

基于机器学习的区域快递包装需求预测优化研究

刘战豫^{1,2}, 张宇飞¹

(1. 河南理工大学 工商管理学院能源经济研究中心, 河南 焦作 454000;

2. 太行发展研究院, 河南 焦作 454000)

摘要: **目的** 快递包装需求预测精准程度是智慧物流体系化建设的重要基础, 本文主要通过对不同机器学习方法、不同特征选择方法、不同参数寻优方法的比较, 选取快递包装需求预测更加精准的方法, 分析主要特征对快递包装需求的影响, 优化区域快递包装需求的研究。**方法** 首先通过不同的机器学习方法进行比较; 然后通过不同的特征选择方法进行比较, 通过不同参数寻优方法比较确定遗传算法对优化随机森林模型参数的效果; 最后为了更好地解释模型, 引入 SHAP 分析的方法, 对不同特征的重要性进行分析。**结果** 改进的随机森林预测模型效果最好, MAE 值、MAPE 值、RMSE 值、 R^2 分别为 2 783、5.1%、4 343、0.99。女性人口和第三产业值是影响快递包装需求最为关键的因素。**结论** 所提出的预测方法有更好的准确性及可解释性, 能为快递包装需求预测提供有力的决策支持。

关键词: 快递包装; 随机森林; 需求预测

中图分类号: TB114

文献标志码: A

文章编号: 1001-3563(2024)01-0246-08

DOI: 10.19554/j.cnki.1001-3563.2024.01.029

Optimization of Regional Express Packaging Demand Prediction Based on Machine Learning

LIU Zhanyu^{1,2}, ZHANG Yufei¹

(1. Energy Economics Research Center of the School of Business Administration, Henan Polytechnic University, Henan Jiaozuo 454000, China; 2. Taihang Development Research Institute, Henan Jiaozuo 454000, China)

ABSTRACT: The degree of accuracy of express packaging demand prediction is an important foundation for the construction of intelligent logistics systemization. The work aims to compare different machine learning methods, different feature selection methods, and different parameter optimization methods, to select a more accurate method of express packaging demand prediction, analyze the impact of the main features on demands of express packaging, and optimize the study of regional express packaging demand. Firstly, through comparison with different machine learning methods, different feature selection methods, and different parameter optimization methods, the effect of genetic algorithm on optimizing parameters of the random forest (RF) model was determined. Finally, in order to better explain the model, the method of SHAP analysis was introduced to analyze the importance of different features. The results showed that the improved random forest prediction model was the most effective with MAE value, MAPE value, RMSE value and R^2 of 2 783, 5.1%, 4 343 and 0.99 respectively, and that female population and tertiary industry value were the most critical factors affecting the demand for express packaging. The results show that the proposed prediction method has better accuracy and interpretability, and can provide powerful decision support for express packaging demand prediction.

KEY WORDS: express packaging; RF; demand prediction

收稿日期: 2023-08-06

基金项目: 2023 年度河南省政府决策研究招标课题 (2023JC031); 河南省高等学校重点科研项目软科学计划 (24A630014)

随着全球经济发展和时代科技的进步,物流发展的机遇与挑战并存,区域快递包装需求因受不确定性因素影响较大,常呈现出随机性、非平稳性等特点,不能准确预测快递包装需求态势,会制约物流企业快递业务高质量增长。针对此问题,根据快递包装需求的不同层次和不同时间纬度的变化,构建准确高效的需求预测模型,通过信息和算法实现供需高、效率准确的匹配研究,将有助于智慧物流体系建设,促进数字化包装管理,使物流企业决策更加科学合理,有利于物流业高质量发展^[1]。

在需求预测研究中,部分学者们采用传统的数理统计方法对数据进行预测分析,如灰色预测模型^[2]、ARIMA 模型^[3]、SARIMA 和多元回归相结合^[4]。然而随着大数据时代的到来,对数据的处理难度呈几何倍增,高维度、高容量的数据难以通过传统数理统计方法来处理,机器学习在处理此类问题时的优势日趋明显。

随着机器学习和数据挖掘的快速发展,机器学习逐渐应用于需求预测领域,在电力需求^[5]、产品需求^[6]、能源需求^[7]等领域已有成熟运用。冯易等^[8]指出相比于单一学习器,如随机森林等集成学习器更具优势。Feng 等^[9]利用 RBF 神经网络对我国能源需求进行预测。李国祥等^[10]利用 LSTM 模型对区域物流进行预测。孙俊军等^[11]利用 XGBoost 模型对纸包装行业的订单量进行预测。Zhang 等^[12]利用 BP 神经网络进行预测,均取得较好效果。同时,也有学者为更好提高预测精度,提升模型运算效率,利用组合模型来进行预测,如将灰色预测模型和 BP 神经网络相结合^[13],利用蚁群算法优化支持向量机^[14],利用主成分分析结合神经网络模型进行预测^[15]。

在包装领域,学者们较多关注货架期预测^[16-18]和包装工程、包装材料等相关领域预测^[19-20],鲜有利用机器学习对区域快递包装需求进行预测分析的研究。因此本文通过将不同预测模型引入区域快递包装需求中,通过对比选取最优模型,并对最优模型进一步优化以提升预测精度。

1 研究对象

本文以河南省快递包装需求为例,相关快递包装需求影响因素数据来源于对国家统计局和历年《河南统计年鉴》的整理。快递包装数据按照行业公布数据进行计算,并采用物流业相关数据进行修正^[21-22]。

1.1 研究对象描述

河南作为中原人口大省,2022 年常住人口已达到 9 872 万人,消费市场规模化增长显著。快递量在 2022 年达到 44.53 亿件,2023 年前 8 个月河南快递

业务量为 36.19 亿件,居全国第 6,同比增长了 24.5%。河南消费市场规模化增长带来快递需求量激增,快递需求激增的同时对快递包装产生了巨大影响。快递包装量的准确评估与预测对物流业高质量发展具有积极促进作用。鉴于此,亟须对河南省快递包装量预测进行优化提升,为快递包装产业科学规划奠定基础。

1.2 影响因素分析

区域性快递包装需求有着地区性特点,受当地社会和经济因素影响,同时快递包装作为快递产业链上重要一环,依赖于地区物流业发展水平。本文从地区经济现状出发,通过借鉴其他文献资料^[22,23,24],结合实际性、科学性以及可获取性原则,将影响快递包装需求量的因素归结为区域物流、经济发展、消费水平、人口规模四大类。

1) 区域物流。快递需求趋势和快递包装需求趋势一致。快递包装作为快递产业链上的重要一环,与快递产业的发展和快递量的需求密不可分。当快递行业低迷,快递使用量少时,快递包装的需求也会随之下降,反之,当快递需求提升,与之密切相关的快递包装需求也随之提升。本文通过货运量、邮政业务总量等来体现快递的发展和需求。

2) 经济发展。快递包装需求受当地整体经济趋势影响,当地经济呈现下行趋势时,地区产业负担重,订单少,对外快递运输量少,快递包装需求也会随之下降,反之,则会上升。本文通过地区生产总值和第一、二、三产业产值等来体现当地经济情况。

3) 消费水平。居民消费水平与快递需求呈正相关,消费者的消费能力强,快递购买量大,快递包装的需求就高。同时,考虑到互联网的应用促进了电商的发展,带来快递需求量的不断提升,故将互联网普及也作为影响因素纳入指标之中。

4) 人口规模。人口基数对快递包装需求有间接的影响。在其他条件一定的情况下,人口基数越大,快递使用频率越高,快递包装的需求量越大。为更好地分析不同性别对快递包装需求的影响,将人口分为男性人口和女性人口作为输入特征,方便进行模型可解释分析。

1.3 指标体系构建

根据四大类变量指标,按照物流业相关文献^[24-25]和物流业统计年鉴,提出相应的观测指标。第 1 类采用货运量、货物周转量、进出口总额、邮政业务总量、基础设施投资增速等指标;第 2 类采用地区生产总值、第一、二、三产业产值、商品零售价格指数、社会消费品零售总额等指标;第 3 类采用互联网用户数、居民消费价格指数、人均消费支出、人均可支配收入等指标;第 4 类采用男性人口和女性人口等指标。具体如表 1 所示。

表 1 影响因素选取
Tab.1 Selection of influencing factors

类型	变量名称
区域物流	货运量
	货物周转量
	进出口总额
	邮政业务总量
	基础设施投资增速
经济发展	地区生产总值
	第一产业产值
	第二产业产值
	第三产业产值
	商品零售价格指数
	社会消费品零售总额
消费水平	互联网用户数
	居民消费价格指数
	人均消费支出
	人均可支配收入
人口规模	男性人口
	女性人口

2 研究设计

2.1 预测方法优化

随机森林算法（RF）是由 Breiman（2001）所提出的一种集成学习算法，该算法利用自助聚集策略提取多个样本，为每个样本构建一个子树，结合所有子树的预测结果得到最终预测值，因此随机森林算法具备更显著的泛化性和准确性。随机森林算法的基本内核是多个弱学习器组成一个强学习器来提高全局准确性，因此该模型具备较强的鲁棒性。与此同时，随机森林算法模型中的参数会影响模型整体性能，如 `max_depth` 反映了树的复杂程度。虽然更高的深度有利于学习样本之间的逻辑关系，但过高的深度又容易造成模型拟合过高，因此选择正确的参数集合，对模型性能提升具有重要意义^[26-27]。本文通过遗传算法对模型参数采用迭代寻优的方式得到最佳参数，同时鉴于冗杂的样本特征会产生噪声，对模型学习能力产生负向影响，因此使用 Boruta 算法对特征进行选取。预测流程如下，具体流程如图 1 所示。

1) 通过分析初步选择模型特征。




图 1 预测模型流程
Fig.1 Flowchart of prediction model

2) 使用 Boruta 算法对模型特征进行选取，其通过迭代构造原始特征和阴影特征的重要性(Z-score)，并以 Z-score 为评价指标进行对比。只有原始特征重要性高于最好阴影特征重要性的原始特征才被判定为重要特征。

3) 将“快递包装需求预测”作为预测目标，划分训练集和测试集，并进行初步预测分析。

4) 初始化种群，将实际值和预测值之间的误差作为适应度函数不断进行迭代，利用遗传算法自适应调整随机森林模型参数。

5) 选取最优参数作为随机森林模型参数进行预测^[26]。首先将 X_k 和 Y_k 作为输入变量和输出变量组成样本，如式 (1) 所示；从训练样本 L 中有放回的、随机的抽取 Z 个独立样本子集 L_i ，如式 (2) 所示。

$$L = \{(X_k, Y_k)\}_{k=1}^N \tag{1}$$

$$L_i = \{(X_k, Y_k)\}_{k=1}^{N_B} \quad (i=1, 2, 3, \dots, Z) \tag{2}$$

式中： N 为训练样本数量； N_B 为样本子集数量。在任一样本子集中， N_B 相互独立且服从同一分布，在每个样本子集中分别建立相对应的决策树模型。最后将 Z 个子模型所得预测值进行简单平均，输出模型结果 $\hat{Y}_E$ ，如式 (3) 所示。

$$\hat{Y}_E = \frac{1}{P} \sum_{k=1}^P \hat{Y}_k \tag{3}$$

为确定模型预测能力，本文选择常见的平均绝对误差 (Mean Absolute Error, MAE)，平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE)，均方根误差 (Root Mean Square Error, RMSE) 和拟合优度 R^2 作为评价指标对模型预测效果进行评价。同时鉴于 BP 神经网络、随机森林等算法模型在相同参数下所得结果略有差异，为更好检验模型性能，本文选择重复实验的方法，验证所得结果^[10]。

2.2 优化过程分析

2.2.1 不同机器学习方法比较

为更好地显示模型性能，方便进一步分析，本文通过与其他预测模型进行比较，展现不同模型对数据处理和算法学习的能力。采用未进行处理特征进行输入，同时除 PSO-BP 模型外均采用默认参数进行预测，以选取最优模型进行进一步优化。具体结果如表 2 所示。

通过试验结果可以看出随机森林模型在各评价指标的表现上均优于其他模型。综合来看，尽管如 PSO-BP 模型经过算法调参，但相对随机森林表现来说，其性能还是有所欠缺。而其他模型如 GBDT，虽在 R^2 中与随机森林持平，但在其他指标中则落后于随机森林模型。本文为更好地挖掘随机森林模型潜力，对输入特征和模型参数进行进一步处理。

表 2 不同机器学习方法实验结果

Tab.2 Experimental results of different machine learning methods

方法	MAE 值	MAPE 值/%	RMSE 值	R^2
PSO-BP	15 639	14	28 314	0.94
Adaboost	22 706	18	42 818	0.86
GBDT	11 874	15	18 823	0.97
XGBoost	23 273	17	43 033	0.86
随机森林	10 941	12	18 517	0.97

2.2.2 不同特征选择方法比较

特征选择可以提高模型的泛化能力，减小冗余数据对模型性能的影响。对于特征选择，本文选择使用过滤式特征选择法、封装式特征选择法、嵌入式特征选择法^[28]。Boruta 算法在已有研究中已被证明在特征选择实践中具有良好效果^[29-30]，因此引入 Boruta 算法进行特征选择，并与其他方法进行比较。考虑到部分研究在模型构建中未进行特征选择，因此将不进行特征选择的方法也纳入比较范围。

通过表 3 可以看出，根据 MAE 值从大到小排名为 Boruta、嵌入式特征选择方法、无特征选择、封装式特征选择方法、过滤式特征选择方法；根据 MAPE 值从大到小排名则是 Boruta、嵌入式特征选择方法、封装式特征选择方法、无特征选择、过滤式特征选择方法；根据 RMSE 值从大到小排名则是 Boruta、嵌入式特征选择方法、无特征选择、封装式特征选择方法、过滤式特征选择方法；根据 R^2 从大到小排名则是 Boruta、嵌入式特征选择方法=无特征选择、封装式特征选择方法、过滤式特征选择方法。综合来说 Boruta 算法表现最优，相对于其他特征选择方法，其 MAE 值、MAPE 值、RMSE 值、 R^2 均为优异。传统的特征选择方法所选特征子集具有较差的稳定性，而 Boruta 算法能够在不降低预测准确率和精确率的情况下，有效移除冗余数据，减少数据的噪声和扰动。

表 3 不同特征选择方法实验结果

Tab.3 Experimental results of different feature selection methods

方法	MAE 值	MAPE 值/%	RMSE 值	R^2	特征维度
过滤式	22 412	13	45 193	0.85	9
封装式	12 997	10.7	24 163	0.95	9
嵌入式	10 289	10.3	17 916	0.97	13
Boruta	7 557	6.4	13 631	0.98	7
无特征选择	10 941	12	18 517	0.97	17

2.2.3 不同参数寻优方法比较

随机森林模型包含框架参数和决策树参数 2 种，

通过算法自动寻找到各参数之间的平衡,能够控制模型的复杂程度和拟合程度,防止过拟合现象的发生,有利于充分调动模型性能,挖掘模型潜能。将经过特征选取的指标作为输入变量,通过参数寻优方法对模型进行调参,促使模型达到相对最优性能。模型参数具体调参范围如表4所示,评价结果如表5所示。

表4 参数搜索范围
Tab.4 Specific parameter settings

参数名称	寻找范围
n_estimators	1~500
max_depth	1~50
min_samples_split	1~20
min_samples_leaf	1~10

据表5所示,根据MAE值从大到小排名为遗传算法、贝叶斯优化、网格搜索、网格随机搜索、默认参数;根据MAPE值从大到小排名为遗传算法、默认参数、贝叶斯优化、网格搜索、网格随机搜索;根据RMSE值从大到小排名为遗传算法、贝叶斯优化、网格搜索、网格随机搜索、默认参数;根据 R^2 从大到小排名为遗传算法=贝叶斯优化=网格搜索、网格随机搜索=默认参数。网格搜索和网格随机搜索方法相对贝叶斯优化和遗传算法来说,存在难以处理多优化组合的缺点。当待优化组合较多,数量级超过上万个组合时,对网络搜索方法和网格随机搜索方法的处理能力带来极大挑战。网格搜索方法是遍历所有组合,使用穷举法去寻找最优组合,网格随机搜索方法是采用随机搜索的方法寻找最优,虽然降低了大量数据所造成的臃肿现象,但是其随机因素导致寻优结果易出现较大波动。贝叶斯优化虽然经过对目标函数的不断学习,使得到的信息不断更新目标函数先验分布,进而优化全局结果预测参数,但是相对遗传算法来说,其初始化存在随机性,进而导致结果存在波动。遗传算法在经过多轮迭代之后具备鲁棒性,预测结果相对更加准确和稳定。综合来看,经过Boruta算法进行特征选取,使用遗传算法优化后的随机森林模型(Bor-GA-RF)进行预测,所达到的效果为最优,预测对比图如图2所示,评价指标MAE值、MAPE值、RMSE值、 R^2 分别为2 783、5.1%、4 343、0.99。

2.3 重要特征分析

SHAP特征重要性指各个特征在模型预测中,对提高模型整体预测性能的贡献程度的大小,使用各特征对目标变量影响程度的绝对值来表现^[31]。它能够更加直接地显示出不同特征指标对模型的影响程度,重要性程度越高,该特征变量对快递包装需求预测的影响就越大。通过SHAP分析可以更好地了解不同特征对快递包装需求预测的影响。

表5 不同参数选择方法实验结果
Tab.5 Experimental results of different parameter selection methods

方法	MAE 值	MAPE 值/%	RMSE 值	R^2
默认参数	7 557	6.4	13 631	0.98
网格搜索	6 493	8.9	9 897	0.99
网格随机搜索	7 432	9.1	11 875	0.98
贝叶斯优化	6 041	8.4	9 192	0.99
遗传算法	2 783	5.1	4 343	0.99




图2 预测值和实际值对比
Fig.2 Comparison of predicted and actual values

为更全面了解不同特征对快递包装需求预测的影响,对Boruta算法特征选择过的数据进行进一步分析,如图3所示。影响快递包装需求预测的重要程度按从大到小排序是女性人口(X11)、第三产业值(X4)、男性人口(X10)、邮政业务总量(X15)、第二产业值(X3)、人均可支配收入(X14)、互联网用户(X17)。女性人口对快递包装需求预测的影响程度高于其他特征。




图3 特征重要程度排序
Fig.3 Ranking of feature importance

从图3可以看出,女性人口和第三产业值是影响快递包装需求最为关键的因素。第三产业对快递包装需求的影响远高于其他产业经济,这是快递包装需求与快递行业发展密切相关的体现,邮政业务总量的影

响力也佐证了这一点。同时“她经济”的到来,女性消费者在网络购物之中相对于男性更容易成瘾,也更具冲动性^[32],这导致了女性消费者对快递的需求更强,对快递包装需求的影响远高于男性。

3 结语

本文提出了一种基于随机森林算法的优化预测模型(Bor-GA-RF),并利用SHAP分析法对相关特征进行分析,有效提高了快递包装需求预测的准确性和可解释性,同时丰富了区域性快递包装需求预测的研究。通过对不同机器学习预测方法的对比,确定随机森林在区域快递需求预测上性能优异。针对快递包装需求预测数据存在噪声和冗余数据的问题,通过对不同特征选择方法的对比,Bor-GA-RF使用Boruta算法来确定最佳特征子集,并使用遗传算法自适应调整随机森林模型的超参数,以达到模型精度提升的效果。为评价模型性能,本文使用平均绝对误差(MAE)、平均绝对百分比误差(MAPE)、均方根误差(RMSE)、拟合优度(R^2)作为模型预测精度评价指标,在机器学习方法、特征选择、参数寻优3个阶段进行比较分析,选取最优方法进行模型组合以提高预测精度。为进一步明确各特征对快递包装需求预测目标的影响,本文使用SHAP分析的方法,确定不同特征在预测时所做出的贡献程度,从而确定不同特征的重要程度。

通过总结可以得出以下结论:相对于其他预测方法,随机森林预测模型具有较好的预测精度;Boruta特征选择方法在该模型实践中优于其他特征选择方法;经过遗传算法调参所得到的最终预测组合模型(Bor-GA-RF)的性能优于其他调参方法所优化的预测模型的性能,Bor-GA-RF组合模型在区域快递包装需求预测中精度更高;通过模型可解释分析的探索,能够可视化地看出经过Boruta算法筛选后的特征在模型预测中对模型的影响,如女性人口对快递包装需求的影响高于男性人口,究其原因是女性消费者在网络购物之中相对于男性更容易成瘾。

本研究仍存在许多不足需要改进,在未来的研究中,可以考虑引入更详细的数据,以提升预测模型的学习能力,从而达到更好的预测效果。同时在未来还可以考虑使用更好的机器学习方法和更好的优化算法来解决问题。

参考文献:

- [1] 冉茂亮,陈彦如,杨新彪.基于EEMD-LMD-LSTM-LEC深度学习模型的短时物流需求预测[J].控制与决策,2022,37(10):2513-2523.
- [2] RAN M L, CHEN Y R, YANG X B. Short-Term Logistics Demand Forecasting Based on EEMD-LMD-LSTM-LEC Deep Learning Model[J]. Control and Decision, 2022, 37(10): 2513-2523.
- [3] HU Y C. Constructing Grey Prediction Models Using Grey Relational Analysis and Neural Networks for Magnesium Material Demand Forecasting[J]. Applied Soft Computing, 2020, 93: 106398.
- [4] DEY B, ROY B, DATTA S, et al. Forecasting Ethanol Demand in India to Meet Future Blending Targets: A Comparison of ARIMA and Various Regression Models[J]. Energy Reports, 2023, 9: 411-418.
- [5] FANG T T, LAHDELMA R. Evaluation of a Multiple Linear Regression Model and SARIMA Model in Forecasting Heat Demand for District Heating System[J]. Applied Energy, 2016, 179: 544-552.
- [6] JNR E O N, ZIGGAH Y Y. Electricity Demand Forecasting Based on Feature Extraction and Optimized Backpropagation Neural Network[J]. e-Prime-Advances in Electrical Engineering, Electronics and Energy, 2023, 6: 100293.
- [7] KIM S. Innovating Knowledge and Information for a Firm-Level Automobile Demand Forecast System: A Machine Learning Perspective[J]. Journal of Innovation & Knowledge, 2023, 8(2): 100355.
- [8] EMAMI J M, GHADERI S F. Energy Demand Forecasting in Seven Sectors by an Optimization Model Based on Machine Learning Algorithms[J]. Sustainable Cities and Society, 2023, 95: 104623.
- [9] 冯易,王杜娟,胡知能,等.基于改进LightGBM集成模型的胃癌存活性预测方法[J].中国管理科学,2023,31(10):234-244.
- [10] FENG Y, WANG D J, HU Z N, et al. Prediction Method for Gastric Cancer Survivability Based on an Improved LightGBM Ensemble Model[J]. Chinese Journal of Management Science, 2023, 31(10): 234-244.
- [11] FENG X, BAO W, HA B. Prediction on China Energy Demand Based on RBF Neural Network Model[J]. Advanced Materials Research, 2013, 805/806: 1421-1424.
- [12] 李国祥,马文斌,夏国恩.基于深度学习的物流需求预测模型研究[J].系统科学学报,2021,29(2):85-89.
- [13] LI G X, MA W B, XIA G E. Research on Logistics Demand Forecast Mode Based on Deep Learning[J]. Chi-

- nese Journal of Systems Science, 2021, 29(2): 85-89.
- [11] 孙俊军, 张伟, 张一等. 面向纸包装行业的订单预测模型构建与应用研究[J]. 包装工程, 2023, 44(S2): 132-139.
- SUN J J, ZHANG W, ZHANG Y, et al. Research on the Construction and Application of Order Prediction Model for the Paper Packaging Industry[J]. Packaging Engineering, 2023, 44(S2): 132-139.
- [12] ZHANG D H, LOU S. The Application Research of Neural Network and BP Algorithm in Stock Price Pattern Classification and Prediction[J]. Future Generation Computer Systems, 2021, 115(aug.): 872-879.
- [13] HUANG L J, XIE G J, ZHAO W D, et al. Regional Logistics Demand Forecasting: A BP Neural Network Approach[J]. Complex & Intelligent Systems, 2023, 9(3): 2297-2312.
- [14] YU N, XU W, YU K L. Research on Regional Logistics Demand Forecast Based on Improved Support Vector Machine: A Case Study of Qingdao City under the New Free Trade Zone Strategy[J]. IEEE Access, 2020, 99: 1.
- [15] CHEN Y, WU Q M, SHAO L J. Urban Cold-Chain Logistics Demand Predicting Model Based on Improved Neural Network Model[J]. International Journal of Metrology and Quality Engineering, 2020, 11: 5.
- [16] AN Y Q, LIU N, XIONG J, et al. Quality Changes and Shelf-Life Prediction of Pre-Processed Snakehead Fish Fillet Seasoned by Yeast Extract: Affected by Packaging Method and Storage Temperature[J]. Food Chemistry Advances, 2023, 3(3): 100418.
- [17] MOHI-ALDEN K, OMID M, RAJABIPOUR A, et al. Quality and Shelf-Life Prediction of Cauliflower under Modified Atmosphere Packaging by Using Artificial Neural Networks and Image Processing[J]. Computers and Electronics in Agriculture, 2019, 163(7): 104861.
- [18] 蔡佳昂, 卢立新, 卢莉璟, 等. 全脂奶粉包装内外水分传质及其防潮包装货架期预测[J]. 包装工程, 2022, 43(17): 42-48.
- CAI J A, LU L X, LU L J, et al. Moisture Mass Transfer Inside and Outside Whole Milk Powder Packaging and Shelf Life Prediction of Moisture-Proof Packaging[J]. Packaging Engineering, 2022, 43(17): 42-48.
- [19] KROELL N, CHEN X Z, MAGHMOUMI A, et al. Sensor-Based Particle Mass Prediction of Lightweight Packaging Waste Using Machine Learning Algorithms[J]. Waste Management, 2021, 136: 253-265.
- [20] 陈雅, 姜凯译, 李耀翔, 等. 基于近红外的 PE 包装蓝莓新鲜度无损检测[J]. 包装工程, 2022, 43(7): 1-10.
- CHEN Y, JIANG K Y, LI Y X, et al. Nondestructive Detection of Freshness of PE Packaged Blueberries Based on NIR[J]. Packaging Engineering, 2022, 43(7): 1-10.
- [21] 夏文汇, 张兰蕤, 夏乾尹, 等. 基于“一带一路”的重庆物流灰色模型预测及包装管理研究[J]. 重庆理工大学学报(社会科学版), 2020, 34(5): 58-66.
- [22] 张道顺. S企业物料需求预测与配送路径优化研究[D]. 济南: 山东财经大学, 2022.
- ZHANG D S. Research on Material Demand Forecast and Distribution Path Optimization of S Enterprise[D]. Jinan: Shandong University of Finance and Economics, 2022.
- [23] 冀琴, 朱敏, 刘睿. 重庆市中心城区快递自提点空间格局及影响因素研究——基于 POI 数据[J]. 重庆师范大学学报(自然科学版), 2021, 38(3): 121-128.
- JI Q, ZHU M, LIU R. The Spatial Pattern and Relation of the Pickup Points Based on POI in Chongqing[J]. Journal of Chongqing Normal University (Natural Science), 2021, 38(3): 121-128.
- [24] 徐晓燕, 杨慧敏, 吕修凯, 等. 基于山东省不同模型的物流需求预测比较研究[J]. 包装工程, 2022, 43(23): 207-215.
- XU X Y, YANG H M, LYU X K, et al. Comparative Research on Forecast of Logistics Demand in Shandong Province Based on Different Models[J]. Packaging Engineering, 2022, 43(23): 207-215.
- [25] 李林汉, 岳一飞, 田卫民. 基于 PCA 与 Markov 残差灰色模型的京津冀物流能力评价和预测[J]. 北京交通大学学报(社会科学版), 2019, 18(2): 129-142.
- LI L H, YUE Y F, TIAN W M. Principal Component Analysis and Markov Residual Grey Based Evaluation and Prediction of Logistics Capabilities of Beijing, Tianjin and Hebei[J]. Journal of Beijing Jiaotong University (Social Sciences Edition), 2019, 18(2): 129-142.
- [26] 朱昶胜, 李岁寒. 基于改进果蝇优化算法的随机森林回归模型及其在风速预测中的应用[J]. 兰州理工大学学报, 2021, 47(4): 83-90.
- ZHU C S, LI S H. Random Forest Regression Model Based on Improved Fruit Fly Optimization Algorithm

- and Its Application in Wind Speed Forecasting[J]. Journal of Lanzhou University of Technology, 2021, 47(4): 83-90.
- [27] PROBST P, WRIGHT M, BOULESTEIX A L. Hyperparameters and Tuning Strategies for Random Forest[J]. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 2018, 9(3): 1-18.
- [28] 郭海湘, 黄媛玥, 顾明赞, 等. 基于自适应多分类器系统的甲状腺疾病诊断方法研究[J]. 系统工程理论与实践, 2018, 38(8): 2123-2134.
- GUO H X, HUANG Y Y, GU M Y, et al. Thyroid Disease Diagnosis Method Research Based on Adaptive Multiple Classifier System[J]. Systems Engineering-Theory & Practice, 2018, 38(8): 2123-2134.
- [29] HABIBI A, DELAVAR M, SADEGHIAN M, et al. A Hybrid of Ensemble Machine Learning Models with RFE and Boruta Wrapper-Based Algorithms for Flash Flood Susceptibility Assessment[J]. International Journal of Applied Earth Observation and Geoinformation, 2023, 122(122): 103401.
- [30] GHOSH I, DATTA CHAUDHURI T, ALFARO-CORTS E, et al. A Hybrid Approach to Forecasting Futures Prices with Simultaneous Consideration of Optimality in Ensemble Feature Selection and Advanced Artificial Intelligence[J]. Technological Forecasting and Social Change, 2022, 181: 121757.
- [31] PARSA A B, MOVAHEDI A, TAGHIPOUR H, et al. Toward Safer Highways, Application of XGBoost and SHAP for Real-Time Accident Detection and Feature Analysis[J]. Accident; Analysis and Prevention, 2020, 136: 105405.
- [32] 金祖旭. 电子商务市场中“她经济”模式精准营销策略[J]. 商业经济研究, 2017(23): 59-61.
- JIN Z X. Precision Marketing Strategy of "other Economy" Model in E-Commerce Market[J]. Journal of Commercial Economics, 2017(23): 59-61.