

# 一种用于季节性产品需求预测的 多元化堆叠回归模型

刘斌,丁昊

(上海理工大学 管理学院,上海 200093)

**[摘要]**产品需求预测是智慧供应链的核心环节。针对具有季节性的快消品的需求特点,设计了一种结合Blending线性与多机器学习模型融合的多元化堆叠回归模型RXOEL-X。首先,介绍了RXOEL-X模型的构建及运行步骤,然后基于一组公开数据将此模型与五种传统单一化模型进行比较,证明其在预测精度方面比其他模型更优。同时基于某饮料公司的实际销售数据,对模型性能进行进一步测试,证明RXOEL-X模型在预测精度、数据拟合能力、时间效率等方面整体表现最佳。RXOEL-X模型为季节性产品乃至更广泛的企业供应链管理中的需求预测问题提供了一种前沿的解决策略,有利于帮助企业在节省成本、减少库存积压的同时,提高对市场变化的响应速度和供应链的整体灵活性。

**[关键词]**季节性产品;需求预测;多元化堆叠回归模型;机器学习;智慧供应链

**[中图分类号]**F713.52

**[文献标识码]**A

**[文章编号]**1005-152X(2024)06-0015-16

## 0 引言

随着全球经济和产业结构的持续变化,企业在复杂多变的外部环境中面临各种运营挑战,例如产品供需失衡、库存积压、物流问题等。有效的供应链管理,特别是精准的需求预测,成为企业应对这些挑战、避免资源浪费、降低成本和提高运营效率的关键。需求预测需要综合考虑历史销售、市场趋势、季节性、促销活动等因素,以实现资源的合理规划和供应链的高效稳定运作。因此,企业亟需开发精准灵活、能适应市场变化的预测模型。

本研究提出了一种多元化堆叠回归模型RXOEL-X,其结合了Blending线性回归、随机森林(RF)、极限梯度提升(XGBoost)、普通最小二乘法(OLS)、ElasticNet和长短期记忆网络(LSTM)等多种算法的优势,并以XGBoost作为次级模型进行优化。该模型结合了机器学习的强大数据分析能力以及传统统计方法的稳健性和深度学习的非线性建模能力,通过模型融合技术显著提高了预测性能。特别的是,它能够有效捕捉时间序列数据中的季节性和长期依赖关系,适用于具有明显季节性和趋势性特征的供应链需求预测。通过实际企业运行数据验证,该模型在预测准确性上超过了其他常规时间序列预测模型。此外,本研究还改进了ElasticNet模型,采用高级参数优化技术,提升了模型的精确度和鲁棒性。在与相关模型的对比实验中,RXOEL-X模型展示出了广泛的适用性和卓越性能。

本文不仅为相关理论研究提供了新的视角,也为解决企业的实际问题提供了有效方案。

**[收稿日期]**2024-04-30

**[基金项目]**国家自然科学基金资助项目(71971134)

**[作者简介]**刘斌(1971-),男,上海理工大学管理学院教授,博士生导师,研究方向:供应链管理、决策分析等;  
丁昊(2000-),女,上海理工大学管理学院硕士研究生,研究方向:智能预测与决策。

## 1 文献综述

随着时代的发展,产品的需求对于企业乃至社会的发展越来越至关重要。Belvedere,等<sup>[1]</sup>强调了需求预测在快时尚等行业中的重要性,他们认为,短期销售波动对于快时尚行业的影响非常大,因此需求预测不仅需要依赖统计方法提供的基础数据,还需考虑预测过程中的人为因素,如预测者的情绪、偏好以及对产品的了解程度,这些因素都可能对预测结果产生影响。因此,有效的需求预测必须平衡这些因素,以确保预测结果尽可能地接近实际销售情况,帮助企业在多变的市场环境中做出合理的库存和生产决策。Liang,等<sup>[2]</sup>指出,准确可靠的需求预测对于各大零售商来说至关重要,这是由于需求预测的结果将直接影响到零售商的产品分类规划、门店选址等一系列运营决策。Kuck,等<sup>[3]</sup>指出,与产品质量相比,更加重要的是对于产品需求的预测,其直接影响到企业的库存管理能力与运营成本。Trapero,等<sup>[4]</sup>指出需求预测是供应链管理中的一项关键任务,库存控制政策直接受到概率需求预测精度的影响。Punia,等<sup>[5]</sup>指出高质量的需求预测对于企业发展的重要性,因此在预测产品需求时需要确保数据的准确性与质量。Lee<sup>[6]</sup>提出科学的需求预测是一个重要而具有极大挑战性的难题,这是因为需求预测的结果将直接影响到企业未来的发展。

越来越多的企业开始重视产品需求预测,需求预测的方法也逐渐增加。He,等<sup>[7]</sup>提出了一种新的基于集成学习XGBoost的销售预测模型,旨在提高小样本数据环境下电子商务产品预测的准确性。该研究结合了多维度指标,如在线搜索、评论、页面访问量等,并通过熵法融合相似指标。其模型引入了Logistic函数和正则化项,并利用贪婪算法进行优化。Lei,等<sup>[8]</sup>针对现代企业面临的多产品需求预测问题,提出了一种新的预测方法。该方法考虑到除历史需求趋势外,关联产品的需求趋势对于预测的重要性,通过将关联产品需求作为附加预测因子融入到自回归(AR)模型中,以提高预测精度。面对高维时间序列数据,研究引入了变量简化方案以防止过度拟合。Steenbergen,等<sup>[9]</sup>结合了K-means聚类、RF和分位数回归森林的需求预测方法,提出了一种名为Demand Forest的需求预测方法,通过对需求模式的聚类分析和引入期内总需求的分位数预测来优化库存,同时这种机器学习方法能够利用历史销售数据和产品特征,对新上市产品进行预测,辅助新产品的库存管理。Selim,等<sup>[10]</sup>在需求预测的过程中提出了一个鲁棒的短期多变量多步预测框架,该框架使用时间卷积网络(TCNs),能够抵抗缺失或错误数据的影响。Xu,等<sup>[11]</sup>提出了一个六步骤的多级组合预测模型,旨在预测具有分层服务结构的产品服务需求。该模型融合了方法组合预测和信息组合预测的优势,通过空气压缩机服务预测案例,验证了模型的性能超过了单一预测模型及其直接组合。该方法可灵活定制于其他产品服务需求预测场景,尤其适用于处理分层时间序列数据。Guo,等<sup>[12]</sup>提出了一种用于预测季节性制造业需求的新型混合预测方法。该方法结合了Prophet模型和支持向量回归(SVR)模型的优势,其中Prophet负责捕捉季节性波动并确定SVR模型的输入变量,而SVR则用于识别非线性模式。这种混合PROPHET-SVR方法能够自定义节假日影响、季节性变化,并有效考虑预测残差,从而提高了预测的准确性。研究结果显示,该混合方法在预测性能上超越了其他传统预测技术。Joseph,等<sup>[13]</sup>认为在不断变化的市场环境中,准确的产品需求预测对于企业决策者制定战略至关重要,他们开发了一个结合了Lazy Adam优化器的CNN BiLSTM框架,用于提高商店商品需求预测的准确性。

机器学习在需求预测方面展现出多样化的方法和综合性分析特点,结合了销售人员意见、专家意见、市场实验等传统方法和现代的时间序列与统计分析技术,并利用多维度指标进行全面数据分析。深

度学习算法,特别是 LSTM,被应用于捕捉时间序列数据中的复杂模式,而集成学习方法如 XGBoost 和 RF 则用于提升预测的准确性和泛化能力。为此,本文提出了一种多元化堆叠回归模型 RXOEL-X,它结合了 Blending 线性回归、RF、XGBoost、OLS、ElasticNet 和 LSTM 的优点,并以 XGBoost 作为次模型,通过整合不同预测技术的优势,克服了现有智能预测方法的限制,使预测结果更准确、可靠和可解释,同时该模型能够处理高维数据和复杂非线性关系,防止过拟合,适应性和鲁棒性方面优势明显,展现了智能预测技术在提高预测准确性和应对复杂预测挑战方面的潜力和进步。

表 1 归纳总结了相关文献中的预测模型的技术细节与性能,并与本文的 RXOEL-X 模型进行了对比。

表 1 预测模型的技术细节与性能对比

模型名称	技术细节与性能
XGBoost 销售预测模型	提高小样本数据环境下电子商务产品预测的准确性,结合了多维度指标,采用熵权法融合相似指标,加入 Logistic 函数和正则化项,并使用贪婪算法进行优化
自回归(AR)模型	考虑关联产品需求趋势对预测的重要性,通过将关联产品需求作为附加预测因子融入模型,提高预测精度,并引入变量简化方案以防止过度拟合
Demand Forest 需求预测方法	结合了 K-means 聚类、RF 和分位数回归森林,优化库存管理并预测新上市产品,提升预测精度
时间卷积网络(TCNs)	鲁棒的短期多变量多步预测框架,能够抵抗缺失或错误数据的影响
多级组合预测模型	融合方法组合预测和信息组合预测的优势,适用于处理分层服务结构的产品服务需求,验证表明其性能超过单一预测模型及其组合
基于经验模态分解(EMD)的协同训练模型	采用双层优化策略,结合差分进化算法和交互式模糊规划,优化神经网络训练,克服子序列间复杂关系,提升预测精度
时空特征增强模型	通过稳态分析方法学习时空特征,采用卷积滤波器,并将特征序列转化为图像序列,保持空间和时间特征的关联性
混合系统动力学(SD)和发电组合规划(PGMP)模型	减少预测误差,对 PGMP 模型中的马尔可夫链状态转移矩阵进行修正
傅立叶时变灰色模型(FTGM)	提高季节性需求预测的准确性,结合灰色预测方法和傅立叶函数的优势,采用数据驱动的选择算法自适应确定模型的傅立叶阶数
RXOEL-X	整合了 Blending 线性回归、RF、XGBoost、OLS、ElasticNet 和 LSTM 的优点,以 XGBoost 作为次模型,能够提高预测准确性,同时有效分析高维数据并处理复杂非线性关系,防止过拟合,适应市场的力量更强

## 2 RXOEL-X 模型的构建及运行步骤

本文提出了一种多元化堆叠回归模型 RXOEL-X,即将 LSTM、XGBoost、RF 等模型堆叠,再与 Blending 多元回归线性模型结合进行综合预测,从而提高季节时间序列的预测精度。与传统的时间序列预测模型 BP 和 ARIMA 相比,本文先使用了一种基于贝叶斯的曲线拟合的方法来平滑和预测时间序列数据,然后构建了一个包含 LSTM、XGBoost、RF 等模型的需求预测系统,并通过 Blending 和模型堆叠技术对预测结果进行优化,通过比较各模型与集成方法的性能来提高预测精度。

在这个集成模型中,有 5 个主模型:RF、XGBoost、OLS、ElasticNet 和 LSTM,以及一个次级模型 XGBoost。

## 2.1 模型框架与流程

本研究采用了一种多模型集成的方法,基本思想是:首先独立训练一系列不同的主模型,在此基础上,利用Blending技术综合主模型的预测结果,通过线性回归的方式进行组合。在Blending过程中,各主模型的预测值被线性组合成一个整体预测,即:

$$P_{blend} = \alpha_1 P_1 + \alpha_2 P_2 + \dots + \alpha_n P_n \quad (1)$$

其中, $P$ 表示各主模型的预测值,而 $\alpha_1, \alpha_2, \dots, \alpha_n$ 是线性回归系数,系数通过最小化预测误差来优化选择。

接着,使用XGBoost作为次级模型,它将Blending技术得到的预测值作为输入特征,以此训练次级模型。次级模型的作用是进一步学习主模型预测结果的残差和模式。

最终,次级模型的输出被用作最终的预测结果,即:

$$P_{final} = extXGBoost(P_{blend}) \quad (2)$$

其中, $P_{blend}$ 是Blending模型的输出。

整个预测过程的目标是通过结合多个模型的独特优势和特性来提高整体预测的准确性。Blending模型通过线性回归将不同模型的预测值有效地结合在一起,而次级模型XGBoost则在此基础上对这些组合预测的残差和模式进行了深入学习,从而得出更为精确的最终预测结果。

## 2.2 模型运行步骤

RXOEL-X模型的运行步骤如图1所示。

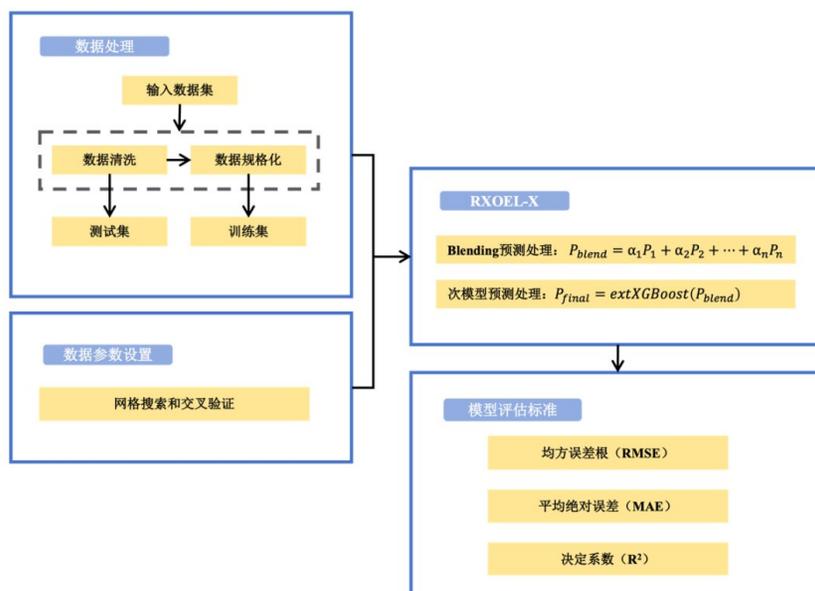


图1 RXOEL-X模型的运行步骤

首先,收集并清洗数据,同时对其进行了一系列预处理操作,如缺失值处理、特征编码以及数据的归一化或标准化,以确保数据的质量和一致性。

其次,将数据拆分为训练集、验证集和测试集,以便进行模型的训练和评估。本文训练了多个不同类型的主模型,包括RF、XGBoost、OLS、带有L1和L2正则化的ElasticNet线性回归模型,以及针对序列

数据的LSTM。每个模型在验证集上的预测结果被记录并用作构建次级训练数据的新特征集。

接着,使用这些特征训练一个次级XGBoost模型,该模型学习如何最佳地结合主模型的预测结果。在所有主模型对测试集完成预测后,收集预测结果作为次级模型的输入特征,并利用次级模型生成最终预测结果。

最后,通过适当的指标对模型进行评估和优化,以确保其在实际应用中达到最优性能。

### 3 模型的性能分析与应用

本文将从两个角度来分析RXOEL-X模型的性能。首先通过使用第十一届“泰迪杯”数据挖掘挑战赛中的一组公开数据,将RXOEL-X模型与五种经典需求预测模型进行比较。然后将某公司的实际数据应用到RXOEL-X模型中,并与多种组合模型进行对比,以更好地测试模型性能。本文中所有实验都在Python中进行。

#### 3.1 与传统单一化模型比较

基于能够获取原始训练和测试数据、确保方法学上的多样性、展示不同的预测机制和优势等标准,选择RF、XGBOOST、LSTM、ARIMA、BP等五种经典需求预测方法,与RXOEL-X模型进行性能比较。

将第十一届“泰迪杯”数据挖掘挑战赛中的一组公开数据应用到六种模型中进行需求预测,严格遵循相关文献中的方法和步骤,得到这些模型的均方根误差(RMSE)、平均绝对误差(MAE)以及决定系数( $R^2$ ),比较结果见表2。

表2 模型比较结果

模型名称	RMSE	MAE	$R^2$
RF	1.094 0	0.844 3	0.392 2
XGBOOST	1.220 4	0.929 8	0.254 3
LSTM	1.150 0	0.870 0	0.340 0
ARIMA	1.081 0	0.814 0	0.414 0
BP	1.560 1	1.282 8	0.222 1
RXOEL-X	1.012 0	0.523 0	0.892 4

(1)RMSE值分析。RMSE是衡量模型预测误差大小的指标, RMSE值越低,意味着模型的预测精度越高,误差越小。

六种模型的RMSE值对比如图2所示,具体分析见表3。

从表3可以看出,集成模型的优越性在于其综合了多个模型的优势,抵消了单个模型的弱点,从而提供了更准确的预测结果。特别是在本例中,RXOEL-X模型显著优于所有单一模型,表明了集成方法在处理复杂预测任务时的潜力和效能。

(2)MAE值分析。MAE值衡量的是模型预测值与实际值之间的平均偏差大小,较低的MAE值表明模型的预测准确性更高。

六种模型的MAE值对比如图3所示,具体分析见表4。

由表4可以看出,集成模型在MAE性能指标上具有明显优势,其低误差表明了这些模型在预测精

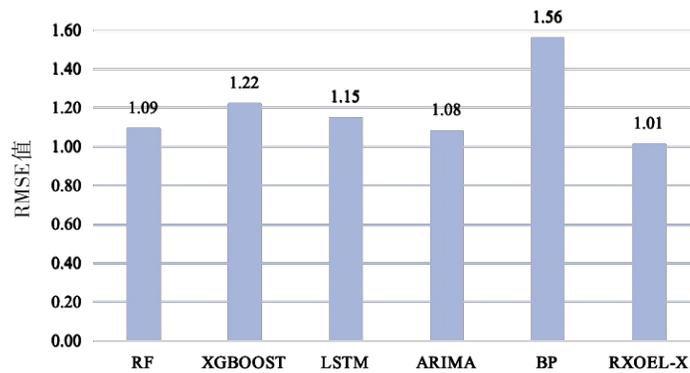


图2 六种模型的RMSE值对比

表3 RMSE值分析

模型名称	分析
RF	在此数据集上,RF模型的RMSE值为1.094,显示了中等水平的预测误差。虽然不是最佳,但相比于BP模型,其预测精度更高
XGBoost	此模型的RMSE值为1.2204,略高于RF模型,表明XGBoost在此数据集的预测性能略逊一筹。尽管如此,它仍然是一种相对有效的预测工具,但可能需要进一步的参数调整来提高精度
LSTM	LSTM模型的RMSE值为1.15,表明它在处理此数据集时的预测误差较低,优于XGBoost,但略逊于RF和ARIMA模型。这反映了LSTM在捕捉时间序列数据的长期依赖性方面的优势
ARIMA	ARIMA模型展现出最佳的单模型预测能力,其RMSE值为1.081,是所有模型中最低的。这突显了ARIMA在处理此类时间序列数据,尤其是在捕捉数据的线性趋势方面的高效性
BP	BP模型的RMSE值为1.5601,是所有模型中最高的,表明其在此数据集上的预测性能最差。这可能是因为BP神经网络在处理复杂数据特征时的局限性,需要更加精细的网络架构设计和参数优化
RXOEL-X	此模型的RMSE值显著降低至1.012,是所有模型中最优的,表明集成方法可能在提高预测精度方面具有显著优势。RXOEL-X的高精度可能归因于不同模型特征捕捉能力的互补,从而有效降低了整体预测误差

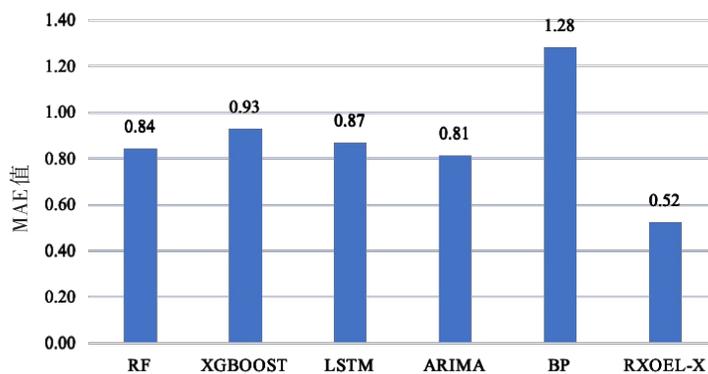


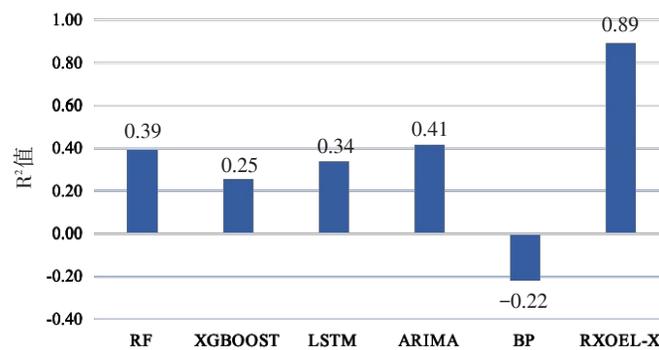
图3 六种模型的MAE值对比

表4 MAE值分析

模型名称	分析
RF	在此数据集上,RF模型的MAE值为0.844 3,显示了相对较低的平均绝对误差。虽然不是所有模型中最低,但相比于BP模型,其在准确性方面展示了更好的性能
XGBoost	此模型的MAE值为0.929 8,略高于RF模型,表明在处理此数据集时,XGBoost的预测准确性稍逊一筹。尽管如此,它仍然是一种有效的预测方法,但可能需要通过参数调整来进一步提升其准确性
LSTM	LSTM模型的MAE值为0.87,略高于RF模型,但低于XGBoost模型。这表明LSTM在捕捉时间序列的复杂特性方面具有一定的优势,但在准确性方面仍有提升的空间
ARIMA	ARIMA模型以0.814的MAE值表现出所有单一模型中最佳的预测能力,这强调了ARIMA在处理时间序列数据,尤其是具有明显线性趋势和季节性的数据时的高效性
BP	BP模型的MAE值为1.282 8,是所有模型中最高的,表明其在此数据集上的预测准确性最差。这可能与BP神经网络的结构和参数配置有关,需要进一步优化以提高其性能
RXOEL-X	此模型的MAE值显著降低至0.523,是所有模型中最优的,表明集成方法在提高预测准确性方面具有显著的优势。RXOEL-X的高准确度可能归因于不同模型在捕捉数据特征方面的互补性,从而有效减少了预测值与实际值之间的平均偏差

准度方面的强大能力,特别是RXOEL-X模型在MAE上表现最好,意味着其在实际应用中能为决策提供更可靠的数据支持。

(3) $R^2$ 值分析。对比不同模型的 $R^2$ 值,可以衡量每个模型对数据变异性解释的能力。 $R^2$ 值越接近1,表明模型对数据的拟合越好,预测的准确性越高。6种模型 $R^2$ 值对比如图4所示,具体分析见表5。

图4 六种模型的 $R^2$ 值对比

由表5可以看出,RXOEL-X模型在本轮分析中表现最佳,具有最接近1的 $R^2$ 值,显示出其在预测准确性和解释数据方面的优异能力,这进一步证明了集成不同预测模型可以提高整体模型的性能,特别是在复杂的预测任务中。

通过三种指标对比可知,RXOEL-X模型的RMSE、MAE均低于其他方法,且 $R^2$ 值最接近1,因此该模型在预测精度方面优于其他模型。

## 3.2 基于实例的模型性能分析

### 3.2.1 数据描述和预处理。

本文选择了一家中国领先的饮料公司,其产品的销售具有明显的季节性和周期性。例如,夏季是冷饮销售旺季,而冬季需求较低;节假日和特定活动期间的促销活动以及温暖的

表5 R<sup>2</sup>值分析

模型名称	分析
RF	R <sup>2</sup> 值为0.392 2,表明RF模型在拟合数据集的变异性方面表现一般。尽管它在所有模型中并非表现最佳,RF模型仍然在处理复杂数据集时展现出一定的能力,尤其是在避免过度拟合方面
XGBoost	R <sup>2</sup> 值仅为0.254 3,意味着XGBoost模型在预测任务中的拟合能力较差,解释数据变异性的能力相对较弱
LSTM	R <sup>2</sup> 值为0.34,较低的R <sup>2</sup> 值表明LSTM模型在捕捉和预测时间序列数据的复杂模式方面有一定的局限性,可能需要更多的数据或改进网络结构来优化性能
ARIMA	R <sup>2</sup> 值为0.414,略微高于RF模型,这显示ARIMA模型在本数据集上具有一定的拟合能力,尤其是在处理具有线性趋势和季节性的时间序列数据时
BP	R <sup>2</sup> 值为-0.222 1,这表明在本数据集上,BP模型不仅未能捕捉数据的变异性,反而表现出与数据趋势相反的预测趋势。这可能意味着模型的结构或训练过程需要重大调整
RXOEL-X	具有最接近1的R <sup>2</sup> 值,达到了0.892 4,这个结果显示了该模型在数据的变异性解释上的卓越性能,几乎完美地拟合了数据

天气条件也会显著提升销量。因此,该公司面临库存管理和生产决策的挑战,需根据多种外部因素优化供应链和生产计划。

以该公司2015年1月至2022年3月的每日销售数据和相关因素共计2 602个观察点为训练集,通过时间序列分解技术分析销售数据,将其拆分为趋势、季节性和随机成分,以揭示销售模式。该方法允许模型学习不同季节和天气条件下的销售变化。分析显示,销量呈现出明显的变化趋势和规律的季节性波动特别是与天气因素紧密相关,如图5所示。这种现象强调了在进行时间序列预测时,选择能够捕获趋势和季节性变化的模型的重要性。

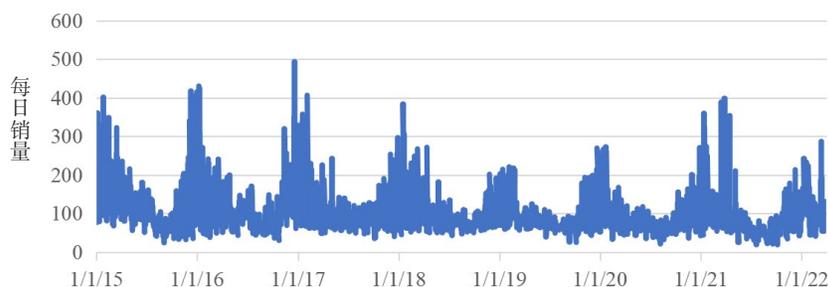


图5 饮料公司每日销量

3.2.2 比较模型和参数设置。为了能够更好的测试RXOEL-X模型的性能,本文选择了10个组合模型与其进行相关对比,分别是LSTM-OLS、LSTM-ElasticNet、RF-OLS、RF-ElasticNet、XGBoost-OLS、XGBoost-ElasticNet、(RF、OLS)-ElasticNet、(XGBoost、OLS)-ElasticNet、(RF、XGBoost、OLS、ElasticNet、LSTM)-ElasticNet、(RF、XGBoost、OLS、ElasticNet、LSTM)-OLS。此外将从单个模型LSTM、RF、XGBoost中得到的趋势分量和残差分量作为混合模型中子模块输入。

表6是对相关模型的简要描述。每个模型都通过不同的技术组合来提高预测精度和减少过拟合的风险,旨在优化对公司需求的预测。

表6 10种组合模型的简要描述

模型名称	分析
LSTM-OLS	结合了LSTM模型和OLS回归。LSTM负责捕捉时间序列数据中的长期依赖性和非线性模式,而OLS则在LSTM输出的基础上提供参数估计,旨在优化预测精度
LSTM-ElasticNet	与LSTM-OLS类似,这个模型也利用了LSTM来处理序列依赖性,但在LSTM的输出上运用了ElasticNet回归。ElasticNet结合了L1和L2正则化,既能进行特征选择(类似Lasso回归),又能稳定模型(类似Ridge回归)
RF-OLS	结合了RF算法和OLS回归。RF是一个基于决策树的集成学习方法,能够处理高维数据和非线性关系。OLS作为后处理步骤,利用RF的输出进行参数估计
RF-ElasticNet	将RF的预测结果作为输入,使用ElasticNet回归作为第二阶段的预测器。这样可以借助RF处理复杂数据结构的能力,同时通过ElasticNet正则化来提升模型的泛化能力
XGBoost-OLS	结合了XGBoost算法和OLS回归。XGBoost能够提供精准的预测结果,并处理各类数据问题,而OLS则在模型输出上进行线性回归拟合
XGBoost-ElasticNet	与XGBoost-OLS模型相似,本模型使用XGBoost进行初始预测,然后利用ElasticNet回归在XGBoost结果的基础上进行优化,结合了两种技术的优点。
(RF,OLS)-ElasticNet	首先结合RF和OLS回归进行预测,然后使用ElasticNet作为第二阶段的模型来进一步处理RF+OLS的输出,目的是利用ElasticNet的正则化特性来提升最终预测的稳定性
(XGBoost,OLS)-ElasticNet	类似于(RF,OLS)-ElasticNet模型,这个模型先将XGBoost和OLS结合,得到一个预测结果,然后再通过ElasticNet进行第二次预测。这样做可以抓住XGBoost在处理复杂模式中的强大能力,同时借助ElasticNet减少过拟合
(RF,XGBoost,OLS,ElasticNet,LSTM)-ElasticNet	这是一个多层次的堆叠模型,它首先集成了RF、XGBoost、LSTM的预测能力,并结合了OLS和ElasticNet的线性回归结果,然后再次使用ElasticNet对全部集成的结果进行优化。这是一个复杂的模型,理论上能够综合各种预测模型的优势
(RF,XGBoost,OLS,ElasticNet,LSTM)-OLS	与上一个模型类似,这也是一个集成模型,不同的是在最后阶段它使用OLS来对集成结果进行拟合。通过这样的方法可以期望模型拥有较好的预测能力,同时OLS能够提供明确的模型参数解释

表7 11种模型的编号对应关系

模型名称	编号
LSTM-OLS	1
LSTM-ElasticNet	2
RF-OLS	3
RF-ElasticNet	4
XGBoost-OLS	5
XGBoost-ElasticNet	6
(RF,OLS)-ElasticNet	7
(XGBoost,OLS)-ElasticNet	8
(RF,XGBoost,OLS,ElasticNet,LSTM)-ElasticNet	9
(RF,XGBoost,OLS,ElasticNet,LSTM)-OLS	10
RXOEL-X	11

由于模型的名称较长,因此采用编号来指代相关的模型,表7是11种模型与编号的对应关系,表8是11种模型的计算结果,各模型之间的对比如图6—图8所示。

表8 11种模型的计算结果

模型名称	RMSE	MAE	R <sup>2</sup>
LSTM-OLS	12.828 9	7.952 3	0.966 8
LSTM-ElasticNet	12.830 2	7.952 9	0.966 8
RF-OLS	15.312 6	6.587 5	0.952 7
RF-ElasticNet	15.318 8	6.586 6	0.952 7
XGBoost-OLS	6.129 5	3.656 7	0.992 4
XGBoost-ElasticNet	6.129 7	3.656 7	0.992 4
(RF、OLS)-ElasticNet	8.538 4	5.606 0	0.985 3
(XGBoost、OLS)-ElasticNet	9.423 2	5.090 5	0.992 4
(RF、XGBoost、OLS、ElasticNet、LSTM)-ElasticNet	9.424 4	5.097 0	0.992 3
(RF、XGBoost、OLS、ElasticNet、LSTM)-OLS	6.129 8	3.656 9	0.992 4
RXOEL-X	5.987 6	3.324 2	0.992 4

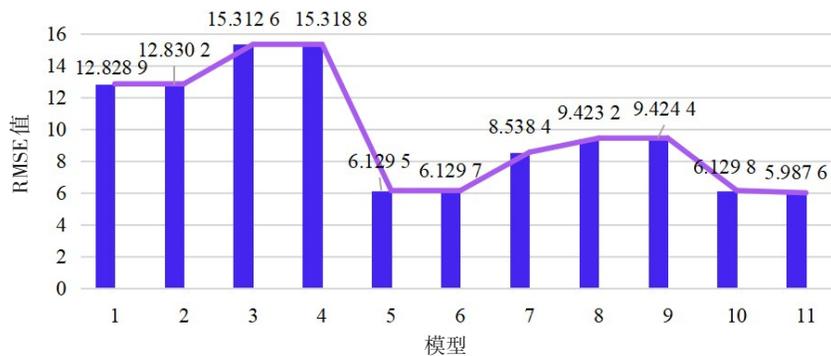


图6 11种模型的RMSE值对比

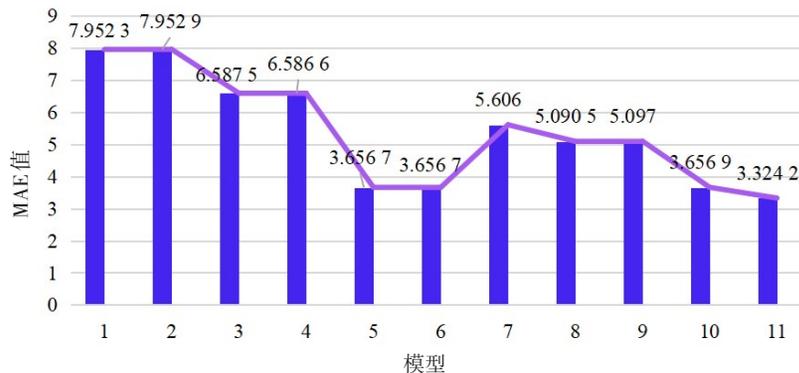


图7 11种模型的MAE值对比

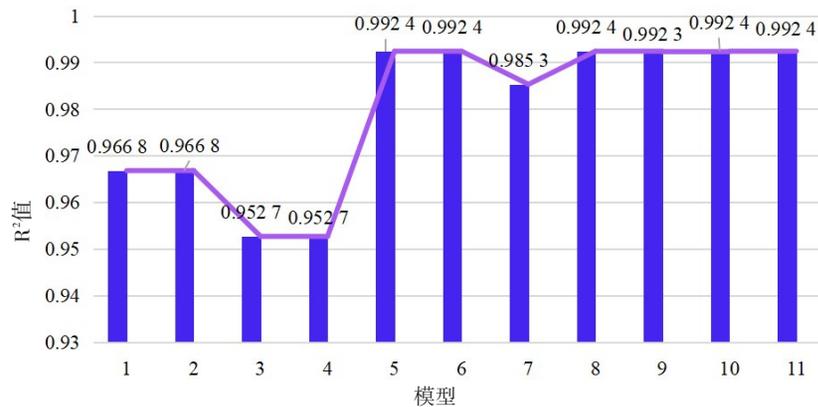


图8 11种模型的R<sup>2</sup>值对比

11种组合模型的对比结果分析见表9。

表9 11种组合模型对比结果分析

模型名称	分析
LSTM-OLS和LSTM-ElasticNet	这两个模型在三项指标上的表现非常接近,几乎没有差异。RMSE和MAE相对较高,而R <sup>2</sup> 值较好,表明模型对数据的拟合程度相对较好,但预测误差也较大
RF-OLS和RF-ElasticNet	类似于LSTM的情况,这两个模型的表现也非常接近。它们在RMSE方面的表现最差,MAE中等,R <sup>2</sup> 值尚可但仍然较低,整体上看表现一般
XGBoost-OLS和XGBoost-ElasticNet	这两个模型在所有指标上表现都非常好,RMSE和MAE都是所有模型中最低的,而R <sup>2</sup> 值最高。这表明XGBoost基础模型在预测上非常准确且拟合程度很高
(RF,OLS)-ElasticNet	该模型的表现中等范围内,RMSE和MAE都比RF和LSTM的变体要好,但比XGBoost的变体要差。R <sup>2</sup> 值较好,但仍然没有超过XGBoost相关模型
(XGBoost,OLS)-ElasticNet和(RF,XGBoost,OLS,ElasticNet,LSTM)-ElasticNet	这两个模型的表现相当,R <sup>2</sup> 值极高,但在RMSE和MAE指标上,它们并没有超过单独的XGBoost模型
(RF,XGBoost,OLS,ElasticNet,LSTM)-OLS	类似于XGBoost-OLS和XGBoost-ElasticNet,该模型在所有指标上都表现优异,这表明在该组合中XGBoost可能是驱动性能的关键因素
RXOEL-X	这个模型在所有指标上都表现出色,尤其在RMSE上有轻微的改善,是最佳表现的模型之一,这反映了集成学习方法通过组合不同模型的优势来提升整体性能的有效性

整体上,基于XGBoost的模型和集成模型在RMSE、MAE和R<sup>2</sup>三项指标上均表现出较高的预测精度和数据拟合能力。尤其是RXOEL-X模型,它在综合各项指标后,可以认为是整体最优的模型,显示了综合多种模型和技术可以有效提高预测性能的潜力。而基于RF和LSTM的模型在这次比较中表现较差,尤其是在RMSE指标上。在实践中,选择最佳模型还需要考虑计算成本、模型训练和推断时间以及具体任务的需求。

### 3.3 敏感性分析

敏感性分析是评估模型输出对于输入参数变动敏感程度的重要工具。通过敏感性分析,可以更好

地理解模型如何从输入得到输出,从而提高模型的透明度和解释性。因此,在模型开发和应用过程中进行敏感性分析,不仅可以增强对模型行为的理解,还可以显著提高模型的性能和可靠性,使其更加符合实际应用需求。为此在本研究中,通过对11种模型中11个随机数据点的删除来测试该模型的相关敏感性,结果见表10, RMSE前后对比如图9所示。

表10 敏感性分析结果

模型名称	上一次RMSE	目前RMSE	变化(%)
LSTM-OLS	313 530.09	368 935.73	18
LSTM-ElasticNet	123 344.55	217 322.32	76
RF-OLS	213 573.42	299 423.92	40
RF-ElasticNet	192 446.99	252 861.35	31
XGBoost-OLS	156 351.93	213 234.80	36
XGBoost-ElasticNet	145 708.26	185 347.54	27
(RF、OLS)-ElasticNet	216 538.05	253 563.32	17
(XGBoost、OLS)-ElasticNet	126 738.08	181 325.52	43
(RF、XGBoost、OLS、ElasticNet、LSTM)- ElasticNet	135 785.10	191 326.62	41
(RF、XGBoost、OLS、ElasticNet、LSTM)-OLS	245 786.10	297 844.64	21
RXOEL-X	12 335.47	12 521.01	2

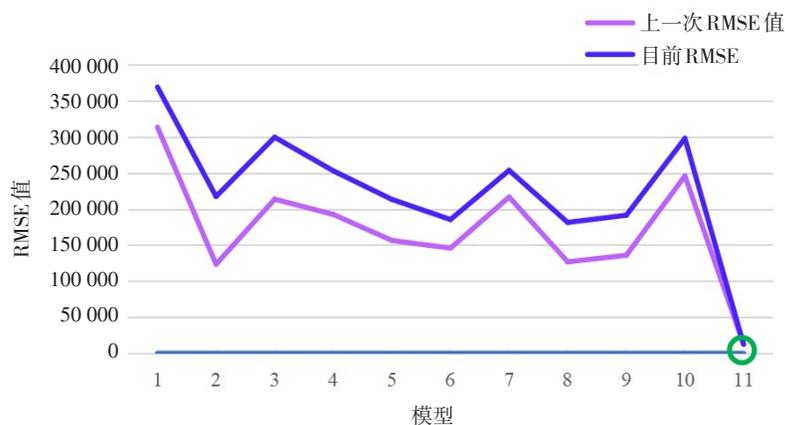


图9 11种模型的RMSE值前后对比

11种模型的敏感性对比分析具体见表11。

RXOEL-X模型在比较中展示了最优性能,其RMSE的变化率仅为2%,表明其预测准确性受到的影响极小,展现出极高的鲁棒性。该模型融合了RF、XGBoost、OLS、ElasticNet正则化和LSTM等多种机器学习技术,通过集成方法减少单一模型缺陷的影响,提高整体预测准确性和鲁棒性。特别是加入的XG-

表11 11种组合模型的敏感性对比分析

模型名称	分析
LSTM-OLS	RMSE从313 530.09上升到368 935.73,变化率为18%,表明模型的预测准确性有所下降
LSTM-ElasticNet	RMSE从123 344.55增加到217 322.32,变化率高达76%,这是所有模型中变化幅度最大的,表明其敏感性极高,可能对某些参数或数据变化特别敏感
RF-OLS	RMSE从213 573.42增加到299 423.92,变化率为40%,表明这个模型相对于其他模型也比较敏感
RF-ElasticNet	RMSE从192 446.99增加到252 861.35,变化率为31%,表明该模型的稳定性相对较好,但仍有显著变化
XGBoost-OLS	RMSE从156 351.93增加到213 234.8,变化率为36%,显示出中等程度的敏感性
XGBoost-ElasticNet	RMSE从145 708.26增加到185 347.54,变化率为27%,相比其他模型,这个模型的敏感性较低
(RF、OLS)-ElasticNet	RMSE从216 538.05增加到253 563.32,变化率为17%,表明该模型的稳定性相对较高
(XGBoost、OLS)-ElasticNet	RMSE从126 738.08增加到181 325.52,变化率为43%,表明该模型较为敏感
(RF、XGBoost、OLS、ElasticNet、LSTM)-ElasticNet	RMSE从135 785.097增加到191 326.62,变化率为41%,显示出较高的敏感性
(RF、XGBoost、OLS、ElasticNet、LSTM)-OLS	RMSE从245 786.097增加到297 844.64,变化率为21%,表明模型的稳定性较高
RXOEL-X	RMSE变化最小,从12 335.47增加到12 521.01,变化率仅为2%,显示出极高的稳定性和低敏感性

Boost优化了模型性能,使RXOEL-X模型能在不同数据集和应用场景中保持稳定的性能。

### 3.4 时间性分析

时间性分析强调了模型运行速度的重要性,除了准确性外,模型效率也是选择预测模型的一个关键因素。11种模型的时间性分析结果如图10所示。由图10可以看出,RXOEL-X模型在时间效率上表现最佳,其时间优化非常成功。模型9和模型10也展现了较高的时间效率,这可能得益于有效的模型优化。相比之下,模型1、模型2以及模型5的运行时间较长,这可能是由于模型本身复杂或未充分优化。一些集成模型在时间性能上优于单一模型,这可能与模型的优化策略和硬件加速有关。在实际应用中,选择模型时应考虑计算资源限制和快速响应需求,同时注意时间性能与预测准确性之间的权衡。

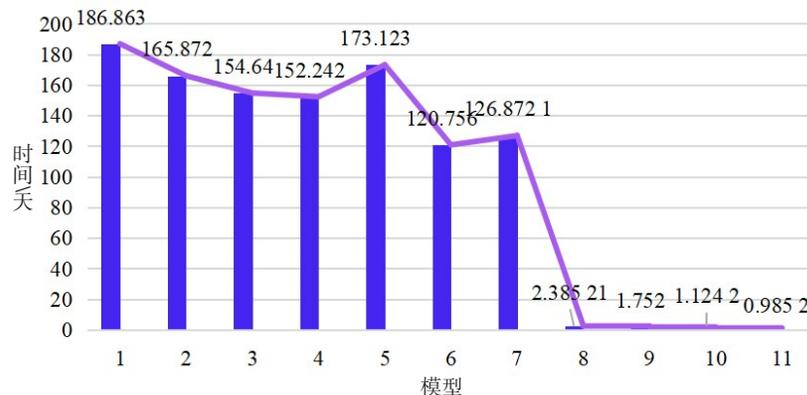


图10 时间性分析结果

### 3.5 结果与讨论

本文评估了16个模型,包括5个单一模型和11个集成模型,发现模型性能存在显著差异。在所有评估指标上,XGBoost-OLS和XGBoost-ElasticNet模型表现最优,而模型RXOEL-X在稳定性上表现出色,敏感性分析中的变化率仅为2%。相反,LSTM-ElasticNet模型在数据变动下的敏感性最高,变化率达到76%,表明部分模型在面对数据波动时可能不够稳定。总的来说,基于XGBoost的模型在预测精度和数据拟合上卓越,而RXOEL-X模型在稳定性方面优势明显,展示了机器学习方法与传统预测技术结合的优势,特别是在处理非线性和高变异性数据时,集成模型可能是更佳的选择。

## 4 结语

在当前全球经济复杂多变的背景下,企业供应链管理显得尤为关键。为了准确预测市场需求并优化资源配置,本研究提出了一种创新的多元化堆叠回归模型RXOEL-X。该模型结合了智能预测和客观学习的理念,实现了对时间序列数据中季节性和非线性模式的非结构化处理。通过集成线性回归、LSTM、XGBoost和RF模型,并运用模型堆叠技术,有效地捕获了这些复杂模式。

本文经过深入分析,得出了模型的关键优势与局限性。在优势方面,模型通过集成多个主流模型的独特优势,实现了高精度的预测。模型不仅结合了机器学习的强大数据处理能力和传统统计方法的稳健性,而且通过RF和XGBoost提供的抗过拟合能力,增强了模型的稳定性。LSTM的长期依赖关系捕捉能力在处理季节性和趋势性需求预测方面至关重要,而ElasticNet的引入则强化了鲁棒性,防止了过拟合,并通过优化参数选择进一步提升了模型性能。研究同时关注了模型的准确性和鲁棒性,确保模型在多变环境下具备可靠的预测能力。

然而,模型的局限性也不容忽视。复杂的多模型融合可能会导致模型结构变得复杂,从而增加计算成本和理解难度,本文提出的RXOEL-X模型尽管集成了多种模型,但相较于其他集成模型在时间效率上表现最佳,可见时间优化非常成功。在应用条件有限时,可以通过特征选择方法保留最重要的特征,来减少模型的复杂度,或使用简单但有效的模型,实现在降低计算成本的同时保持较好的性能。模型的性能在很大程度上依赖于数据的质量和数量,在数据质量较差或数据量有限的情况下,可能难以发挥最佳效果。此外,模型参数的调整过程可能非常耗时,尤其是在运用交叉验证和网格搜索方法进行优化时。未来可以采用自动化超参数调优方法来替代耗时的网格搜索,同时使用分层交叉验证来减少过拟合并提高模型的泛化能力。预测者的情感偏差和产品参与度也可能对模型的判断调整产生影响,从而影响预测的准确性。未来可以在模型开发过程中引入更多的客观指标,建立相关行业系统化的评价标准和流程,确保模型判断的客观性和一致性。需要说明的是,尽管模型在饮料行业中展现了良好的应用效果,但在其他行业或领域的泛化能力还需进一步验证和测试。未来可以收集来自不同领域的数据,进行广泛的测试和验证,以增加训练数据的多样性和代表性,从而提高模型的泛化能力。

总而言之,RXOEL-X模型为饮料行业乃至更广泛的企业供应链管理中的需求预测问题提供了一种前沿的解决策略。它利用智能化的工具和方法,协助企业在节省成本、减少库存积压的同时,提高对市场变化的响应速度和供应链的整体灵活性。展望未来,进一步的研究可以在此基础上,探索适用于不同行业背景的预测模型,并考虑如何将这些预测能力与企业的战略决策相结合,以推进供应链管理的高效和智能化发展。

## [参考文献]

- [1] BELVEDERE Valeria,GOODWIN Paul.The influence of product involvement and emotion on short-term product demand forecasting[J].International Journal of Forecasting,2017,33:652-661.
- [2] LIANG Mengkun,YANG Liping,LI Kai,et al.Improved collaborative filtering for cross-store demand forecasting[J].Computers & Industrial Engineering,2024,190.
- [3] KUCK M,FREITAG M.Forecasting of customer demands for production planning by local k-nearest neighbor models[J].International Journal of Production Economics,2020,231.
- [4] TRAPERO J R,FRUTOS DE ENRIQUE HOLGADO,PEDREGAL D J.Demand forecasting under lost sales stock policies[J].International Journal of Forecasting,2023(9):4.
- [5] PUNIA Sushil,SHANKAR Sonali.Predictive analytics for demand forecasting:a deep learning-based decision support system[J].Knowledge-Based Systems,2022,258.
- [6] LEE Misuk.Modeling and forecasting hotel room demand based on advance booking information[J].Tourism Management,2018,66:62-71.
- [7] HE X,MA S,WU Y,et al.E-commerce product sales forecast with multi-dimensional index integration under small sample[J].Computer Engineering and Applications,2019,55(15):177-184.
- [8] LEI M,LI LUO Y.Demand forecasting approaches based on associated relationships for multiple products[J].Entropy,2019,21:974-992.
- [9] STEENBERGEN van R M,MES M R K.Forecasting demand profiles of new products[J].Decision Support Systems,2020,139.
- [10] SELIM Turkoglu,BURCU Erkmn,YAVUZ Eren,et al.Integrated Approaches in Resilient Hierarchical Load Forecasting via TCN and Optimal Valley Filling Based Demand Response Application[J].Applied Energy,2024,260.
- [11] XU Zhitao,SONG Wenyan,ZHANG Qin,et al.Product service demand forecasting in hierarchical service structure[J].Procedia CIRP,2017,64:145-150.
- [12] GUO Liang,FANG Weiguo,ZHAO Qihong,et al.The hybrid PROPHET-SVR approach for forecasting product time series demand with seasonality[J].Computers & Industrial Engineering,2021,161.
- [13] JOSEPH Reuben Varghese,MOHANTY Anshuman,TYAGI Soumyae,et al.A hybrid deep learning framework with CNN and bi-directional LSTM for store item demand forecasting[J].Computers and Electrical Engineering,2022,103.

## A Diversified Stacked Regression Model for Seasonal Product Demand Forecasting

LIU Bin, DING Hao

(School of Management, University of Shanghai for Science & Technology, Shanghai 200093, China)

**Abstract:** With continuous changes in the global economic and industrial structure, effective supply chain management, especially accurate demand forecasting, has become the key for enterprises to cope with challenges, avoid resource waste, reduce costs and improve operational efficiency. Therefore, it is of great significance to develop a forecasting model that is accurate, flexible and adaptable to market changes.

In this paper, we proposed a diversified stacked regression model RXOEL-X, which combines the advantages of multiple algorithms including Blending Linear Regression, Random Forest (RF), Extreme Gradient Boost (XGBoost), Ordinary Least Squares (OLS), ElasticNet and Long Short-Term Memory Network (LSTM), and uses XGBoost as a secondary optimization model, which not only utilizes the powerful data analysis capabilities of machine learning, but also taps the robustness of traditional statistical methods and the nonlinear modeling capabilities of deep learning. The model fusion technology employed significantly improved the forecasting performance of the model, especially enabling it to effectively capture the seasonality and long-term dependence in the time series data, which is suitable for the demand forecasting of supply chains with obvious seasonality and trend characteristics. After introducing the construction and operation steps of RXOEL-X, the model is compared with five traditional simple models based on a set of public data, proving that the RXOEL-X model is better than the other models in terms of forecasting accuracy. At the same time, based on the actual sales data of a beverage company, the performance of the model was further tested and compared with 10 combination models, proving that the RXOEL-X model excelled in terms of prediction accuracy and data fitting ability. Through a sensitivity analysis, the forecasting accuracy of the RXOEL-X model was found to be virtually insusceptible to external influence, showing extremely high robustness. In a temporal analysis, the model also performed best.

The RXOEL-X model provides a frontier solution for the forecasting of seasonal product demand and a wide range of corporate supply chain management issues, which can help companies save costs and reduce inventory backlogs while improving their response speed to market changes and the overall flexibility of the supply chain.

**Keywords:** seasonal product; demand forecasting; diversified stacked regression model; machine learning; smart supply chain