型,得到的结果作为次级测试集。次级数据集由生成的次级训练集和次级测试集组成;最后,用次级数据集训练和测试元模型得到最终的预测结果。




图 2 标准 Stacking 算法结构
Fig. 2 Structure diagram of standard Stacking algorithm

3.2 GSSA 模型

标准 Stacking 算法主要存在两个问题,即新数据集生成和基模型选择问题。由于新数据集是利用基模型生成的,若直接利用基模型的训练集来生成新数据集中的训练集会导致信息泄露和过拟合。另外,标准 Stacking 算法通过集成基模型的预测结果来提升模型的整体预测效果,基模型的选择会严重影响标准 Stacking 算法整体预测效果。基模型数量过多或预测精度太差会使标准 Stacking 算法运算效率或预测精度较低。为了解决上述两个问题,本文构建了一种新型 GSSA 模型。首先,使用 LOOCV 法修改标准 Stacking 算法,来

生成新的数据集,达到提高模型预测精度的目标;然后,利用网格搜索算法^[17]来选择合适的机器学习算法作为标准 Stacking 算法基模型以使其达到最优的性能。

网格搜索算法可以看作是一种穷举法,在所有候选模型中,通过循环遍历,尝试每一种组合的可能性,直到 GSSA 模型的性能达到最优。本文的网格搜索算法可定义为

$$\begin{aligned} \max & g(w_i M_i) \\ \text{s.t. } & w_i = \{0, 1\}_{i=1}^N \end{aligned} \quad (3)$$

式中 $g(w_i M_i)$ 为 GSSA 模型预测结果的回归评价指标 R^2 , M_i 为备选基模型, w_i 为备选基模型的系数。 $w_i=0$, 表示该模型未选用; $w_i=1$, 表示该模型选作基模型。

标准 Stacking 算法的 GSSA 模型结构如图 3 所示。GSSA 模型的构建共分为三个阶段。

(1) 模型选择阶段。通过网格搜索算法从备选的机器学习模型中选出使 GSSA 模型预测效果达到最优的模型组合作为基模型。

(2) 第二阶段。首先,将每个基模型在原始训练集上通过 LOOCV 法进行训练,将得到的每个样本的预测结果进行纵向合并,得到每个基模型生成的新训练集;然后,在每一轮训练后,将训练过的基模型在整个原始数据集上对测试集进行预测,对预测结果取平均值,得到每个基模型生成的新测试集;最后,最终的新训练集由每个基模型生成的新训练集横向合并得到,最终的新测试集由每个基模型生成的新测试集横向合并得到。

(3) 第三阶段。将生成的新数据集中的训练集和测试集分别用于训练和测试元模型,元模型在测试集上的预测结果作为 GSSA 模型最终的预测结果。

3.3 模型评价指标

为了更好地评估 GSSA 模型的预测效果,本文选用常用的三种回归分析评价指标相关系数 R^2 、平均绝对误差 MAE 和均方根误差 RMSE 作为模型评价的标准。三个评价指标的具体公式为

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\left[\sum_{i=1}^N (y_i - \bar{y})^2 \right]} \quad (4)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (5)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (6)$$

式中 N 为样本数量, y_i 为真实值, $\hat{y}_i$ 为模型预测值。




图 3 GSSA 模型结构
Fig. 3 Structure diagram of GSSA model

3.4 几种常用的机器学习模型对比

为了找到最优的基模型组合,本文首先建立了其他 11 种常用的机器学习模型列入表 2。基于这些常用的机器学习模型,本文对新型 Y 型高强度钢柱的屈曲强度进行预测。图 4 和图 5 显示了 11 种不同机器学习模型预测结果的回归评价指标的分布情况。可以看出,基于支持向量回归的两个模型 BO-SVR、SVR-RBF 和高斯过程回归模型 GPR 的 R^2 均在 0.96 以上,MAE 和 RMSE 也小于其他模型。这三种模型的预测精度明显优于其他模型,说明其在高维小样本数据集上具有较好的适用性。RF,GBR 和 KNN 这三个机器学习模型的 R^2 均在 0.90 以下,MAE 和 RMSE 也相对较大,其预测精

度相对最差。

表 2 机器学习模型及简称
Tab. 2 Machine learning models and abbreviations

简称	模型
RF	随机森林
GBR	梯度提升回归
KNN	K-近邻
LR	线性回归
LASSO	拉索回归
AdaBoost	自适应提升
BPNN	误差反向传播神经网络
RR	岭回归
SVR-RBF	径向基支持向量回归
GPR	高斯过程回归
BO-SVR	贝叶斯优化支持向量回归



图4 预测模型的结果对比(11个模型的 R^2)Fig. 4 Comparison of the prediction models' results (R^2 for the 11 models)

图5 预测模型的结果对比(11个模型的 MAE 和 RMSE)

Fig. 5 Comparison of the prediction models' results (MAE and RMSE for the 11 models)

3.5 GSSA 模型构建

为了进一步提高模型的性能,达到更高的预测精度,本文建立了基于标准 Stacking 算法的 GSSA 模型。本文 GSSA 模型的构建分为三个阶段。

(1) 模型选择阶段。选用本文预测效果较好的四个模型 BO-SVR, GPR, RR 和 BPNN 作为 GSSA 模型的备选基模型。通过网格搜索算法选择,最终选用 BO-SVR, GPR 和 RR 作为 GSSA 模型的基模型。

(2) 第二阶段。采用 LOOCV 法在数据集上对三个基模型进行训练,产生新的数据集。

(3) 第三阶段。为了防止过拟合,选用简单的 LR 模型做为元模型,然后用新数据集训练 LR 模型并得到最终的预测结果。

4 Bland-Altman 法与 SHAP 模型介绍

4.1 Bland-Altman 法

为了验证 GSSA 模型的可靠性,本文采用 Bland-Altman 法^[18]对 GSSA 模型的预测结果与有限元仿真分析和实验测量的结果进行一致性评价。Bland-Altman 法通过分析两种测量结果的均值 Mean 与

差值的均值 μ 和标准差 σ 来确定两种方法的一致性。如果新方法测量结果的偏差 Bias 有 95% 落在和 $\mu - 2\sigma$ 和 $\mu + 2\sigma$ 之间,则说明两种方法具有一致性,新方法可以和旧方法互换使用。

4.2 SHAP 模型

GSSA 模型内部结构复杂,因此,很难判断输入和输出之间的相关关系。本文采用由 Lundberg 等^[19]提出的 SHAP 模型去解释 GSSA 模型的预测结果。SHAP 模型是一种基于合作博弈的可加性特征归因方法。其可以简单理解为模型的实际预测值是由模型的平均预测值和每个输入特征的贡献线性相加得到的。每个输入特征的贡献可以通过计算该特征的 Shapley 值得到。SHAP 模型通过建立一个解释模型 $g(x')$ 来代替可解释性极差的黑盒模型 $f(x)$ 。解释模型 $g(x')$ 的公式为

$$g(x') = \phi_0 + \sum_{i=1}^P \phi_i x'_i \quad (7)$$

式中 $g(x')$ 为模型的预测值。 ϕ_0 为一个常数,表示所有样本的预测均值。 ϕ_i 为特征 i 的 SHAP 值。 $x' \in \{0, 1\}^P$ 为简化后的特征,其取值只能为 0 和 1,取值为 0 时表示该特征不存在,不会对样本产生贡献,取值为 1 时相反。 P 为输入特征的数量。

5 结果分析与讨论

5.1 GSSA 模型预测精度分析

GSSA 模型、标准 Stacking 模型和基模型的预测结果回归评价指标对比列入表 3。图 6 给出了 GSSA 模型、标准 Stacking 模型和基模型预测结果的回归评价指标的分布情况。其中,通过手动选取的标准 Stacking 模型的基模型与 GSSA 模型的基模型相同。由表 3 可知,相较于标准 Stacking 模型和基模型中预测性能最好的 BO-SVR, GSSA 模型预测结果的回归评价指标均得到了进一步的提升。可以看出, GSSA 模型是这些机器学习模型中预测性能最优的。

图 7 和图 8 分别给出了有限元仿真值和 GSSA 模型预测值与实验值的对比。其中,测试样本的实验值和有限元仿真分析值都来自于文献^[15]。图 7 和图 8 的散点越靠近拟合直线说明该值越接近于实验值。可以看出, GSSA 模型预测值比有限元仿真分析值更集中分布在拟合直线附近,说明 GSSA 模型预测值更接近实验值。

表3 GSSA模型、标准 Stacking模型和基模型
预测结果回归评价指标

Tab.3 Regression evaluation criteria for the prediction results of the GSSA model, standard Stacking model and the base models

模型	R^2	MAE	RMSE
RR	0.9333	58.6414	68.3072
GPR	0.9727	38.2158	43.7205
BO-SVR	0.9735	34.1074	43.0754
标准 Stacking	0.9727	38.2207	43.7307
GSSA	0.9752	31.9545	41.6456




图6 预测模型的结果对比(GSSA模型、标准 Stacking模型和基模型的 R^2 , MAE 和 RMSE)

Fig.6 Comparison of the prediction models' results (R^2 , MAE and RMSE for the GSSA model, standard Stacking model and the base models)




图7 有限元仿真分析值和实验值对比
Fig.7 Comparison of finite element simulation values and experimental values




图8 GSSA模型预测值和实验值对比
Fig.8 Comparison of predicted values of GSSA model and experimental values

测试样本中,有限元仿真分析值和 GSSA 模型预测值的相对误差分布如图9所示。可以看出, GSSA 模型预测值的相对误差更集中分布在误差为0的直线周围,说明 GSSA 模型预测值的总体相对误差更小。因此, GSSA 模型相较于有限元仿真分析具有更高的准确性。




图9 有限元仿真分析值和 GSSA 模型预测值的相对误差分布
Fig.9 Relative error distribution of finite element simulation values and GSSA model prediction values

5.1 GSSA 模型可靠性分析

图10和图11分别是 GSSA 模型相对于有限元仿真分析和实验测量结果的 Bland-Altman 图,中间黑色实线是偏差 Bias 的均值 μ , 上下两条红色




图10 GSSA模型相对于实验测量结果的 Bland-Altman 图
Fig.10 Bland-Altman plots of buckling strength values predicted by GSSA model against experimental values




图11 GSSA模型相对于有限元仿真分析结果的 Bland-Altman 图
Fig.11 Bland-Altman plots of buckling strength values predicted by GSSA model against finite element simulation values

虚线代表 95%一致性界限的上下置信限。可以看出,两张 Bland-Altman 图中所有 11 个测试样本均落在 95%一致性界限内。结果表明,GSSA 模型相对于实验测量和有限元仿真分析的结果均具有良好的-致性,GSSA 模型是可靠的。

5.2 GSSA 模型可解释性分析

GSSA 模型的预测结果可以用 SHAP 方法从全局和局部两个角度进行解释。图 12(a)是从全局角度出发对所有输入特征的重要性排序。根据输入特征在整个数据集上 SHAP 值的均值大小来进行特征重要性排序,SHAP 值的均值越大,说明该特征对预测结果的影响程度越大。可以看出,初始几何参数和初始缺陷均对输出结果有重要影响,而初始几何参数的影响程度更大。影响屈曲强度最重要的 6 个特征依次为 b_b , e_{0y} , L , I_x , e_{0by} 和 I_y , 其中特征 b_b 的影响效果明显大于其他所有特征。图 12(b)展示了所有输入特征的 SHAP 值的分布情况以及其重要性排序。 y 轴从上到下依次是按照特征重要性排序的 20 个输入特征。 x 轴表示

SHAP 值的大小。图 12(b)的每一个点代表一个样本。蓝色的点表示该点的特征值较小,红色的点表示该点的特征值较大。点的水平分布表示该特征导致预测值更大还是更小。如图 12(b)左上角的蓝色点表示较小的 b_b 值将导致预测值减小大约 1。可以看出,总体上, b_b 和 I_x 值越大,屈曲强度值也越大,而 e_{0y} , L , e_{0by} 和 I_y 越大,屈曲强度值则越小。

为了更好地观察各特征是如何影响屈曲强度的,本文从局部角度出发,选取测试集中的一个样本对其进行解释。图 13 可以看作是对式(7)的可视化表示。图 13 中 base value 表示所有预测值的均值,对应式(7)的 ϕ_0 , 其大小为 -0.018 , $f(x)$ 表示该样本实际预测值,对应式(7)的 $g(x')$ 。红条表示使该样本预测值相对预测均值增大的特征。红条的长度表示该特征的 SHAP 值。红条越长,说明该特征使预测值增大越多。蓝条表示使该样本预测值相对预测均值减小的特征。可以看出,对于该样本影响最大的特征是 e_{0y} , 其使预测值偏小。




图 12 利用 SHAP 值对 GSSA 模型进行全局解释(SHAP 特征重要性和 SHAP 概要)

Fig. 12 Global interpretations of GSSA model by SHAP values (SHAP feature importance and SHAP summary plot)




图 13 利用 SHAP 值对单个样本进行局部解释(单个样本 SHAP 值)

Fig. 13 Local interpretations of individual samples by SHAP values (individual interpretations for selected samples)

其他特征如 L , e_{0by} , e_{0x} 和 I_x , 其也使预测值偏小, I_y , b_a 和 t_a 使预测值偏大。这些特征对于该样本的预测值都起到了重要的影响。

6 结 论

本文提出了一种基于改进 Stacking 算法的 GSSA 模型, 并对 420 MPa 高强度钢 Y 型截面柱屈曲强度进行预测。预测结果的回归评价指标 $R^2 = 0.9752$, $MAE = 31.9545$, $RMSE = 41.6456$ 。预测结果表明, GSSA 模型的预测精度要优于基模型 BO-SVR, GPR 和 RR 以及其他几种常用的机器学习模型和传统的有限元模型。为了进一步验证 GSSA 模型的可靠性, 本文采用 Bland-Altman 法对 GSSA 模型进行了一致性评价。计算结果表明, GSSA 模型预测值相对于实验测量和有限元仿真分析结果的偏差均落在 95% 一致性界限内。因此, GSSA 模型相对于实验测量和有限元仿真分析具有良好的一致性, GSSA 模型是可靠的。最后, 本文引入 SHAP 模型对 GSSA 模型进行了可解释性分析。从全局角度出发, 本文对影响屈曲强度的因素进行了重要性排序, 影响屈曲强度最重要的 6 个因素依次为 b_b , e_{0y} , L , I_x , e_{0by} 和 I_y 。从局部角度出发, 本文通过 SHAP 值分析和解释了单个样本的各因素具体是如何影响屈曲强度的。

参考文献(References):

- [1] Wu T B. Precision forming technique of ultra-high-strength steel shell body with thin wall and deep blind hole [J]. *Acta Armamentarii*, 2005, **26**(4): 515.
- [2] Yang F L, Han J K, Yang J B, et al. Some advances in the application of weathering and cold-formed steel in transmission tower [J]. *Journal of Electromagnetic Analysis and Applications*, 2009, **1**(1): 24-30.
- [3] Ban H Y, Shi G, Shi Y J, et al. Experimental investigation of the overall buckling behaviour of 960 MPa high strength steel columns [J]. *Journal of Constructional Steel Research*, 2013, **88**: 256-266.
- [4] Ghanbari Ghazijahani T, Jiao H, Holloway D. Experimental study on damaged cylindrical shells under compression [J]. *Thin-Walled Structures*, 2014, **80**: 13-21.
- [5] Ranawaka T, Mahendran M. Numerical modelling of light gauge cold-formed steel compression members subjected to distortional buckling at elevated temperatures [J]. *Thin-Walled Structures*, 2010, **48**(4-5): 334-344.
- [6] Wang H K, Yu Y, Yu J X, et al. Effect of pitting defects on the buckling strength of thick-wall cylinder under axial compression [J]. *Construction and Building Materials*, 2019, **224**: 226-241.
- [7] Haidarali M R, Nethercot D A. Finite element modeling of cold-formed steel beams under local buckling or combined local/distortional buckling [J]. *Thin-Walled Structures*, 2011, **49**(12): 1554-1562.
- [8] 叶红玲, 李继承, 魏 南, 等. 基于深度学习的跨分辨率结构拓扑优化设计方法 [J]. *计算力学学报*, 2021, **38**(4): 430-436. (YE Hong-ling, LI Ji-cheng, WEI Nan, et al. Cross-resolution acceleration design for structural topology optimization based on deep learning [J]. *Chinese Journal of Computational Mechanics*, 2021, **38**(4): 430-436. (in Chinese))
- [9] 阎 军, 许 琦, 张 起, 等. 人工智能在结构拓扑优化领域的现状与未来趋势 [J]. *计算力学学报*, 2021, **38**(4): 412-422. (YAN Jun, XU Qi, ZHANG Qi, et al. Current and future trends of artificial intelligence in the field of structural topology optimization [J]. *Chinese Journal of Computational Mechanics*, 2021, **38**(4): 412-422. (in Chinese))
- [10] 苏国韶, 武振兴, 燕柳斌. 工程结构优化的进化策略-高斯过程协同优化方法 [J]. *计算力学学报*, 2013, **30**(5): 610-615. (SU Guo-shao, WU Zhen-xing, YAN Liu-bin. Engineering structural optimization using a cooperative optimization method based on evolution strategy and gaussian process [J]. *Chinese Journal of Computational Mechanics*, 2013, **30**(5): 610-615. (in Chinese))
- [11] Xie Q, Suvarna M, Li J L, et al. Online prediction of mechanical properties of hot rolled steel plate using machine learning [J]. *Materials & Design*, 2021, **197**: 109201.
- [12] Yan F, Song K, Liu Y, et al. Predictions and mechanism analyses of the fatigue strength of steel based on machine learning [J]. *Journal of Materials Science*, 2020, **55**(31): 15334-15349.
- [13] Pala M, Caglar N. A parametric study for distortional buckling stress on cold-formed steel using a neural network [J]. *Journal of Constructional Steel Research*, 2007, **63**(5): 686-691.
- [14] Le L M, Ly H B, Pham B T, et al. Hybrid artificial intelligence approaches for predicting buckling damage of steel columns under axial compression [J]. *Materials (Basel Switzerland)*, 2019, **12**(10): E1670.
- [15] Yu X L, Deng H Z, Zhang D H, et al. Buckling behavior of 420 MPa HSSY columns: Test investigation

- and de-sign approach[J]. *Engineering Structures*, 2017, **148**:793-812.
- [16] Wolpert D H. Stacked generalization[J]. *Neural networks*, 1992, **5**(2):241-259.
- [17] Li W W, Xing X X, Liu F, et al. Application of improved grid search algorithm on SVM for classification of tumor gene[J]. *International Journal of Multimedia and Ubiquitous Engineering*, 2014, **9**(11): 181-188.
- [18] Bland J M, Altman D G. Statistical methods for assessing agreement between two methods of clinical measurement[J]. *Lancet*, 1986, **1**(8476):307-310.
- [19] Lundberg S M, Lee S I. A unified approach to interpreting model predictions[A]. Proceedings of the 31st International Conference on Neural Information Processing Systems[C]. 2017.

Prediction of buckling capacity of high-strength steel columns based on improved stacking ensemble learning

HE Zhi-cheng¹, HAN Jiang¹, SONG Xian-hai^{*2}, ZHANG Gui-yong³

(1. State Key Laboratory of Advanced Design and Manufacture for Vehicle Body, Hunan University, Changsha 410082, China;

2. School of Materials Science and Engineering, Nanchang Hangkong University, Nanchang 330036, China;

3. State Key Laboratory of Structural Analysis, Optimization and CAE Software for Industrial Equipment, School of Naval Architecture, Dalian University of Technology, Dalian 116024, China)

Abstract: The existing knowledge of buckling strength is insufficient due to the complicated formation mechanism of buckling strength, which is influenced by various factors. Machine learning has been initially applied to predict mechanical properties of structures such as buckling strength in recent years. However, the small samples based on experimental tests easily cause overfitting, resulting in low prediction accuracy. In this paper, a Grid Search-Stacking Algorithm (GSSA) model based on the improved Stacking Algorithm was proposed to predict the buckling strength of high-strength steel columns, and the prediction accuracy of buckling strength is improved. First, based on the standard Stacking algorithm, the GSSA model was constructed by employing the grid search algorithm to select the optimal combination of base models and the leave-one-out cross-validation (LOOCV) method to train the base models, which effectively solves the problem of low prediction accuracy caused by the training of small samples; then, in order to further verify the reliability of the GSSA model, this paper adopted the Bland-Altman method to evaluate the consistency of the GSSA model, and the results show that the GSSA model has high reliability. Finally, the SHAP model was introduced to perform an interpretability analysis of buckling strength predicted by the GSSA model and realizes the evaluation of its influence factors.

Key words: buckling strength; standard Stacking algorithm; GSSA model; Bland-Altman method; SHAP model

引用本文/Cite this paper:

何智成, 韩 荭, 宋贤海, 等. 基于改进 Stacking 集成学习的高强度钢柱屈曲能力预测[J]. 计算力学学报, 2023, **40**(4):585-593.

HE Zhi-cheng, HAN Jiang, SONG Xian-hai, et al. Prediction of buckling capacity of high-strength steel columns based on improved stacking ensemble learning[J]. *Chinese Journal of Computational Mechanics*, 2023, **40**(4):585-593.