

基于机器学习的电商物流末端配送需求预测与调度优化研究

马欣媛

上海理工大学管理学院, 上海

收稿日期: 2026年6月18日; 录用日期: 2026年7月2日; 发布日期: 2026年8月11日

摘 要

随着电子商务的快速发展, 末端配送已成为配送成本的主要构成部分和运营效率的关键瓶颈。传统调度方法大多依赖静态规则或人工经验, 难以有效应对电商订单需求波动带来的不确定性。本文旨在构建一种融合机器学习预测与优化调度的决策框架, 以降低电商物流末端配送成本、提升时效达成率。本文基于某电商平台城市配送中心的历史订单数据, 提取时间、天气、区域等多维特征, 构建XGBoost、LightGBM、随机森林和LSTM四种机器学习模型, 对比预测精度并选取最优模型。将预测结果嵌入调度决策流程, 采用将预测分布信息纳入调度决策的方法处理预测不确定性, 形成预测驱动的调度策略, 并通过电商平台真实数据仿真验证。XGBoost在预测精度上优于对比模型, 平均绝对误差为23.6件/小时。本文提出的预测-调度一体化方法较人工调度降低配送成本20.2%, 较静态调度降低10.8%; 时效达成率提升至91.8%, 较人工调度提高13.3个百分点。在电商大促期间, 该方法有效缓解了订单峰值带来的配送压力。

关键词

电商物流, 末端配送, 机器学习, 需求预测, 调度优化

Research on Demand Forecasting and Scheduling Optimization for E-Commerce Logistics Last-Mile Delivery Based on Machine Learning

Xinyuan Ma

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

Received: June 18, 2026; accepted: July 2, 2026; published: August 11, 2026

Abstract

With the rapid development of e-commerce, last-mile delivery has become the main component of delivery costs and a key bottleneck for operational efficiency. Traditional scheduling methods mostly rely on static rules or manual experience, which are unable to effectively cope with the uncertainty brought about by fluctuations in e-commerce order demands. This paper aims to construct a decision framework that integrates machine learning prediction and optimization scheduling to reduce the cost of e-commerce logistics last-mile delivery and improve the on-time delivery rate. Based on the historical order data of a certain e-commerce platform's urban distribution center, this paper extracts multi-dimensional features such as time, weather, and region, and builds four machine learning models: XGBoost, LightGBM, random forest, and LSTM. It compares the prediction accuracy and selects the optimal model. The prediction results are embedded into the scheduling decision process, and the method of incorporating the prediction distribution information into the scheduling decision is adopted to handle the prediction uncertainty, forming a prediction-driven scheduling strategy, and verified through real data simulation of the e-commerce platform. XGBoost outperforms the comparison models in terms of prediction accuracy, with an average absolute error of 23.6 items per hour. The proposed prediction-scheduling integrated method reduces the delivery cost by 20.2% compared to manual scheduling and by 10.8% compared to static scheduling; the on-time delivery rate is increased to 91.8%, which is 13.3 percentage points higher than manual scheduling. During e-commerce promotions, this method effectively alleviates the delivery pressure caused by peak orders.

Keywords

E-Commerce Logistics, Last-Mile Delivery, Machine Learning, Demand Forecasting, Scheduling Optimization

Copyright © 2026 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

现如今，电子商务的蓬勃发展极大地改变了城市商业形态与消费模式。据数据统计，我国快递业务量连续 12 年位居世界第一，其中超过 80% 的快递业务量来源于电商交易[1]。在这一庞大的物流网络中，末端配送作为连接消费者与电商平台的关键环节，其运营效率直接影响着用户体验与企业运营成本。据统计，末端配送成本约占电商物流总成本的 30% 至 50%，随着消费者对配送时效要求的不断提升，末端配送压力持续加大[2]。

末端配送之所以成为电商物流的痛点，源于其独特的内在特征。首先，电商末端配送具有高频次、小批量特点，然而由于业务量巨大，单个配送员日均处理包裹量可达 200 件以上[3]，导致压力剧增。其次，电商末端配送受时空约束显著，城市交通、社区管理、消费者作息等因素交织影响，使路径规划异常复杂。电商订单还具有典型的“潮汐”特征，工作日与周末、早高峰与晚高峰的订单分布差异明显。同时，电商末端配送面临极大的需求不确定性。“618”、“双 11”等促销活动会导致订单量爆发式增长，雨雪天气也使线上订单增加而配送效率下降，形成双重压力。

传统的电商末端配送调度多依赖人工经验或静态规则，难以应对实时变化的需求。在电商大促期间，

某平台曾因需求激增导致配送时效下降 30%，大量用户投诉。这一现象表明，仅依靠传统调度方法已经难以满足日益复杂的电商运营需求。近年来，随着大数据与人工智能技术的普及，机器学习在需求预测中的应用为调度优化提供了新的可能[4]。通过精准预测区域、时段内的配送需求，电商企业可以提前调整车辆与人员配置，实现“预测驱动”的动态调度。

然而，现有研究多将预测与调度分离处理，未能充分发挥预测信息的决策价值。一方面，预测模型追求精度最大化，却忽视了预测误差对后续决策的影响；另一方面，调度模型通常假设需求已知，缺乏对不确定性因素的系统考量。因此，构建预测与调度一体化的决策框架，实现数据驱动与优化调度的深度融合，具有重要的理论价值与现实意义。

本文聚焦电商物流末端配送中的需求预测与调度优化问题，构建了基于机器学习的预测 - 调度一体化框架，为电商企业提升末端配送效率、降低运营成本提供理论支撑与实践指导。

2. 文献综述

2.1. 电商物流末端配送研究

末端配送是电商物流的“最后一公里”，国内外学者对此进行了广泛研究。Ho 等[5]研究了需求驱动的仓储分配优化问题，提出了基于实时需求的动态存储策略，有效提升了仓储效率。在路径优化方面，车辆路径问题及其变体是主要研究范式，Faramarzzadeh 和 Akpinar [6]综述了卡车与无人机协同配送的最新进展，指出混合配送模式可显著提升效率。在服务模式创新方面，共同配送、智能快递柜、无人配送等新模式不断涌现。蒋丽等[7]研究了新零售背景下卡车与无人机协同的电商物流末端配送优化问题，验证了协同配送的优越性。

2.2. 需求预测方法

需求预测是电商供应链管理中的基础问题。传统预测方法包括时间序列模型和回归模型，但难以处理复杂非线性关系。随着机器学习的发展，集成学习方法在预测精度上显著优于传统模型。Ni 等[8]构建了 Stacking 融合框架用于电商动态需求预测，验证了集成学习的优越性。Bhavishya 和 Anusha [9]对比了 XGBoost、LightGBM、随机森林在电商预测中的表现，指出集成方法优于单一模型。对于时间依赖性强的序列数据，LSTM 等循环神经网络也展现出独特优势。柴和平等[10]研究了基于货量预测与优化调度的电商物流网络问题，提出预测精度直接影响调度效果。

2.3. 考虑不确定性的车辆路径优化研究

电商物流末端配送可建模为车辆路径问题，确定性环境下已取得丰富成果[11]，但订单的时空波动与促销突变使确定性方案效果受限。Hoogendoorn 与 Spliet [12]评估了随机需求建模的偏差，Jeong 等[13]构建了自适应鲁棒优化应对能耗不确定性，Wang 与 Zhao [14]及 Zhang 等[15]从分布鲁棒角度处理不确定顾客与随机模糊环境。然而，上述方法对促销引发的分布漂移及电商时空依赖刻画不足。在机器学习应用方面，Elmachtoub 等[16]指出现有预测仅多输出点估计值，未能有效量化并传递不确定性信息至优化决策，导致预测与调度分离。这一脱节恰为本文构建预测 - 调度一体化框架提供了学术切入点。

2.4. 研究评述

综上所述，现有研究存在以下不足：第一，预测与调度分离，未能形成一体化决策框架；第二，预测信息利用不足，多仅使用点预测值，忽略预测误差分布所蕴含的不确定性信息；第三，对大规模电商物流问题的求解效率关注不够。简瑜莎和张长江[17]分析了新时代“电商平台 + 农村物流”发展困境与路

径,指出信息不对称是制约调度效率的关键因素。刘倩等[18]从大数据技术角度探讨了跨境电商物流优化路径,强调数据驱动决策的重要性。针对上述不足,本文构建了机器学习预测与调度优化一体化框架,将预测的概率分布信息嵌入调度决策,并通过电商平台真实数据验证方法的有效性。

3. 方法

3.1. 问题背景与数据来源

本文以某大型电商平台城市配送中心为研究对象。该平台是国内领先的 B2C 电商平台,以自营物流著称。研究的分拨中心位于某新一线城市核心区,服务半径约 15 公里,覆盖 5 个行政区的 78 个配送网格。配送中心每日处理订单量约 5 万件,配备配送车辆 45 辆,配送人员 80 人。配送流程为:订单在每日凌晨完成分拣和装车,配送人员在 8:00 至 20:00 之间完成配送。平台承诺“当日达”服务,用户可通过 APP 实时追踪包裹位置。

数据来源为平台 2025 年 6 月至 9 月共 4 个月的订单日志,包含订单时间、地点、配送员、实际签收时间等信息,数据总量约 600 万条订单记录。这四个月中包含了“618”电商大促,订单量峰值达到平日的 3 倍。同时收集了外部特征数据:天气数据来自气象局 API,节假日数据根据国家法定节假日和平台活动日历整理,交通指数数据来自高德地图 API。区域特征数据包括人口密度、POI 密度、住宅小区数量、商业网点数量、道路密度等,通过公开统计数据与 GIS 工具提取[19]。

3.2. 特征工程

本文设计了多维度的特征体系:第一类是历史特征,包括过去 7 天同一时段同一区域的订单量、过去 24 小时同一区域的订单量、过去一周同一星期几的订单量均值。第二类是时间特征,包括小时、星期几、是否工作日、是否节假日、是否为电商促销日。第三类是外部特征,包括温度、降水量、风力等级、天气类型、交通拥堵指数。第四类是区域特征,包括人口密度、POI 密度、住宅小区数量、商业网点数量、道路网络密度。对于分类变量采用 One-Hot 编码,对连续变量进行标准化处理,最终特征维度为 156 维。

3.3. 需求预测模型

本文选取四种代表性机器学习算法进行对比:XGBoost 是基于梯度提升树的集成学习算法,能有效处理非线性关系与特征交互;LightGBM 是改进算法,训练速度更快;随机森林通过集成多棵决策树,具有良好的抗过拟合能力;LSTM 是专为序列数据设计的循环神经网络,能有效捕捉长期依赖关系。数据按 7:2:1 的比例划分为训练集、验证集和测试集,采用滚动窗口方式进行验证,窗口大小为 7 天,评估指标采用平均绝对误差和均方根误差。

3.4. 预测驱动的调度优化数学模型

本节建立考虑预测不确定性的末端配送调度数学模型,以形式化描述 3.5 节所述调度策略。

3.4.1. 符号与变量

集合: N 为配送网格集合; K 为可用车辆集合; 节点 0 表示配送中心。

参数: c_{ij} 为行驶成本; f 为单位车辆固定成本。

预测输出: 对每个网格 i , 预测模型给出需求均值 μ_i 和标准差 σ_i 。

决策变量:

$x_{ijk} \in \{0,1\}$: 车辆 k 是否从 i 行驶到 j 。

$y_{ik} \in \{0,1\}$: 网格 i 是否由车辆 k 服务。

3.4.2. 数学模型

目标函数为最小化总成本(车辆固定成本 + 行驶成本):

$$\min \sum_{k \in K} \sum_{j \in N} f \cdot x_{0jk} + \sum_{k \in K} \sum_{i,j} c_{ij} x_{ijk} \quad (1)$$

约束条件包括:

- (1) 每个网格被服务一次;
- (2) 路径连续性与车辆起止约束;
- (3) 时间窗约束: 到达时间满足客户要求。

3.4.3. 模型说明

上述模型将预测的两类信息有机融入调度决策: 均值 μ_i 决定路径的基础结构, 方差 σ_i 通过安全库存调节每条路径的容量冗余度。预测不确定性越大的区域, 其所在路径可容纳的网格数越少, 从而在宏观上引导更多车辆资源向高不确定性区域倾斜, 实现“预测驱动”的资源优化配置。

3.5. 求解算法

对于大规模电商物流网络, 直接求解优化问题计算量巨大。本文设计自适应大邻域搜索算法进行高效求解。该算法的基本思想是: 从一个初始解出发, 反复进行“破坏”和“修复”操作, 不断改进解的质量。

初始解采用插入启发式算法生成: 随机排序所有配送点, 依次将每个点插入到使成本增加最小的车辆路径中, 若超出容量则启用新车。这种初始解生成方法简单高效, 能够快速得到一个可行方案。

破坏算子包括随机移除、最差移除和时空相关移除三种。随机移除指的是从当前解中随机选取一定数量的配送点并删除; 最差移除指的是剔除对成本贡献最大的配送点; 时空相关移除则指删除时空上相近的配送点, 便于后续批量重排。

修复算子包括贪婪插入和后悔插入两种。贪婪插入将移除的配送点插入到使成本增加最小的位置; 后悔插入计算每个移除点插入各路径的后悔值, 优先插入后悔值大的点, 避免后续无法插入的困境。

每个算子被选中的概率根据其历史表现动态调整。表现好的算子获得更高的选择概率, 表现差的算子则逐渐被淘汰。这种自适应机制能够根据问题特征自动选择最优算子组合。

算法采用模拟退火接受准则, 以一定概率接受劣质解, 避免陷入局部最优。随着迭代进行, 接受概率逐渐降低, 算法趋于收敛。

3.5.1. 算子设计

破坏算子: 随机移除、最差移除(移除成本贡献大的点)、时空相关移除(移除时空邻近的点)、不确定性感知移除(优先移除变异系数 μ_i/σ_i 大的高不确定性点)。

修复算子: 贪婪插入(插入到成本增量最小位置)、后悔插入(优先插入后悔值大的点)。

3.5.2. 关键参数设置

关键参数设置如表 1 所示。上述参数取值均通过多次预实验对比调优确定, 能够在保证求解质量的同时兼顾计算效率。

其中, 最大迭代次数 $I_{\max}$ 取 5000 次, 经实验观察, 超过此迭代数后目标函数值下降趋于平缓, 继续增加计算时间对解质量提升有限。破坏比例 ρ 设为 0.15, 可在对当前解形成有效扰动同时保留路径骨

架结构，避免过度破坏导致收敛缓慢。初始温度 T_0 设置为初始解成本的 5%，使得算法在初期以约 50% 的概率接受劣解，有利于跳出局部最优。冷却速率 γ 取 0.995，采用缓慢退火策略以保证算法在中后期充分收敛。风险容忍度 α 设为 0.05，对应 95% 的容量满足概率，与电商物流行业对末端配送可靠性的实际要求相符。上述参数均通过多次预实验对比调优确定。

Table 1. Key parameter settings
表 1. 关键参数设置

参数	符号	取值	说明
最大迭代次数	$I_{\max}$	5000	平衡解质量与计算时间
破坏比例	ρ	0.15	适度扰动，保留解的骨架
初始温度	T_0	$0.05 \times S_0$	初期接受概率约 50%
冷却速率	γ	0.995	缓慢降温，利于收敛
风险容忍度	α	0.05	容量满足率 95%，行业常见要求

4. 结果

4.1. 预测模型对比结果

四种模型在测试集上的预测性能对比如表 2 所示。

Table 2. Performance comparison of different prediction models
表 2. 不同预测模型的性能对比

模型	平均绝对误差(件/小时)	均方根误差(件/小时)	训练时间(秒)
XGBoost	23.6	31.2	156
LightGBM	24.1	32.5	98
随机森林	25.3	33.8	342
LSTM	24.8	33.1	1280

实验结果表明，XGBoost 在平均绝对误差和均方根误差两个指标上均表现最优，平均绝对误差为 23.6 件/小时。综合考虑预测精度与计算效率，本文选择 XGBoost 作为后续调度优化的预测模型。

4.2. 特征重要性分析

通过 XGBoost 的特征重要性分析发现，对电商订单预测贡献最大的特征依次为：过去 7 天同一时段订单量(23.2%)、小时(15.6%)、是否电商促销日(11.3%)、降水量(8.7%)、人口密度(7.2%)。这一结果表明，历史需求模式和时间特征是预测的核心依据，电商促销活动和天气特征也发挥重要作用。

4.3. 调度优化结果

将本文方法与人工调度、静态调度、时序预测调度三种基准方法进行对比，各方案在测试期的平均表现如表 3 所示。

实验结果表明，本文方法相比人工调度降低配送成本 20.2%，提升时效达成率 13.3 个百分点；相比静态调度，成本降低 10.8%，时效提升 8.6 个百分点；相比时序预测调度，成本降低 5.4%，时效提升 5.1 个百分点。在“618”电商大促期间，人工调度方案时效达成率下降至 65%，而本文方法仍保持在 82% 以上。

Table 3. Comparison of costs and service performance among different scheduling schemes
表 3. 不同调度方案的成本与服务表现对比

调度方案	平均单件成本(元)	时效达成率(%)	车辆使用数(辆)	平均行驶距离(km)
人工调度	2.18	78.5	45	2850
静态调度	1.95	83.2	41	2670
时序预测调度	1.84	86.7	38	2580
本文方法	1.74	91.8	34	2410

4.4. 电商场景下的应用效果

为验证本文方法在电商场景下的实际应用效果，选取三个典型场景进行对比分析：在电商大促日，订单量从平日的 5 万件激增至 15 万件，本文方法通过提前三天预测各区域订单量，将时效达成率从 65% 提升至 82%；在恶劣天气日，订单量增长 25%且配送效率下降 30%，本文方法通过提前预判天气影响，时效达成率维持在 85%以上；在工作日与周末对比中，本文方法根据预测结果动态调整区域资源配置，车辆使用数减少 15%，行驶距离降低 12%。

4.5. 预测精度对调度效果的敏感性分析

为深入探究预测精度与调度效果之间的定量关系，本文设计了敏感性分析实验。通过在测试集上人为引入不同程度的预测噪声，模拟不同精度水平下的预测结果，进而评估其对调度成本与时效达成率的影响。具体而言，以 XGBoost 模型的最优预测结果为基准，分别叠加标准差为 0.5、1.0、1.5 和 2.0 倍原始预测误差的高斯噪声，生成五组不同精度等级的预测序列，并分别输入调度优化模型进行求解。实验结果如表 4 所示。

Table 4. Comparison of scheduling effects under different prediction precisions
表 4. 不同预测精度下的调度效果对比

预测误差倍数	MAE (件/小时)	平均单件成本(元)	时效达成率(%)
0.0 (原始)	23.6	1.74	91.8
0.5	35.4	1.78	89.2
1.0	47.2	1.83	86.5
1.5	59.0	1.89	83.1
2.0	70.8	1.96	79.4

实验结果表明，随着预测误差的增加，调度成本呈近似线性上升趋势，时效达成率则相应下降。当平均绝对误差从 23.6 件/小时增至 70.8 件/小时时，单件配送成本上升约 12.6%，时效达成率下降 12.4 个百分点。这一结果进一步验证了预测精度对调度效果的关键驱动作用，也表明本文所提一体化框架在高精度预测条件下能发挥更大的优化效能。

5. 讨论

5.1. 预测精度对调度效果的影响

将测试期数据按预测误差大小分为五组，计算每组调度结果的平均成本。结果显示，当平均绝对误差小于 15 件/小时时，平均成本为 1.68 元；当平均绝对误差在 15 至 25 件/小时之间时，成本为 1.74 元；当平均绝对误差大于 35 件/小时时，成本升至 1.89 元。这表明预测精度对调度效果具有显著影响，提升

预测精度是优化调度效果的基础。进一步结合敏感性分析结果可知,预测误差每增加 10 件/小时,单件配送成本约上升 0.03~0.05 元,时效达成率约下降 1.5~2.0 个百分点。这一量化关系为电商企业在预测系统建设与调度决策中的资源投入提供了参考依据。

5.2. 融合机制的价值

对比仅使用点预测的调度方案与本文采用概率分布信息的方案发现,后者成本降低 4.2%,时效达成率提升 2.8 个百分点。这表明将预测误差分布信息纳入调度模型,能够更有效地应对电商订单需求不确定性,提升方案的鲁棒性。

5.3. 电商物流管理启示

本研究对电商物流管理具有以下启示:第一,数据驱动是提升末端配送效率的关键,电商平台积累的海量数据蕴含着巨大价值;第二,预测与调度需要一体化设计,电商企业应建立跨部门协同机制;第三,应对不确定性需要系统思维,从预测、调度、执行等多个环节系统设计;第四,差异化服务是电商竞争的关键,可根据用户画像提供差异化服务。

5.4. 局限性与未来研究方向

本研究存在以下局限性:数据来源限于单一电商平台的城市配送中心;模型假设需求相互独立,未考虑相邻区域间的需求相关性;调度模型为静态优化,未考虑实时动态调整。未来研究可从多源数据融合、时空相关性建模、实时动态调度算法、电商物流与供应链协同优化等方向展开。

6. 结论

本文聚焦电商物流末端配送中的需求预测与调度优化问题,构建了基于机器学习的预测-调度一体化框架。主要结论如下:

第一,在需求预测方面,XGBoost 算法优于 LightGBM、随机森林和 LSTM,平均绝对误差为 23.6 件/小时。历史需求、时间特征和电商促销活动是影响预测精度的关键因素。

第二,在调度优化方面,本文方法较人工调度降低配送成本 20.2%,提升时效达成率 13.3 个百分点;较静态调度降低配送成本 10.8%,提升时效达成率 8.6 个百分点。在“618”电商大促期间,本文方法将时效达成率从 65%提升至 82%,有效缓解了订单峰值带来的配送压力。

第三,在电商场景下,本文方法在恶劣天气日、工作日与周末切换等典型场景中均表现良好,展现出较强的适应能力。

第四,预测精度对调度效果具有显著影响,将预测概率分布信息纳入调度模型可进一步提升方案鲁棒性。

本文提出的预测-调度一体化框架,实现了数据驱动与优化调度的深度融合,为电商企业提升末端配送效率、降低运营成本提供了理论支撑与实践指导。

参考文献

- [1] 韩鑫. 从世界最大寄递网络看活力中国(读数·年度数据深一度) [N/OL]. 人民日报, 2026-01-28(08). http://paper.people.com.cn/rmrb/pc/content/202601/28/content_30136225.html, 2026-06-05.
- [2] Gomes, A.C., De Lima Junior, F.B., Soliani, R.D., Oliveira, P.R.D.S., De Oliveira, D.A., Siqueira, R.M., et al. (2023) Logistics Management in E-Commerce: Challenges and Opportunities. *Revista de Gestão e Secretariado*, **14**, 7252-7272. <https://doi.org/10.7769/gesec.v14i5.2119>
- [3] 卢越. 推进快递行业高质量发展思考[J]. 中国投资(中英文), 2024(Z9): 68-69.

-
- [4] Chen, T. and Guestrin, C. (2016) Xgboost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco, 13-17 August 2016, 785-794. <https://doi.org/10.1145/2939672.2939785>
 - [5] Ho, G.T.S., Tang, V., Tong, P.H. and Tam, M.M.F. (2025) Demand-Driven Storage Allocation for Optimizing Order Picking Processes. *Expert Systems with Applications*, **272**, Article 126812. <https://doi.org/10.1016/j.eswa.2025.126812>
 - [6] Faramarzzadeh, M. and Akpinar, Ş. (2025) A Literature Review of Collaborative Truck and Drone in Last-Mile Delivery. *Computers & Industrial Engineering*, **209**, Article 111477. <https://doi.org/10.1016/j.cie.2025.111477>
 - [7] 蒋丽, 王洪艳, 梁昌勇. 新零售背景下卡车与无人机协同的电商物流末端配送优化[J]. 系统管理学报, 2024, 33(6): 1461-1470.
 - [8] Ni, L., Huang, Z. and Fu, N. (2025) A Stacking-Based Fusion Framework for Dynamic Demand Forecasting in E-Commerce. *Mathematics*, **13**, Article 3436. <https://doi.org/10.3390/math13213436>
 - [9] Bhavishya, S.M. and Anusha, T. (2025) Enhancing Demand Prediction Accuracy in E-Commerce with Ensemble Machine Learning. In: Dou, R., Liu, J., Khasawneh, M.T., Masehian, E., Shu, D., Kalganova, T. and Vyas, N., Eds., *Atlantis Highlights in Intelligent Systems*, Atlantis Press, 527-538. https://doi.org/10.2991/978-94-6463-866-0_44
 - [10] 柴和平, 沈雪, 季英杰, 马和平. 基于货量预测与优化调度的电商物流网络问题研究[J]. 科技创新与生产力, 2024, 45(10): 22-27.
 - [11] Boysen, N., Fedtke, S. and Schwerdfeger, S. (2021) Last-Mile Delivery Concepts: A Survey from an Operational Research Perspective. *OR Spectrum*, **43**, 1-58. <https://doi.org/10.1007/s00291-020-00607-8>
 - [12] Hoogendoorn, Y.N. and Spliet, R. (2025) An Evaluation of Common Modeling Choices for the Vehicle Routing Problem with Stochastic Demands. *European Journal of Operational Research*, **321**, 107-122. <https://doi.org/10.1016/j.ejor.2024.09.007>
 - [13] Jeong, J., Ghaddar, B., Zufferey, N. and Nathwani, J. (2024) Adaptive Robust Electric Vehicle Routing under Energy Consumption Uncertainty. *Transportation Research Part C: Emerging Technologies*, **160**, Article 104529. <https://doi.org/10.1016/j.trc.2024.104529>
 - [14] Wang, X. and Zhao, J. (2025) Distributionally Robust Optimization of the Vehicle Routing Problem with Uncertain Customers. *Journal of Industrial and Management Optimization*, **21**, 1983-2006. <https://doi.org/10.3934/jimo.2024159>
 - [15] Yin, F. and Zhao, Y. (2025) Wasserstein Distributionally Robust Equilibrium Optimization under Random Fuzzy Environment for the Electric Vehicle Routing Problem. *IEEE Transactions on Fuzzy Systems*, **33**, 1120-1132. <https://doi.org/10.1109/tfuzz.2024.3504822>
 - [16] Elmachtoub, A.N. and Grigas, P. (2022) Smart “Predict, Then Optimize”. *Management Science*, **68**, 9-26. <https://doi.org/10.1287/mnsc.2020.3922>
 - [17] 简瑜莎, 张长江. 新时代“电商平台 + 农村物流”发展困境与路径分析[J]. 物流科技, 2024, 47(22): 37-39.
 - [18] 刘倩, 钟颖, 林梅. 大数据技术背景下跨境电商物流优化路径研究[J]. 中国商论, 2024, 33(23): 85-88.
 - [19] 周艳红. 大数据分析在电商物流需求预测与库存布局中的应用研究[J]. 全国流通经济, 2025(23): 61-64.