



智能系统学报

CAAI TRANSACTIONS ON INTELLIGENT SYSTEMS

支持向量机与神经网络相结合的板带凸度预测

刘明华, 张强

引用本文:

刘明华,张强. 支持向量机与神经网络相结合的板带凸度预测[J]. 智能系统学报, 2022, 17(3): 506–514.

LIU Minghua,ZHANG Qiang. Prediction of strip crown based on support vector machine and neural network[J]. *CAAI Transactions on Intelligent Systems*, 2022, 17(3): 506–514.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202101002>

您可能感兴趣的其他文章

仿人机器人步态平衡泛化模型的建立与仿真

Modeling and simulation of humanoid robot gait balance generalization

智能系统学报. 2020, 15(3): 537–545 <https://dx.doi.org/10.11992/tis.201810017>

深度学习的双人交互行为识别与预测算法研究

Human interaction recognition and prediction algorithm based on deep learning

智能系统学报. 2020, 15(3): 484–490 <https://dx.doi.org/10.11992/tis.201812029>

基于自组织递归模糊神经网络的PM2.5浓度预测

Prediction of PM2.5 concentration based on self-organizing recurrent fuzzy neural network

智能系统学报. 2018, 13(4): 509–516 <https://dx.doi.org/10.11992/tis.201710007>

基于递归神经网络的风暴潮增水预测

Prediction of storm surge based on recurrent neural network

智能系统学报. 2017, 12(5): 640–644 <https://dx.doi.org/10.11992/tis.201706015>

基于粒子群优化的Elman神经网络无模型控制

Elman model-free control method based on particle swarm optimization algorithm

智能系统学报. 2016, 11(1): 49–54 <https://dx.doi.org/10.11992/tis.201507025>

大数据与深度学习综述

Deep learning with big data: state of the art and development

智能系统学报. 2016, 11(6): 728–742 <https://dx.doi.org/10.11992/tis.201611021>



微信公众平台



期刊网址

DOI: 10.11992/tis.202101002

网络出版地址: <https://kns.cnki.net/kcms/detail/23.1538.TP.20220322.1652.004.html>

支持向量机与神经网络相结合的板带凸度预测

刘明华, 张强

(西安建筑科技大学 冶金工程学院, 陕西 西安 710055)

摘要: 为提高热轧生产过程中板带凸度的预测精度, 提出了一种将粒子群优化算法 (particle swarm optimization, PSO)、支持向量回归 (support vector regression, SVR) 和 BP 神经网络 (back propagation neural network, BPNN) 相结合的板带凸度预测模型。采用 PSO 算法优化 SVR 模型的参数, 建立了 PSO-SVR 板带凸度预测模型, 提出采用 BPNN 建立板带凸度偏差模型与 PSO-SVR 板带凸度模型相结合的方法对板带凸度进行预测。采用现场数据对模型的预测精度进行验证, 并采用统计指标评价模型的综合性能。仿真结果表明, 与 PSO-SVR、SVR、BPNN 和 GA-SVR 模型进行比较, PSO-SVR+BPNN 模型具有较高的学习能力和泛化能力, 并且比 GA-SVR 模型运算时间短。

关键词: 支持向量回归; 神经网络; 板带凸度; 粒子群优化算法; 热轧板带过程; 机器学习; 预测; 大数据

中图分类号: TP16 **文献标志码:** A **文章编号:** 1673-4785(2022)03-0506-09

中文引用格式: 刘明华, 张强. 支持向量机与神经网络相结合的板带凸度预测 [J]. 智能系统学报, 2022, 17(3): 506-514.

英文引用格式: LIU Minghua, ZHANG Qiang. Prediction of strip crown based on support vector machine and neural network[J]. CAAI transactions on intelligent systems, 2022, 17(3): 506-514.

Prediction of strip crown based on support vector machine and neural network

LIU Minghua, ZHANG Qiang

(School of Metallurgical Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: To improve the prediction accuracy of strip crown in a hot-rolled production process, a modeling method combining particle swarm optimization (PSO) algorithm, support vector regression (SVR), and BP neural network (BPNN) is proposed. The PSO algorithm was employed to optimize the parameters of the SVR model, and the PSO-SVR strip crown prediction model was established. A method combining the BPNN strip crown deviation model with the PSO-SVR strip crown model is also proposed to predict the strip crown. The prediction accuracy of the model was validated with field experimental data, and the comprehensive performance of the model was evaluated using statistical indicators. The simulation results show that in contrast to the PSO-SVR, SVR, BPNN, and GA-SVR models, the PSO-SVR+BPNN model exhibits a greater learning capacity and generalization ability. The computing time of the PSO-SVR+BPNN model is also less than that of the GA-SVR model.

Keywords: support vector regression; neural network; strip crown; particle swarm optimization algorithm; hot strip rolling process; machine learning; prediction; big data

随着社会经济的发展和科学技术的进步, 板带材是工农业生产中重要的金属材料, 人们对板带材的质量要求越来越高^[1]。板形是板带轧制的关键技术指标, 主要包括板带凸度和平直度。目前, 板带凸度一直存在严重的问题, 其不良凸度会直接造成巨大的资源浪费或其他潜在风险^[2]。板

带轧制是一个多变量、强耦合、非线性和时变性的过程, 而按照传统理论方法建立的板带凸度预测模型^[3], 在建模中假设和简化了轧制过程的诸多实际因素 (将一个复杂非线性问题变成多个线性问题等), 导致模型精确度较差, 不能满足高精度轧制技术的要求^[4]。因此, 迫切需要一种新的方法建立具有高精度预测能力的板带凸度模型。

与传统理论方法不同, 人工智能方法^[5]是模

收稿日期: 2021-01-02. 网络出版日期: 2022-03-23.

通信作者: 刘明华. E-mail: lmhxuat@163.com.

拟人脑处理真实发生的过程,基于实验数据对目标值预测,可防止假设脱离实际和简化过于粗糙而产生的误差。随着人工智能技术的发展,许多学者开始将人工神经网络(ANN)^[6-7]和支持向量机(SVM)^[8-9]引入轧制领域。针对采用传统理论方法建立板带凸度模型考虑影响参数较少导致传统数学模型预测误差大的问题,方敏^[10]提出一种BP神经网络(BPNN)与有限元(FEM)模型相结合的方法对板带凸度进行预测,将FEM仿真结果用于训练和测试BPNN模型。仿真结果表明,BPNN与FEM相结合的板带凸度预测模型的预测精度远高于传统数学模型的预测精度。针对传统BPNN预测模型存在易陷入局部极小值点和收敛速度慢等问题,朱永波等^[11]采用自适应变异粒子群算法优化BPNN模型的权值和阈值,将已优化的BPNN模型用于预测板带凸度。仿真结果表明,该模型预测效果与传统BPNN模型相比有所改善。在以上研究中,ANN已经广泛应用于轧制领域且该模型的预测精度高于传统数学模型的预测精度,但它也有一些不足之处。ANN以传统统计学为基础,它的内容是样本无穷大时的渐进理论,但现实中样本往往是有限的,采用ANN方法建立的板带凸度预测模型往往会产生过拟合现象。因此,急需一种在样本有限的情况下,也可以实现较高泛化能力的板带凸度模型。

与ANN方法不同,SVM是一种基于结构风险最小化原理的算法,保证了该模型具有良好的泛化能力^[12]。SVM以统计学理论为基础,根据有限的样本在模型的复杂性和学习能力之间寻求最佳折中,以期获得最好的泛化能力^[13-14]。支持向量回归(SVR)是SVM在回归条件下的应用^[15]。Fei等^[16]提出在样本有限的条件下,采用ANN方法不适合建立预测模型,而采用SVR方法建立的预测模型具有较高的泛化性能。Wu等^[17]在实验数据有限的情况下,为提高SVR轧制力模型的预测精度,采用粒子群优化算法(PSO)优化SVR模型参数,结果表明,PSO-SVR模型相比SVR和BPNN模型具有较高的预测精度,且SVR比BPNN模型预测精度高。综上可得,在样本数据有限的情况下,采用SVR建立模型可以避免ANN建立模型所产生的过拟合现象,采用PSO算法^[18]可以提高SVR模型的预测精度,即PSO-SVR模型具有较高的泛化能力,但另一方面PSO算法优化参数虽可以有效保证模型参数的有效性,但板带轧制过程干扰因素较多、测量数据存在误差和数据处理不当等因素都会导致输入数据存在偏差,使PSO-SVR模型难以准确地预测板带凸度。

为提高PSO-SVR模型的预测精度,本文提出采用BPNN建立板带凸度偏差模型与PSO-SVR板带凸度模型相结合的方法对板带凸度进行预测。采用现场数据验证模型的预测性能,结果表明,与PSO-SVR、SVR、BPNN和GA-SVR模型比较,PSO-SVR+BPNN模型具有较高的学习能力和泛化能力。

1 建立 PSO-SVR 板带凸度预测模型

1.1 板凸度的基本概念

板凸度是指板带材横向的断面厚度差,即板带的中间与边部厚度之差,板凸度的计算公式为

$$C = h_c - \frac{h_e + h_e'}{2}$$

式中: C 为板带凸度; h_c 为中心厚度; h_e 和 h_e' 为边部代表点厚度。

板带凸度示意图如图1所示,其中 e 表示板材边部代表点距板材边上之间的距离,通常取 $e = 25 \text{ mm}$ 或 $e = 40 \text{ mm}$ 处,本文分析中均取 $e = 40 \text{ mm}$ 。




图1 板带凸度示意图

Fig. 1 Schematic diagram of strip crown

1.2 实验数据的采集与处理

从某中厚板厂的热轧生产线上获取670组Q355B板带轧制数据,作为实验样本,如表1所示。选择轧前板材厚度 H_0 、轧后板材厚度 H_1 、轧前温度 T_0 、轧后温度 T_1 、轧前板材宽度 B 、轧制力 F 、轧制力矩 P 、轧制速度 v 、摩擦系数 μ 和轧前板材凸度 C_0 作为输入变量,并选择轧后板材凸度 C_1 作为输出变量。

从工厂收集的样本包含异常和嘈杂的数据,会降低模型的准确度,为获得真实的分析结果,利用T检验准则处理样本,舍去34组异常数据,最终选择636组数据作为实验数据,其中500组数据作为训练集,剩余数据作为测试集。不同的影响因素通常具有数量级差异,将会降低模型的预测精度和训练速度。在建模之前,实验数据进行归一化为 $[-1,1]$,归一化公式为

$$x'_i = 2 \times \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} - 1$$

式中 $\max(x_i)$ 和 $\min(x_i)$ 分别为序列的最大值和最小值, $i = 1, 2, \dots, l$ 。

表 1 热轧实验数据
Table 1 Experimental data of hot rolling

序列	H_0/mm	H_1/mm	$T_0/^\circ\text{C}$	$T_1/^\circ\text{C}$	B/mm	F/kN	$P/\text{kN}\cdot\text{m}$	$v/\text{r}\cdot\text{m}^{-1}$	μ	C_0/mm	C_1/mm
1	72.66	65.01	980.2	964.5	2309.64	13532.6	801.1	20	1.293	0.0484	0.08929
2	48.12	43.12	917.0	906.8	2613.54	17322.3	828.9	25	1.335	0.10565	0.12629
3	53.25	47.83	839.6	829.2	2107.04	19770.7	984.5	30	1.337	0.29848	0.31889
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
669	38.4	35.67	868.3	851.5	2309.64	13536.3	478.3	35	1.329	0.13191	0.09457
670	65.76	58.83	986.4	865.7	2613.54	19546.4	1101.3	20	1.165	0.46068	0.21446

1.3 SVR 理论

SVR 是一种机器学习方法^[15], SVR 的基本思想是通过 $\phi(x)$ 将非线性的低维不可分割数据映射到高维特征空间, 并在该特征空间中执行线性 SVR。

SVR 函数可以表述为

$$f(x) = (w \cdot x) + b \quad (1)$$

式中: $f(x)$ 为预测值; w 为惯性权值; $w \cdot x$ 为 w 和 x 的内积; b 为阈值。

引入两个松弛变量 ξ_i 和 ξ_i^* , 优化问题可变成:

$$\min_{w, b, \xi_i, \xi_i^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*)$$

$$\text{s.t.} \begin{cases} (w \cdot x_i) + b - y_i \leq \varepsilon + \xi_i \\ y_i - (w \cdot x_i) - b \leq \varepsilon + \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0, i = 1, 2, 3, \dots, l \end{cases}$$

式中: C 为惩罚因子; ξ_i 和 ξ_i^* 为松弛变量; ε 为不敏感损失参数。

引入拉格朗日函数和基于强对偶关系, 并将核函数 $K(x_i, x) = \varphi(x_i) \cdot \varphi(x)$ 代入化简, 式 (1) 可以重写为

$$f(x) = \sum_{i=1}^l (\alpha_i^* - \alpha_i) K(x_i, x) + b$$

式中 α_i 和 α_i^* 是拉格朗日乘子向量。

选择核函数对于 SVR 至关重要, 它将直接影响数据样本的非线性映射。为了获得更好的泛化能力, 选择 RBF 核函数用于 SVR 模型, 公式为

$$K(x_i, x) = \exp(-g|x_i - x|^2)$$

式中 g 是 RBF 核函数的参数。

C 和 g 是影响 SVR 模型预测精度的重要参数, 选择 PSO 算法优化二者的最佳组合, 以确保模型的最佳性能。

1.4 PSO 算法优化 SVR 模型参数

PSO 算法是一种基于群体智能原理的随机优化算法, 由 Kennedy 和 Eberhart 在 1995 年提出^[19]。PSO 算法受到鸟类觅食行为的启发并应用到解决优化问题^[20], 粒子群在高维空间中随机分布并跟

踪个体极值和种群极值不断更新自己的位置和速度, 使其向全局最优粒子的位置靠近, 并试图在空间中搜索最优参数 (C, g) ^[21]。

2 建立 PSO-SVR+BPNN 板带凸度预测模型

2.1 BPNN 板带凸度偏差预测模型

ANN 通过调整节点之间的关系来处理信息, 具有强大的自学习能力。本文 ANN 采用常用的 BPNN 模型, 模型结构由一个输入层、单或多隐含层和一个输出层组成^[22]。利用训练集检验 SVR 模型的误差, 并将误差数据集用于训练 BPNN 模型。因此, 在本节选择轧后板带凸度的预测偏差 X_C 作为 BPNN 模型的因变量, BPNN 与 SVR 模型的自变量保持一致, 即 BPNN 模型输入层节点数为 10, 输出层节点数为 1。在相同条件下, 使用多隐含层所获得的预测结果并未比单隐含层网络拟合效果好, 所以本文选择单隐含层进行建模, 通过经验公式和试凑法^[23]确定单隐含层节点数为 6, 输入层到隐含层的网络权值为 ω_{ij} , 隐含层到输出层的网络权值为 ω_{jk} , 由以上参数绘制 BPNN 的拓扑结构如图 2。




图 2 BPNN 拓扑结构

Fig. 2 Topological structure of BPNN

2.2 PSO-SVR+BPNN 板带凸度预测模型

在实际应用中, 板带轧制过程干扰因素较多, 测量数据存在误差和数据处理不当, 这些问题都

会导致输入数据存在偏差, 使 PSO-SVR 模型难以准确地描述板带凸度变化趋势。为提高该模型的预测精度, 提出了将 PSO-SVR 板带凸度预测模型和 BPNN 板带凸度偏差模型相结合的方法对板带凸度进行预测。该方法的主要思想是在无外界因素干扰的情况下, 经过 PSO 算法优化的 SVR 模型具有良好的泛化能力, 能够很好地反映板带凸度变化的主要趋势, 用它来预测板带凸度的主值; BPNN 模型反映扰动因素对板带凸度的影响, 用它来纠

正板带凸度的偏差。BPNN 修正 PSO-SVR 模型的预测误差, 从而使 PSO-SVR 模型预测误差弱化, 将两者的优势进行组合, 可以得到最佳的预测效果, PSO-SVR+BPNN 模型预测板带凸度公式为

$$c_2' = c_1' + x_c$$

式中: c_2' 为 PSO-SVR+BPNN 模型的预测值; c_1' 为 PSO-SVR 模型的预测值; x_c 为 BPNN 模型的预测偏差。

本文所提出的 PSO-SVR+BPNN 模型的建模过程如图 3 所示。

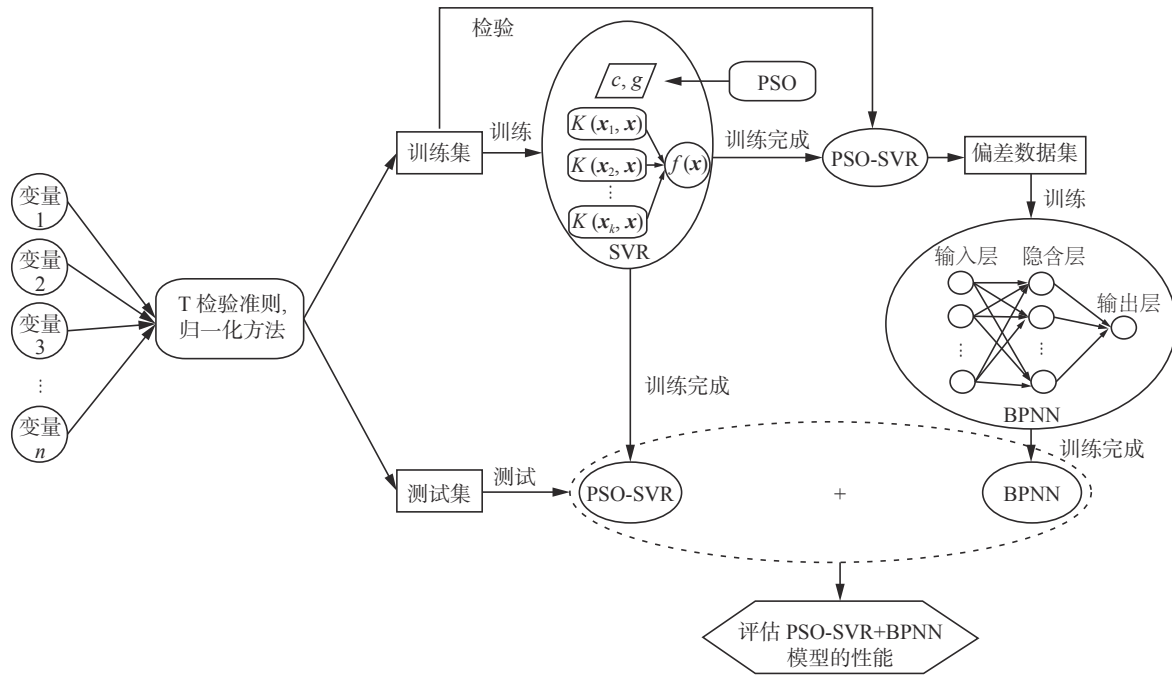


图 3 PSO-SVR+BPNN 模型的建模流程

Fig. 3 Modeling process of PSO-SVR+BPNN model

从工厂获取实验数据, 并利用 T 检验准则和归一化方法预处理实验数据, 使其消除异常数据和数量级差异。其次, 采用 PSO 算法优化 SVR 模型参数, 利用训练集检验建立 PSO-SVR 模型时所产生的误差, 并将误差数据集用于训练 BPNN 模型, 将 PSO-SVR 与 BPNN 模型相结合进行预测板带凸度。最后, 利用测试集测试 PSO-SVR+BPNN 模型的预测精度, 并采用决定系数 (R^2)、根均方误差 (RMSE)、平均绝对误差 (MAE) 和平均绝对百分比误差 (MAPE) 用于评估模型的综合性能, 公式为

$$R^2 = \frac{\left(l \sum_{i=1}^l y_i y_i' - \sum_{i=1}^l y_i \sum_{i=1}^l y_i' \right)^2}{\left[l \sum_{i=1}^l y_i^2 - \left(\sum_{i=1}^l y_i \right)^2 \right] \left[l \sum_{i=1}^l y_i'^2 - \left(\sum_{i=1}^l y_i' \right)^2 \right]}$$

$$RMSE = \sqrt{\frac{1}{l} \sum_{i=1}^l (y_i - y_i')^2}$$

$$MAE = \frac{1}{l} \sum_{i=1}^l |y_i - y_i'|$$

$$MAPE = \frac{1}{l} \sum_{i=1}^l \left| \frac{y_i - y_i'}{y_i} \right| \times 100\%$$

式中: y' 为模型的预测数据集; y 为模型的目标数据集。

3 实验结果与分析

3.1 PSO-SVR+BPNN 模型与 PSO-SVR、SVR 和 BPNN 模型比较

为了体现 PSO-SVR+BPNN 模型综合性能的优越性, 采用 PSO-SVR、SVR 和 BPNN 建立板带凸度模型, 利用 R^2 、RMSE、MAE 和 MAPE 评估模型的综合性能。在训练集和测试集上, 4 种模型预测值与目标值的回归结果, 如图 4 所示。从图 4 可得, 采用 SVR 的 3 种模型的回归性能明显优于 BPNN 模型。在训练集和测试集上, BPNN 模型的 R^2 不高于 0.995, 而基于 SVR 的 3 种模型的所

有 R^2 均高于 0.997, 这充分说明了基于 SVR 的 3 种模型比 BPNN 模型的预测精度高。由此可见, 基于 SVR 板带凸度预测模型具有较高的泛化能力。

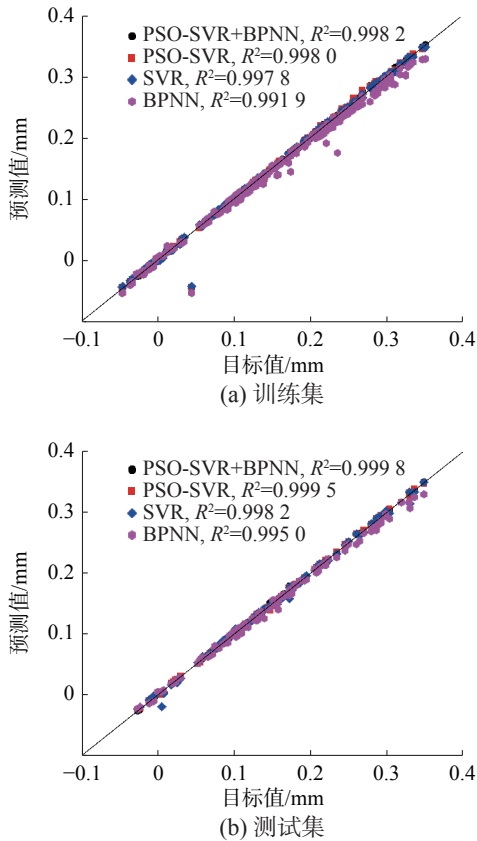


图 4 PSO-SVR+BPNN、PSO-SVR、SVR 和 BPNN 模型预测值与目标值的回归结果

Fig. 4 Regression results of predicted values and target values of PSO-SVR+BPNN, PSO-SVR, SVR and BPNN models

图 4 描述了在训练集和测试集上, PSO-SVR 与 SVR 模型相比具有较大的 R^2 值, 即 PSO-SVR 比 SVR 模型预测性能好。同理可得, 与 PSO-SVR 相比, PSO-SVR+BPNN 模型具有较好的预测性能。实验结果表明, 采用 PSO 算法优化 SVR 模型参数, 可以提高 SVR 模型的学习能力和泛化能力; 利用 BPNN 模型纠正 PSO-SVR 模型的预测偏差,

可以提高 PSO-SVR 模型的学习能力和泛化能力。

图 5 描述了不同模型预测值与目标值的比较。从图 5 中可得, 基于 SVR 的 3 种模型和 BPNN 模型有较高预测精度, 但无法直接地区别各模型的预测精度, 因此分别从两个数据集上任意选取五个连续的样本点测试模型的预测性能, 如表 2 所示。表 2 清楚地显示 PSO-SVR+BPNN 模型与 PSO-SVR、SVR 和 BPNN 模型之间的预测精度差异。在训练集和测试集上, PSO-SVR+BPNN 模型预测值的相对误差在 2% 以内; PSO-SVR、SVR 和 BPNN 模型预测值中大部分数据点的相对误差分别在 5%、8% 和 11% 以内。以上结果表明, SVR 与 BPNN 模型相比具有较高的预测性能, 但低于 PSO-SVR 模型的预测性能; 与 PSO-SVR、SVR 和 BPNN 模型相比, PSO-SVR+BPNN 模型的学习能力和预测精度最高。

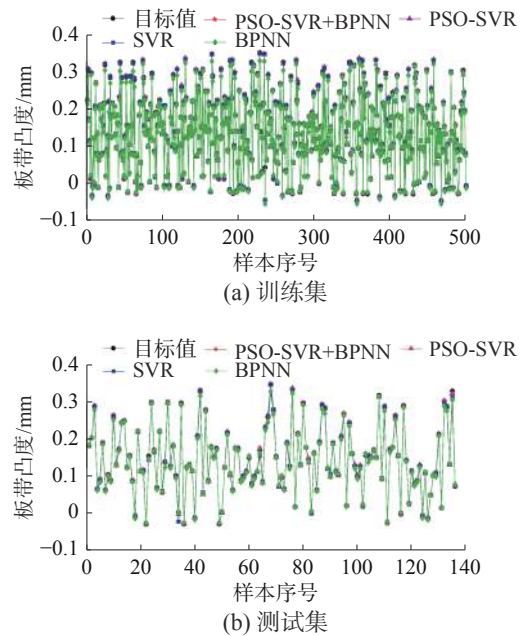


图 5 PSO-SVR+BPNN、PSO-SVR、SVR 和 BPNN 模型预测值与目标值的比较

Fig. 5 Comparison of predicted values and target values for PSO-SVR+BPNN, PSO-SVR, SVR and BPNN models

表 2 部分样本数据下不同模型的相对误差

Table 2 Relative error of different models under partial sample data

数据集	序号	目标值 /mm	PSO-SVR+BPNN		PSO-SVR		SVR		BPNN	
			预测值/mm	相对误差/%	预测值/mm	相对误差/%	预测值/mm	相对误差/%	预测值/mm	相对误差/%
训练集	1	0.249 57	0.249 74	-0.07	0.251 64	-0.83	0.252 00	-0.97	0.246 94	1.05
	2	0.094 32	0.093 96	0.38	0.095 92	-1.70	0.097 52	-3.39	0.098 56	-4.50
	3	-0.004 72	-0.004 79	-1.48	-0.004 94	-4.66	-0.002 18	53.81	-0.010 01	-112.08
	4	-0.011 73	-0.011 73	0.00	-0.009 76	16.79	-0.008 97	23.53	-0.014 85	-26.60

续表 2

数据集 序号	目标值 /mm	PSO-SVR+BPNN		PSO-SVR		SVR		BPNN		
		预测值/mm	相对误差/%	预测值/mm	相对误差/%	预测值/mm	相对误差/%	预测值/mm	相对误差/%	
测试集	5	0.139 51	0.139 312	0.14	0.139 20	0.22	0.128 78	7.69	0.125 35	10.15
	1	0.125 22	0.125 14	0.06	0.125 11	0.09	0.126 87	−1.32	0.122 34	2.30
	2	0.219 81	0.219 96	−0.07	0.221 43	−0.74	0.217 02	1.27	0.212 55	3.30
	3	0.106 20	0.104 37	1.72	0.103 14	2.88	0.109 44	−3.05	0.109 84	−3.43
	4	0.065 55	0.065 14	0.63	0.064 07	2.26	0.063 37	3.33	0.061 96	5.48
	5	0.177 97	0.178 07	−0.06	0.178 19	−0.12	0.175 21	1.55	0.173 55	2.48

通过 RMSE、MAE 和 MAPE 测试各模型的综合性能。表 3 列出了各模型在训练集和测试集上 3 种误差指标的计算值, 图 6 是从计算结果中得出误差分布的直方图。表 3 和图 6 清楚地表明, 在训练集和测试集上, PSO-SVR+BPNN 模型的 RMSE、MAE 和 MAPE 指标最小, 分别为 0.004 2 和 0.001 2、0.000 9 和 0.000 8、2.371 5% 和 2.690 3%。PSO-SVR+BPNN 模型的 MAPE 在 2.7% 以内; PSO-SVR、SVR 和 BPNN 模型的 MAPE 分别在 7.1%、16.4% 和 18.4% 以内。以上结果与表 2 结果保持一致, PSO-SVR+BPNN 模型与其他 3 种模型相比具有最佳的学习能力和泛化能力, 再次验证了 PSO-SVR+BPNN 板带凸度模型的优越性。


表 3 不同模型的性能统计分析

Table 3 Performance statistical analysis of different models


模型	数据集	RMSE	MAE	MAPE/%
PSO-SVR+BPNN	训练集	0.004 2	0.000 9	2.371 5
	测试集	0.001 2	0.000 8	2.690 3
PSO-SVR	训练集	0.004 4	0.001 8	6.735 7
	测试集	0.002 1	0.001 6	7.019 1
SVR	训练集	0.004 7	0.002 5	11.209 5
	测试集	0.003 9	0.002 8	16.348 0
BPNN	训练集	0.007 3	0.005 6	17.734 7
	测试集	0.006 4	0.004 7	18.360 7

此外, 对影响 PSO-SVR+BPNN 板带凸度模型性能的主要因素进行定量分析, 将未优化 SVR 模型参数 C 和 g , 设定为模型 1; 未优化 BPNN 模型隐含层节点数, 设定为模型 2; 未删除异常数据, 设定为模型 3; 以上因素全部考虑, 设定为模型 4, 采用 R^2 指标评价各模型的预测性能, 实验结果如表 4 所示。从表 4 可以看出, 在训练集和测试集上, 模型 3 的 R^2 最小, 模型 2 的 R^2 相对较小, 而模型 1 的 R^2 相对较大。因此, 异常数据对模型性能

的影响最大, 其次, 隐含层节点数对模型性能的影响较小, 而参数 C 和 g 对模型性能的影响最小。



(a) 训练集



(b) 测试集

图 6 不同模型的误差直方图

Fig. 6 Error histograms of different models

表 4 不同条件下模型性能的影响

Table 4 Impact of model performance based on different conditions

模型	条件	R_1^2	R_2^2
模型1	未优化 C 和 g	0.998 0	0.998 9
模型2	未优化隐含层节点	0.991 9	0.987 8
模型3	未删除异常数据	0.955 6	0.934 1
模型4	全部优化	0.998 2	0.999 8

3.2 PSO-SVR+BPNN 模型与 GA-SVR 模型比较

遗传算法 (GA)^[24] 是一种通过模拟自然进化过程搜索最优解的方法, 具有较高的全局优化能力、通用性强且适用于并行处理的优点, 常常被

使用在模型参数优化方面。本节采用 GA 算法优化 SVR 参数, 建立 GA-SVR 板带凸度预测模型, 并将 PSO-SVR+BPNN 与 GA-SVR 模型进行综合性能对比。

PSO 与 GA 算法相同的参数设置: 种群规模 20, 终止迭代次数 20, C 和 g 取值 (0.01, 100) 和 (0, 1)。特有参数设置: 对于 PSO 算法, 惯性权值为 $1/(2\ln 2)$, 加速因子为 $\ln 2 + 0.5$; 而 GA 算法, 交叉概率为 0.4 和变异概率为 0.1。在相同条件下, GA-SVR 与 PSO-SVR+BPNN 模型在训练集和测试集上预测值的比较, 如图 7 所示。图 7 中显示两个模型都具有较高的预测精度。为了直观地分析 2 个模型之间的性能差异, 采用 RMSE、MAE 和 MAPE 评估模型的预测性能, 如表 5 所示。在训练集和测试集上, PSO-SVR+BPNN 模型的 3 个误差指标均明显低于 GA-SVR 模型的 3 个误差指标。以上结果充分证明, PSO-SVR+BPNN 比 GA-SVR 模型具有更高的学习能力和预测精度。

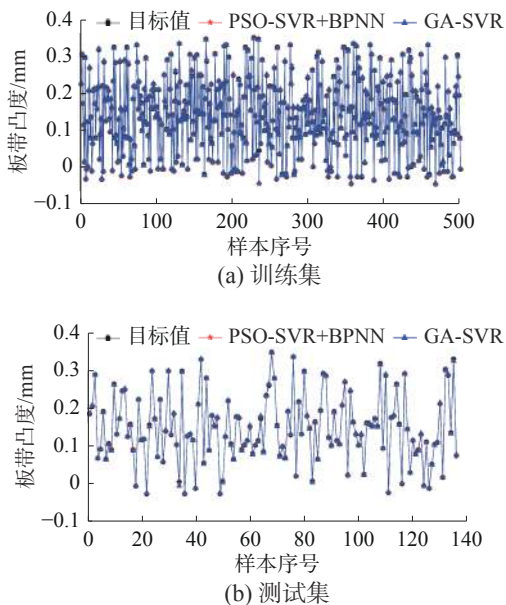


图 7 PSO-SVR+BPNN 和 GA-SVR 模型预测值与目标值的比较

Fig. 7 Comparison of predicted values and target values for PSO-SVR+BPNN and GA-SVR model

表 5 不同模型的性能统计分析

Table 5 Performance statistical analysis of different models

模型	数据集	RMSE	MAE	MAPE/%
PSO-SVR+BPNN	训练集	0.0042	0.0009	2.3715
	测试集	0.0012	0.0008	2.6903
GA-SVR	训练集	0.0045	0.0021	10.4214
	测试集	0.0024	0.0019	12.5999

此外, 运算时间是判断模型是否能在线应用的一个重要指标。图 8 描述 PSO-SVR+BPNN 和 GA-SVR 模型在不同迭代条件下的运算时间。从图 8 中可得, 在相同迭代次数条件下, GA-SVR 模型的运算时间明显高于 PSO-SVR+BPNN 模型。随着迭代次数的增加, GA-SVR 模型比 PSO-SVR+BPNN 模型运算时间的增长趋势更显著, 因此 PSO-SVR+BPNN 模型更适合热轧生产过程中板带凸度的在线预测。




图 8 PSO-SVR+BPNN 模型与 GA-SVR 模型运算时间比较

Fig. 8 Comparison of computing time for PSO-SVR+BPNN and GA-SVR model

4 结束语

为了提高热轧生产过程中板带凸度的预测精度, 本文建立了 PSO-SVR 模型与 BPNN 模型相结合的混合模型 PSO-SVR+BPNN 对板带凸度进行预测。实验结果表明: 1) 基于 SVR 板带凸度预测模型具有很高的泛化能力; 2) 在实验数据有限的情况下, 基于 SVR 模型比 BPNN 模型更适合作为板带凸度预测模型; 3) 采用 BPNN 模型与 PSO-SVR 模型相结合的方法可以提高 PSO-SVR 模型的学习能力和泛化能力; 4) PSO-SVR+BPNN 模型比 PSO-SVR、SVR、BPNN 和 GA-SVR 模型具有较高的学习能力和泛化能力, 并且比 GA-SVR 模型更适合热轧生产过程中板带凸度的在线预测。

参考文献:

- [1] 薛涛, 杜凤山, 孙静娜, 等. 基于 FEM-ANN 的冷轧带钢轧制力预报 [J]. 中南大学学报: 自然科学版, 2013, 44(11): 4456–4460.
XUE Tao, DU Fengshan, SUN Jingna, et al. Rolling force prediction of cold strip rolling based on FEM-ANN[J]. Journal of Central South University: (science and technology edition), 2013, 44(11): 4456–4460.
- [2] DENG Jifei, SUN Jie, PENG Wen, et al. Application of neural networks for predicting hot-rolled strip crown[J].

- Applied soft computing*, 2019, 78: 119–131.
- [3] SAMAREH S P H, KHADEMHOSEINI B H, ALIZADEH Y, et al. Calculation of work roll initial crown based on desired strip profile in hot rolling[J]. *Neural Computing and Applications*, 2013, 24(5): 1123–1133.
 - [4] 张强. 基于支持向量机的热轧板带轧制力预测 [D]. 西安: 西安建筑科技大学, 2021: 2.
ZHANG Qiang. Prediction of rolling force of hot rolled strip based on support vector machine[D]. Xi'an: Xi'an University of Architecture and Technology, 2021: 2.
 - [5] CHUN M S, BIGLOU J, Lenard J G, et al. Using neural networks to predict parameters in the hot working of aluminum alloys[J]. *Journal of materials processing technology*, 1999, 86: 245–251.
 - [6] 冀秀梅, 王龙, 高克伟, 等. 极限学习机在中厚板轧制力预报中的应用 [J]. 钢铁研究学报, 2020, 32(5): 393–399.
JI Xiumei, WANG Long, GAO Kewei, et al. Application of ELM to predict plate rolling force[J]. *Journal of iron and steel research*, 2020, 32(5): 393–399.
 - [7] 马威, 李维刚, 赵云涛, 等. 基于深度学习的热连轧轧制力预测 [J]. 钢铁研究学报, 2019, 31(9): 805–815.
MA Wei, LI Weigang, ZHAO Yuntao, et al. Prediction of hot-rolled roll force based on deep learning[J]. *Journal of iron and steel research*, 2019, 31(9): 805–815.
 - [8] WANG Liyong, LI Le, ZHANG Zhihua. Accurate descriptions of hot flow behaviors across β Transus of Ti-6Al-4V alloy by intelligence algorithm GA-SVR[J]. *Journal of materials engineering and performance*, 2016, 25(9): 3912–3923.
 - [9] 王前锋. 基于改进型支持向量机算法的轧机轧制力预测 [J]. 锻压技术, 2019, 44(4): 131–137.
WANG Qianfeng. Rolling force prediction of rolling mill based on improved support vector machine algorithm[J]. *Forging and stamping technology*, 2019, 44(4): 131–137.
 - [10] 方敏. 轧制过程板形预测控制的研究 [D]. 杭州: 杭州电子科技大学, 2015: 55.
FANG Min. Research on flatness prediction control in rolling process[D]. Hangzhou: Hangzhou Dianzi University, 2015: 55.
 - [11] 朱永波, 张飞, 张勇军, 等. 基于粒子群优化的带钢凸度神经网络预测模型研究 [J]. 冶金自动化, 2019, 43(2): 11–15.
ZHU Yongbo, ZHANG Fei, ZHANG Yongjun, et al. Particle swarm optimized neural network for strip crown prediction model research[J]. *Metallurgical industry automation*, 2019, 43(2): 11–15.
 - [12] CHENG M Y, HOANG N D, WU Y W. Hybrid intelligence approach based on LS-SVM and differential evolution for construction cost index estimation: A Taiwan case study[J]. *Automation in construction*, 2013, 35: 306–313.
 - [13] VAPNIK V N. The nature of statistical learning theory[J]. *IEEE transactions on neural networks*, 1997, 8(6): 1564–1564.
 - [14] VAPNIK V N. An overview of statistical learning theory[J]. *IEEE transactions on neural networks*, 1999, 10(5): 988–999.
 - [15] WANG Hu, LI Enying, LI Guangyao. The least square support vector regression coupled with parallel sampling scheme metamodeling technique and application in sheet forming optimization[J]. *Materials and design*, 2009, 30(5): 1468–1479.
 - [16] FEI Shengwei, HE Chuangxin. Prediction of dissolved gases content in power transformer oil using BASA-based mixed kernel RVR model[J]. *International journal of green energy*, 2019, 16(8): 652–656.
 - [17] WU Dongsheng, YANG Qin, WANG Dazhi. Rolling force prediction based on PSO optimized support vector regression[C]//Seventh International Conference on Natural Computation. Shanghai: IEEE, 2011: 839–483.
 - [18] WANG Dongshu, TAN Dapei, LIU Lei. Particle swarm optimization algorithm: an overview[J]. *Soft computing*, 2017, 22(2): 387–408.
 - [19] Eberhart R, Kennedy J. A new optimizer using particle swarm theory[C]// Proceedings of the 6th International Symposium on Micro Machine and Human Science. Nagoya: IEEE, 1995: 39–43.
 - [20] 刘明华, 张强, 刘英华, 等. 基于机器学习的热轧轧制力预测 [J]. 锻压技术, 2021, 46(10): 233–241.
LIU Minghua, ZHANG Qiang, LIU Yinghua, et al. Rolling force prediction of hot rolling based on machine learning method[J]. *Forging and stamping technology*, 2021, 46(10): 233–241.
 - [21] 杨轻, 杨忠, 许昌亮, 等. 改进 PSO 算法及其无人机电力巡线规划应用 [J]. 应用科技, 2019, 46(3): 80–85.
YANG Qing, YANG Zhong, XU Changliang. Improved particle swarm optimization algorithm and its application in unmanned aerial vehicle power line patrol[J]. *Applied science and technology*, 2019, 46(3): 80–85.
 - [22] 高喜峰, 翟立宾, 徐万海. 应用 BP 神经网络的柔性圆柱涡激振动预报 [J]. 哈尔滨工程大学学报, 2020, 41(8): 1150–1155.

GAO Xifeng, ZHAI Libin, XU Wanhai. Prediction of vortex-induced vibration of flexible cylinder using BP neural network[J]. Journal of Harbin Engineering University, 2020, 41(8): 1150–1155.

- [23] 张旭, 杜景林. 改进 PSO-GA-BP 的 PM2.5 浓度预测[J]. 计算机工程与设计, 2019, 40(6): 1718–1723.

ZHANG Xu, DU Jinglin. PM2.5 concentration prediction based on improved PSO-GA-BP[J]. Computer engineering and design, 2019, 40(6): 1718–1723.

- [24] ZHOU Yuting, XIA Yufeng, JIANG Lai, et al. Modeling of the hot flow behaviors for Ti-6Al-4V-0.1Ru alloy by GA-BPNN model and its application[J]. [High Temperature materials and processes](#), 2018, 37(6): 551–562.

作者简介:



刘明华, 副教授, 博士, 主要研究方向为轧制过程数模与控制。



张强, 硕士研究生, 主要研究方向为基于支持向量机板材轧制过程建模。

第一届自然语言处理技术与应用研讨会

在第六个全国科技工作者日来临之际, 由中国人工智能学会、南京邮电大学主办, 南京邮电大学计算机学院、CAAI 自然语言理解专委会承办, 江苏省人工智能学会数据挖掘与应用专委会协办的第一届自然语言处理技术与应用研讨会将于 2022 年 5 月 28 日, 在江苏省南京市南京邮电大学仙林校区举行, 线上会议和线下会议将同时进行。

本次会议旨在为来自各界的研究人员提供一个开放的平台, 分享各自想法、研究成果和经验, 增进自然语言处理领域的学者学术交流, 凝聚学术界和产业界的力量, 深入探讨自然语言处理研究中的前沿技术和重要应用, 推动中国自然语言处理领域的健康发展。本次会议邀请了来自复旦大学、同济大学、中兴通讯研究院等知名高校和研究机构的专家担任嘉宾进行学术分享。

观看地址: <https://meeting.tencent.com/dw/iFP02fOjeRAJ>