

基于 Stacking 集成学习的无缝钢管连轧电耗预测<sup>\*</sup>

李一恒 孙 抗 赵来军

(河南理工大学电气工程与自动化学院 焦作 454000)

**摘 要:** 无缝钢管生产作为高能耗行业的典型代表,其节能降耗一直都备受关注。通过预测电耗,企业可以找到节能降耗的有效途径,从而减少生产过程中的电能消耗,提升生产效率。为提高无缝钢管连轧电耗预测精度,采用一种改进的 Stacking 集成学习模型对电耗进行预测。首先,对采集到的电耗数据进行预处理,并基于嵌入法采用 XGBoost 和 LightGBM 进行特征选择;然后,采用随机搜索和贝叶斯优化结合的方法对基学习器开展超参数优化,在 Stacking 集成模型的首层中,选择 LightGBM、ET 和 MLP 作为基学习器;最后,根据基学习器在数据上的预测表现来赋予它们相应的权重,同时将原数据集也加入元学习器训练。结果表明:改进的 Stacking 集成学习模型具有最好的预测效果,其  $R^2$  为 0.975 7,预测精度比单一基学习器和传统的 Stacking 集成学习模型都要高,证明了所提方法的有效性。

**关键词:** 无缝钢管;Stacking 集成学习;电耗预测

**中图分类号:** TN98      **文献标识码:** A      **国家标准学科分类代码:** 520.1040

## Electricity consumption prediction for seamless steel pipe continuous rolling based on Stacking ensemble learning

Li Yiheng Sun Kang Zhao Laijun

(School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454000, China)

**Abstract:** Seamless steel pipe production, as a typical representative of high-energy-consuming industries, has always been a focus of energy-saving and consumption reduction. By predicting power consumption, enterprises can identify effective ways to save energy, thereby reducing electricity consumption in the production process and improving production efficiency. In order to improve the accuracy of electricity consumption prediction for seamless steel pipe continuous rolling, an improved Stacking ensemble learning model is adopted to predict power consumption. Firstly, the collected power consumption data is preprocessed, and XGBoost and LightGBM are used for feature selection based on embedding method. Then, a combination of random search and Bayesian optimization is used to optimize the hyperparameters of the base learners. In the first layer of the Stacking ensemble model, LightGBM, ET, and MLP are selected as the base learners. Finally, based on the predictive performance of the base learners on the data, they are assigned corresponding weights, and the original dataset is also included in the training of the meta-learner. The results show that the improved Stacking ensemble learning model has the best prediction effect, with an  $R^2$  of 0.975 6. The prediction accuracy is higher than that of single base learners and traditional Stacking ensemble learning models, demonstrating the effectiveness of the proposed method.

**Keywords:** seamless steel pipe; Stacking ensemble learning; electricity consumption prediction

## 0 引言

无缝钢管在国民经济中占有重要地位,是工业中的重要原材料,在石油化工、航空航天、煤炭开采、电力等行业应用广泛<sup>[1]</sup>。近年来,随着全球对能源效率和环境保护的日益关注,如何减少无缝钢管生产过程中的电能消耗,提高能

源使用效率,成为了工业界面临的重要挑战。

在众多能源优化方案中,预测和管理无缝钢管连轧过程的电能消耗成为了一个关键的研究方向。准确的电能消耗预测不仅可以帮助企业合理安排生产计划,减少能源浪费,还能为实现绿色制造、降低碳排放提供重要支持<sup>[2]</sup>。

近年来,机器学习技术在许多领域展现出了卓越的性

能,特别是在数据驱动的预测任务中。Stacking 集成学习,作为一种高效的机器学习方法,通过结合多个不同模型的预测结果来提高预测的准确性而受到了广泛的关注。它的主要优势在于能够融合不同模型,从而达到比单一模型更好的预测效果。赵艳茹等<sup>[3]</sup>利用 Stacking 集成学习设计了一种室内污染气体感知和评价系统,能够对局域网内的环境进行实时检测。夏雨薇等<sup>[4]</sup>在降维融合特征的基础上结合 Stacking 集成学习,提出了一种织物疵点分类算法,有效的提高了分类准确率。徐凯等<sup>[5]</sup>基于 Stacking 提出了一种集成模型,此模型能够做到城轨列车的精准定位。李川等<sup>[6]</sup>利用集成学习的方法为不平衡分布的数据驱动故障诊断研究提供了未来的发展方向。宋建等<sup>[7]</sup>以极端梯度提升树(extreme gradient boosting, XGBoost)、轻量级梯度提升(light gradient boosting machine, LightGBM)和岭回归为基学习器,以弹性回归为元学习器构建了 Stacking 集成模型,在注塑件预测方面的均方根误差较 XGBoost 和 LightGBM 分别降低了 16% 和 20%。Cui 等<sup>[8]</sup>提出了一种基于 Stacking 的集成学习方法,用于地震伤亡的预测。针对配电网能量管理和节能降耗的要求,曾铮等<sup>[9]</sup>利用集成学习方法构建了电费回收风险预测模型,实验结果表明与传统的逻辑回归算法相比,该方法可以更加准确地对用户是否会欠费进行预测。胡以婵等<sup>[10]</sup>将人工智能技术 XGBoost 算法、类别增强提升树算法(categorical boosting, CatBoost)、多层感知机算法(multilayer perceptron, MLP)、随机森林算法(random forest, RF)与集成学习方式有效结合,提出一种基于 Stacking 模型融合的高性能混凝土强度预测方法,实验表明该模型能够对高性能混凝土强度进行很好的预测。在钢铁领域的预测任务中,机器学习也得到了广泛的应用。王斌等<sup>[11]</sup>采用一种智能寻优灰狼算法对最小二乘支持向量机(least squares support vector machine, LSSVM)进行优化,建立了轧钢厂电耗预测模型,此模型预测精度较高,能够对轧钢厂每天的电耗进行很好的预测。Xiong 等<sup>[12]</sup>提出一种基于主成分降维和人工蜂群动态搜索融合的随机森林预测模型,用于带钢精轧电耗预测,此模型能满足实际生产中对厂级轧制需求的预测。

虽然机器学习在钢铁行业应用广泛,但缺少在无缝钢管连轧过程电耗预测方面的研究,Stacking 集成学习提供了一种预测思路,值得去探索。本文旨在探索利用 Stacking 集成学习方法来预测无缝钢管连轧过程的电耗。首先,对采集到的连轧电耗数据进行预处理;然后进行特征选择,并对预选基学习器进行超参数优化和五折交叉验证,通过性能分析和差异性分析选择 LightGBM、极端随机树(extra trees, ET)和 MLP 为基学习器建立 Stacking 集成学习预测模型;随后,为了增强模型的预测准确性,根据基学习器的表现赋予相应的权重,并将原始数据集引入到元学习器的训练中去。最后,通过对预测结果进行分析,证明了

Stacking 集成学习在无缝钢管连轧电耗预测方面的可行性。

## 1 研究方法

### 1.1 Stacking 集成模型

#### 1) 传统的 Stacking 集成模型

Stacking<sup>[13]</sup>是一种集成学习方法,由 Wolpert 于 1992 年提出,是异质集成的典型例子。Stacking 集成模型是一种通过组合多个基本模型的预测结果来生成最终预测的方法,其基本思想是利用不同模型的多样性提高预测性能。在 Stacking 中,首先训练多个基本模型,然后将它们的预测结果作为新特征输入到另一个模型中,称为元学习器,从而得到最终的预测结果。

由于第 2 层的元学习器直接使用第 1 层基学习器训练的结果作为输入,所以传统的 Stacking 集成学习模型会存在过拟合的风险。为了避免这种情况,采用  $k$  折交叉验证方法。其基本思想是将原始数据集划分成  $k$  个大小相似的子集,称为折叠(folds),然后依次将每个子集作为验证集,其余  $k-1$  个子集作为训练集,重复  $k$  次训练和验证过程,最终取  $k$  次验证结果的平均值作为模型的性能指标。以五折交叉验证为例,如图 1 所示。




图 1 五折交叉验证示例图

#### 2) 改进的 Stacking 集成模型

传统的 Stacking 集成学习模型通常在第 2 层的元学习器的训练中使用由第 1 阶段各模型预测的输出值组合而成的数据集。虽然这一策略有助于减轻过拟合问题并提升模型性能,但也可能导致部分原始训练集信息的丢失。为了进一步提升 Stacking 集成学习模型的性能,考虑对 Stacking 模型进行改进。

将原始数据集加入到元学习器的训练是一种可行的改进方法。这样做可以丰富元学习器的训练集,包括原始训练集和第 1 层基学习器交叉验证生成的新数据集,从而使

得元学习器能够学习到这些数据集之间的内在联系,以增强模型的预测准确性。

根据基学习器的预测精度进行特征加权也是热门的改进方法。此方法考虑到每个基学习器抓取特征能力不同,为了保证数据信息能够被每个基学习器更好的利用,对第 2 层元学习器使用的第 1 层基学习器的预测结果进行加权,权重的大小按预测精度的高低进行分配。通过这种方式,可以更有效地利用每个学习器中的信息,达到更好的预测结果。权重的计算公式如下:

$$w_i = \frac{RMSE_i}{\sum_{j=1}^N RMSE_j}$$
 (1)

式中:  $w_i$  是第  $i$  个基学习器的权重,  $RMSE_i$  是该基学习器的均方根误差。

为了得到更好的预测结果,本文把上述两种改进方法结合起来对 Stacking 集成学习模型进行改进。首先,在进行模型预测训练时加入原始数据集,使元学习器更好的捕捉数据集之间的关系;其次,对各基学习器的预测结果进行特征加权,让元学习器能够更好的利用各个基学习器的预测结果,得到更准确的结果。最终改进过后的 Stacking 集成模型的流程图如图 2 所示。

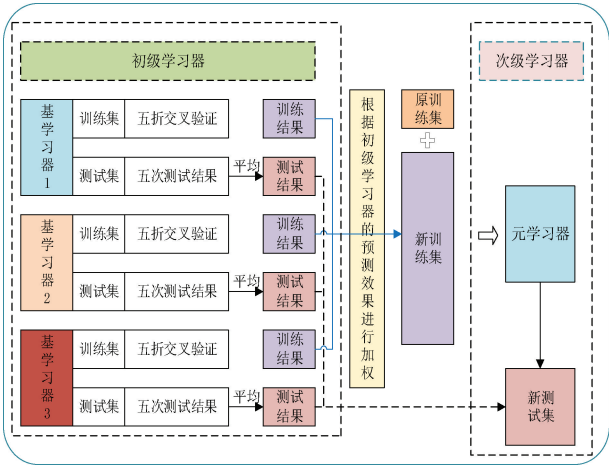


图 2 改进的 Stacking 集成学习模型原理图

1.2 基学习器模型

在 Stacking 集成模型中,如果各基学习器的学习能力越强并且差异性显著,那么模型预测效果会更好。本文选

择 XGBoost、LightGBM、ET 和 MLP 作为 Stacking 集成学习的预选模型。

1) XGBoost<sup>[14]</sup> 是一种基于决策树的集成学习算法,其采用了梯度提升的策略。与传统的梯度提升算法相比, XGBoost 采用正则化和树剪枝等技术,能有效地提高模型的泛化能力,避免过拟合现象。

2) LightGBM<sup>[15]</sup> 是一种基于梯度提升决策树的集成学习算法。LightGBM 的特点在于其采用基于直方图的算法,这使得算法的内存使用更少,同时加快了训练速度。此外, LightGBM 通过支持类别特征的直接处理和更高效的数据分割策略来提高模型的泛化能力。

3) ET 算法<sup>[16]</sup> 是一种集成学习算法,属于随机森林家族。与随机森林不同的是, ET 在构造决策树的过程中,对每个节点的分裂使用全部特征而非随机子集,且分裂阈值是完全随机选择的。这种极端的随机性使得 Extra Trees 比随机森林有更快的训练速度,因为它减少了寻找最优分裂点的计算量。此外,这种随机性也有助于提高模型的泛化能力,减少过拟合。

4) MLP<sup>[17]</sup> 是一种前馈人工神经网络模型,它包含至少 3 层的节点:一个输入层、一个或多个隐藏层以及一个输出层。每个节点与前一层的每个节点连接,并通过激活函数进行非线性转换。MLP 使用反向传播算法进行训练,通过调整神经网络中的权重和偏置以减少预测误差,对非线性问题有很好的表现能力。

2 Stacking 集成学习模型构建

2.1 数据预处理

无缝钢管的生产过程是一个典型的复杂非线性系统,涉及多个环节和设备。这一过程异常复杂,其影响参数众多并且相互之间耦合性强,因而难以完全理解其生产机制。其生产流程如图 3 所示。在无缝钢管的生产流程中,影响连轧电耗的参数有很多。有一部分是产品和设备的规格,很容易在工艺卡上查到。然而,大多数参数由于设备和工艺的原因采集起来十分困难。因此,本文在构建 Stacking 集成学习预测模型时,选择了在连轧过程中变化较大且容易采集的参数作为模型的预选输入特征。这些输入特征包括毛管外径、毛管壁厚、荒管壁厚、芯棒直径、延伸系数、出口速度、成品外径和成品壁厚。



图 3 无缝钢管生成流程图

在数据采集过程中,受某些因素的影响,可能有异常值的出现。这些异常值的存在可能会对模型的预测造成干扰,影响模型的预测结果。因此,对于用于预测的原始数据进行数据的处理是必要的。图 4 为各参数的箱线图,通

过观察箱线图可以分析出是否存在异常值。

从图 4 中可以看出,毛管外径、芯棒直径、延伸系数和成品外径的数据无明显异常值。毛管壁厚的中位数略靠近箱体的上部,说明数据可能略微左偏,箱体较短,表示该

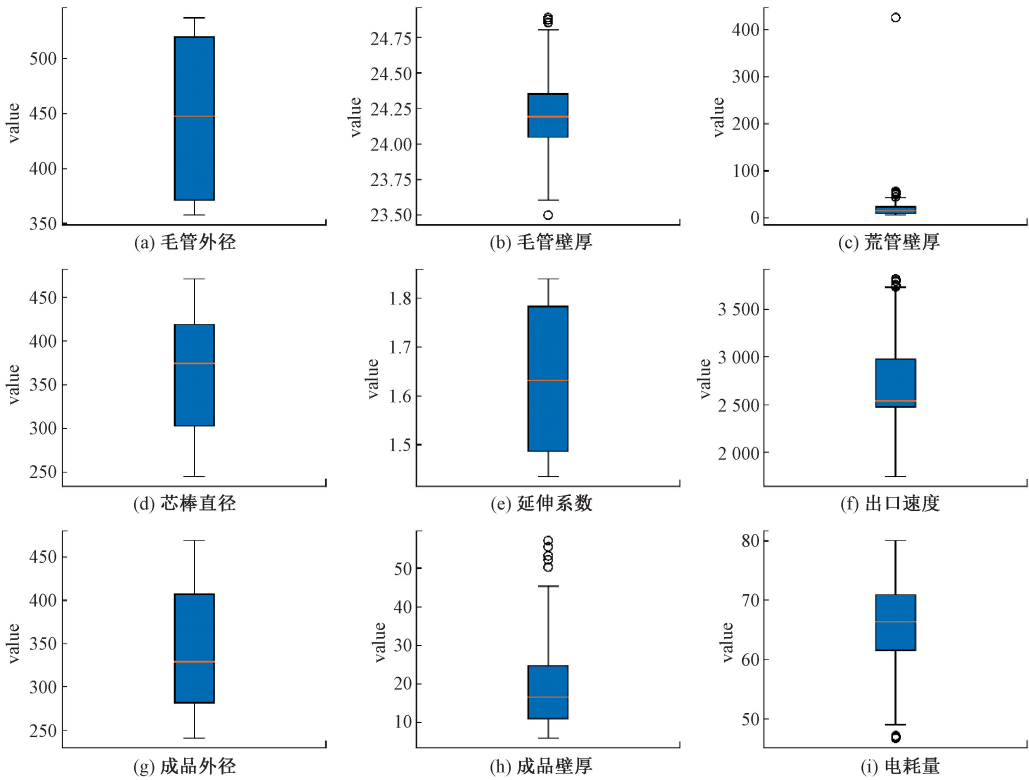


图 4 各参数箱线图

变量的四分位数间距较小,波动性较低,存在一些高值的异常点;荒管壁厚的中位数也略微偏向箱体上部,可能有轻微的左偏,箱体长度适中,波动性中等,异常点主要集中在高值区域;出口速度的中位数靠近箱体的中间位置,箱体长度较长,说明变量的波动性比较大,有许多高值的异常点;成品壁厚的中位数略微偏向箱体的下部,呈现轻微的右偏,箱体较长,表示波动性较大,存在一些高值的异常点。

通过上述分析可知,数据中存在异常点,为了防止异常值的存在对模型的预测造成干扰,本文选择删除这些异常点来保证预测模型的准确性。

2.2 特征选择

特征选择是机器学习的一个关键步骤,它对提高模型的性能、减少过拟合的风险、降低计算成本、以及提升模型的可解释性都有着至关重要的作用。通过移除不相关或冗余的特征,特征选择有助于减少模型的噪声,从而提高模型的准确度和预测能力。完成连轧电耗数据预处理后,

为选择影响连轧过程能耗的强相关特征变量从而提高模型的性能,使用 XGBoost 和 LightGBM 模型基于嵌入法采用特征集成的方法对特征进行选择。

首先,使用两种不同的梯度提升模型 XGBoost 和 LightGBM 对数据进行训练,并从每个模型中获得特征的重要性评分。然后,使用归一化处理将从两种模型中获得的特征重要性评分进行归一化,使得所有特征的重要性评分都被缩放到[0,1]的范围内。接下来,对归一化后的两个模型相应特征的重要性评分进行乘积,以生成一个新的特征重要性评分。最后,对计算出的新的特征重要性评分进行排序,然后根据需求选择合适的输入特征。式(2)为其原理公式。相乘之后的特征重要性评分如表 1 所示。

$$FI(j) = f(lgbm(j)) \times f(xgb(j)) \quad (2)$$

式中:  $FI(j)$  是两个模型相乘过后的第  $j$  个特征的重要性评分,  $f(lgbm(j))$  是经过归一化处理的 LightGBM 模型第  $j$  个特征的重要性评分,  $f(xgb(j))$  是经过归一化处理的 XGBoost 模型第  $j$  个特征的重要性评分。

表 1 特征重要性评分

特征重要性得分	出口速度	芯棒直径	毛管壁厚	成品外径	毛管外径	成品壁厚	荒管壁厚	延伸系数
	1.00	0.38	0.35	0.34	0.31	0.29	0.27	0.25

根据表中两个模型相乘之后的特征重要性得分可知,所有输入特征的得分都超过了 0.2,都与电耗量存在一定

的相关性,因此,表中的所有特征变量都可用作 Stacking 集成学习模型的输入。最终,确定输入特征为:出口速度、



芯棒直径、毛管壁厚、成品外径、毛管外径、成品壁厚、荒管壁厚和延伸系数。

2.3 回归模型建立

本文基于 Stacking 集成学习原理对无缝钢管连轧电耗进行预测,第 1 层的基学习器使用 LightGBM、ET 和 MLP 具有一定差异性的模型,选择方法在下文给出。同时,为了避免模型过拟合,第 2 层的元学习器采用具有较强泛化能力的线性回归(LR)。图 5 为无缝钢管连轧电能消耗预测方法流程图,其具体实现如下:

- 1)采集数据,对采集的原始电耗数据进行预处理剔除掉异常值;
- 2)分别使用 XGBoost 模型和 LightGBM 模型对预处

理过的数据进行特征重要性排序,然后进行特征集成选择合适的特征,生成新的数据集;

- 3)使用交叉验证按 7 : 3 的比例将新生成的数据集划分为训练集和测试集;
- 4)选择 LightGBM、ET 和 MLP 作为基学习器模型,选择依据下文给出,并对基学习器模型进行超参数优化;
- 5)根据第 1 层基学习器的预测精度为它们的预测结果赋予相应的权重,并把原数据集一起加入到第 2 层的元学习器中进行训练;
- 6)为了减少过拟合的风险,选择结构简单的线性回归(LR)作为元学习器进行预测,得到最终的连轧电耗预测结果。

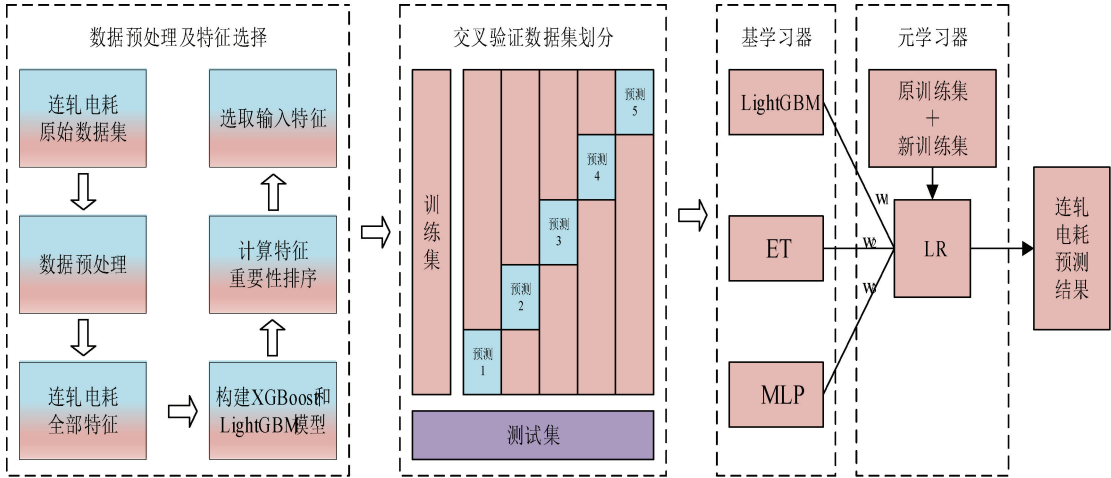


图 5 整体流程图

3 实验结果及分析

3.1 评价指标

本文采用平均绝对百分比误差(MAPE)、均方根误差(RMSE)以及决定系数(R<sup>2</sup>)对模型的预测结果进行评价。

平均绝对百分比误差(MAPE)表示的是预测值与实际值之间的偏差程度。MAPE 的值越低,表示预测的准确性越高,公式如下:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \tag{3}$$

均方根误差(RMSE)是均方误差的算数平方根, RMSE 的值越低,表示预测模型的准确性越高,公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \tag{4}$$

决定系数(R<sup>2</sup>)是一种用于评估回归模型拟合优度的统计量。当 R<sup>2</sup> 越接近 1,表示模型越能很好地解释因变量的变异性,拟合效果越好,公式如下:

$$R^2 = 1 - \frac{\sum_i (\hat{y}_i - y_i)^2}{\sum_i (\bar{y}_i - y_i)^2} \tag{5}$$

式中: n 为样本数,  $\hat{y}_i$  为预测值,  $y_i$  为实际值,  $\bar{y}_i$  为平

均值。

3.2 超参数优化

模型的超参数对模型的预测结果有很大的影响,在机器学习常常通过超参数优化来找到最佳的预测模型。随机搜索是一种简单而有效的优化方法,通过在超参数空间内随机采样参数的组合,并评估它们的性能来进行优化。这种方法简单,通常能找到相对不错的超参数组合。但缺点是未利用之前试验结果来指导下一次选择,可能需要更多试验次数找到最优超参数。贝叶斯优化基于贝叶斯定理,通过构建目标函数的概率模型来选择下一个尝试的超参数组合。其核心思想是在每次迭代中寻找使得目标函数在当前概率模型下最大化的超参数组合,逐步优化目标函数的值。优点是能够利用之前试验结果指导下一次选择,在相同试验次数下通常能找到更好的超参数组合。但缺点是在高维空间可能面临计算挑战,对初始参数选择较敏感。

为了更好的对模型的超参数进行优化,使 Stacking 集成学习模型拥有更好的预测效果,本文使用随机搜索和贝叶斯优化相结合的方法对基学习器进行训练,来找到各基学习器的最佳超参数。此方法先利用随机搜索在大范围

内快速定位性能不错的参数区域,然后通过贝叶斯优化在这些区域内进行精细化搜索,有效利用历史信息指导搜索方向,以提高搜索效率和精度。这种方法优化了计算资源

的使用,确保了在有限资源下实现最佳的模型性能。使用上述方法进行超参数优化过后的各基模型的部分最佳超参数如表 2 所示。

表 2 各模型最优超参数

模型	XGBoost	LightGBM	ET	MLP
最优超参数	max_depth=12	max_depth=9	n_estimators=112	
	min_child_weight=19	num_leaves=41	max_depth=9	alpha=0.001 2
	learning_rat=0.014 3	learning_rate=0.012 3	min_samples_split=9	learning_rate_init=0.041 8
	n_estimator=653	n_estimators=639	min_samples_leaf=1	

3.3 基学习器的选择

由于基学习器的性能影响最终集成模型的准确性,因此,为找到 Stacking 集成的最优模型,本文从基学习器的预测性能出发,通过分析对比预选基学习器的预测能力,找到合适的基学习器。首先,使用经过特征降维的数据集对预选的基学

习器进行预测训练,并对各预选基学习器进行超参数优化,最后得到每个预选基学习器的最佳预测结果。图 6 展示了 4 个预选基学习器在测试集上的预测结果,横坐标为实际电耗量,纵坐标为各预选基学习器对电耗量的预测值,中间的虚线为完美拟合线,数据点越靠近虚线代表着模型的拟合优度越好。

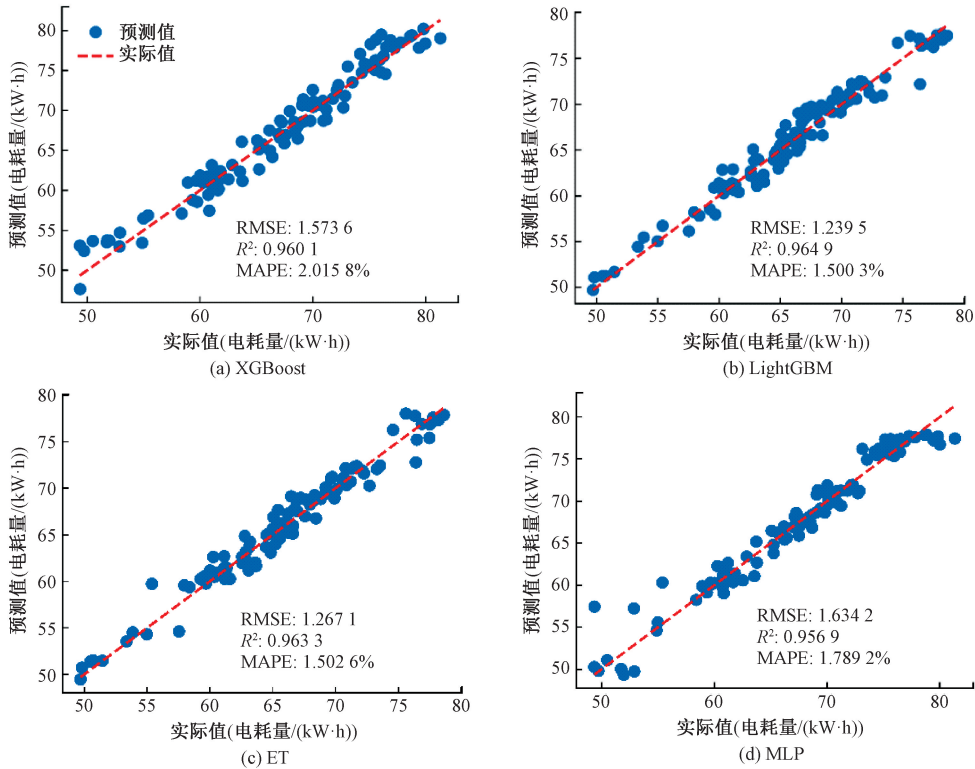


图 6 基学习器预测结果

从图 6 中可以看出,4 个基学习器模型都有较好的预测精度,但 LightGBM 更加贴近完美拟合线,具有最好的拟合优度。LightGBM 的线性回归系数  $R^2$  为 0.964 9,高于 XGBoost、ET 和 MLP 的线性回归系数(分别为 0.960 1、0.963 3 和 0.956 9),具有最好的预测性能。另外,结合误差来看,LightGBM 的平均绝对百分比误差 MAPE 和均方根误差 RMSE 在 4 个基学习器中也都是最小的(分别为 1.500 3%和 1.239 5),这也说明了 LightGBM 在基学习器

中具有最好的预测精度。

由于 XGBoost 和 LightGBM 模型都是基于梯度提升的学习器,考虑到基学习器的差异性,本文 Stacking 集成模型基学习器选择 XGBoost 和 LightGBM 中预测性能好的 LightGBM 和 ET 以及 MLP。

3.4 传统和改进的 Stacking 预测结果比较

根据上文所述,LightGBM、ET 和 MLP 被选为 Stacking 集成预测模型第 1 层的基学习器,LR 由于其结构

简单且泛化能力强被选为第 2 层的元学习器。图 7 展示了传统的 Stacking 集成模型和本文所用改进的 Stacking 集成模型在测试集上的回归表现。从图 7 中可知,传统的 Stacking 集成模型和改进的 Stacking 集成模型都能够对电

耗进行较好的预测,预测精度都高于单个基学习器,并且改进的 Stacking 集成模型能够做到更好的预测,其线性回归系数  $R^2$  为 0.975 7 高于传统 Stacking 集成模型的 0.969 3,两个误差指标也都低于传统的 Stacking 集成模型。




图 7 传统与改进的 Stacking 集成学习模型预测对比图

为了进一步显示本文所用方法的优越性,表 3 展示了本文所用方法和上述提到的特征加权和在预测中加入原始数据集的改进方法以及传统 Stacking 集成模型预测结果对比。从表 3 中可以看出,本文所用方法的各项指标都要优于其他 3 种方法,能够做到最好的预测效果。表明本文使用的改进 Stacking 集成模型能更好的利用从基学习器处获得的信息,充分发挥各基学习器的优势,最终得到最好的预测结果。

表 3 集成方法的预测结果

集成方法	$R^2$	MAPE/%	RMSE
本文所用方法	0.975 7	1.244 5	1.031 6
加权的 Stacking	0.971 1	1.434 7	1.124 1
加入原始数据的 Stacking	0.970 1	1.438 4	1.144 0
传统的 Stacking	0.969 3	1.460 8	1.158 2

3.5 不同预测方法比较

不同的集成方法对模型的性能有很大的影响。本节将本文使用的改进 Stacking 集成与回归问题中常用的集成方法 Voting 和 Blending 进行比较。Voting<sup>[18]</sup>是将多个基模型的预测结果取平均值,以得到最终预测结果。Voting 的训练时间短,易于实现,但在集成的基础模型差异较大时无法做到最优。Blending<sup>[19]</sup>与 Stacking 类似,也是将多个基本模型的预测结果进行组合,以得到最终的预测结果。Blending 能够考虑不同模型的贡献,并且能够很好的应对异质模型集成问题,但是它的训练时间较长,训练时需要更多的数据。在 Voting 和 Blending 两种方法中,同样选择 LightGBM、ET 和 MLP 模型作为基学习器,LR 作为第 2 层的元学习器。为了更好的突出本文所用方法的优势,把机器学习领域最新的能耗预测方法也加入比较,该方法是使用麻雀算法来优化 XGBoost 模型<sup>[20]</sup>,在电

能预测上取得了较好的效果。表 4 显示了不同方法的预测结果。可以清楚地看到,本文所用的改进 Stacking 集成模型的各项评价指标都要优于 Voting、Blending 和改进的 XGBoost 模型,拥有最好的预测性能,说明了本文所提方法在连轧电耗预测方面的可行性。

表 4 不同集成方法的预测结果

集成方法	$R^2$	MAPE/%	RMSE
本文所用方法	0.975 7	1.244 5	1.031 6
Voting	0.969 8	1.420 0	1.149 1
Blending	0.968 9	1.463 9	1.167 0
改进的 XGBoost	0.973 1	1.306 7	1.085 7

4 结 论

进行无缝钢管连轧电能预测有助于优化生产计划、降低成本、提高能源利用效率、调整设备运行状态以及节能减排,从而实现生产过程的高效运行和可持续发展。为了解决无缝钢管连轧电耗预测问题,本文采用一种改进的 Stacking 集成学习方法对无缝钢管连轧过程中的电耗进行预测。结果表明,本文提出的方法能够有效的对连轧过程中的电耗进行预测,并且从预测结果上来看,改进的 Stacking 集成学习模型具有最好的预测效果,可以为钢铁行业的调度优化提供理论支撑。

参考文献

[1] 肖成. 无缝钢管连轧过程建模与轧制规程优化[D]. 长沙:中南大学,2014.

[2] 刘志峰,黄海鸿,李磊,等. 绿色制造:碳达峰、碳中和目标下制造业的必然选择[J]. 金属加工(冷加工),2022,(1): 15-19.

[3] 赵艳茹,陈向东,丁星. 基于 Stacking 室内污染气体感

- 知与评价系统[J]. 电子测量技术, 2021, 44(6): 173-178.
- [4] 夏雨薇, 石美红, 贺飞跃, 等. 基于降维融合特征和集成学习的织物疵点分类[J]. 国外电子测量技术, 2019, 38(7): 86-91.
- [5] 徐凯, 杨锐. 基于 QPSO-DBN 集成学习的城轨列车定位研究[J]. 电子测量与仪器学报, 2022, 36(9): 21-28.
- [6] 李川, 伍依凡, 杨帅. 不平衡分布的数据驱动故障诊断的研究进展[J]. 仪器仪表学报, 2023, 44(8): 181-197.
- [7] 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.
- [8] CUI S, YIN Y, WANG D, et al. A stacking based ensemble learning method for earth-quake casualty prediction [J]. Applied Soft Computing, 2021, 101: 107038.
- [9] 曾铮, 刘光明. 集成学习方法在电费回收风险预测中的应用研究[J]. 机电工程技术, 2020, 49(12): 148-1.
- [10] 胡以婵, 梁铭, 谢灿荣, 等. 基于 Stacking 模型融合的高性能混凝土强度预测方法[J]. 硅酸盐通报, 2023, 42(11): 3914-3926.
- [11] 王斌, 李凯, 纪召红, 等. 基于组合算法的轧钢厂电耗预测[J]. 冶金自动化, 2022, 46(4): 72-77.
- [12] XIONG X, DAO M D, YU X X, et al. Research on prediction method of finish rolling power consumption of multispecific strip steel based on random forest optimization model[C]. 2020 39th Chinese Control Conference(CCC), IEEE, 2020: 5977-5984.
- [13] WOLPERT D H. Stacked generalization[J]. Neural networks, 1992, 5(2): 241-259.
- [14] CHEN T, GUESTRIN C. XGBoost: A scalable tree boosting system [J]. ACM, 2016, DOI: 10.1145/2939672.2939785.
- [15] MENG Q. LightGBM: A highly efficient gradient boosting decision tree [C]. Neural Information Processing Systems Curran Associates Inc. 2017. .
- [16] GEURTS P, ERNST D, WEHENKEL L. Extremely randomized trees[J]. Machine learning, 2006, 63: 3-42.
- [17] WIDIASARI I R, NUGROHO L E. Deep learning multilayer perceptron (MLP) for flood prediction model using wireless sensor network based hydrology time series data mining [C]. 2017 International Conference on Innovative and Creative Information Technology(ICITech), IEEE, 2017: 1-5.
- [18] PHYO P P, BYUN Y C, PARK N. Short-term energy forecasting using machine-learning-based ensemble voting regression[J]. Symmetry, 2022, 14(1): 160.
- [19] WU T, ZHANG W, JIAO X, et al. Evaluation of stacking and blending ensemble learning methods for estimating daily reference evapotranspiration [J]. Computers and Electronics in Agriculture, 2021, 184: 106039.
- [20] LI X, WANG Z, YANG C, et al. An advanced framework for net electricity consumption prediction: incorporating novel machine learning models and optimization algorithms: a case study in turkey[J]. Energy, 2024: 131259.

## 作者简介

**李一恒**(通信作者), 硕士研究生, 主要研究方向为智能供配电。

E-mail: 709197611@qq.com

**孙抗**, 博士, 教授, 主要研究方向为电力系统运行与控制、智能电器。

E-mail: sunkang@hpu.edu.cn

**赵来军**, 博士, 硕士生导师, 主要研究方向为电弧与电接触、高压电气设备状态监测。

E-mail: zhaolaijun@hpu.edu.cn