

基于机器学习的多时间粒度需求预测研究

——以某制造企业供应链管理为例

谭俊辉, 邱一峰*

韩山师范学院数学与统计学院, 广东 潮州

收稿日期: 2025年4月29日; 录用日期: 2025年5月21日; 发布日期: 2025年5月30日

摘要

本文基于国内某大型制造企业在2015年9月1日至2018年12月20日面向经销商的出货数据, 探讨了在全球供应链不确定性加剧与数字化转型加速的背景下, 企业需求预测面临的多源异构数据整合、非线性波动(如疫情引发的“牛鞭效应”)和跨粒度决策协同等挑战。本文通过对比XGBoost、LightGBM和随机森林(RF)模型在月、周、日三种时间粒度下的预测性能。研究发现, 模型精度随预测频率提高呈系统性衰减, 并由此提出构建多粒度联合优化框架的必要性, 以实现不同决策层级的精度与资源分配平衡。

关键词

机器学习, 时间粒度, 需求预测

Research on Machine Learning-Based Demand Forecasting across Multiple Time Granularities

—A Case Study of Supply Chain Management in a Manufacturing Enterprise

Junhui Tan, Yifeng Qiu*

School of Mathematics and Statistics, Hanshan Normal University, Chaozhou Guangdong

Received: Apr. 29th, 2025; accepted: May 21st, 2025; published: May 30th, 2025

*通讯作者。

Abstract

Based on the shipment data of a large domestic manufacturing enterprise to distributors from September 1, 2015 to December 20, 2018, this article explores the context of intensified global supply chain uncertainties and accelerated digital transformation. Enterprise demand forecasting faces challenges such as the integration of multi-source heterogeneous data, nonlinear fluctuations (such as the “bullwhip effect” triggered by the epidemic), and cross-granularity decision-making collaboration. This paper compares the prediction performance of XGBoost, LightGBM and Random Forest (RF) models at three time granularities: month, week and day. The research finds that the model accuracy systematically decays with the increase of the prediction frequency. Based on this, the necessity of constructing a multi-granularity joint optimization framework is proposed to achieve the balance of accuracy and resource allocation at different decision-making levels.

Keywords

Machine Learning, Time Granularity, Demand Forecasting

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. 引言

在全球供应链不确定性加剧和数字化转型[1]的背景下,企业需求预测面临多源数据整合、非线性波动特征和跨层级决策协同三大挑战。复杂的外部环境让企业供应链面对诸多难题,传统统计模型已经不能满足需求,企业需要采用更先进的技术,用机器学习和深度学习来提高预测的准确性和效率。

现在的研究多集中于单一时间尺度的预测,比如只关注周预测或月预测。但实际企业运营中,不同决策层级,像战略、战术和运营层面,各自都需要不同时间尺度的预测来支持决策。

本文基于国内某大型制造企业 2015 至 2018 年的经销商出货数据,分析企业需求预测面临的三大难题:多源异构数据整合、需求波动的非线性(如疫情导致的“牛鞭效应[2]”)以及跨时间粒度的决策协同。研究选择了 XGBoost、LightGBM 和随机森林三种常用的机器学习模型,在月粒度、周粒度和日粒度三个时间维度上进行预测任务。通过对比分析,结果清楚地显示了单一时间粒度模型在实际应用中的局限性。接着,本文构建一个多粒度联合优化框架,目的是整合不同时间尺度预测模型的优势,平衡预测精度,从而提高企业需求预测的整体效果。

2. 数据预处理

2.1. 缺失值处理

本文数据来源于国内某大型制造企业在 2015 年 9 月 1 日至 2018 年 12 月 20 日面向经销商的出货数据。数据集在各字段层面不存在显性缺失值,表明数据采集与存储过程未发生技术性异常。然而,通过时间序列的连续性检验,发现全品类销售记录在特定日期呈现系统性空白,具体缺失时段包括:

- 2015 年 10 月 1 日~3 日(国庆法定假期);
- 2016 年 1 月 1 日(元旦假期);
- 2016 年 2 月 4 日~14 日、2017 年 1 月 24 日~2 月 2 日、2018 年 2 月 12 日~21 日(农历春节假期及调休)

期)。

此现象表明, 数据缺失并非由随机因素(如数据录入错误)导致, 而是与企业生产周期、经销商运营中断存在强因果关系, 属于典型的非随机缺失(MNAR)。

2.2. 重复值处理

使用 Python 中 pandas 库下 Dataframe 类的 `duplicated().sum()`方法, 对出货数据进行重复值分析, 发现在 597694 条原始数据中存在重复数据 312 条, 用 Dataframe 类的 `drop_duplicates()`方法, 将重复值删除, 剩余数据为 597,382 条。

2.3. 异常值处理

本研究采用分层循环处理异常值, 图 1 以商品唯一标识符(item_code)为分组依据, 对原始数据集进行多级处理。每个商品实体独立进入处理流程, 确保组内数据同质性与组间异质性分离, 消除跨商品混杂效应。流程核心步骤如下:

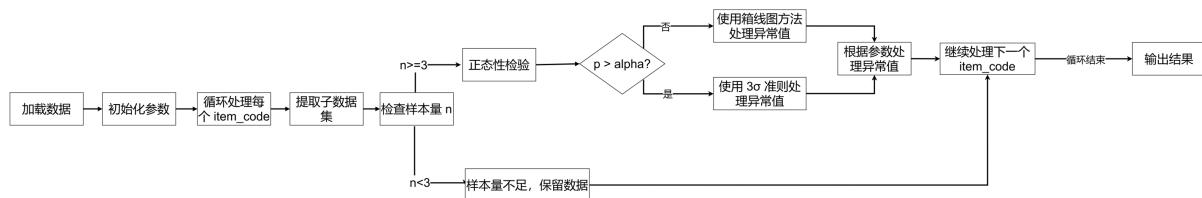


Figure 1. Outlier handling flowchart

图 1. 异常值处理流程图

- (1) 初始化参数: 设定显著性水平($\alpha = 0.05$)、样本容量阈值($n_{min} = 3$)及异常值处理策略(删除/填补)。
- (2) 外层循环迭代: 遍历所有 item_code, 依次提取子数据集 D_k 。

对于每个子集 D_k , 动态评估其样本容量 n_k , 并根据统计功效理论选择检验方法:

极小样本($n_k < 3$): 跳过检验, 保留原始数据。

有效样本($n_k > 3$):

$$\text{检验方法} = \begin{cases} \text{Shapiro-Wilk 检验} & 3 \leq n < 50 \\ \text{Kolmogorov-Smirnov 检验} & n \geq 50 \end{cases}$$

对于有效样本, 进行正态性检验[3]并根据 p 值与显著性水平 α 的关系, 采用以下规则确定异常值边界:

$$\text{异常值处理方法} = \begin{cases} 3\sigma \text{准则: } [\mu - 3\sigma, \mu + 3\sigma], & p > \alpha, \text{ 正态} \\ \text{箱线图方法: } [Q1 - 1.5 \cdot IQR, Q3 + 1.5 \cdot IQR], & p \leq \alpha, \text{ 非正态} \end{cases}$$

对子数据集 D_k 中的异常值执行删除操作。具体而言, 直接移除超出设定边界的数据点, 以确保数据集的纯净性。这一处理方式旨在避免异常值对后续分析结果产生偏差或误导, 从而提升数据质量, 为后续建模和分析提供可靠的数据基础。

3. 数据分析

3.1. 需求弹性对需求量的影响

需求弹性是经济学中的核心概念之一, 用于衡量需求量对价格变动的敏感程度[4]。根据弹性的大小,

可以将需求分为完全无弹性、无弹性、单位弹性、弹性、完全弹性五类。需求弹性的计算公式为:

$$PED = \frac{\% \Delta Q}{\% \Delta P}$$

其中, $\% \Delta Q$ 表示需求量的百分比变化, $\% \Delta P$ 表示价格的百分比变化。

基于上述模型, 我们对符合帕累托法则(80%)的商品进行了需求弹性分析[5], 结果如图 2 所示:

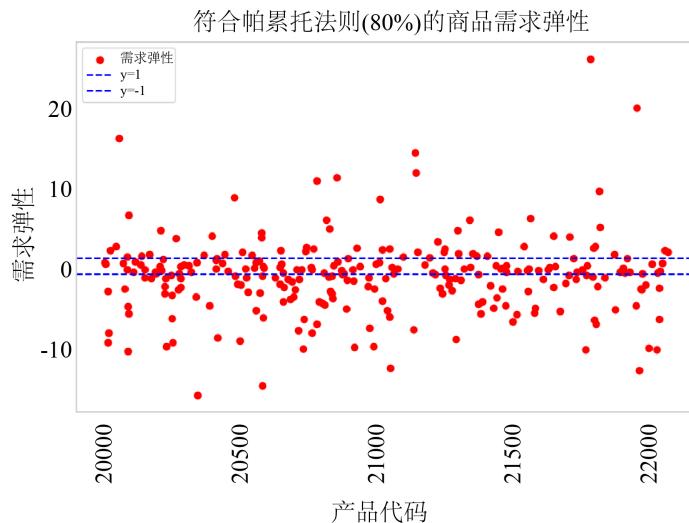


Figure 2. Analysis of price and demand elasticity

图 2. 价格与需求弹性分析

3.1.1. 弹性接近 1 或 -1 的商品

大部分商品的需求弹性接近 1 或 -1, 表明这些商品的需求量对价格变化较为敏感。价格的小幅变动可能导致需求量的相应变动。对于这些商品, 企业在制定价格策略时需要谨慎, 因为价格的调整可能会直接影响销量。

3.1.2. 弹性远大于 1 或远小于 -1 的商品

图中部分点远离 $y = 1$ 和 $y = -1$ 线, 表明这些商品需求弹性高(绝对值大于 1)或低(绝对值小于 -1)。高弹性商品需求量对价格变化敏感, 适合促销策略[6], 价格小降可显著提升销量; 低弹性商品需求量对价格变化不敏感, 促销效果不佳, 企业需考虑其他营销策略。

3.2. 产品类别对需求量的影响

帕累托图的分析方法基于“二八法则”, 即少数关键因素(约 20%)对结果的贡献占绝大部分(约 80%) [7]。通过识别这些关键因素, 企业可以更有效地分配资源, 优化管理策略。在供应链管理中, 这种方法有助于识别核心产品类别, 确保其供应链的稳定性和高效性[8], 同时对长尾产品进行合理管理, 避免资源浪费。

3.2.1. 核心产品与长尾产品的分布特征

图 3 显示, 首类产品(大类 306)需求量达 30.6×10^7 , 占总需求的 40%, 凸显其市场价值。前 5 类产品累计占比达 89%, 表明企业高度依赖少数核心产品。长尾产品(大类 301、303、304)需求量逐级递减, 末位产品仅占 0.2×10^7 , 累计占比不足 12%, 对整体需求贡献小, 可能存在库存积压或低效资源

占用问题。

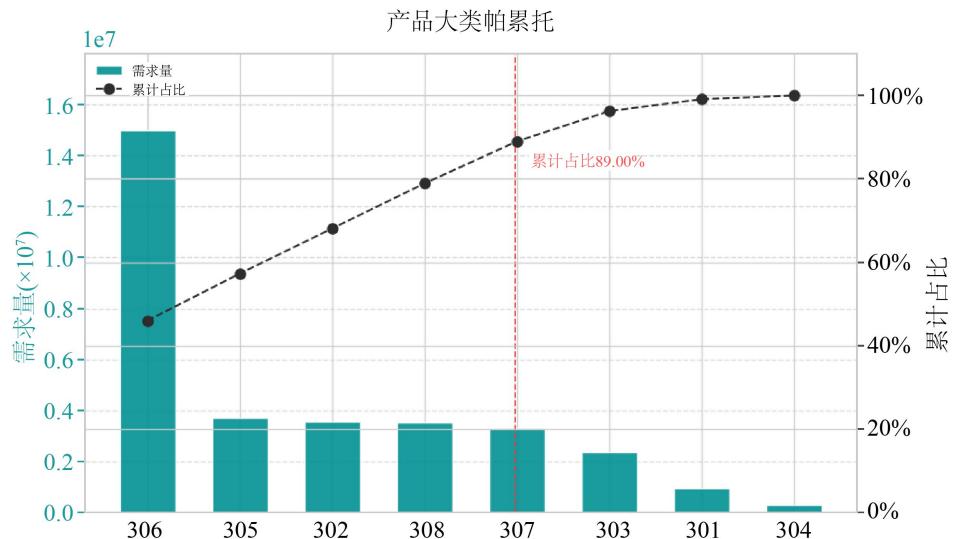


Figure 3. Product category Pareto chart
图 3. 产品大类帕累托图

3.2.2. 细分类别的分布特征

图 4 首类细类(细类 407)需求量达 14×10^7 , 占总需求的 40%, 是核心产品的主要贡献者。前 5 类细类累计占比达 85.12%, 存在明显的“二八效应”。长尾细类需求量低, 累计占比增长缓慢, 对整体需求贡献有限。

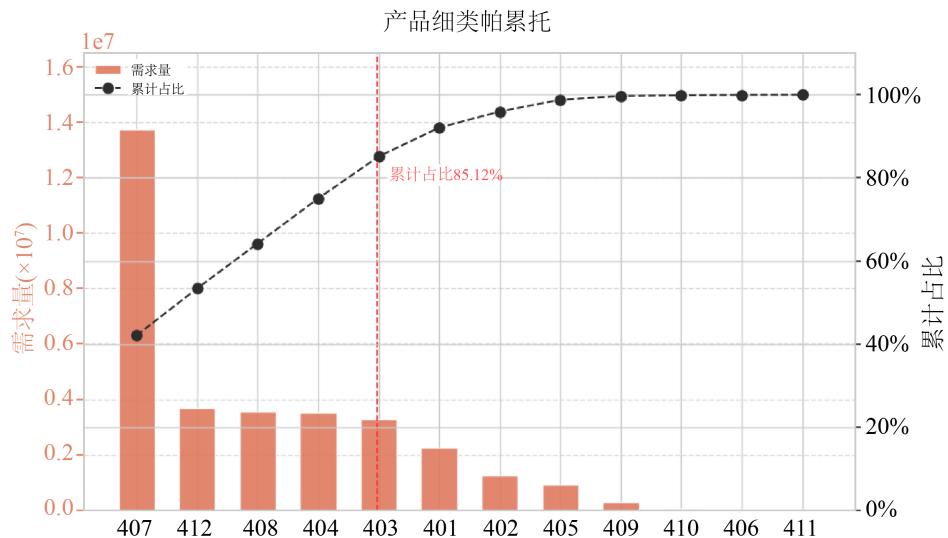


Figure 4. Product subcategory Pareto chart
图 4. 产品细类帕累托图

3.2.3. 产品大类与细类的对应关系

表 1 产品大类与细类的对应关系表明, 核心大类主要由少数高需求细类驱动。大类 306 由细类 407

和 402 组成, 需求量最高; 而大类 303 虽包含多个细类(410、401、406、411), 但整体需求量较低, 显示细类间需求分布不均。

Table 1. The correspondence between major and minor product categories
表 1. 产品大类与细类对应关系

大类编号	对应细类编号
301	405
302	408
303	410, 401, 406, 411
304	409
305	412
306	407, 402
307	403
308	404

3.3. 节假日及周末对需求量的影响

本文基于中国法定节假日及周末的销售数据, 分析促销活动对商品需求量的影响。通过对比不同日期类型(普通日、周末、节假日)的日均销量, 据图 5 探究促销策略在特定时间段的实施效果。

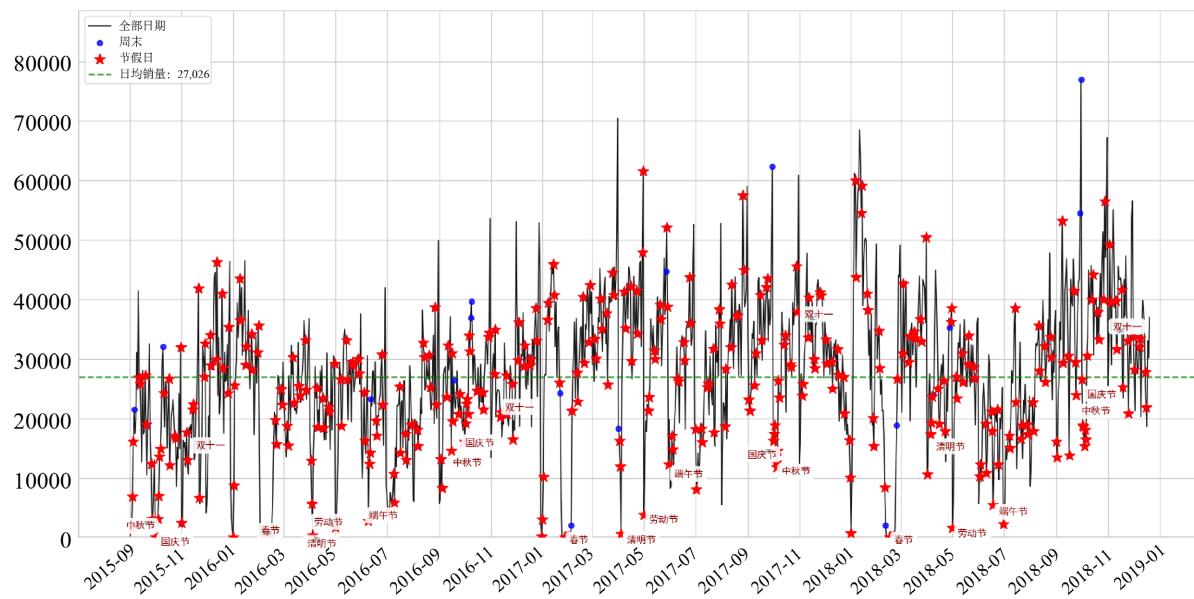


Figure 5. Graph of demand changes during holidays and weekends
图 5. 节假日及周末需求量变化图

3.3.1. 节假日需求量的特点

节假日需求量波动大, 部分显著高于平均值, 部分低于平均值。消费高峰或活动增加的节假日需求量极高, 可达全年峰值; 而人们减少外出或消费意愿低的节假日需求量则低, 与节假日性质相关。

3.3.2. 周末需求量特点

周末需求量波动大, 可能接近最高值或低于平均水平。通常高于工作日, 但受天气等因素影响, 部分周末可能低于平均水平。

4. 产品需求量预测

4.1. 集成学习方法

集成学习通过整合多个基学习器提升模型精度和泛化能力[9], 主要分为 Bagging 和 Boosting 两种范式。基学习器可以是异构或同构模型。

- **Bagging:** 采用 Bootstrap 重采样生成多个训练子集(约 63.2% 的样本有放回抽样), 并行训练多个基模型(如决策树)。分类任务采用多数表决, 回归任务采用算术平均。Bagging 降低模型方差, 优化高方差基模型, 增强抗干扰能力和预测稳定性, 抑制过拟合, 优化决策边界。
- **Boosting:** 模型训练采取序列化方式, 每次训练后调整样本权重, 误分类样本权重提升, 聚焦难以处理的样本。通过加权求和整合基模型预测结果。从初始权重开始, 逐步调整权重训练新的弱学习器, 直至达到预定数量, 最终形成强学习器。Boosting 通过迭代调整权重, 逐步提升模型性能。

4.2. 模型评估指标

本研究采用平均绝对误差(MAE)、均方根误差(RMSE)和决定系数(R^2)三类指标, 综合评估模型的预测精度与拟合能力。

4.2.1. 平均绝对误差(Mean Absolute Error, MAE)

MAE 反映预测值与真实值的平均绝对偏差, 计算公式为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

其中, y_i 为真实值, \hat{y}_i 为预测值, n 为样本量。MAE 量纲与因变量一致, 对异常值不敏感, 适用于需均衡评估整体偏差的场景。

4.2.2. 均方根误差(Root Mean Square Error, RMSE)

RMSE 通过平方运算放大较大误差的影响, 计算公式为:

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

RMSE 与 MAE 量纲相同, 但对异常值敏感, 更适用于需严控极端误差的工程场景。

4.2.3. 决定系数(Coefficient of Determination, R^2)

R^2 衡量模型对因变量变异的解释能力, 计算公式为:

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

其中, \bar{y} 为真实值均值。 R^2 取值范围为 $[0, 1]$, 值越接近 1 表示模型拟合效果越优, 但需结合 RMSE/MAE 避免过拟合误判。

4.3. 特征工程体系

4.3.1. 滞后窗口特征

基于时间序列的惯性效应, 引入历史观测值的滞后项作为特征[10]。设时间序列为 Q_t , 滞后窗口特征

定义为:

$$Lag_w(t) = Q_{t-w}$$

其中, 滞后窗口长度 w 的选取与业务周期严格对齐, 特征构造仅依赖历史观测值, 具体策略如下表 2 所示:

Table 2. Lagging window feature application strategy table
表 2. 滞后窗口特征应用策略表

时间粒度	窗口集合	业务意义
月粒度	$w \in \{1, 3, 6, 12\}$	月度需求惯性修正、季度业务对齐、半年度计划回溯、年度周期性复盘
周粒度	$w \in \{1, 4, 12, 24\}$	周内运营惯性、月度趋势映射、季度传导效应、半年度规律捕捉
日粒度	$w \in \{7, 14, 30\}$	周内行为模式、双周活动关联、月内策略对齐

4.3.2. 滑动窗口特征

滑动窗口特征通过聚合历史窗口内的统计量, 提取时间序列的局部趋势与波动规律[10]。设时间序列为 Q_t , 窗口宽度为 w , 核心特征定义如下:

$$\begin{aligned} Mean_w(t) &= \frac{1}{w} \sum_{k=1}^w Q_{t-w+k} \\ Std_w(t) &= \sqrt{\frac{1}{w-1} \sum_{k=1}^w (Q_{t-w+k} - Mean_w(t))^2} \\ Max_w(t) &= \max \{Q_{t-w-1}, Q_{t-w}, \dots, Q_{t-1}\} \end{aligned}$$

窗口宽度的选择需与业务复盘周期对齐, 具体策略如下表 3 所示:

Table 3. Sliding window feature application strategy table
表 3. 滑动窗口特征应用策略表

时间粒度	窗口集合	业务意义
月粒度	$w \in \{3, 6, 12\}$	季度需求平滑、半年度波动抑制、年度基线生成
周粒度	$w \in \{4, 12, 24\}$	月度趋势提取、季度噪声过滤、半年度异常检测
日粒度	$w \in \{7, 14, 30\}$	周内均衡分析、双周弹性规划、月内风险预警

4.3.3. 节假日与周末特征

在时间序列预测中, 捕捉关键日期效应是提升模型精度的重要手段。通过统计当前月、周、日的节假日天数和周末天数。

4.4. 参数优化

优化方法

RandomizedSearchCV 是 scikit-learn 库中用于超参数优化的一种方法, 通过随机采样的方式在超参数空间中寻找最优的超参数组合。与 GridSearchCV 不同, RandomizedSearchCV 不会穷举所有可能的超参数组合, 而是通过随机采样来减少计算量, 同时仍然能够找到接近最优的超参数组合。

RandomizedSearchCV 的核心思想是:

- 1) 在超参数空间中随机采样一定数量的超参数组合。
- 2) 对每个采样的组合进行交叉验证, 评估模型性能。
- 3) 选择性能最好的超参数组合作为最终结果。

这种方法特别适合于超参数空间较大或计算资源有限的情况, 因为它可以显著减少计算时间。下表 4, 是 RandomizedSearchCV 的主要参数及其作用:

Table 4. The main parameters of RandomizedSearchCV

表 4. RandomizedSearchCV 的主要参数

参数名	作用
estimator	用于训练的模型
param_distributions	超参数的分布或取值范围。可以是字典, 其中键是超参数名称, 值是可能的取值列表或分布。
n_iter	随机采样的次数
cv	交叉验证的折叠数
random_state	随机种子, 用于保证结果的可复现性。
scoring	评估指标
n_jobs	并行计算的 CPU 核心数
verbose	控制输出的详细程度

4.5. 各时间粒度预测分析

表 5 展示了 XGBoost [11]、LightGBM [12]和随机森林(RF) [13]模型在月、周、日三种时间粒度下的预测性能, 评估指标包括决定系数(R^2)、平均绝对误差(MAE)和均方根误差(RMSE)。

Table 5. Model evaluation under different time granularities

表 5. 不同时间粒度下的模型评估

模型	评估模型								
	月			周			日		
	R^2	MAE	RMSE	R^2	MAE	RMSE	R^2	MAE	RMSE
XGBoost	0.69	115.02	451.67	0.58	33.50	146.05	0.32	8.38	40.71
LightGBM	0.69	113.27	451.64	0.58	32.99	145.91	0.32	8.16	40.80
RF	0.68	117.97	456.48	0.57	34.55	146.41	0.32	8.52	40.81

4.5.1. 模型性能表现

在月粒度预测中, XGBoost 和 LightGBM 的 R^2 均为 0.69, 拟合程度相当, LightGBM 的 MAE 和 RMSE 最低(MAE = 113.27, RMSE = 451.64), 表现最优; XGBoost 稍逊(MAE = 115.02, RMSE = 451.67); RF 的 R^2 为 0.68, 精度最低(MAE = 117.97, RMSE = 456.48)。

在周粒度预测方面, 三种模型拟合程度和精度接近, XGBoost 的 R^2 最高($R^2 = 0.58$, MAE = 33.50, RMSE = 146.05), 表现稍好; LightGBM (MAE = 32.99, RMSE = 145.91)和 RF (MAE = 34.55, RMSE = 146.41)表现相当。

对于日粒度预测, 三种模型 R^2 均为 0.32, 拟合有限。RF 的 MAE 最低(MAE = 8.16), 表现稍优; XGBoost (MAE = 8.38, RMSE = 40.71)和 LightGBM (MAE = 8.52, RMSE = 40.81)精度相近, XGBoost 的 RMSE 略低。

4.5.2. 时间粒度对模型性能的影响

从时间粒度的角度来看, 从月到周再到日, 模型的 R^2 值普遍下降, 数据复杂性和波动性增加, 拟合难度加大。月粒度数据波动小, 易捕捉趋势, 拟合程度高; 日粒度波动强, 拟合难度大, R^2 值低。

在预测精度方面, 月粒度预测的 MAE 和 RMSE 值较大, 因时间跨度长, 累积误差大; 周粒度和日粒度误差值较小, 因短期波动性强, 模型能更精确反映实际波动。

4.5.3. 未来研究方向

本次研究指出单一粒度模型的局限性, 为未来研究提供启示。未来应构建多粒度联合优化框架, 综合考虑各时间粒度的数据特征和预测需求, 平衡预测精度与资源分配。

4.6. 多粒度联合优化

在单一时间粒度下, 模型预测受限。日粒度预测受高频噪声干扰, 传统时序特征对瞬时需求激增解释力不足, 导致难以捕捉短期快速变化, 影响精度。为此, 本研究引入周粒度和月粒度的滞后窗口、滑动窗口及周期性特征, 构建多粒度联合优化框架, 增强模型鲁棒性和精度。

4.6.1. 多粒度特征构建

在日粒度时间序列中, 除了传统的滞后窗口特征和滑动窗口特征, 我们引入以下特征:

(1) 滞后窗口特征

周粒度引入过去 1、4、12 周的值, 捕捉短期运营惯性与趋势, 弥补日粒度特征的不足。

月粒度计算过去 1 个月、3 个月、6 个月的数据均值、方差、最大值、最小值, 精准提取局部趋势和波动规律, 为高频波动提供长期趋势参考。

(2) 滑动窗口特征

周粒度计算过去 4 周和 12 周的均值、方差、最大值、最小值, 找出局部趋势和波动规律, 帮助模型应对高频噪声, 更准确预测未来需求。

月粒度计算过去 3 个月、6 个月的均值、方差、最大值、最小值, 平滑长期数据波动, 为模型提供稳定的参考基准, 增强对长期趋势的捕捉能力。

(3) 周期性特征

周粒度引入周粒度周期性编码, 动态调整周编号, 量化促销活动需求衰减效应及周内运营规律, 增强对瞬时需求激增的预测能力。

月粒度引入月度周期性编码, 动态相位偏移 = 8, 将月份编码与自然年份 1 月对齐, 精准捕捉季节性规律, 为日度数据的瞬时需求激增提供周期性背景信息。

4.6.2. 多粒度联合优化框架

通过整合上述多粒度特征, 构建多粒度联合优化框架[14]。该框架的核心在于:

1) 特征融合: 融合日、周、月粒度特征, 形成综合特征集, 使模型同时捕捉短期波动和长期趋势, 增强对高频噪声的适应能力。

2) 模型优化: 基于多粒度特征优化 XGBoost、LightGBM 和随机森林等模型, 提升其在高频噪声和复杂周期性变化下的鲁棒性和预测性能。

4.6.3. 多粒度协同预测

从表 6 中可以看出, 多粒度联合优化框架显著提升了模型的预测性能。具体而言:

- **XGBoost:** $R^2 = 0.56$, MAE = 5.93, RMSE = 32.57, 多粒度特征支持下显著降低误差, 对日粒度高频噪声鲁棒性强。
- **LightGBM:** $R^2 = 0.57$, MAE = 6.06, RMSE = 32.49, 表现最佳, R^2 最高且 RMSE 最低, 对日粒度瞬时需求激增预测精准。
- **RF:** $R^2 = 0.55$, MAE = 6.51, RMSE = 32.15, R^2 略低但 RMSE 最低, 对日粒度高频波动稳定性好。

Table 6. Multi-granularity model evaluation

表 6. 多粒度的模型评估

模型	评估模型		
	R^2	MAE	RMSE
XGBoost	0.56	5.93	32.57
LightGBM	0.57	6.06	32.49
RF	0.55	6.51	32.15

5. 总结

5.1. 研究主要发现

5.1.1. 需求价格弹性

- 弹性接近 1 或 -1: 大多数商品对价格变化敏感, 需在定价时谨慎。
- 弹性极端值: 高弹性商品适合促销, 低弹性商品需其他营销策略。
- 异常值: 需求弹性异常的商品需进一步分析, 以理解其背后原因。

5.1.2. 产品类别

企业应优先保障核心产品的供应链稳定性, 确保库存充足和供应链畅通。对长尾产品进行需求评估, 精简库存, 避免积压。对高需求细类实施精细化管理, 对低需求细类考虑合并或淘汰, 以优化产品线。

5.1.3. 节假日效应

节假日需求波动大, 部分节假日因消费高峰或活动增加, 需求量显著高于平均值, 甚至达全年峰值; 而部分节假日因人们减少外出或消费意愿低, 需求量低于平均值, 与节假日性质有关。

周末需求波动较大, 通常高于工作日, 因购物、餐饮和娱乐活动增加。但受天气、活动安排等外部因素影响, 部分周末需求量可能低于平均值。

5.2. 预测建模对比

5.2.1. 单一预测

- 月粒度: XGBoost 和 LightGBM 的 R^2 值均为 0.69, 对长期趋势敏感但忽视突发波动; RF 的 R^2 为 0.68, 精度最低。
- 周粒度: XGBoost ($R^2 = 0.58$, MAE = 33.50) 和 LightGBM ($R^2 = 0.57$, MAE = 33.27) 接近, 对节假日响应滞后; RF ($R^2 = 0.57$, MAE = 34.55) 稍逊。
- 日粒度: 三种模型 R^2 值均为 0.32, 拟合有限。RF (MAE = 8.16) 最佳, 但仍难捕捉瞬时需求激增, 需

融合实时数据提升性能。

5.2.2. 多粒度协同

本文提出多粒度协同预测框架，整合不同时间尺度信息，减少高频噪声影响，关注长期趋势和周期性规律，提升模型稳定性。引入滞后窗口和滑动窗口特征后，XGBoost 的 R² 提升至 0.56，MAE 为 5.93，RMSE 为 32.57；LightGBM 的 R² 提升至 0.57，MAE 为 6.06，RMSE 为 32.49；RF 的 R² 为 0.55，MAE 为 6.51，RMSE 为 32.15。动态相位偏移和周期性编码助力精准捕捉季节性和短期运营规律，提升预测性能。该框架显著提升制造业需求预测的准确性和鲁棒性，为供应链优化和动态决策提供支持。未来可探索多粒度特征与深度学习模型结合，应对复杂业务场景和数据挑战。

基金项目

韩山师范学院博士启动项目(编号：XJ2022001502)。

参考文献

- [1] 贾建鸿, 叶春明. 数字化转型对物流企业供应链管理的影响[J]. 物流科技, 2022, 45(18): 105-109.
- [2] Bhattacharya, R. and Bandyopadhyay, S. (2010) A Review of the Causes of Bullwhip Effect in a Supply Chain. *The International Journal of Advanced Manufacturing Technology*, **54**, 1245-1261.
<https://doi.org/10.1007/s00170-010-2987-6>
- [3] Djonguet, T.K.M. and Nkiet, G.M. (2025) Asymptotic Normality for Kernel-Based Test of Conditional Mean Independence in Hilbert Space. *Mathematica Slovaca*, **75**, 215-224. <https://doi.org/10.1515/ms-2025-0017>
- [4] Kapsalyamova, Z., Juatova, S., Azhgaliyeva, D. and Ouarda, T.B.M.J. (2025) Measuring Energy Poverty by Estimating the Income Elasticity of Energy Demand: An Application to Kazakhstan. *Utilities Policy*, **95**, Article ID: 101901.
<https://doi.org/10.1016/j.jup.2025.101901>
- [5] Nar, M. (2021) The Relationship Between Income Inequality and Energy Consumption: A Pareto Optimal Approach. *The Journal of Asian Finance, Economics and Business (JAFeB)*, **8**, 613-624.
- [6] 李佳楠, 金晓彤, 赵太阳, 等. 体验与实物商品价值评估中消费者价格线索敏感性的非对称效应[J]. 南开管理评论, 2024, 27(8): 135-147.
- [7] Alkiyat, M. (2021) A Practical Guide to Creating a Pareto Chart as a Quality Improvement Tool. *Global Journal on Quality and Safety in Healthcare*, **4**, 83-84. <https://doi.org/10.36401/jqsh-21-x1>
- [8] Sun, F., Qu, Z., Wu, B. and Bold, S. (2024) Enhancing Global Supply Chain Distribution Resilience through Digitalization: Insights from Natural Resource Sector of China. *Resources Policy*, **95**, Article ID: 105169.
<https://doi.org/10.1016/j.resourpol.2024.105169>
- [9] Zhang, C. and Ma, Y.Q. (2012) Ensemble Machine Learning. Springer. <https://doi.org/10.1007/978-1-4419-9326-7>
- [10] Sun, R., Huang, W., Dong, Y., Zhao, L., Zhang, B., Ma, H., et al. (2022) Dynamic Forecast of Desert Locust Presence Using Machine Learning with a Multivariate Time Lag Sliding Window Technique. *Remote Sensing*, **14**, Article 747.
<https://doi.org/10.3390/rs14030747>
- [11] Pritam, P.D. and Joyce, W. (2024) XGBoost for Regression Predictive Modeling and Time Series Analysis: Learn How to Build, Evaluate, and Deploy Predictive Models with Expert Guidance. Packt Publishing Limited.
- [12] Sadig, H.E., Kamal, M., Rehman, M.u., Habadi, M.I., Alnagar, D.K., Yusuf, M., et al. (2025) Advanced Time Complexity Analysis for Real-Time COVID-19 Prediction in Saudi Arabia Using LightGBM and XGBoost. *Journal of Radiation Research and Applied Sciences*, **18**, Article ID: 101364. <https://doi.org/10.1016/j.jrras.2025.101364>
- [13] Zhang, Y., Wu, X., Tian, Z., Gao, W., Peng, H. and Yang, K. (2023) Comparison of Random Forest, Support Vector Regression, and Long Short Term Memory for Performance Prediction and Optimization of a Cryogenic Organic Rankine Cycle (ORC). *Energy*, **280**, Article ID: 128146. <https://doi.org/10.1016/j.energy.2023.128146>
- [14] Kammoun, M.A., Hajej, Z., Bennour, S., Salem, N., Mabrouk, O.E. and Baccar, A. (2025) Deep Learning Framework for Multi-Demand Forecasting and Joint Prediction of Production, Distribution, and Maintenance across Multiple Manufacturing Sites. *The International Journal of Advanced Manufacturing Technology*, **136**, 2349-2376.
<https://doi.org/10.1007/s00170-024-14916-7>