

doi:10.3969/j.issn.1007-7545.2024.02.001

基于灰狼优化支持向量机回归与 SHAP 值的 锡冶炼能耗预测

马朝君¹, 彭巨擘¹, 袁海滨¹, 郑光发², 么长慧¹, 章夏冰¹, 冯早²

(1. 云南锡业集团(控股)有限责任公司 研发中心, 昆明 650200;
2. 昆明理工大学 信息工程与自动化学院, 昆明 650500)

摘要: 锡冶炼过程综合能源消耗占整个锡生产过程 90%, 存在很大节能潜力。针对锡冶炼过程综合能耗机理模型难以建立、导致预测准确度不高的问题, 提出灰狼优化的支持向量机回归(GWO-SVR)模型用于锡冶炼过程综合能耗的预测, 并以某锡冶炼厂为例, 将所提模型与 SVR、RF(随机森林)、BP(反向传播神经网络)、LR(线性回归)模型进行比较。结果表明, GWO-SVR 模型可获得最理想的预测结果, 在预测精度上相比于其他机器学习算法有着巨大优势。此外, 使用 SHAP 值从全局解释和单样本解释两个方面解释所建立的 GWO-SVR 模型, 可视化特征对输出的贡献, 增加了 GWO-SVR 的可解释性, 并以此制定可靠的节能策略。

关键词: 锡冶炼预测模型; 模型可解释性; 支持向量机回归; 灰狼优化算法

中图分类号: TF814 **文献标志码:** A **文章编号:** 1007-7545(2024)02-0001-07

Energy Consumption Prediction of Tin Smelting Based on Grey Wolf Optimized Support Vector Machine Regression and SHAP Values

MA Chaojun¹, PENG Jubo¹, YUAN Haibin¹, ZHENG Guangfa²,
YAO Changhui¹, ZHANG Xiabing¹, FENG Zao²

(1. Research and Development Center, Yunnan Tin Industry Group (Holding) Co., Ltd., Kunming 650200, China;
2. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: The comprehensive energy consumption of tin smelting process accounts for 90% of the entire tin production process, which has great energy-saving potential. Address to the difficulty in establishing the comprehensive energy consumption mechanism model of tin smelting process and the low prediction accuracy, the Gray Wolf Optimization Support Vector Machine Regression (GWO-SVR) model was proposed to predict the comprehensive energy consumption of tin smelting process. Taking a tin smelter as an example, the proposed model was compared with the SVR, RF (Random Forest), BP (Back Propagation Neural Network) and LR (Linear Regression) models. The results show that the GWO-SVR model yields the most desirable prediction results, and has great advantages over other machine learning algorithms in terms of prediction accuracy. Furthermore, using SHAP values to explain the GWO-SVR model from both global interpretation and single-sample interpretation and visualize the contribution of features to the output increases the interpretability of GWO-SVR, and thus develops a reliable energy-saving strategy.

收稿日期: 2023-10-23

基金项目: 云南省科技厅基础研究合作项目(202101BC070001-023)

作者简介: 马朝君(1988-), 女, 高级工程师

Key words: tin smelting prediction models; model interpretability; support vector machine regression; grey wolf optimization algorithm

锡作为人类最早发现并使用的金属之一,具有安全、无毒、熔点低、延展性好、易与其他金属形成合金等优点,主要应用于电镀、合金、催化剂、阻燃剂等,在工业、国防、航空航天等领域扮演着重要角色,是我国战略性金属原材料^[1]。锡行业是我国重要的基础工业,在最近几年需求的持续拉动以及国家优惠政策的支持下,锡行业取得了快速发展。自1993年以来,我国的锡精矿产量长期保持在世界前列^[2]。2018年度我国的锡矿产量为15.8万t,占世界锡矿总产量的41.2%。其中,云南、内蒙古、广西、湖南及江西占总产量的99%^[2]。同时锡行业也一直是我国工业耗能的大户,冶炼环节的能耗就占据总生产能耗的90%^[3],能源消耗主要是以煤为主、电为辅的形式。因此,开展锡冶炼过程能耗预测和耗能因素追溯的研究,对锡冶炼流程的优化和完成节能减排目标具有重要意义。

锡的冶炼过程主要可以分为三部分,即焙烧、还原熔炼和精炼。焙烧主要是在回转窑中去除杂质的过程;还原熔炼经过几十年的生产实践和市场的优胜劣汰,目前还原熔炼技术为顶吹炉熔炼、电炉熔炼和反射炉熔炼并存的格局,在国内主要是以顶吹炉熔炼为主;精炼过程则主要以火法精炼为主。虽然目前针对锡冶炼过程能耗预测的研究较少,但钢铁和铝等金属流程工业的节能得到广泛研究,其相关成果也可为锡冶炼过程节能研究奠定一定基础。

李海英等^[4]使用灰色关联分析法确定了钢铁行业中影响烧结工序能耗的因素,并建立了基于遗传算法的BP神经网络(GA-BP)烧结能耗预测仿真模型,为烧结工艺的能源合理利用提出了新的思路并挖掘了节能潜力。ZHAO等^[5]建立了基于多元线性回归的热轧过程能耗预测模型,不仅很好地预测了热轧过程的能源消耗,同时通过人员的调度提高了工作效率。姜曙光等^[6]建立了基于线性回归模型分析了转炉过程的煤气与其影响因素之间的关系,有效预测高炉煤气生成量的同时提出了部分节能思路,但其建模过程未考虑炼铁过程的强耦合性、强非线性等特点。潘瑶等^[7]针对小样本环境下,提出了应用改进型偏最小二乘回归建立预测模型的方法对高炉能耗进行预测,该方法较传统的回归分析、主成分回归具有更大的优势,具有计算量小、预测精度较高等优点。高盛祥^[8]基于小波神经网络建立了过程

能耗预测模型,使用蚁群算法对模型进行优化,并利用所建模型对高炉、转炉、轧机进行了工序能耗预测,但是由于钢铁企业能耗预测涉及变量多、关系复杂、伴有耦合关系、受随机因素影响大等特点,使得预测难度大大提高,因此,陈光等^[9]结合了BP神经网络和广义回归网络算法对轧钢高炉炼铁工序建立能耗预测模型,取得了一定的效果。杨宏韬等^[10]则针对BP网络由于初始值阈值随机生成导致算法稳定性和准确性不佳的问题,利用遗传算法优化BP神经网络的初始权值和阈值,建立了GA-BP模型预测氧气消耗,结果表明,算法的准确性和稳定性都得到了提升。

在能耗预测中,支持向量机(SVM)、随机森林和神经网络等机器学习模型由于对于大量数据挖掘能力强、非线性拟合能力强、预测结果准确等优点,是近年来能耗预测领域的热门方法^[11-12]。但这些方法也有一定局限性,如何对预测后的结果进行解释以制定节能策略依然是急需解决的问题。基于此,本文提出基于灰狼优化支持向量机回归和SHAP值的锡冶炼能耗预测模型,在获取锡冶炼企业生产历史数据的基础上,比较了灰狼优化支持向量机回归预测模型与其他模型的预测效果,此外,从多个角度对灰狼优化支持向量机回归模型进行解释,并以此制定节能策略。

1 锡冶炼过程能耗影响因素分析

锡冶炼过程的总能耗主要由3部分组成,固体燃料占比40%~45%,主要是指无烟煤和焦炭,电力能源占比10%~15%,气体能源占比35%~40%。

由于锡冶炼过程自身复杂强耦合的特点,导致了从配料开始直到成品产出期间,每一步流程都有影响能耗的因素。如焙烧工序中焙砂产量、精炼工序锡锭产量、精炼工序碳渣量和铝渣量等因素对整个冶炼过程综合能耗有着直接的影响,而回转窑进风速度和进风压力、奥斯麦特炉炉内压力和炉渣温度等参数通过影响燃烧过程而间接影响综合能耗。经过分析整理,14个相关的影响因素可分成直接影响因素和间接影响因素,其中直接影响因素包括:焙烧工序焙砂产量(PSC)、奥炉熔炼工序粗锡产量(ALXC)、精炼工序焊锡产量(JLXC)、精炼工序锡锭产量(JLDC)、精炼工序碳渣产量(JLT)、精炼

工序铝渣产量(JLL)。间接影响因素包括:焙烧工序进风速度(PSF)、焙烧工序进风压力(Psy)、奥炉熔炼工序炉内压力(ALY)、奥炉熔炼工序进风速度(ALF)、奥炉熔炼工序进风压力(ALFY)、奥炉熔炼工序炉渣温度(ALZY)、精炼工序进风速度(JLF)、精炼工序进风压力(JLY)。

2 基于灰狼优化支持向量机回归和 SHAP 值的锡冶炼能耗预测

2.1 支持向量机回归模型

支持向量机回归(Support Vector Machine Regression, SVR)是一种强大的机器学习技术,用于解决回归问题。它是支持向量机(Support Vector Machine, SVM)在回归领域的扩展应用,被广泛用于预测和建模任务中。与传统的线性回归模型不同,SVR是通过在特征空间中构建一个最优超平面,将输入样本映射到高维特征空间,并建立一个线性回归模型。与普通线性回归不同的是,SVR关注的是预测值与真实值之间的边界间隔,而不是寻找最佳拟合线。通过最小化预测值与真实值之间的误差,并控制在一定范围内,SVR能够更准确地预测目标变量的值。

SVR的核心思想是利用支持向量,它们是训练样本中距离超平面最近的样本点。这些支持向量对于确定最优超平面起着重要作用。此外,SVR还使用了核函数,通过将输入样本映射到高维特征空间,可以更好地处理非线性关系。常用的核函数包括线性核、多项式核和径向基函数(RBF)核。选择适当的核函数和调整相关参数是使用SVR的关键。SVR在实际应用中具有广泛的用途。它在金融预测、股票市场分析、医学研究等领域都取得了显著的成果。相比传统的线性回归模型,SVR能够更好地处理非线性关系和高维数据,具有较强的鲁棒性和准确性。

2.2 灰狼优化支持向量机回归

SVR已经在众多领域得到应用^[13-15],尤其在针对小样本、非线性和局部最小等问题上应用广泛。然而,当SVR用于能耗数据的回归预测问题上时,其识别性能与SVR的参数选择具有密切关系,若使用人工对参数进行选取,则识别效果往往达不到最佳。针对这个问题,引入灰狼优化算法(Grey Wolf Optimizer, GWO)对SVR中的超参数进行优化。

GWO是MIRJALILI等^[16]在2014年提出的

一种智能优化算法。该算法是基于狼的层次分工系统和狩猎行为,对整个迭代优化过程进行建模。该方法中的狼按照社会等级从高到低排列为 α 、 β 、 δ 、 ω 。社会等级较低的狼的行为需要服从社会等级较高的狼的领导,展开狩猎行动。本文将灰狼优化算法应用在SVM中惩罚因子 c 和核参数 g 的寻优,从而可以提高综合能耗的预测准确性和效率。基于灰狼优化算法的支持向量机算法流程如图1所示。

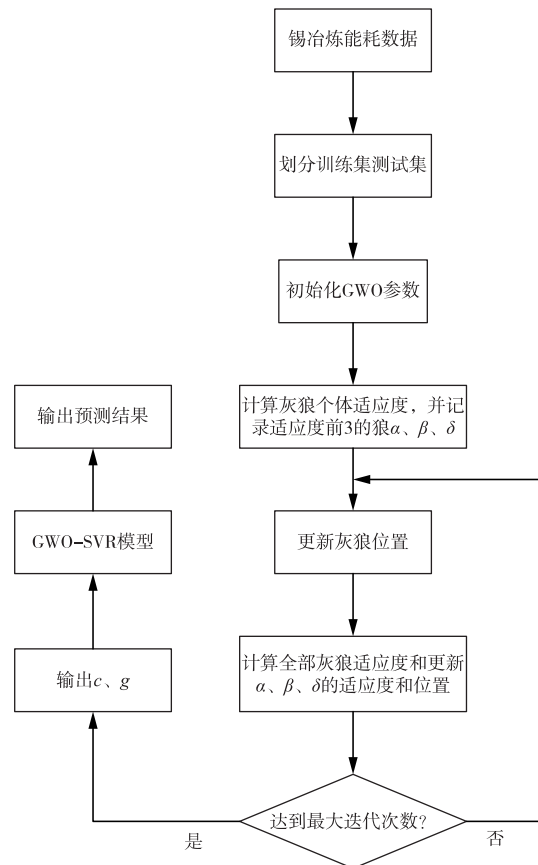


图1 GWO-SVR算法流程图

Fig. 1 Flowchart of GWO-SVR algorithm

具体步骤如下。

1)初始化灰狼种群数量 N 和最大迭代次数 N_m ,设置SVR中参数和 g 的取值范围,并选择5折交叉验证的能耗预测精度作为适应度函数,适应度函数表达式为:

$$F(x) = \frac{1}{N} \sum_{1 \leq i \leq N} (L_1(i) - L_0(i)) \quad (1)$$

式中, L_1 和 L_0 分别代表模型预测的能耗值和实际能耗值; N 代表样本的数量。

2)初始化狼群的位置和初始适应度值。

3)遍历并计算灰狼种群中每个灰狼个体的适应度,并记录前三个灰狼个体的位置分别为 P_α 、 P_β 、 P_δ 。

4)更新算法中的系数向量 \mathbf{A} 、 \mathbf{C} 和收敛因子 a ，计算公式为：

$$\begin{cases} \mathbf{A}=2ar_1-a \\ \mathbf{C}=2r_2 \end{cases} \quad (2)$$

式中， r_1 和 r_2 都是在 $[0,1]$ 内的随机数，分别用于生成 \mathbf{A} 、 \mathbf{C} 的新值。

5)计算并更新每只狼之间的距离和它们的位置。该行为的数学模型表示如下：

$$\begin{cases} D_\alpha = |\mathbf{C}_1 \mathbf{P}_\alpha - \mathbf{P}|, D_\beta = |\mathbf{C}_2 \mathbf{P}_\beta - \mathbf{P}|, D_\delta = |\mathbf{C}_3 \mathbf{P}_\delta - \mathbf{P}| \\ \mathbf{P}_1 = \mathbf{P}_\alpha - H_1 D_\alpha, \mathbf{P}_2 = \mathbf{P}_\beta - H_2 D_\beta, \mathbf{P}_3 = \mathbf{P}_\delta - H_3 D_\delta \\ \mathbf{P}(t+1) = (\mathbf{P}_1 + \mathbf{P}_2 + \mathbf{P}_3) / 3 \end{cases} \quad (3)$$

式中， \mathbf{P}_α 、 \mathbf{P}_β 、 \mathbf{P}_δ 表示当前种群 α 、 β 、 δ 的位置向量； H_1 、 H_2 、 H_3 是系数，通过概率分布随机生成，用于调节灰狼移动的幅度； \mathbf{C}_1 、 \mathbf{C}_2 、 \mathbf{C}_3 为随机向量； \mathbf{P} 为灰狼的位置向量； D_α 、 D_β 、 D_δ 分别为候选灰狼与最优三只狼之间的距离。

6)确定是否达到迭代次数，若达到则记录最优方案。否则返回步骤 3。

7)使用最佳参数 c 和 g 建立 SVR 预测模型。

2.3 模型评估

基于测试集的预测结果，采用拟合优度 (R^2) 和均方根误差 (RMSE) 作为回归模型性能的评价指标。一般而言，较小的均方根误差以及较大的拟合优度表明模型具有较高的预测精度。评价指标定义如下：

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

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (5)$$

式中， \hat{y}_i 为第 i 个样本预测值； y_i 为第 i 个样本真实值； \bar{y} 为样本均值； N 为样本数。

2.4 SHAP 值理论

本研究使用 SHAP 方法来解释随机森林模型，SHAP 是一种利用博弈论方法来解释任何机器学习模型输出结果的算法。SHAP 值解释模型具体过程为：首先计算每个特征向量对综合能源消耗的贡献度，然后统计所有被解释样本的特征的 SHAP 绝对值的均值，得到每个特征与综合能耗的贡献度。

其中第 i 个特征 SHAP 值的具体计算式为：

$$\varphi_i(f, x') = \sum_{S \subseteq F \setminus \{x'_i\}} \left[\frac{|S|!(M-|S|-1)!}{M!} \times [f(S \cup x'_i) - f(S)] \right] \quad (6)$$

式中， M 为特征的个数； F 为所有的特征的集合； f 为被解释的模型， $f(S) = E[f(x) | x_s]$ ； x_i 为一个被解释的特征向量实例； x'_i 为特征向量中的第 i 个特征； S 为 $F \setminus \{x'_i\}$ 的子集； φ_i 为第 i 个特征的 SHAP 值。

3 实例分析

3.1 数据集及数据预处理

典型的锡冶炼过程主要由焙烧、还原熔炼、精炼三个主要环节组成。本文使用国内某锡冶炼厂 2018 年 1 月至 2022 年 12 月的能耗数据对所提出的基于 SHAP 值的 GWO-SVR 模型进行验证。

虽然锡冶炼厂的能耗数据集对节能分析预测方面的研究非常有用，但由于某些数据是人工采集，该数据集也存在一些缺点，如存在大量缺失值和异常值，数据之间的不一致性。这些问题可能会影响分析的准确性和可靠性。因此，在进行数据分析之前，对原始数据进行预处理是非常重要的，预处理包括清洗数据、填补缺失值、标准化数据和筛选数据等操作，可以提高数据的质量和可靠性，从而更好地进行数据分析和推断，本研究对锡冶炼厂能耗数据集进行了以下缺失值处理、异常值检测和替换与归一化等预处理工作。此外，对于不同类型的能源消耗数据按照《综合能耗计算通则》统一折算为标准煤，以简化建模过程，其中部分核算标准(折标准煤系数)取值如下：天然气 1.33×10^{-3} kgce/m³、液化天然气 $1.757 2 \times 10^{-3}$ kgce/m³、新水 0.257 1 kgce/t、软化水 0.485 7 kgce/t、煤气 1.786×10^{-3} kgce/m³、汽油 1.471 4 kgce/kg。

将预处理后的数据输入 GWO-SVR 模型中训练后，结果如图 2 所示，图 2 中，GWO-SVR 模型预测准确度为 98.7%，灰狼优化算法的狼群数量和最大迭代次数分别为 20 和 50，SVR 中 c 和 g 的取值范围为 $[0.01, 20]$ 。经参数寻优后参数 c 的取值为 8， g 的取值为 0.25。

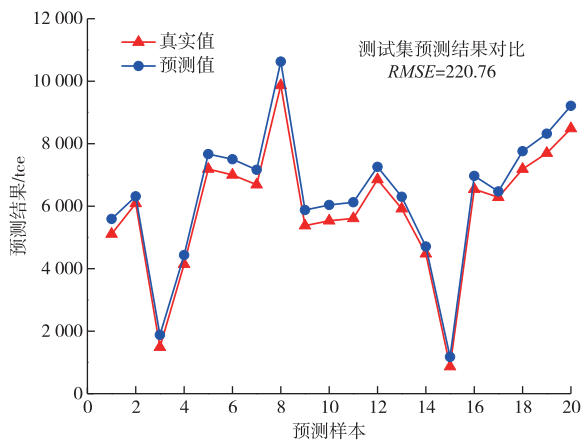


图 2 GWO-SVR 预测结果
Fig. 2 Prediction results of GWO-SVR

为了验证本文所提出的 GWO-SVR 模型的有效性,分别构建 SVR、RF(随机森林)、BP(反向传播神经网络)、LR(线性回归)模型,模型性能如表 1 所示。相比于 SVR 模型,GWO-SVR 模型的预测性能显著高于前者,并且也显著高于 RF、BP、LR 模型,该模型在小样本预测时有着显著优势。

表 1 模型性能比较

Table 1 Comparison of model performance			
模型	R^2	RMSE	MAE
GWO-SVR	0.987	220.76	166.51
SVR	0.953	414.30	287.67
RF	0.873	681.10	492.69
BP	0.275	1 633.45	1 251.06
LR	0.831	787.87	630.12

3.2 模型解释

对于 SVR 模型,使用 SHAP 值计算每个特征的贡献并进行评估,图 3 为特征全局 SHAP 解释图,横轴代表每个特征的 SHAP 值,其中正值和负值分别代表与输入特征与输出能源消耗量呈正相关与负相关,纵轴表示按特征重要性排序的特征名称,特征对应的每个点表示单个样本的 SHAP 贡献值,并且从红色到蓝色的颜色变化表示特征的取值从高到低,图 3 中 SHAP 全局解释结果表明,在 SVR 模型中,最显著的特征是 JLDC(精炼工序锡锭产量)、ALXC(奥炉熔炼工序粗锡产量)、JLT(精炼工序碳渣)等,均与综合能耗呈正相关,即较高的精炼工序锡锭产量和奥炉熔炼工序粗锡产量会导致较高的综合能耗,而 ALZY(奥炉熔炼工序炉渣温度)、ALFY

(奥炉熔炼工序进风压力)、JLF(精炼工序进风速度)等特征则与综合能耗呈负相关。在这些特征中,其 SHAP 值多是呈现长尾分布,也就是说某些特征的极端值对综合能耗产生很大的影响。特征全局 SHAP 解释图的开发有助于能耗管理部门了解现有整个流程中特征总体影响趋势,以制定锡冶炼行业总体节能方向。




图 3 特征全局 SHAP 解释图

Fig. 3 Feature global SHAP interpretation map

虽然特征的全局 SHAP 值解释图中包含丰富信息,但其中某些特征交互作用过于强烈,导致分析起来过于复杂,而 SHAP 值力图用于解决这一局限性,该图旨在说明在某个样本中这些不同特征是如何影响输出的,相比与特征 SHAP 值依赖图,SHAP 值力图更加容易被节能设计师理解。如图 4 所示, $E[f(x)]$ 表示 SHAP 值的基准值,也即是模型预测值的均值,其中蓝色代表有负向影响,红色代表有正向影响。从图 4 的最下面红色柱状条可知,5 个不重要的特征产生了 0.01 的正向影响,此外,ALZY=0.04 产生了 0.07 的正向影响,而 PSY=0.965 产生了 0.06 的负向影响,以此类推可得到样本最终预测值即是 0.509,并且在该样本中 PSY(焙烧工序进风压力)、JLDC(精炼工序锡锭产量)等是导致能耗降低的主要因素,而 ALZY(奥炉熔炼工序炉渣温度)、ALXC(精炼工序焊锡产量)是导致能耗增加的主要因素。该图的开发可为节能设计师对锡冶炼过程能耗的关键特征设计提供参考,以降低生产能耗。

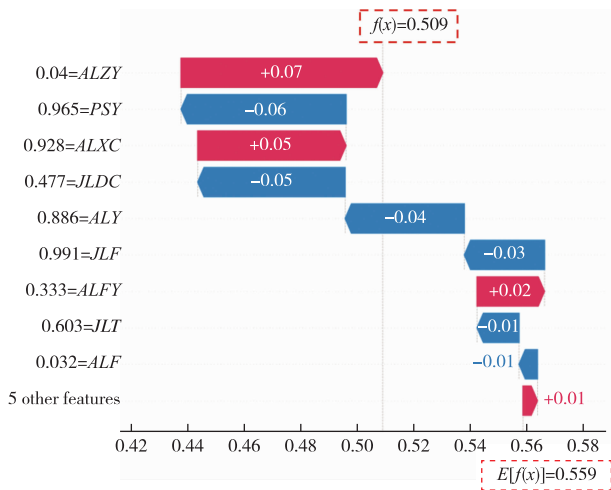


图4 单样本 SHAP 值力图

Fig. 4 Force diagram of single sample SHAP values

4 结论

1)通过对锡冶炼过程中综合能耗的影响因素进行机理分析,选取了 14 个主要因素作为影响能耗的关键特征,分别为:焙砂产量、粗锡产量、焊锡产量、锡锭产量、碳渣产量、铝渣产量、回转窑进风速度、回转窑进风压力、奥炉炉内压力、奥炉进风速度、奥炉进风压力、奥炉炉渣温度、精炼进风速度、精炼进风压力。

2)将关键特征作为预测模型的输入建立 GWO-SVR、SVR、RF、BP、LR 模型,预测综合能源的消耗。测试结果表明,本文所提的 GWO-SVR 模型具有很高的预测精度和对小样本数据的泛化能力,能够根据不同生产工艺参数准确预测出综合能耗值,解决了锡冶炼过程综合能耗机理模型建立困难进而导致预测综合能耗准确率不高的问题。

3)分别从全局解释、单样本解释两个层面解释建立的 SVR 模型,即从总体上看这五年中各特征对综合能耗的影响情况,以把握总体的节能方向,此外针对某月的单样本开发 SHAP 值力图,以可视化该样本中特征对综合能耗的影响情况。该方法的开发有助于增加现有机器学习算法的可解释,扩大其的应用领域。

参考文献

[1] 王莉,陈萍,姚磊.我国锡矿资源形势及对策分析[J].中国矿业,2019,28(11):44-47.
WANG L,CHEN P,YAO L. Analysis of the situation of tin ore resources and countermeasures in China[J]. China Mining Magazine,2019,28(11):44-47.

[2] 张建福.我国锡矿开发利用现状及可持续发展建议[J].

世界有色金属,2019(22):257-259.

ZHANG J F. Current situation of tin mine development and utilization in China and suggestions for sustainable development[J]. World Nonferrous Metals,2019(22):257-259.

[3] 何金梅.锡冶炼能耗与节能[J].冶金能源,1986(4):30-34.
HE J M. Energy consumption and energy saving in tin smelting[J]. Metallurgical Energy,1986(4):30-34.

[4] 李海英,李富鹏,李闯,等.基于遗传算法优化 BP 神经网络的烧结能耗预测[J].冶金能源,2021,40(1):56-60.
LI H Y,LI F P,LI C, et al. Prediction of sintering energy consumption based on genetic algorithm optimized BP neural network[J]. Metallurgical Energy,2021,40(1):56-60.

[5] ZHAO J,WANG W,LIU Y, et al. A two-stage online prediction method for a blast furnace gas system and its application[J]. IEEE Transactions on Control Systems Technology,2011,19(3):507-520.

[6] 姜曙光.济钢能源中心煤气平衡预测模型研究[D].济南:山东大学,2009.
JIANG S G. Research on gas balance prediction model of Jigang energy centre [D]. Ji'nan: Shandong University, 2009.

[7] 潘瑶,李莉.基于改进型最小二乘法的高炉炼铁工序能耗预测方法[J].计算机应用,2012,32(A2):51-53.
PAN Y,LI L. Improved partial least squares method for predicting energy consumption of blast furnace ironmaking process[J]. Computer Applications,2012,32(A2):51-53.

[8] 高盛祥,董人菘,邹俊杰,等.基于蚁群优化的小波神经网络钢铁生产能耗预测模型[J].昆明理工大学学报(自然科学版),2015,40(2):80-87.
GAO S X,DONG R X,ZOU J J, et al. An ant colony optimization based wavelet neural network energy consumption prediction model for steel production[J]. Journal of Kunming University of Science and Technology (Natural Science Edition),2015,40(2):80-87.

[9] 陈光,李玲云,丁毅,等.钢铁企业系统能耗影响因素分析[J].钢铁,2014,49(4):86-89.
CHEN G,LI L Y,DING Y, et al. Analysis of influencing factors of system energy consumption in iron and steel enterprises[J]. Iron and Steel,2014,49(4):86-89.

[10] 杨宏韬,张德江,李秀兰,等.遗传神经网络能耗预测模型在钢铁企业中的应用[J].长春工业大学学报(自然科学版),2007(增刊1):186-189.
YANG H T,ZHANG D J,LI X L, et al. Application of

- genetic neural network energy consumption prediction model in iron and steel enterprises [J]. Journal of Changchun University of Technology (Natural Science Edition), 2007(Suppl. 1):186-189.
- [11] 肖冉,魏子清,翟晓强. 基于支持向量机的办公建筑逐时能耗预测[J]. 上海交通大学学报, 2021, 55(3):331-336.
XIAO R, WEI Z Q, ZHAI X Q. Prediction of hour-by-hour energy consumption of office buildings based on support vector machine[J]. Journal of Shanghai Jiao Tong University, 2021, 55(3):331-336.
- [12] 付川琪,刘清倦,杨杰,等. 基于 CFD 仿真和 SVM 算法的建筑能耗预测系统[J]. 现代电子技术, 2022, 45(8):75-79.
FU C Q, LIU Q Q, YANG J, et al. Building energy consumption prediction system based on CFD simulation and SVM algorithm[J]. Modern Electronic Technology, 2022, 45(8):75-79.
- [13] 段青玲,魏芳芳,张磊,等. 基于 Web 数据的农业网络信息自动采集与分类系统[J]. 农业工程学报, 2016, 32(12):172-178.
DUAN Q L, WEI F F, ZHANG L, et al. Automatic collection and classification system of agricultural network information based on Web data[J]. Journal of Agricultural Engineering, 2016, 32(12):172-178.
- [14] 杨秋玉,阮江军,黄道春,等. 基于 VMD-Hilbert 边际谱能量熵和 SVM 的高压断路器机械故障诊断[J]. 电机与控制学报, 2020, 24(3):11-19.
YANG Q Y, RUAN J J, HUANG D C, et al. Mechanical fault diagnosis of high-voltage circuit breaker based on VMD-Hilbert marginal spectral energy entropy and SVM[J]. Journal of Electrical Machines and Control, 2020, 24(3):11-19.
- [15] 胡冬,刘作军,陈玲玲,等. 基于支持向量机-隐马尔科夫模型的外骨骼穿戴者步速意图识别[J]. 生物医学工程学杂志, 2022, 39(1):84-91.
HU D, LIU Z J, CHEN L L, et al. Support vector machine-hidden Markov model-based step speed intention recognition for exoskeleton wearers [J]. Journal of Biomedical Engineering, 2022, 39(1):84-91.
- [16] MIRJALILI S, SEYED-MOHAMMAD M, ANDREW L. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69(2):46-61.