

基于PSO-XGBoost的船舶特涂工序能耗预测

蒋清华¹, 任新民¹, 姜军¹, 欧阳彬², 彭保³

(1.友联船厂(蛇口)有限公司, 广东 深圳 518067;

2.湖南工商大学, 湖南 长沙 410205;

3.深圳信息职业技术学院, 广东 深圳 518172)

✉renxinmin@cmhk.com; jiangqinghua0115@163.com; jiangjun8880@163.com; 2248918560@qq.com; pengb@sziit.edu.cn



摘要: 涂装是修造船企业最大的能耗单元, 能耗预测是船舶智能能效优化中的一项重要任务。应用XGBoost模型对船舶特涂工序能耗进行分析。采用基于博弈论的SHAP(解释机器学习模型输出)方法解释变量因子对目标准确预测的影响。利用粒子群算法(PSO)优化XGBoost模型超参数, 从而构建PSO-XGBoost模型对船舶特涂工序能耗历史数据进行训练拟合, 并与其他能耗预测模型进行对比实验。结果表明, 基于PSO-XGBoost的船舶特涂工序能耗预测模型的预测结果误差MAPE仅为12.21%, 效果优于XGBoost、LR、KNN、RF模型。

关键词: 船舶特涂; 能耗预测; SHAP; PSO-XGBoost模型

中图分类号: TP31 **文献标识码:** A

Energy Consumption Prediction of Tank Coating Process of Ship based on PSO-XGBoost

JIANG Qinghua¹, REN Xinmin¹, JIANG Jun¹, OUYANG Bin², PENG Bao³

(1.You Lian Dockyards (Shekou) Co., Ltd., Shenzhen 518067, China;

2.Hunan University of Technology and Business, Changsha 410205, China;

3.Shenzhen Institute of Information Technology, Shenzhen 518172, China)

✉renxinmin@cmhk.com; jiangqinghua0115@163.com; jiangjun8880@163.com; 2248918560@qq.com; pengb@sziit.edu.cn

Abstract: Tank coating is the largest energy consumption unit in shipbuilding enterprises, and energy consumption prediction is an important task in intelligent energy efficiency optimization of ships. This paper proposes to use XGBoost model to analyze the energy consumption of ship tank coating process. SHAP (SHapley Additive exPlanations) method based on game theory is used to explain the influence of variable factors on accurate target prediction. Particle swarm optimization (PSO) is used to optimize the super-parameters of XGBoost model, and then PSO-XGBoost is constructed to train and fit the historical energy consumption data of ship tank coating process. The comparison experiment is conducted with other energy consumption prediction models. Experiment results show that the prediction error MAPE of energy consumption model of ship tank coating process based on PSO-XGBoost is only 12.21%, which is better than XGBoost, LR, KNN, RF models.

Keywords: tan coating of ships; energy consumption prediction; SHAP; PSO-XGBoost model

1 引言(Introduction)

近几年, 致力于降低船舶修造领域工业能耗的船舶能源物联网技术被广泛研究, 为城市“双碳”量化管理提供了大量有益的参考资料。为了降低船舶非生产性航行时间和维修费用, 提高船舶盈利空间, 必须对船舶进行科学的维护和管理, 控制和优化船舶维修和保养过程中设备的能耗。因此, 开展船舶能效优化技术研究具有重要意义^[1-2]。机器学习等技术的出现与发展促进了船舶能效优化研究相关算法的精进。针对以上情况, 本文以友联船厂的某货轮为例进行研

究, 从降低船舶特涂工序(一种船舶维修保养方式)过程中的电能消耗预测误差的角度出发, 结合实船采集数据, 基于XGBoost机器学习模型, 通过粒子群算法(Particle Swarm Optimization, PSO)优化模型超参数提升船舶特涂工序能耗预测模型的预测效果。

2 相关研究(Related research)

随着世界人口的增长, 人们对物品的需求逐渐增加, 世界各国之间的货物贸易增多, 货物运输需求增大, 世界上通过船舶运输的货物约占总运输货物的80%。运载化学品的船舶

由于装载货物的特殊性，所以需要定期使用特别的涂层进行维修和保养(即船舶特涂业务)，其中就涉及维修设备的电力消耗。在维修和保养过程中因设备老化、施工安排不当等造成的电能浪费问题极大地增加了企业的维修成本。近年，船舶修造成为高技术和高能耗特征并重的重点工业领域，其高能耗问题是船舶企业所在城市管理的重点和难点。随着科学技术的进步，船舶绿色化、智能化发展理念也随之提出，修造船企业如何优化修造船过程中的能效问题，已经成为该行业发展过程中亟待解决的重要一环^[2]。依托机器学习算法，通过将记录并解读船舶修造过程中的数据，用于对船舶能耗影响因素的归纳分析，进而建立能耗预测模型，可以对船舶能耗进行详细的描述和预测^[3]。

BESIKCI等^[4]和YAN等^[5]分别运用人工神经网络和BP神经网络方法对船舶数据进行能效预测。BESIKCI等在模型基础上建立了决策支持系统，用来减少油耗，而YAN等则是利用模型实现多要素影响下的船舶能效智能预测。

船舶航行时，环境因素会对其产生一定的影响，因此在进行能效预测时，有些学者也考虑了环境因素的影响。LEIFSSON等^[6]使用人工神经网络完成模型内部参数确定工作，并在考虑风浪对船舶油耗影响的同时，加入污低附着物这一被人们广泛忽略的影响因素，使得所建立的白箱模型具有更高的适用性。YANG等^[7]提出船舶在航行过程是否出现失速现象是影响船舶油耗的重要因素，因此YANG等使用航速优化模型求解(Kwon)方法测算船舶在实际运输过程中受到外界环境如风浪等影响时的航行速度，并建立油耗预测模型。孙双休等^[8]提出了最小二乘支持向量机模型，对船舶集中空调系统能耗进行分析预测。牛晓晓等^[9]采用人工鱼群算法优化支持向量机，对柴油机性能进行回归分析，取得了高精度的预测效果。WANG等^[10]主要采用小波神经网络预测船舶主机转速与油耗之间的关系。叶睿等^[11]基于人工神经网络，使用一艘丹麦籍客滚轮的运营数据，建立了油耗预测模型。GAO等^[12]运用高斯混合模型聚类，结合最大似然算法对数据进行分析，分析结果表明油耗量与主机转速之间的关系并不是一一对应的，其受海况的影响较大。王凯等^[13]结合船舶油耗及其影响因素进行实船采集数据，采用不同机器学习算法对船舶能耗进行预测分析，验证各算法的特点和优势。YAN等^[14]通过大量实验，摆脱了单一环境对船舶油耗的限制，使用K-mean聚类方法重点研究长江内河区域不同位置对船舶油耗产生的影响。

3 研究方法(Research method)

本研究中采用的方法概述如图1所示。本研究分三个阶段进行：第一阶段，研究人员采集友联船厂2021年9月至2022年4月共4艘货轮特涂作业各舱室工序能耗数据，并对数据集进行清洗。第二阶段：将处理好的能耗数据用于训练、验证和测试PSO-XGBoost模型。采用K-fold交叉验证技术及粒子群算法优化模型的超参数，并使用15%的测试集确保模型不会出现过拟合或欠拟合。第三阶段：通过与其他能耗预测模型进行效果对比实验，验证PSO-XGBoost与优越性，最终将PSO-XGBoost模型用于船舶特涂能耗预测，解释预测结果背后的潜在原因，并揭示新的见解。

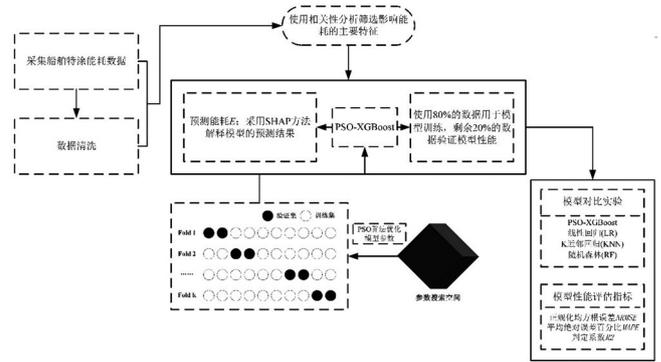


图1 研究方法流程图

Fig.1 Research method flow chart

3.1 船舶特涂能耗数据描述

研究人员以友联船厂的4艘进行特涂作业的货轮(包括萨法轮、托玛琳轮、坦桑石轮及丹娜轮)为研究对象，采集自2021年9月至2022年4月的船舶特涂作业各舱室工序能耗(E)数据如表1所示。

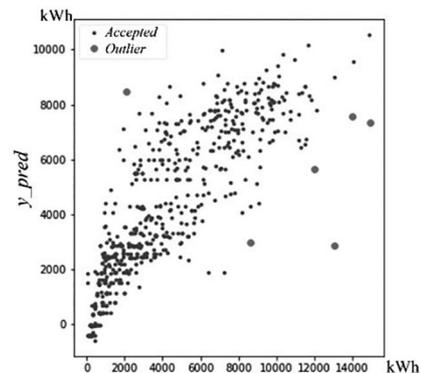
表1 PSO-XGBoost模型分析中使用的船舶特涂信息
Tab.1 Ship tank coating information used in PSO-XGBoost model analysis

影响因素	萨法轮	托玛琳轮	坦桑石轮	丹娜轮
舱室数量/个	22	18	8	22
施工面积/m ²	27,600	24,801	11,091	27,454
工序/道	10	10	10	10
施工队/个	7	10	9	9
设备总数/台	40	52	25	53
总能耗/kWh	1,200,162.81	753,397.85	255,251.77	828,235.33

采用船舶特涂业务相关变量作为能耗预测的影响因素，包括工序类型(Pr)、施工面积(M)、施工时长(T)、各类特涂设备数(包括冷风机 Nc 、除湿机 Nd 、吸砂机 Ns)、设备总数($Nsum$)、风管数(Nf)、温度要求(Ta)及湿度要求(H)。上述变量是根据船舶特涂业务流程及能耗预测相关领域的研究经验选择的，这表明这些因素对船舶特涂工序能耗预测最重要。收集并整理最终的船舶特涂工序能耗数据用作训练PSO-XGBoost模型的目标。

3.2 基于数据清洗与特征筛选的初步数据分析

为消除样本中异常数据的影响，需要删除掉样本中的异常值。基于 3σ 准则采用岭回归算法筛选出样本数据中的异常值，如图2(a)—图2(c)所示为数据集中的异常值分布情况，最终剔除掉编号为[39, 77, 94, 102, 162, 329]共六个异常样本。



(a)预测值中的异常值分布

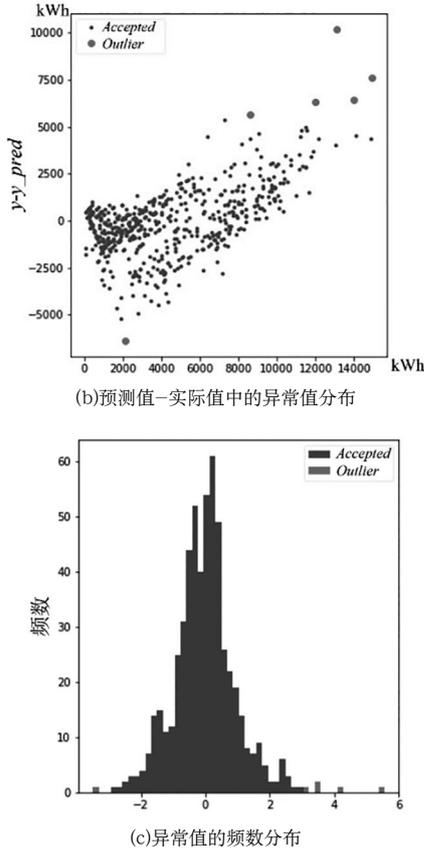


图2 数据集中的异常值分布情况

Fig.2 The distribution of outliers in a dataset

图3展示了目标变量船舶特涂能耗与其影响因素变量之间的相关性情况。风管数 N_f 、设备总数 N_{sum} 与能耗 E 之间的相关系数较大，分别为0.75、0.62。温度要求 T_a 和湿度要求 H 与能耗 E 之间相关系数均为0.56。此外， T_a 与 H 之间显著相关(相关系数达0.87)。由于 M 、 N_c 、 N_s 、 T 与 E 的低相关性，以及 T_a 与 H 之间高度相关，因此本文仅使用 Pr 、 N_f 、 N_d 、 N_{sum} 、 T_a 作为构建模型的能耗影响变量。

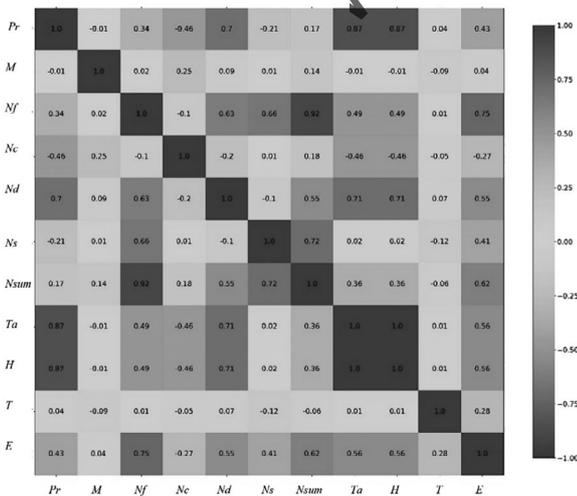


图3 各变量之间的热力相关图

Fig.3 Thermodynamic correlation diagram between variables

3.3 XGBoost模型

极限梯度提升树(XGBoost)^[15]是基于树的boosting算法的一种变体。从概念上来说，XGBoost是学习特征 X 和目标 Y 之间的函数关系 f 的一个迭代过程，在该过程中，各个树按顺序根据前一棵树的残差进行训练。树的预测数学形式可表示如下：

$$\hat{Y} = \phi(X) = \frac{1}{n} \sum_{k=1}^n f_k(X) \quad (1)$$

其中， \hat{Y} 为能耗 E 的预测值， $1 \leq k \leq n$ ， $\sum_{k=1}^n f_k(X)$ 是 n 棵树学习的函数总数。最小化规范化目标 $L(\phi)$ ，用模型学习函数集 f_k 表示如下：

$$L(\phi) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (2)$$

其中， $\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \|\omega\|^2$ ， l 是一个可微的凸损失函数，用于度量预测值 \hat{y}_i 和实际值 y_i 之间的差异。 Ω 是一个额外的正则化项，用于惩罚模型中更多树的生长，降低计算复杂度，从而减少模型过拟合。 γ 是每个叶节点的复杂度， T 为每棵树的叶结点数， λ 为惩罚参数， $\|\omega\|^2$ 是叶节点上分数的向量。值得注意的是，如果将正则化参数 Ω 设置为零，学习目标就回归到传统的梯度树提升。

3.4 粒子群优化算法(PSO)

由Eberhart and Kennedy(1995)提出的粒子群优化算法(PSO)是根据鸟类倾向于更好的搜索路线的掠食性轨迹而制定的^[16]。这是一种基于种群的随机搜索方法，具有参数少、过程简单的优点，已被应用于解决许多领域的优化问题。在 D 维超空间的优化问题中， m 个粒子中的每个粒子都可以根据计算结果调整其位置和速度。第 k 步的位置向量可以表示为 $x_i^k = (x_{i1}^k, x_{i2}^k, \dots, x_{id}^k)$ ，速度向量是 $v_i^k = (v_{i1}^k, v_{i2}^k, \dots, v_{id}^k)$ ，第 k 个粒子的最佳位置为 p_i ，全局最佳位置为 p_g 。粒子的运动可以通过公式(3)和公式(4)计算得到：

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 r_1 (p_{id} - x_{id}^k) + c_2 r_2 (p_{gd} - x_{id}^k) \quad (3)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1}, \quad i = 1, 2, \dots, m; d = 1, 2, \dots, D \quad (4)$$

其中， k 表示迭代次数， i 为粒子数， d 为搜索方向， ω 表示权重， $p_i = (p_{i1}, p_{i2}, \dots, p_{id})$ 表示粒子的局部最佳位置， $p_g = (p_{g1}, p_{g2}, \dots, p_{gd})$ 作为所有粒子的全局最佳位置， c_1 和 c_2 表示学习因素，并被视为常数， r_1 和 r_2 表示在 $[0, 1]$ 中均匀分布的随机量，采用公式(3)和公式(4)求出最佳解。

4 实验与结果(Experiments and results)

4.1 实验目的

本次实验首先使用XGBoost模型进行船舶特涂工序能耗预测任务训练，同时采用PSO算法对模型的超参数进行优化，其次将优化后的模型与线性回归(LR)、随机森林(RF)、K近邻回归(KNN)等能耗预测模型进行对比，探究PSO-XGBoost模型的预测效果是否优于其他模型。

4.2 实验环境

实验采用Intel酷睿i5-12500H 12核16线程CPU，显卡使用4 GB NVIDIA GTX 3050Ti，编程语言使用Python 3.9。为了避免模型训练过程中发生过拟合，本次实验采用早期停止法。

实验参数设置如下：迭代次数 $epoch$ 设为5，批量大小 $batch\ size$ 设为10，学习率 $learning\ rate$ 设为0.0001，早期停止批量大小设为500。

4.3 评估指标

采用回归任务中常用的评估指标：平均绝对误差百分比(MAPE)、判定系数(R^2)和正规化均方根误差(NRMSE)，各个指标的计算方法如公式(5)—公式(7)：

$$MASE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - y_{predi}|}{y_i} \times 100\% \quad (5)$$

$$R^2 = 1 - [(\sum_{i=1}^n (y_i - y_{predi})^2) / (\sum_{i=1}^n (y_i - \mu)^2)] \quad (6)$$

$$NRMSE = 100 \times \sqrt{\sum_{i=1}^n (y_i - y_{predi})^2 / n / r} \quad (7)$$

其中， y_i 、 y_{predi} 分别表示目标变量的实际值与预测值， n 表示预测样本总数， r 表示数据集的尺度， μ 为测试数据集中目标变量的平均值。

4.4 实验结果与分析

4.4.1 实验结果

将船舶特涂工序能耗数据按0.8 : 0.2划分为训练样本集合与测试样本集合，训练集用来训练模型，并在测试集上对模型预测效果进行验证(每种方法均进行5折交叉验证)。PSO-XGBoost模型及其他对比模型的预测效果见表2，XGBoost的NRMSE为8.56%，MAPE为13.36%， R^2 为86.37%。本文提出的模型PSO-XGBoost的NRMSE为7.69%，MAPE为12.21%， R^2 为91.90%，各项指标明显优于其他模型。

表2 PSO-XGBoost模型及其他对比模型的预测效果
Tab.2 Prediction error of PSO-XGBoost model and other comparison models

评价指标 模型名称	NRMSE/%	MAPE/%	R^2 /%
XGBoost	8.56	13.36	86.37
LR	10.49	48.11	85.37
KNN	10.84	37.02	83.06
RF	9.20	18.50	89.06
PSO-XGBoost	7.69	12.21	91.90

4.4.2 结果分析

本次实验结果表明，PSO-XGBoost与XGBoost、LR、KNN和RF等能耗预测机器学习方法相比，表现出了优异的性能，并且采用PSO算法进行参数寻优，有效提升了模型的预测精度。

此外，为了使PSO-XGBoost模型的预测结果具有可解释性，研究人员采用基于博弈论的SHAP方法^[17]结合随机森林模型计算特征变量的贡献度，综合考虑算法速度和算法准确率，设定决策树个数 $K=500$ ，特征总数 $M=5$ 。运行程序得到五个特征的贡献度，图4是根据SHAP值得到的特征分析图。横轴有正负值，表示对船舶特涂工序能耗的正负影响，图4中各点表示各个特征关于每个样本的SHAP值。SHAP值小于0的点表示对能耗值有负向的影响，SHAP值大于0的点表示对能耗值有正向的影响。排名第一的变量SHAP值大于0的点明显多于小于0的点，说明变量风管数(N_f)对船舶特涂工序能耗的影响是正向的，即设备连通向舱室的风管数越多，其能耗会越高。排名第二的变量是工序类型(Pr)，不同工序使用到的设备不同，达到施工要求的标准也不相同，其对能耗的影响有正有负，因此在整个数据集中变量风管数(N_f)的SHAP值正负分布均匀。排名最后的变量温度要求(Ta)的SHAP值接近于0，这是由于特涂作业中各个类型的工序对舱室内的温度要求基

本一致，因此温度要求(Ta)对模型预测能耗的贡献较小。

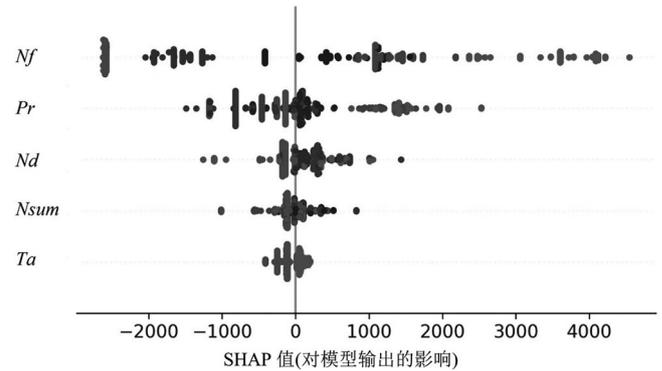


图4 特征分析图

Fig.4 Analysis diagram of features

5 结论(Conclusion)

船舶特涂工序能耗受多种因素影响，为了实现船舶能源的智能化管理，提出了一种能耗预测模型，该模型对特征重要性和多元变量的相关性进行建模，同时使用基于博弈论的SHAP方法分析能耗及其影响因素之间的关系，最终实现了船舶特涂工序能耗预测。主要结论如下。

(1)提出了一种基于PSO-XGBoost船舶特涂工序能耗预测模型。将该模型的预测结果与其他方法进行对比发现，PSO-XGBoost的最高性能为NRMSE=7.69%，预测误差MAPE值仅为12.21%，模型可解释性 R^2 为91.90%，证明了该模型的可预测性。同时研究表明，利用PSO算法调整模型超参数可有效提升预测性能。

(2)从挖掘船舶特涂工序能耗的影响因素角度，根据相关性分析选择 Pr 、 N_f 、 N_d 、 N_{sum} 、 Ta 作为预测模型的主要输入变量。同时，采用基于博弈论的SHAP方法计算变量的特征贡献度，分析了其与能耗的关系。结果表明，风管数 N_f 对模型预测的贡献度最大，温度要求 Ta 对模型预测的贡献度最小。

(3)船舶特涂工序能耗主要来源于设备消耗的电能，因此设备的损耗会影响其使用效率进而影响能耗，但目前的船舶能耗数据中没有涉及设备损耗的信息。此外，船舶特涂工序能耗数据是一种时间序列，季节性等时间特征会影响特涂设备的使用及施工达标要求等情况，从而导致能耗变化。今后可考虑加入设备损耗、时间特征进行建模，从而更好地预测船舶特涂工序能耗。

参考文献(References)

- [1] WANG K, YAN X P, YUAN Y P. Dynamic Optimization of ship Energy Efficiency Considering Time-Varying Environmental Factors[J]. Transportation-Research Part D: Transport and Environment, 2018, 62:685-698.
- [2] YAO Z Y, ZHENG K, SHI G Z, et al. Multi-objective Optimization Design for Independent Type C Cargo Tanks of Small and Medium-scaled LNG Carriers[J]. Ship & Ocean Engineering, 2021, 50(3):45-48.
- [3] CHAAL M. Ship Operational Performance Modelling for Voyage Optimization Through Fuel Consumption Minimization[D]. World Maritime University, 2018.
- [4] BESIKCI E B, ARSLAN O, TURAN O, et al. An Artificial Neural Network Based Decision Support System for Energy

- Efficient Ship Operations[J]. Computers and Operations Research, 2016, 66:393-401.
- [5] YAN X P, SUN X, YIN Q Z. Multi-parameter Sensitivity Analysis of Operational Energy Efficiency for Inland River Ships Based on Backpropagation Neural Network Method[J]. Marine Technology Society Journal, 2015, 49:148-153.
- [6] LEIFSSON L P, VARSDOTTIR H S, SIGURSSON S P. Grey-box modeling of an ocean vessel for operational optimization[J]. Simulation Modelling Practice and Theory, 2008, 16(8):923-932.
- [7] YANG L, CHEN G, ZHAO J, et al. Ship speed optimization considering ocean currents to enhance environmental sustainability in maritime shipping[J]. Sustainability, 2020, 12:36-49.
- [8] 孙双林,杨倩.基于最小二乘支持向量机的船舶集中空调系统能耗预测[J].舰船科学技术,2020,42(02):184-186.
- [9] 牛晓晓,刘文斌,聂志斌,等.基于AFSA优化的支持向量机柴油机性能预测模型[J].船舶工程,2019,41(07):44-48,79.
- [10] WANG K, YAN X, YUAN Y. Real-time optimization of ship energy efficiency based on the prediction technology of working condition[J]. Transportation Research Part D Transport & Environment, 2016, 46:81-93.
- [11] 叶睿,许劲松.基于人工神经网络的船舶油耗模型[J].船舶工程,2016,38(03):85-88.
- [12] GAO Z B, DU T L, ZHANG Y, et al. Application of Clustering Algorithm for Data Mining in Ship Energy Efficiency[J]. Journal of Wuhan University of Technology(Transportation Science & Engineering), 2019, 43(2):286-290.
- [13] 王凯,徐浩,黄连忠,等.基于机器学习的船舶能耗智能预测方法分析[J].船舶工程,2020,42(11):87-93.
- [14] YAN X P, WANG K, YUAN Y P, et al. Energy-efficient shipping: An application of big data analysis for optimizing engine speed of inland ships considering multiple environmental factors[J]. Ocean Engineering, 2018, 169: 457-468.
- [15] CHEN T, GUESTRIN C. Xgboost: A scalable tree boosting system[C]// ACM. Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining. San Francisco: Association for Computing Machinery, 2016:785-794.
- [16] XIA C X, WANG Z L. Drivers analysis and empirical mode decomposition based forecasting of energy consumption structure[J]. Journal of Cleaner Production, 2020, 27(12):54-58.
- [17] 丁珍妮,陈华友,朱家明.三角模糊数组合预测模型及其 Shapley值近似解法[J].统计与决策,2019,35(24):68-72.

作者简介:

- 蒋清华(1969-),男,本科,高级工程师.研究领域:物联网,双碳技术,大数据.
- 任新民(1966-),男,本科,高级工程师.研究领域:物联网,双碳技术,大数据.
- 姜军(1976-),男,本科,高级工程师.研究领域:物联网,双碳技术,大数据.
- 欧阳彬(1998-),男,硕士生.研究领域:大数据,自然语言处理.
- 彭保(1979-),男,博士,教授.研究领域:物联网,双碳技术,大数据.

(上接第58页)

参考文献(References)

- [1] 陆峰,刘华海,黄长缨,等.基于深度学习的目标检测技术综述[J].计算机系统应用,2021,30(3):1-13.
- [2] 刘建伟,刘俊文,罗雄麟.深度学习中注意力机制研究进展[J].工程科学学报,2021,43(11):1499-1511.
- [3] 王文冠,沈建冰,贾云得.视觉注意力检测综述[J].软件学报,2019,30(2):416-439.
- [4] 林森,刘美怡,陶志勇.采用注意力机制与改进YOLOv5的水下珍品检测[J].农业工程学报,2021,37(18):307-314.
- [5] 刘万军,高健康,曲海成,等.多尺度特征增强的遥感图像舰船目标检测[J].自然资源遥感,2021,33(3):97-106.
- [6] 任欢,王旭光.注意力机制综述[J].计算机应用,2021,41(S1):1-6.
- [7] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J/OL]. (2017-06-12) [2022-09-22]. <https://arxiv.org/abs/1706.03762>.
- [8] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design[J/OL]. (2021-03-04) [2022-09-22]. <https://arxiv.org/abs/2103.02907>.
- [9] WOO S, PARK J, LEE J, et al. CBAM: convolutional block attention module[J/OL]. (2018-07-18) [2022-09-22]. <https://arxiv.org/abs/1807.06521>.
- [10] LIN Z, FENG M, SANTOS C N, et al. A structured self-attentive sentence embedding[J/OL]. (2017-03-09) [2022-09-22]. <https://arxiv.org/abs/1703.03130>.
- [11] LIU Z, LIN Y, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[J/OL]. (2021-08-17) [2022-09-22]. <https://arxiv.org/abs/2103.14030>.

作者简介:

- 曾凯(1988-),男,硕士,工程师.研究领域:深度学习及相关软件类产品的开发.本文通信作者.
- 李响(1981-),男,硕士,高级工程师.研究领域:电力电子产品开发.
- 陈宏君(1981-),男,硕士,正高级工程师.研究领域:深度学习及相关软件类产品的开发.
- 文继锋(1978-),男,硕士,正高级工程师.研究领域:电力保护装置产品研发.