

面向智能配送的外卖订单需求预测模型研究 ——基于随机森林

陈怡璇, 张 峥

上海理工大学管理学院, 上海

收稿日期: 2025年8月26日; 录用日期: 2025年9月10日; 发布日期: 2025年10月16日

摘 要

为提升智能配送系统中外卖订单需求的预测精度以优化运营效率, 本研究针对其时序性、非线性及高噪声特性, 提出了一种基于随机森林(RF)与直方图梯度提升树(GBDT)的两阶段Stacking集成学习预测模型(RF-GBDT)。本研究基于人工采集的数据进行了系统性特征工程, 并创新性地利用GBDT学习RF初步预测的残差以修正系统偏差。实证结果表明, 模型有效识别出“时刻”为最关键特征, 且RF-GBDT组合模型性能显著优于单一模型, 测试集RMSE、MAE和MAPE分别降低了13.9%、19.0%和19.8%, R^2 提升至0.9016, 证实了该框架能为外卖平台提供更精准可靠的需求预测解决方案。

关键词

需求预测, 随机森林, 梯度提升树, Stacking集成学习, 特征工程

Research on Takeaway Order Demand Forecasting Model for Intelligent Delivery —Based on Random Forest

Yixuan Chen, Zheng Zhang

Business School, University of Shanghai for Science & Technology, Shanghai

Received: August 26, 2025; accepted: September 10, 2025; published: October 16, 2025

Abstract

To enhance the prediction accuracy of takeaway order demand in intelligent delivery systems and optimize operational efficiency, this study addresses its temporal, nonlinear, and high-noise characteristics by proposing a two-stage Stacking ensemble learning prediction model (RF-GBDT) based

on Random Forest (RF) and Histogram-based Gradient Boosting Decision Tree (GBDT). The study systematically performs feature engineering based on manually collected data and innovatively employs GBDT to learn the residuals of preliminary RF predictions to correct systemic biases. Empirical results demonstrate that the model effectively identifies “time of day” as the most critical feature, and the RF-GBDT combined model significantly outperforms individual models, reducing RMSE, MAE, and MAPE on the test set by 13.9%, 19.0%, and 19.8%, respectively, while increasing R^2 to 0.9016. This validates that the framework can provide more accurate and reliable demand prediction solutions for takeaway platforms.

Keywords

Demand Forecasting, Random Forest, Gradient Boosting Tree, Stacking Ensemble Learning, Feature Engineering

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 绪论

1.1. 研究背景

随着数字经济与移动支付技术的深度融合, 外卖服务作为即时零售的核心业态, 已实现从“补充性消费”向“日常生活刚需”的转型。据艾瑞咨询《2024 年中国即时配送行业研究报告》显示, 2023 年我国外卖市场交易规模突破 8000 亿元, 日均订单量超 2 亿单, 用户渗透率达 65%, 成为现代城市生活服务体系中的关键基础设施。外卖订单具有明显的时序性和非线性特征, 受多种因素影响, 包括时间段、星期、节假日、天气状况、地理位置以及促销活动等。传统的预测方法如时间序列分析在处理外卖订单需求的非线性、多因素影响时, 常面临拟合能力有限、预测精度不高的不足。因此, 将数据驱动的机器学习方法应用于外卖订单预测, 成为提高预测准确性和平台运营效率的重要方向。

近年来, 机器学习技术在时间序列预测领域展现出强大潜力, 尤其是集成学习方法如随机森林(Random Forest, RF)与梯度提升树(Gradient Boosting Decision Tree, GBDT)因其出色的拟合能力与鲁棒性, 被广泛应用于销量预测、交通流量预测等领域。然而, 在外卖订单预测这一具体场景中, 单一模型往往难以全面捕捉数据中的全部信息, 存在一定的预测偏差与滞后性。因此, 构建能够融合多种模型优势的组合预测框架, 已成为提升预测精度与稳健性的重要研究方向[1] [2]。

1.2. 研究意义

本研究旨在构建一种面向智能配送场景的外卖订单需求预测模型, 通过融合随机森林与直方图梯度提升树(Hist Gradient Boosting), 提出一种两阶段 Stacking 集成学习框架(RF-GBDT), 以修正单一模型的系统性误差, 提升预测性能。该研究不仅有助于丰富时间序列预测理论与方法, 更具备以下实践意义:

首先, 在理论层面, 针对外卖订单需求预测问题, 构建基于随机森林的预测模型, 有助于丰富机器学习在智能配送领域的应用研究。随机森林通过集成学习方法增强模型的稳定性与泛化能力, 能够处理外卖订单数据中存在的高维特征、非线性关系和异常噪声, 为相关研究提供可借鉴的方法论参考。其次, 在实践层面, 外卖平台对订单需求的准确预测能够为配送资源调度提供科学依据。通过预测高峰时段和区域订单量, 平台可合理安排配送员数量、优化配送路线、降低配送延迟和资源浪费, 从而提高运营效率。

本研究对推动智能配送系统的发展具有示范意义。随着大数据和人工智能技术在物流配送领域的广泛应用,数据驱动的预测和决策模式正在成为行业新趋势。构建高精度的订单需求预测模型,不仅有助于提升外卖平台的运营效率,也可为城市智慧物流、零售供应链优化及公共服务调度提供借鉴,推动理论与行业应用的深度融合。

2. 国内外研究现状

2.1. 国外研究现状

外卖订单需求预测作为时间序列预测在智能物流领域的具体应用,其研究方法与技术发展紧随机器学习与数据挖掘领域的进步。国外学者在该领域的研究起步较早,主要集中在传统统计模型、机器学习模型及深度学习模型的应用与优化上。

早期研究多采用经典时间序列模型,如自回归积分滑动平均模型(ARIMA)及其季节性变体(SARIMA)。例如,Chai, S. H.等人系统地阐述了 ARIMA 模型在商业预测中的应用,其优点在于模型形式简洁、可解释性强[3]。然而,此类模型本质上属于线性模型,难以有效捕捉外卖订单数据中复杂的非线性特征和高噪声,预测精度有限。

为克服传统模型的局限性,机器学习模型逐渐成为研究主流。其中,随机森林(Random Forest, RF)和梯度提升树(Gradient Boosting Decision Tree, GBDT)等集成学习算法因其卓越的拟合能力和鲁棒性被广泛应用。Pliakos 提出的随机森林算法通过在全局交互设置上构建多输出决策树,解决了作为多标签分类任务的交互预测问题[4]。Tanizaki 提出了利用机器学习对餐厅的需求进行预测,根据商店位置、天气、事件等各种因素建立针对商店的需求预测模型[5]。这些研究为机器学习在需求预测领域的应用奠定了坚实的理论基础。

2.2. 国内研究现状

国内关于外卖订单预测的研究与实践同样活跃,并与本土化的业务场景结合得更为紧密。我国学者在借鉴国外先进模型的同时,更侧重于针对特定场景的模型优化与融合。

在单一模型优化方面,众多研究验证了不同算法在销量预测中的效果。例如,有学者利用 XGBoost 模型预测 CO₂ 腐蚀速率,并证明了其优于支持向量机(SVM)等传统机器学习算法[6]。另一项研究则针对城市能耗预测问题,采用 LightGBM 模型有效提升了预测效率与精度[7]。这些研究表明,树模型及其集成方法在国内需求预测领域已成为首选工具之一。

随着预测任务复杂度的提升,组合模型(Hybrid Model)的思想成为新的研究趋势。国内研究者认识到,单一模型可能难以完全捕获数据中的所有模式,因此常采用“优势互补”的策略。常见的组合方式包括:1) 分解-重构:先使用季节性分解(STL)或小波变换等方法将原始序列分解为不同成分,再分别对各成分进行建模预测,最后将结果集成;2) 残差修正:利用一个模型进行初步预测,再使用另一个模型对其残差(预测误差)进行建模,以修正系统偏差,这正是本研究采用的核心思路。有文献采用 ARIMA 与 SVM 相结合的策略,用 SVM 捕捉 ARIMA 残差中的非线性模式,取得了良好效果[8]。这为本研究采用 RF-GBDT 的两阶段框架提供了有力的方法论支持。

3. 数据采集与预处理

3.1. 数据来源与采集

本研究的数据源于上海理工大学南校区的外卖智能取餐柜,选择该地点源于其典型的封闭校园环境特征:用户群体高度集中且稳定,主要为在校学生和教职工,消费行为模式相对于开放商圈更具规律性和可研究性。反映了某外卖平台在特定区域内的历史订单数量。原始数据以 Excel 格式存储,包含时间戳

(timestamp)和订单数量(order_count)两个字段,记录了以每两小时为间隔的聚合订单量。数据采集通过平台内部的数据导出工具完成,确保了数据的真实性和完整性。

初始数据集的时间跨度为2024年9月1日至2025年1月31日(一个学期),每日采集时段为午间高峰期的11:00至14:00。该时间窗口覆盖了每日订单最集中、模式最显著的时段。共包含1837条有效记录。数据采集过程中已对缺失值与异常值进行了初步清洗,保证了后续建模的可靠性。

3.2. 数据集划分

为符合时间序列预测的实际情况,避免未来信息泄露,本研究采用前置时间划分法将数据集划分为训练集和测试集:训练集:包含除最后7天外的所有历史数据;测试集:使用最后7天(共7天 $\times$ 12时间点/天=84条样本)作为测试集,用于评估模型的泛化性能。

3.3. 特征工程

基于领域知识与时序数据分析,本研究系统构建了多维特征集,主要包括以下四类:

1. 时间特征:提取并构造了小时(hour)、分钟(minute)、星期几(day_of_week)、是否周末(is_weekend)及连续时间点(time_of_day)等基础特征。为进一步解决时间周期的连续性问题,引入了周期性编码特征,即对小时和星期几进行正弦(hour_sin, day_sin)与余弦(hour_cos, day_cos)变换,将循环时间转化为模型更易处理的连续坐标。

2. 滞后特征:基于自相关图(ACF)分析,序列在短周期、日周期与周周期均表现出显著相关性。据此,选取了多尺度滞后项(Lag=[1, 2, 3, 4, 5, 6, 8, 13, 91]),用以捕捉短期依赖、同日更早时段及一周前相同时刻的订单模式。

3. 滚动统计特征:为刻画序列的近期趋势与波动性,设置了多种时间窗口(4, 8, 12, 24),并计算了滑动窗口内的均值(rolling_mean)、标准差(rolling_std)、最小值(rolling_min)和最大值(rolling_max)。

4. 外部特征:引入了天气指数(weather_index)与促销活动(is_promotion)等外部变量,以量化环境与营销活动对订单量的潜在影响。

如图1所示,特征工程共生成15个特征变量,与目标变量order_count共同构成模型输入,通过对随机森林模型输出的特征重要性进行分析,可以发现:时间因素占据主导地位,time_of_day是最具预测力的特征,这与外卖订单量受用餐时间驱动的业务逻辑高度吻合;历史行为是关键预测因子,一系列滚动统计特征和滞后特征均位列前茅,表明模型的预测强烈依赖于近期历史数据的趋势和水平,时间序列具有明显的短期自相关性;外部变量得到有效验证:外部引入的weather_index和is_promotion特征均显示出显著的重要性,证明了天气条件和营销活动对订单量的确存在系统性影响,本研究成功地将这些影响量化并纳入了预测模型。

3.4. 模型构建与优化

本研究采用两阶段建模策略。第一阶段采用随机森林(Random Forest)作为基础预测模型,其优势在于能够有效捕捉特征与目标之间的非线性关系。第二阶段采用梯度提升机(Hist Gradient Boosting Regression)对第一阶段的预测残差进行建模,旨在修正基础模型的系统性误差。

模型优化过程中,采用随机搜索(Randomized Search CV)与时间序列交叉验证(Time Series Split)对随机森林的超参数进行调优,共进行50次迭代,最终确定最优参数组合为:{n_estimators: 500, max_depth: None, min_samples_split: 10, min_samples_leaf: 2, max_features: 'sqrt'}。残差模型同样经过网格搜索(Grid Search CV)优化,确定最佳参数为:{learning_rate: 0.05, max_depth: 6}。




Figure 1. TOP15 feature importance

图 1. TOP15 特征重要性

4. 基于随机森林的外卖到达量的预测方法

4.1. 研究方法

4.1.1. RF 模型构建

随机森林是一种基于 Bagging 思想的集成学习方法，其基本原理是通过对训练集进行自助采样 (bootstrap sampling)，并在每棵决策树的分裂过程中引入特征随机性，构建多棵独立的回归树，最终以多数投票或平均的方式得到整体预测结果。随机森林具有较强的泛化能力与鲁棒性，能够有效降低单一决策树的过拟合风险。

其预测公式可表示为：

$$\hat{y}_{RF}(x) = \frac{1}{M} \sum_{m=1}^M h_m(x)$$

其中， M 表示随机森林中决策树的数量， $h_m(x)$ 为第 m 棵树的预测结果。本文利用随机森林对外卖需求进行建模，获得初步预测值 $\hat{y}_{RF}$ 。

4.1.2. 模型参数设定与优化

在随机森林模型的构建过程中，超参数的选择会直接影响模型的预测性能。若参数设置不当，容易导致模型出现欠拟合或过拟合，从而降低预测精度。因此，本文在模型训练中引入了超参数调优过程。

具体而言，本文采用随机搜索(Randomized Search)方法对随机森林的关键超参数进行优化。与网格搜索(Grid Search)相比，随机搜索能够在给定的参数分布范围内随机抽取样本点进行评估，在计算效率和搜索广度上更具优势。同时，考虑到外卖需求数据的时间序列特征，本文在调参过程中结合时间序列交叉验证(Time Series Split)，以保证模型在时间维度上的泛化能力[9]。

在调优过程中，本文主要对以下超参数进行搜索，如表 1：

Table 1. Optimal hyperparameter configuration for random forest
表 1. 随机森林最优超参数设置

参数名	主要介绍	最优取值
n_estimators	表示森林中决策树的数量	409
max_depth	用于控制每颗决策树的最大深度	26
min_samples_split	规定了节点进行分裂所需的最小样本数	5
min_samples_leaf	指定了叶节点所需的最小样本数	2
max_features	每棵树在分裂节点时所能考虑的最大特征数	sqrt

4.1.3. RF-GBDT 模型构建

尽管随机森林能够有效建模复杂特征，但其预测结果与实际值之间仍然可能存在系统性误差。为进一步提升模型精度，本文引入残差序列建模思想。残差定义如下：

$$e_i = y_i - \hat{y}_{RF,i}$$

其中， y_i 为真是需求值， $\hat{y}_{RF,i}$ 为随机森林的预测值。残差序列 e_i 包含了随机森林未能捕捉的模式与特征，因此通过对残差建模，有助于对初试预测结果进行修正。

在残差建模环节，本文采用 Hist Gradient Boosting (直方图梯度提升)模型。该方法是梯度提升树(GBDT)的高效实现，其核心思想在于：通过直方图分桶(Histogram Binning)方式将连续特征离散化为固定数量的区间(bin)，并在区间层面寻找最佳分裂点，从而大幅减少计算量与内存消耗，同时保持较高的预测精度。Hist Gradient Boosting 在每一轮迭代中通过拟合残差的负梯度来更新模型，其更新公式为：

$$F_m(x) = F_{m-1}(x) + \eta \cdot h_m(x)$$

其中， $h_m(x)$ 表示基于直方图分析得到的回归树， η 为学习率。通过多轮迭代累积弱学习器，模型能够逐步逼近残差中的非线性规律。最终残差预测值可表示为： $\hat{e}_i = f_{HGB}(X_i)$

结合随机森林的基础预测结果与 Hist Gradient Boosting 的残差修正，最终预测模型可表示为：

$$\hat{y}_i = \hat{y}_{RF,i} + \hat{e}_i$$

其中， $\hat{y}_{RF,i}$ 表示随机森林的初试预测值， $\hat{e}_i$ 表示由 Hist Gradient Boosting 建模得到的残差修正项。

4.2. 实验结果与分析

4.2.1. 评价指标

在对组合模型的性能进行评估时，采用了多种指标以全面衡量其预测能力，包括 MSE、RMSE、MAE 以及 R^2 。MSE、RMSE、MAE 这些指标直接衡量模型预测的准确性，从不同角度反映误差分布；MSE 和 RMSE 量化预测误差的平方，突出大误差的影响；MAE 提供对所有误差的平均视角，适合异常值较多的场景； R^2 评估模型对目标变量变异的解释能力，用于比较模型的整体性能，提供无量纲的指标，便于跨数据集或跨模型比较。同时进行了预测值与真实值的散点图可视化分析，增强了对模型的直观理解，弥补了单一数值指标的局限性。

R^2 值反映了模型预测值与实际值之间的相关性， R^2 值越接近 1，说明模型的预测结果越接近实际数据。RMSE 是 MSE 的平方根，用于衡量模型预测值与实际值之间的平均误差大小。RMSE 值越小，模型的预测精度越高。MAE 是模型预测值与实际值绝对误差的平均值，用于衡量预测值与实际值的平均偏差大小。MAE 值越小，表示模型的预测误差越小。MAPE 是用于评估预测模型准确性的统计指标，以百分

比表示，MAPE 越接近 0%表示该模型越完美。RMSE、MAE、MAPE 和 R² 计算公式如下[10] [11]:

$$\begin{aligned} \text{RMSE} &= \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \\ \text{MAE} &= \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \\ \text{MAPE} &= \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \\ \text{R}^2 &= 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \end{aligned}$$

4.2.2. 模型评价结果

表 2、表 3 分别表示 RF 模型与 RF-GBDT 组合模型在训练集与测试集上的性能评估。

表 4 展示了单一随机森林模型与组合模型在测试集上的性能对比：

Table 2. Evaluation results for the random forest model

表 2. RF 模型评价结果

评估指标 RF 模型	训练集	测试集
RMSE	2.7397	5.8286
MAE	2.0900	4.5169
MAPE	2.3725%	4.4642%
R ²	0.9854	0.8672

Table 3. Evaluation results for the RF-GBDT model

表 3. RF-GBDT 模型评价结果

评估指标 RF-GBDT 模型	训练集	测试集
RMSE	1.2007	5.0183
MAE	0.9035	3.6573
MAPE	1.0423%	3.5804%
R ²	0.9972	0.9016

Table 4. Model performance comparison table

表 4. 模型性能对比表

模型 评估指标标	RMSE	MAE	MAPE	R ²
RF 模型	5.8286	4.5169	4.4642%	0.8672
RF-GBDT 模型	5.0183	3.6573	3.5804%	0.9016
提升(Δ)	0.8103	0.8596	0.8838%	0.0344

4.3. 模型对比分析

4.3.1. 模型预测分析

在训练集部分(见图 2), 模型预测值与真实值之间高度吻合, 两者的波动趋势几乎保持一致, 仅在部分极端峰值处存在轻微偏差。整体来看, 无论是单一随机森林模型还是组合预测模型, 都能够较好地拟合训练数据的走势。这说明模型在训练过程中学习到了时间序列的主要特征和规律, 具备较强的拟合能力。尤其是组合模型, 其在峰值和谷值点的表现更加接近真实情况, 进一步表明其在捕捉复杂非线性关系方面具有优势。




Figure 2. True values vs. model predictions on the training set

图 2. 训练集：真实值与模型预测对比

在测试集的预测结果对比中(见图 3), 可以观察到单一随机森林模型与组合模型在整体趋势上均能够较好地跟随真实值的变化, 但在部分峰值点和谷值点仍存在一定程度的偏差。其中, 随机森林模型在需求剧烈波动时表现出较大的滞后性, 预测值往往偏离真实值。而组合模型在多数情况下更为贴近真实曲线, 尤其在高峰期与低谷期的拟合效果更优, 能够有效缓解单一模型出现的系统性偏差。这表明, GBDT 与随机森林的组合预测能够在保持趋势拟合的同时, 提高对短期波动的捕捉能力。

4.3.2. 模型残差分析

在模型性能对比环节, 本文进一步对随机森林模型与 RF-GBDT 组合模型的残差分布进行了分析。

图 4 展示了两种模型在训练集上的残差表现。可以观察到, 单一随机森林模型的残差波动较为显著, 部分点的残差值超过 ± 4 , 说明该模型在处理时间序列中趋势性与季节性成分时存在一定不足。而组合模型在引入 Hist Gradient Boosting 对整体趋势进行建模后, 再利用随机森林对残差进行修正, 能够显著降低预测偏差。其残差分布更集中于零附近, 整体波动范围明显收窄, 极端误差点亦有所减少。这表明组合模型在捕捉时间序列趋势性与非线性波动方面具备更高的精度和稳定性。由此可以得出结论: 相比单一模型, RF-GBDT 组合模型能够更有效地抑制预测误差, 提升预测结果的可靠性。

在测试集上, 本文同样对两类模型的残差分布进行了对比(见图 5)。从结果可以看出, 随机森林模型




Figure 3. True values vs. model predictions on the test set
图 3. 测试集：真实值与模型预测对比




Figure 4. Residual comparison of models on the training set
图 4. 训练集：模型残差对比

在部分时间段的预测误差波动较大，尤其在需求剧烈变化的日期，残差值出现了明显的正负偏离。而组合模型的残差分布整体更加集中，极端误差点数量相对减少，表现出更好的稳定性和泛化能力。特别是在需求峰值时段，组合模型能够更好地拟合数据特征，从而降低了预测偏差。总体而言，组合模型在测试集上的表现与训练集结果一致，进一步验证了GBDT与随机森林相结合的有效性和适用性。




Figure 5. Residual comparison of models on the test set

图 5. 测试集：模型残差对比

5. 结论与展望

5.1. 研究结论

本研究聚焦于智能配送系统中的核心环节——外卖订单需求预测问题。针对订单数据所具有的时序性、非线性和高噪声等复杂特性，传统时间序列模型拟合能力不足的问题，本文提出了一种融合随机森林(Random Forest, RF)与直方图梯度提升(Hist Gradient Boosting)的两阶段 Stacking 集成学习框架(RF-GBDT 模型)。通过对真实外卖订单数据进行实证研究，本文主要得出以下结论：

1. 集成学习模型在复杂需求预测中显著优于传统模型。研究表明，单一的随机森林模型凭借其集成决策树的优势，能够有效捕捉特征与订单需求间的非线性关系，在测试集上取得了 $R^2 = 0.8672$ 的预测效果，证明了其在处理此类问题上的基本有效性。但其在需求峰值和谷值等剧烈波动点仍表现出一定的预测滞后性和偏差，揭示了单一模型在捕捉全部数据模式方面存在局限性。

2. RF-GBDT 两阶段 Stacking 框架能有效提升预测精度与稳健性。本研究的核心创新在于引入了残差学习机制。第二阶段利用 GBDT 对 RF 预测的残差进行建模，成功地捕获了 RF 模型未能学习的潜在数据模式和系统性误差。实验结果表明，该组合模型在所有关键评估指标上均一致性地优于单一 RF 模型：测试集的 RMSE 从 5.8286 降至 5.0183，MAE 从 4.5169 降至 3.6573，而解释方差 R^2 从 0.8672 提升至 0.9016。这充分验证了所提框架通过模型互补有效降低了预测误差，增强了模型的泛化能力。

3. 特征工程与超参数优化是模型成功的基石。本研究通过皮尔逊相关系数分析了多源特征(时空、天气、节假日等)与目标变量的相关性，为模型输入提供了科学依据。同时，采用随机搜索与时间序列交叉验证(Time Series Split)相结合的调参策略，确保了模型超参数的最优性及其在时间维度上的泛化能力，避免了过拟合，为模型的优异性能提供了坚实保障。

综上所述，本研究不仅验证了机器学习方法在外卖需求预测中的有效性，更重要的是，提出并验证了一种通过残差修正提升模型性能的可行路径。所构建的 RF-GBDT 模型为外卖平台提供了一个高精度、高稳健性的需求预测工具，为其实现动态调度、仓储优化和智能决策提供了可靠的数据驱动支持。

5.2. 研究的局限性

尽管本研究提出的 RF-GBDT 集成模型在外卖订单预测中表现出良好的性能,但仍存在若干局限性,主要源于数据获取、模型构建与实际应用场景之间的约束,具体包括以下四个方面:

首先,本研究在数据广度与深度方面存在不足。所使用数据集在时间跨度和空间范围上仍较为有限,未能纳入多个年份的数据以识别长期趋势与周期性变化,也缺乏多城市样本以验证模型的区域泛化能力。此外,数据粒度仍较粗糙,如未包含具体商圈动态、实时交通状态、商户促销强度等细粒度特征,限制了对微观影响因素的捕捉与建模能力。

其次,模型对突发性外部事件的适应能力较弱。尽管已引入常规节假日与天气指标,但对诸如突发公共卫生事件、区域性交通管制、大型社会活动或竞争平台的突发性促销等“黑天鹅”事件,尚未建立有效的识别与表征机制。这类事件极可能导致订单需求出现异常波动,而在当前模型框架下,其预测性能在极端场景下可能出现显著下降。

第三,模型在实时性与计算效率方面面临权衡挑战。RF-GBDT 组合模型虽显著提升预测精度,但其训练与推理过程的计算开销高于单一模型,尤其在面对超大规模订单数据且需进行实时或近实时预测时,可能难以满足工程部署中对响应速度的要求。本研究尚未涉及模型轻量化改进或在线学习机制的深入探索,因此在实用性和扩展性方面仍存在瓶颈。

最后,模型的可解释性仍有提升空间。尽管通过特征重要性排序初步识别出关键影响因素,但集成学习模型固有的“黑箱”特性尚未得到彻底解决。针对局部预测结果(如特定时间点的订单突变),本研究未引入如 SHAP、LIME 等可解释性工具进行深入分析,这在需要高透明度决策支持的业务场景中,仍是一个值得改进的方向。

综上所述,本研究在数据覆盖、突发事件响应、实时性保障与可解释性方面仍存在一定局限,也为后续研究提供了明确的改进方向。

5.3. 未来研究展望

基于本研究的成果与局限性,未来工作可从以下几个方向进一步深入探索:

首先,可推进多模态数据融合与深度特征提取的研究。通过引入社交媒体情感分析、实时交通路况、卫星影像等多源异构数据,并借助卷积神经网络(CNN)、图神经网络(GNN)等深度学习方法,自动挖掘非结构化数据中的深层特征,将其与现有结构化特征融合,构建更具表达力的多模态预测模型。

其次,应致力于开发自适应与实时更新的预测系统。针对模型实时性不足与突发事件响应弱的问题,可引入在线学习(Online Learning)机制,使模型能够依据新到达数据持续动态更新,迅速适应数据分布变化。同时,可集成异常检测模块,在识别到突发事件时自动触发模型调整或切换备用预测策略,以提升系统鲁棒性。

第三,融合时空图神经网络(ST-GNN)是另一个重要方向。外卖订单需求具有内在的时空关联特性,可将配送区域抽象为图结构中的节点,利用 ST-GNN 同时捕捉区域间复杂的空间依赖关系与时间动态变化,从而更精确地建模订单需求的时空传播规律,实现精细化区域预测。

此外,增强模型的可解释性与可信性也具有重要价值。通过引入可解释人工智能(XAI)技术(如 SHAP、LIME 等),对模型预测结果提供局部和全局解释,不仅能够提升业务人员对模型的信任,还可辅助运营决策,识别关键影响因素,推动从预测到决策的闭环优化。

最后,应推动预测与运营决策的闭环系统构建。未来研究需进一步将高精度预测结果与下游运营策略深度融合,如配送路径优化(VRP)、骑手调度、智能柜布局等,形成“预测-优化-决策”一体化智能

支持系统, 最终实现系统级效率提升与运营成本降低, 充分发挥预测模型在实际业务中的应用潜力。

致谢

在本文的研究与写作过程中, 我始终心怀感恩, 特别感谢我的导师张峥教授, 从选题的精准把关、研究框架的悉心指导到论文的反复雕琢, 其深厚的学术造诣、严谨的治学态度和前瞻性的学术视野让我在探索绿色数字化的道路上不断成长, 每一次耐心的点拨都使我对研究的理解更加深入。同时, 感谢课题组的各位同仁在日常研讨中给予的思想碰撞与热心帮助, 你们的智慧与支持让我在攻坚克难中收获颇丰。最后, 深深感恩家人一直以来的包容与鼓励, 你们的默默支持让我能够心无旁骛地投入学术探索, 是我不断前行的温暖动力。未来, 我将始终铭记这份恩情, 以更严谨的态度和更饱满的热情投身学术研究, 为相关领域的发展贡献更多力量。

基金项目

基于持续创新能力的上海战略新兴产业并购协同机理及路径研究(项目批准号: 2022ZGL013)。

参考文献

- [1] 焦扬庆, 张世文, 颜芳, 等. 基于特征筛选与随机森林的土壤有机质空间预测[J/OL]. 农业环境科学学报, 1-14. <https://link.cnki.net/urlid/12.1347.S.20250826.1558.004>, 2025-09-01.
- [2] 曹岚, 周成功, 袁斌霞, 等. 基于梯度提升回归树-自训练贝叶斯优化支持向量机的光伏阵列故障诊断方法[J]. 太阳能学报, 2025, 46(6): 289-297.
- [3] Chai, S.H., Lim, J.S., Yoon, H. and Wang, B. (2024) A Novel Methodology for Forecasting Business Cycles Using ARIMA and Neural Network with Weighted Fuzzy Membership Functions. *Axioms*, **13**, Article 56. <https://doi.org/10.3390/axioms13010056>
- [4] Pliakos, K., Geurts, P. and Vens, C. (2018) Global Multi-Output Decision Trees for Interaction Prediction. *Machine Learning*, **107**, 1257-1281. <https://doi.org/10.1007/s10994-018-5700-x>
- [5] Tanizaki, T., Hoshino, T., Shimmura, T. and Takenaka, T. (2019) Demand Forecasting in Restaurants Using Machine Learning and Statistical Analysis. *Procedia CIRP*, **79**, 679-683. <https://doi.org/10.1016/j.procir.2019.02.042>
- [6] 彭龙, 韩国庆, 郭书豪, 等. 基于机器学习算法的 CO₂ 腐蚀速率预测[J]. 西安石油大学学报(自然科学版), 2023, 38(2): 113-121.
- [7] 商文颖, 赵琳, 杨朔, 等. 基于多注意力融合与监督学习的城市能耗预测[J]. 北京邮电大学学报, 2025, 48(4): 33-38.
- [8] 刘洋, 高燕琳, 史芸萍, 等. 基于 ARIMA 模型和 ARIMA-SVM 组合模型的流行性感冒的发病预测研究[J]. 首都公共卫生, 2024, 18(4):195-200.
- [9] 成振华, 匡昭敏, 陶伟, 等. 基于随机森林的多蔗区甘蔗产量预测[J/OL]. 甘蔗糖业: 1-8. <https://link.cnki.net/urlid/44.1210.TS.20250815.1017.010>, 2025-08-26.
- [10] 张育杰, 李根, 解建勋, 等. 基于随机森林和 XGBoost 算法的管内流动沸腾传热特性预测研究[J/OL]. 北京航空航天大学学报: 1-17. <https://link.cnki.net/urlid/11.2625.V.20250807.1500.005>, 2025-08-21.
- [11] 亢金涛, 许振浩, 谢辉辉, 等. 基于钻进数据定量解译的隧道围岩完整性评价[J/OL]. 中南大学学报(自然科学版): 1-15. <https://link.cnki.net/urlid/43.1426.N.20250819.2231.002>, 2025-08-21.