

基于LSTM-随机森林组合模型的电商平台产品需求预测

刘 湘, 王 静

武汉科技大学管理学院, 湖北 武汉

收稿日期: 2025年8月11日; 录用日期: 2025年8月25日; 发布日期: 2025年9月9日

摘 要

精准的产品需求预测是电商平台优化供应链管理、降低库存成本及提升用户体验的核心环节。然而, 电商场景中的需求数据具有高波动性、非线性和受多因素(如促销、季节性变化、用户行为等)影响的复杂特征, 传统预测方法难以有效应对。本研究提出一种基于长短期记忆网络(LSTM)和随机森林(Random Forest, RF)的组合预测模型, 通过融合LSTM的时序特征提取能力与随机森林的非线性建模优势, 显著提升了电商场景下的需求预测精度。通过整合某电商平台四类核心产品(电子产品、服装服饰、家居用品、美妆个护)的历史数据, 结果表明, 组合模型在促销期突发需求和季节性波动场景中表现尤为突出, 为电商平台的智能补货、库存优化及动态定价策略提供了有力支持。

关键词

电商需求预测, LSTM, 随机森林, 组合模型

Inventory Demand Forecasting for E-Commerce Platforms Based on Combined LSTM-Random Forest Modeling

Xiang Liu, Jing Wang

School of Management, Wuhan University of Science and Technology, Wuhan Hubei

Received: Aug. 11th, 2025; accepted: Aug. 25th, 2025; published: Sep. 9th, 2025

Abstract

Accurate product demand forecasting is the core link of e-commerce platforms to optimize supply

文章引用: 刘湘, 王静. 基于 LSTM-随机森林组合模型的电商平台产品需求预测[J]. 电子商务评论, 2025, 14(9): 1023-1035. DOI: 10.12677/ecl.2025.1493008

chain management, reduce inventory costs, and improve user experience. However, demand data in e-commerce scenarios has high volatility, nonlinearity, and complex characteristics affected by multiple factors (such as promotions, seasonal changes, user behavior, etc.), making it difficult for traditional forecasting methods to effectively deal with them. This study proposes a combined prediction model based on long short-term memory network (LSTM) and random forest (RF), which significantly improves the accuracy of demand prediction in e-commerce scenarios by combining the temporal feature extraction ability of LSTM with the nonlinear modeling advantages of random forest. By integrating the historical data of the four core products (electronic products, clothing, household products, beauty and personal care) of an e-commerce platform, the results show that the combined model is particularly prominent in the sudden demand and seasonal fluctuation scenarios during the promotion period, providing strong support for the intelligent replenishment, inventory optimization and dynamic pricing strategy of the e-commerce platform.

Keywords

E-Commerce Demand Forecasting, LSTM, Random Forest, Combinatorial Modeling

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. 电商需求预测的挑战与研究背景

在数字经济迅猛发展的浪潮中,电子商务已成为全球贸易的核心引擎,2024 年全球电商交易额突破 30 万亿美元。在这一背景下,精准的产品需求预测成为电商平台提升运营效率、优化用户体验的关键。然而,电商需求预测面临三重独特挑战: 1) 需求波动性更强: 电商平台的“大促经济”(如 618、双 11)导致需求在短期内呈指数级增长; 2) 非线性特征: 用户行为、季节性变化与促销策略的交互作用使得需求模式复杂; 3) 多因素耦合: 价格敏感度、用户复购率、社交媒体舆情等静态与动态特征共同影响需求。

传统时间序列预测方法(如 SARIMA 和指数平滑)在应对实际电商场景中的非线性需求波动和多因素耦合影响时,其预测 RMSE 通常比机器学习模型高 20%~30% [1]。这类方法通常依赖于线性假设和固定参数,难以自适应地捕捉市场需求的动态性和复杂季节性特征[2]。近年来,机器学习与深度学习技术也开始进入电商场景的应用。LightGBM 作为高效的梯度提升框架,凭借训练速度快、内存占用少的优势,在产品需求预测中展现出对特征交互的强处理能力[3],且在大规模电商数据场景下的特征挖掘效率显著优于传统模型[4]。长短期记忆网络(LSTM)作为循环神经网络的改进版本,能有效处理时间序列的长期依赖问题[5],在电商销量、用户流量等时序预测任务中表现出对非线性特征的强捕捉能力,且对数据平稳性要求较低[6]。随机森林则作为基于决策树的集成算法,凭借抗过拟合能力和高维数据处理优势,在各类预测任务中表现稳健。范华鹏等在滇西北森林碳储量估测中面临的复杂生态因子数据,仍能通过多树集成的随机性降低模型对局部数据的过度依赖[7]。芦杨笛等采用 NOA 优化的随机森林处理砂岩孔隙度预测中的高维物探数据时,其表现优于传统线性模型[8]。

然而,单一模型的适用场景存在边界: 树模型(如 LightGBM)难以建模电商“预售期-爆发期-返场期”的长周期时序依赖,而 LSTM 对用户复购率、促销标识等静态特征的处理效率较低[9]。为克服单一模型的局限性,研究者开始探索混合模型在电商预测中的协同效应,部分研究尝试将不同模型进行组合,以提升预测性能,梅俊涛等提出的 LSTM-LightGBM 分层框架,通过 LSTM 提取时序特征后融合静态特征,在用户购买预测中降低 MAE 22%,但未充分考虑电商促销的“短周期强冲击”特性[10]; 李琼等构

建的 GRU-BP 组合网络, 通过捕捉多型号产品的相互制约关系, 为复杂需求形态下的生产与库存管理提供决策支持[11]; Wang 等采用变权重组合方法, 让 LSTM 与 LightGBM 分别建模时序残差与非线性关系, 优化了电商促销期的库存调配, 但对多品类泛化能力不足(如电子产品与服装的需求模式差异显著)。[12]; Tian 等提出的多层双向 LSTM-BO-LightGBM 模型, 在股票波动预测中展现出更强的逼近能力[13]; 杨凡则结合 GRU 的时序依赖捕捉能力与 Transformer 的多头注意力机制, 实现组织间交互模式的建模, 但计算成本过高, 难以适配电商平台数千 SKU 的实时预测需求[14]。

近年来, 其他新兴混合模型也在时序预测领域崭露头角, 但在电商库存场景中仍存在适配性局限: 时间卷积网络(TCN)凭借局部感受野与膨胀机制在短序列特征提取中表现优异[15], 赵钰逸等将 GA 其与 BP 神经网络结合, 在短期需求预测中实现 MAE 降低到 0.14%, 但因长程依赖捕捉不足, 在电商大促跨周期场景中泛化性受限[16]; 吴昊构建的 iWOA-iTransformer 模型通过改进鲸鱼优化算法优化 Transformer 超参数, 虽适用于多变量非线性预测, 但 Transformer 的多头注意力机制计算成本高, 难以适配电商数千 SKU 的实时预测[17]。

尽管上述研究推动了混合模型的发展, 但现有模型在电商跨产品泛化能力上仍有提升空间[18], 尤其在面对数千 SKU 的异构需求模式(稳定型、季节性波动型、突发型等), 模型的扩展性面临严峻挑战。本文针对电商场景的实证研究, 旨在通过真实电商数据验证 LSTM 与随机森林组合模型的有效性与实用性。

针对电商需求预测的场景特性, 本文提出 LSTM-随机森林组合模型: 利用 LSTM 捕捉长周期时序依赖(如季节性趋势、大促周期), 通过随机森林融合多源静态特征(如促销力度、品类属性), 实现“时序-静态”特征的协同建模。相较于现有研究, 创新点在于专门针对电商场景中, 验证“LSTM 捕捉长周期时序趋势 + 随机森林融合多源静态特征”这一混合策略的有效性。通过与多类基线模型对比, 该组合在大促期、跨品类场景中表现稳健, 为同类混合模型的场景化应用提供可复现的实证参考。

2. 电商场景下的 LSTM-随机森林组合模型原理

2.1. 长短期记忆网络(LSTM): 电商时序特征的捕捉机制

LSTM 是循环神经网络(RNN)的改进版本如图 1, 其独特的记忆单元结构有效解决了 RNN 在处理长序列时出现的梯度消失问题, 使其能够更好地捕捉时间序列中的长期依赖关系, 尤其适配电商“长周期 + 短脉冲”的需求特征。在电商场景中, LSTM 的核心价值体现在: ①捕捉大促周期规律: 电商大促




Figure 1. LSTM recurrent neural network
图 1. LSTM 循环神经网络

通常遵循“预售期(提前 2 周)-爆发期(1~3 天)-返场期(1 周)”的周期模式, LSTM 的记忆单元可保留预售期订单数据, 为爆发期需求预测提供依据。②适配季节性波动: 服装、美妆等品类存在显著季节周期, LSTM 的输入门可强化季节特征权重, 输出门动态调整季节趋势对当前需求的影响。

LSTM 的记忆单元包含遗忘门、输入门和输出门, 通过这三个门的协同工作, 控制信息的流入、流出和保留。LSTM 的相关公式如下:

$$i_t = \sigma(W_i x_t + H_i h_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma(W_f x_t + H_f h_{t-1} + b_f) \quad (2)$$

$$o_t = \sigma(W_o x_t + H_o h_{t-1} + b_o) \quad (3)$$

$$\tilde{c}_t = \tanh(W_c x_t + H_c h_{t-1} + b_c) \quad (4)$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (5)$$

$$h_t = o_t * \tanh(c_t) \quad (6)$$

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (8)$$

其中, i_t 为输入门, 决定记忆单元中需要更新的信息(如大促前 14 天的销量增长趋势); f_t 为遗忘门, 决定从记忆单元中丢弃的信息(如非促销期的偶然波动); o_t 为输出门, 决定记忆单元输出的信息(如预测大促当天的需求基数); $\tilde{c}_t$ 为记忆单元状态的候选值; c_t 为当前时刻记忆单元的状态; h_t 为输出值; σ 为 sigmoid 函数, 将值映射到 0~1 之间; $\tanh$ 函数将值映射到 -1 到 1 之间; x_t 为当前时刻的输入(如电商产品的周度销量); W_i 、 W_f 、 H_i 、 H_o 等为权重矩阵; b_i 、 b_f 等为偏置向量。

2.2. 随机森林：电商多源静态特征的融合机制

随机森林是由多个决策树组成的集成学习模型, 具备强抗过拟合能力和高维特征处理优势, 可精准融合电商场景的静态特征。在电商场景中, 随机森林可以融合产品属性, 如电子产品(高单价、低频次)与美妆个护(低单价、高频次)的需求模式差异, 随机森林可通过特征分裂捕捉品类属性对需求的影响; 量化促销策略, 将促销力度、促销渠道等特征转化为可计算变量, 通过多树集成评估其对需求的非线性影响; 处理用户行为特征, 融合用户复购率、加购 - 购买转化率等数据, 例如高复购率品类(如日用品)的需求稳定性更高, 随机森林可通过样本抽样强化此类特征的权重。

在构建随机森林时, 通过随机选择样本和特征来训练每棵决策树, 然后综合所有决策树的预测结果, 通常采用投票或平均的方式得到最终预测值。随机森林的这种构建方式使其具有较强的抗过拟合能力, 能够处理高维数据, 通过构建多棵决策树并融合结果提升预测鲁棒性。其核心机制包括: ① 随机抽样(Bootstrap Sampling): 从原始数据中有放回抽取多个子集训练基决策树, 降低模型方差; ② 特征随机选择: 在每个节点分裂时随机选取部分特征, 增强基模型多样性; ③ 结果融合: 分类任务通过投票法、回归任务通过平均法确定最终预测值。

2.3. LSTM-RF 混合模型架构：电商“时序 - 静态”特征的协同架构

解决解决电商需求数据中的“长周期依赖 + 多特征耦合”问题, 混合预测模型(LSTM-RF)针对电商数据特点设计两阶段架构(图 2), 实现时序动态与静态属性的深度融合:

第一阶段，LSTM 提取电商时序特征，输入预处理后的电商周度需求数据(如过去 14 周销量)，输出两部分信息：① 初步需求预测值；② 隐藏层时序特征(如大促周期趋势、季节性波动强度)。此阶段重点捕捉“预售-爆发”关联、周度销量增长率等动态规律。

第二阶段，随机森林融合多源特征，将 LSTM 输出的时序特征与电商静态特征(表 1)融合后输入随机森林，输出最终预测结果。静态特征涵盖产品、促销、用户三大维度，全面覆盖电商需求的影响因素。




Figure 2. LSTM-RF hybrid model architecture
图 2. LSTM-RF 混合模型架构

Table 1. The core static characteristics of e-commerce scenarios
表 1. 电商场景核心静态特征

Models	Input Features	Purpose
Product attributes	Category (e.g., electronics/clothing), unit price, rating	Determines the demand base (e.g., high-rated products have higher demand stability)
Promotion strategy	Promotion intensity (discount rate) and promotion channel (live/home)	drive short-term demand fluctuations (e.g., the impact of promotion on live streaming channels is more significant) different tree models
User characteristics	Repurchase rate, add-on-purchase conversion rate	Reflects demand continuity (e.g., products with high repurchase rate can reduce safety stock)

3. 电商场景下的实验设计

3.1. 数据来源与电商特性描述

实验数据来源于国内某综合电商平台 2012~2016 年的运营数据，聚焦 4 类核心品类(其中 Type_J 代表美妆类、Type_A 代表家居类、Type_S 代表服饰类、Type_C 代表电子产品类)，覆盖 1200+ SKU，数据频率为日度，经周度聚合后形成 220 个时间节点(2012 年第 1 周至 2016 年第 52 周)，覆盖完整的年度周期与大促节点。数据中存在 3 类典型需求模式：① 稳定型(如 Product_1938，周需求波动 $\leq 5\%$ ，无显著季节性)；② 季节性波动型(如 Product_0613，第四季度需求为第一季度的 2~3 倍，呈现明显季度周期性)；③ 突发型(如 Product_1763，存在季度性突发订单，单次需求为均值的 5~10 倍受促销、紧急订单等因素

影响显著)。原始数据缺失率约 3.2%，异常值(偏离均值 3σ 以上)占比 1.8% (多为刷单、退货异常或极端突发订单)。数据样本如图 3 所示。

Product_Code	Warehouse	Product_Category	Date	Order_Demand
Product_1938	Type_J	Category_001	2012/6/6	4
Product_1938	Type_J	Category_001	2012/7/13	4
Product_1938	Type_J	Category_001	2012/12/13	4
Product_0613	Type_J	Category_001	2012/9/28	1
Product_1938	Type_J	Category_001	2012/12/12	3
Product_1763	Type_J	Category_001	2012/1/5	1
Product_1763	Type_J	Category_001	2012/2/9	7
Product_1763	Type_J	Category_001	2012/2/16	7
Product_1763	Type_J	Category_001	2012/7/18	1
Product_1763	Type_J	Category_001	2012/9/28	1

Figure 3. Raw data samples
图 3. 原数据样本

3.2. 针对电商特性进行数据预处理

由于原始数据存在噪声、缺失值等问题，首先对数据进行清洗，去除异常值；对于缺失值，采用线性插值法进行填补，保留促销期数据完整性。然后，为消除数据量纲和取值范围的影响，对数据进行标准化处理，将其映射到 0~1 区间。然后分别训练 LightGBM、LSTM、随机森林等单一模型；对于 LSTM 模型，设置学习率为 0.001，时间步长为 14 (适配电商“大促前 2 周预热”周期)，隐藏层节点数为 32；对于随机森林模型，设置决策树数量为 50，最大深度为 10，随机种子 42。单一 LightGBM 和随机森林模型的手工时序特征包括：① 滞后特征：提取过去 1/2/4/8 周的需求值(X_{t-1} 、 X_{t-2} 、 X_{t-4} 、 X_{t-8})，捕捉短期依赖与大促周期性重复模式；② 移动统计特征：过去 4 周/12 周的均值、标准差、最大值(如 mean_{t-4} 、 std_{t-12})，反映短期波动强度并且能捕捉季度尺度的趋势特征；③ 季节性特征：周编号(1~52，独热编码)区分不同周的固定需求模式(如年末周需求通常较高)、季度标识(1~4，数值编码)直接反映季度周期性；④ 趋势特征：过去 8 周的线性回归斜率(反映需求增长/下降趋势)。⑤ 融合特征：LSTM 输出的时序预测值。

接着构建 LSTM-随机森林组合模型，先训练 LSTM 模型，将其输出作为随机森林的输入，再训练随机森林模型。同时，选择 LightGBM 模型作为对比模型，以验证组合模型的优势。最后将组合模型应用于多仓库多产品数据，验证其拓展能力。

3.3. 评估指标

因电商数据存在极端值(如大促爆单)，所以就不直接用 MAE 作为评估指标，以免出现较大的均值影响判断。为了全面、客观地评估各模型在产品需求预测任务中的性能表现，本研究选用了平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)、对称平均绝对百分比误差(Symmetric Mean Absolute Percentage Error, SMAPE)、判定系数(Coefficient of Determination, R^2)、中位数绝对百分比误差(MdAPE)精确到小数点后六位，这三个广泛应用且具有代表性的抗干扰评估指标。

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (9)$$

$$\text{SMAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\frac{|y_i| + |\hat{y}_i|}{2}} \times 100\% \quad (10)$$

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

(11)

$$MdAPE = \text{median}\left(\left|\frac{y_i - \hat{y}_i}{y_i}\right| \times 100\%\right)$$

(12)

4. 电商场景下的实证结果与分析

为验证 LSTM-随机森林组合模型在电商需求预测中的有效性，本研究从单品类深度分析与多品类泛化验证两个维度展开实验，重点结合电商特有的促销周期、品类差异、需求波动模式等场景特征，对比不同模型的预测表现，揭示组合模型的适配性优势。选取不同预测模型作为基线对比，如表 2 所示。

Table 2. Compare model statistics tables
表 2. 对比模型统计表

Models	Input Features	Purpose
LSTM	Raw time-series data X_t	To verify whether Random Forest (RF) improves robustness
LightGBM	Handcrafted time-series features + static features	To compare the performance differences between different tree models
LSTM-LightGM	LSTM's hidden state h_t + static features	To validate the superiority of Random Forest (RF)
RandomForest	Handcrafted time-series features	To verify the necessity of LSTM for automatic extraction of time-series features

4.1. 单品类预测：电商典型品类的预测效果验证

选取电商平台中最具代表性的美妆个护品类(典型突发型需求，受促销、网红推荐影响显著)作为研究对象，聚焦其在双 11 大促周期(预售期：第 45 周；爆发期：第 46 周；返场期：第 47~48 周)的需求预测表现，结果如图 4 (横轴：预测节点(周)；纵轴：产品需求量(件)及表 3 所示。




Figure 4. Comparison chart of inventory forecasts for different models for a single product
图 4. 单产品不同模型库存预测对比图

Table 3. Statistical table of errors of different products
表 3. 不同产品误差统计表

Product	Evaluate metrics			
	MAPE	MdAPE	R ²	SMAPE
J1	6.4958	4.2349	0.9268	5.7962
J2	3.5878	2.7977	0.9476	3.4951
A1	2.9499	1.9418	0.9758	3.0306
A2	64.9761	20.0253	0.9384	32.7765
S1	116.9651	28.2321	0.9879	40.8744
S2	10.2623	6.8016	0.9607	9.2997
C1	5.6448	4.7366	0.9877	5.5077
C2	5.1280	2.2333	0.9854	4.7603

从图 4 可以看出, 预售期(第 45 周): 组合模型通过 LSTM 捕捉订单增长趋势, 结合随机森林对“定金膨胀”等促销规则的量化分析, 预测偏差仅 3.1%, 优于单一 LSTM (8.2%)和随机森林(15.6%), 精准匹配电商“预售锁客”规律。

爆发期(第 46 周): 面对单日需求达日常 8 倍的极端场景, 组合模型融合 LSTM 的预售订单时序依赖与随机森林对“直播专场 +5 折秒杀”的促销影响分析, 预测误差降至 3.73%, 避免了单一 LSTM (15.38%)的缺货风险和单一 LightGBM (12.7%)对预售关联的忽略。

返场期(第 47~48 周): 针对大促后需求阶梯式下降特征, 组合模型通过 LSTM 捕捉趋势惯性, 随机森林修正“返场优惠券”的刺激效应, 两周误差分别为 4.2%和 2.8%, 贴合电商“余热消化”场景。

从表 4 可见, 组合模型在美妆个护品类中表现最优: R² 达 0.9388, MAPE 仅 3.7369%, 较单一 LSTM 降低 75.7%, 较单一随机森林降低 42.6%, 充分验证了其对电商“短周期强冲击”场景的适配性, 有效解决了单一模型在“长周期依赖”或“非线性促销影响”上的建模短板。

Table 4. Statistical table of experimental error of model comparison
表 4. 模型对比实验误差统计表


Modle	Evaluate metrics			
	R ²	MdAPE	SMAPE	MAPE
LSTM	-0.1002	12.9299	15.3444	15.3814
LightGBM	0.7712	4.3676	5.7815	5.6772
LSTM-LightGBM	0.7714	4.3341	5.7735	5.6690
RandomForest	0.7539	5.7480	6.4897	6.5163
LSTM-RandomForest	0.9388	3.3152	3.7118	3.7369

4.2. 多品类泛化：电商跨品类的适配性验证


电商平台的核心挑战之一是多品类需求模式的异构性(如电子产品的稳定性、服装服饰的季节性、

家居用品的节日突发型)。为验证组合模型的泛化能力,从4个核心品类中各选取2个代表性SKU(共8个,覆盖稳定型、季节性波动型、突发型需求),对比其预测效果,预测结果如图5(横轴:预测节点(周);纵轴:库存需求量(件);图例:实际值、LSTM-RandomForest 预测值)所示,误差统计如表4所示。


结果显示;稳定型品类(J类):组合模型 R^2 达0.9476,能过滤短期促销的小幅干扰,保持预测稳定性;季节性品类(A类):在季节转换期(如3~4月)预测误差(SMAPE)仅3.03%,精准捕捉春装上市带来的需求增长;突发型品类(S和C类):在促销驱动的突发需求场景中,MAPE较单一模型降低60%以上,有效支撑临时补货决策。整体而言,6种产品 $R^2 \geq 0.95$,表明模型对电商多品类需求模式具有强适配性。




(a) 产品 J1 预测结果




(b) 产品 J2 预测结果




(c) 产品 A1 预测结果




(d) 产品 A2 预测结果




(e) 产品 S1 预测结果



(f) 产品 S2 预测结果



(g) 产品 S1 预测结果



(h) 产品 S2 预测结果

Figure 5. Comparison chart of inventory forecasts for different products**图 5.** 不同产品库存预测对比图

5. 结论与电商应用价值

5.1. 研究结论

LSTM-随机森林组合模型通过融合时序特征与电商静态特征, 显著提升了需求预测精度, 尤其在大促期、季节转换期等电商关键场景表现优异。其核心价值在于: 一是精准捕捉“预售-爆发”长周期关联, 贴合电商经济中“大促驱动”的消费规律; 二是有效量化促销力度、用户复购率等多因素的非线性影响, 适配电商经济中多变量耦合的市场特征; 三是对多品类需求模式具有强泛化能力, 可支撑电商经济中供应链的规模化协同。

5.2. 电商经济应用价值

从电商经济运行视角看, 本模型的实践意义体现在三方面: 一是优化资源配置, 通过精准预测降低库存积压, 缓解电商经济中“供需错配”的核心矛盾; 二是提升市场效率, 为动态定价、促销策略提供数据支撑, 增强电商经济对消费市场的响应速度; 三是赋能中小商家, 模型的轻量化特性可降低中小卖家的预测成本, 助力其在电商经济中实现精细化运营。

5.3. 不足与未来期望

本研究的主要局限在于数据时效性, 实证数据基于 2012~2016 年传统货架电商场景, 而当前电商经济已呈现“直播电商主导流量、即时零售重塑履约、跨境电商拓展边界”的新格局。这些变化可能影响结论在新兴电商经济形态中的适用性。

未来研究可从三方面推进: 一是融合直播弹幕情绪、用户实时地理位置等多源数据, 构建适配“实时化、场景化”电商经济的预测框架; 二探索模型在跨境电商经济中的适配性, 纳入汇率波动、关税政策等宏观经济变量; 三是结合电商经济中“平台-商家-消费者”的协同关系, 将预测结果与供应链金融、消费信贷等环节联动, 强化模型对电商经济生态的支撑作用。

参考文献

- [1] 马佳玉, 孙宗军. 基于组合模型的某农场电商生鲜农产品需求预测研究[J]. 物流科技, 2022, 45(13): 71-74.
- [2] 高东东, 王凤忠, 成祥玉. 基于需求预测的电商仓库库存研究[J]. 物流技术, 2022, 41(8): 78-82.
- [3] Liao, Y., Yang, C. and Zheng, S. (2024) Product Demand Forecasting Based on LGBM Deep Learning Models. *Journal of Applied Mathematics and Computation*, 8, 83-87. <https://doi.org/10.26855/jamc.2024.03.010>
- [4] 李婷婷, 黄欣迪, 曹萌萌, 等. 基于 LightGBM 模型的离散制造业产品物料需求智能预测[J]. 智能计算机与应用, 2023, 13(9): 59-66.
- [5] Zhou, X. (2021) Stock Price Prediction Using Combined LSTM-CNN Model. 2021 *3rd International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI)*, Taiyuan, 3-5 December 2021, 67-71. <https://doi.org/10.1109/mlbdbi54094.2021.00020>
- [6] Qian, F. and Chen, X. (2019) Stock Prediction Based on LSTM under Different Stability. 2019 *IEEE 4th International Conference on Cloud Computing and Big Data Analysis (ICCCBDA)*, Chengdu, 12-15 April 2019, 483-486. <https://doi.org/10.1109/icccbda.2019.8725709>
- [7] 范华鹏, 刘畅, 程锋云. 基于不同机器学习分类算法的滇西北森林碳储量估测[J]. 西南林业大学学报(自然科学), 2025, 45(1): 1-9.
- [8] 芦杨笛, 邓瑞, 汪益, 等. 基于 NOA 优化随机森林算法的砂岩孔隙度预测[J]. 石油地球物理勘探, 2025, 60(1): 1-11.
- [9] 包吉祥, 李林, 赵梦鸽. 基于考虑滞后性 LSTM 模型的电商需求预测[J]. 计算机工程与应用, 2022, 58(24): 276-283.
- [10] 梅俊涛, 陈静, 白静盼. 融合 LSTM 和 LightGBM 的用户购买行为预测算法[J]. 电脑知识与技术, 2024, 20(14): 29-31.

-
- [11] Wang, X., Xu, N., Meng, X. and Chang, H. (2022) Prediction of Gas Concentration Based on Lstm-Lightgbm Variable Weight Combination Model. *Energies*, **15**, Article 827. <https://doi.org/10.3390/en15030827>
- [12] 李琼, 陈佳, 徐斌. 多产品相互制约条件下的制造业产品需求预测研究[J]. 计算机应用与软件, 2021, 38(3): 59-69.
- [13] Tian, L., Feng, L., Yang, L. and Guo, Y. (2022) Stock Price Prediction Based on LSTM and Lightgbm Hybrid Model. *The Journal of Supercomputing*, **78**, 11768-11793. <https://doi.org/10.1007/s11227-022-04326-5>
- [14] 杨凡, 方娜. 基于 GRU 和 Transformer 的跨组织业务流程异常检测[J/OL]. 计算机应用研究, 1-11. <https://link.cnki.net/doi/10.19734/j.issn.1001-3695.2025.04.0117>, 2025-09-04.
- [15] 郑李园, 吴鑫, 李君, 等. 基于 TCN 的电商商品需求预测[J]. 数字技术与应用, 2023, 41(1): 110-113.
- [16] 赵钰逸, 王春晓, 吴桥. 基于组合模型的中小电商商品短期需求预测[J]. 浙江万里学院学报, 2023, 36(1): 7-13.
- [17] 胡昊, 张剑飞. 基于 iWOA-iTransformer 模型的物料需求预测[J]. 高师理科学刊, 2025, 45(4): 27-33+40.
- [18] Bai, X., Zhang, L., Feng, Y., Yan, H. and Mi, Q. (2024) Multivariate Temperature Prediction Model Based on CNN-Bilstm and Randomforest. *The Journal of Supercomputing*, **81**, Article No. 162. <https://doi.org/10.1007/s11227-024-06689-3>