

基于分位数回归模型的物流分拣中心短期货运量预测与风险量化研究

王超^{1,2}, 梁豪¹, 李波^{3*}

¹江西财经大学统计与数据科学学院, 江西 南昌

²江西出版传媒集团博士后管理办公室, 江西 南昌

³华中师范大学数学与统计学院, 湖北 武汉

收稿日期: 2025年10月25日; 录用日期: 2025年11月16日; 发布日期: 2025年11月26日

摘要

随着全球贸易深化与消费需求升级, 现代物流已成为衔接生产与消费、降低社会成本、保障供应链韧性并支撑经济高效运转的核心基础设施。为解决物流分拣中心货运量存在时间波动性与不确定性, 导致资源调配不合理的问题, 本文提出分位数随机森林(Q-RF)与分位数LSTM(Q-LSTM)两种模型, 用于货运量预测。研究以57个分拣中心过去3个月日货运量为基础, 预测未来7天货运量。本研究初步显示, 分位数回归方法可对货运量波动风险进行有效量化, 并且在短期货物量预测中随机森林的稳定性与准确性表现相对更优, 其结果能为物流分拣中心的人力设备调配、作业流程优化提供一定数据支撑, 进而可能对降低运营成本、提升物流网络服务效率与客户满意度。

关键词

货运量预测, 分位数回归, 随机森林, LSTM

Research on Short Term Freight Volume Prediction and Risk Quantification of Logistics Sorting Centers Based on Quantile Regression Model

Chao Wang^{1,2}, Hao Liang¹, Bo Li^{3*}

¹School of Statistics and Data Science, Jiangxi University of Finance and Economics, Nanchang Jiangxi

²Postdoctoral Management Office of Jiangxi Publishing and Media Group, Nanchang Jiangxi

*通讯作者。

文章引用: 王超, 梁豪, 李波. 基于分位数回归模型的物流分拣中心短期货运量预测与风险量化研究[J]. 统计学与应用, 2025, 14(11): 382-393. DOI: 10.12677/sa.2025.1411338

³School of Mathematics and Statistics, Central China Normal University, Wuhan Hubei

Received: October 25, 2025; accepted: November 16, 2025; published: November 26, 2025

Abstract

With the deepening of global trade and the upgrading of consumer demand, modern logistics has become the core infrastructure that connects production and consumption, reduces social costs, ensures supply chain resilience, and supports efficient economic operation. To solve the problem of time fluctuation and uncertainty in the freight volume of logistics sorting centers, which leads to unreasonable resource allocation, this paper proposes two models, quantile random forest (Q-RF) and quantile LSTM (Q-LSTM), for freight volume prediction. Based on the daily freight volume of 57 sorting centers in the past 3 months, predict the freight volume for the next 7 days. This study preliminarily shows that quantile regression method can effectively quantify the risk of freight volume fluctuations, and the stability and accuracy of random forests are relatively better in short-term cargo volume prediction. The results can provide certain data support for the allocation of human equipment and optimization of operation processes in logistics sorting centers, which may further reduce operating costs, improve logistics network service efficiency and customer satisfaction.

Keywords

Freight Volume Prediction, Quantile Regression, Random Forest, LSTM

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

随着电子商务的快速发展和消费者对配送时效性要求的不断提高,现代物流网络面临着前所未有的挑战。作为物流体系中的关键节点,分拣中心承担着海量货物的接收、分拣与转运任务,其运行效率直接影响到整个物流网络的服务水平和运营成本。然而,分拣中心的货量存在明显的时间波动性和不确定性,如果不能准确预测货量并合理安排人员班次,往往会导致人力资源浪费或运力不足,从而影响物流运作的稳定性与经济性。近年来,数据驱动的预测与优化方法为解决这一问题提供了新的思路。通过对历史货量数据进行建模,可以识别出潜在的周期性规律与随机波动,从而提升预测精度;与此同时,结合预测结果进行科学的人员排班优化,能够在保证服务质量的前提下有效降低人力成本。

2. 问题描述

2.1. 研究背景

随着物流行业的快速发展,货运量的预测对于物流中心的运营管理和资源优化配置具有重要意义。近年来,对于时间序列的建模和预测受到了越来越多的关注。传统统计方法以其模型可解释性强、计算成本低的特点,在货运量预测中应用广泛,核心思路是通过分析历史数据的统计规律建立预测模型。李锐天[1]针对分拣中心货物量预测问题,提出基于 ARIMA 时间序列模型的解决方案。ARIMA 有效捕捉分拣中心货物量随时间变化的线性趋势与周期性规律。该研究为分拣中心的人员排班、设备启停规划及作

业流程优化提供量化依据,减少低谷期资源闲置与高峰期运力不足的问题。王德胜[2]以河北省铁路货运量为研究对象,基于关键影响因素构建多元线性回归与 GM (灰色模型),分别对河北省铁路货运量进行预测,为区域铁路物流规划及与物流中心的衔接协调提供方法参考。伍信怡等[3]以三峡船闸 2006~2019 年月货运量为样本,构建指数平滑法与 SARIMA (4, 1, 1) (1, 1, 1)模型,经对比发现指数平滑法预测精度更高,进而用其预测 2021 年该船闸全年货运量,为枢纽调度与决策提供依据。随着数据复杂度提升,人工智能的相关算法因其在复杂数据特征提取与建模方面的优势,逐渐成为时序预测领域的研究重点。很多学者将机器学习和深度学习方法与传统统计模型结合起来处理复杂的非线性问题。俞小凤[4]以铁路货运为对象,选取钢材、煤炭、原油加工等六个经济指标,运用支持向量机、人工神经网络、Bagging 和随机森林四种机器学习算法进行预测,并比较不同算法的优劣,结果表明机器学习方法在铁路货运量预测中具有较好的可行性。邓联涛[5]建立江西省物流需求预测指标体系,采用支持向量机、极限学习机、随机森林等模型,结果显示组合预测精度高于单一模型,并预测江西省未来五年的物流需求趋势较为平稳。汪孝健[6]将长三角地级市进行谱聚类分组,再结合 Prophet 模型预测各类指标,并利用随机森林模型进行快递业务量预测。研究发现长三角快递总体呈上升趋势,但不同城市群差异明显。辜勇[7]针对集装箱多式联运数据缺失问题,提出采用插值法和 K 邻近插补法修复数据,并通过特征筛选和网格搜索交叉验证改进随机森林模型。以营口至武汉案例验证,结果表明改进后的模型准确性和稳定性均优于指数平滑法和 XGBoost 模型。王泽宇,张志清[8]以湖北省物流需求为研究场景,采用 LSTM 和 GRU 网络对 2000~2021 年湖北省货运量进行预测。基于 LSTM 预测结果指出 2022~2024 年湖北省货运量呈回暖趋势,并从经济增长、基础设施建设、政策支持三方面提出物流发展建议。刘梦聪[9]构建 ARIMA-LSTM 组合模型用于短途运输货物量预测。ARIMA 模型擅长捕捉时间序列的线性趋势,LSTM 则能挖掘非线性特征,通过将两种模型结合,弥补单一模型在复杂数据模式下的预测短板,提升短途运输场景下货运量预测的准确性,为短途物流线路规划、车辆调度提供数据支撑。江帆,刘利民[10]提出 GM-LSTM 组合模型用于港口物流需求预测。GM (灰色模型)和 LSTM 二者结合可充分利用港口物流历史数据,提升港口物流需求预测的可靠性,为港口基础设施建设规划、航线调整及物流资源调配提供决策参考。程肇兰等[11]将 LSTM 网络应用于铁路货运量预测。以铁路货运历史数据为基础,通过 LSTM 网络的门控机制记忆关键信息,解决传统 RNN 梯度消失问题,准确预测铁路货运量变化。研究结果可为铁路部门制定货运计划、优化运输线路及调配运力资源提供依据,提升铁路物流运输效率。叶晓龙等[12]提出 X11-WT-LSTM 多尺度组合预测模型用于物流货运量预测。该模型通过多尺度处理,更全面捕捉物流货运量的复杂变化规律,提升预测精度,为物流中心的库存管理、运输调度提供更精细的决策支持。燕学博,曹雨[13]基于多模型的铁路货运量预测对比研究,涉及 ARIMA、LSTM、GRU 等多种模型。通过收集铁路货运历史数据,分别构建不同预测模型,在数据非线性特征显著时,LSTM、GRU 等深度学习模型预测效果优于 ARIMA;而在数据线性趋势明显且样本量较小时,ARIMA 模型表现更简洁高效,为不同场景下铁路货运量预测模型的选择提供参考。在实际的现实条件下,我们不仅关注预测货运量的“单点值”,而且关注货运量的具有量化机会的预测区间,分位数回归满足这一要求。在 1978 年,Koenker, Bassett [14]首次提出了分位数回归(Quantile Regression)的概念。他们突破了传统普通最小二乘法(OLS)只能估计条件均值的局限,将回归模型扩展到条件分布的不同分位点。该方法通过最小化加权绝对偏差和(check function),使得研究者不仅可以估计均值效应,还能分析自变量在不同条件下对因变量的分布特征影响。郝令昕等[15]全面介绍了分位数回归的基本思想,解释其如何刻画不同条件分布位置下变量间的关系。它系统论述了分位数回归的数学原理、估计算法、统计推断以及模型扩展。同时结合大量实例展示了分位数回归在经济学、社会科学等领域的实际应用价值。国外对于分位数回归起源较早,但随着时代发展,分位数回归也广泛的应

用到国内的相关领域。但就目前来说，利用分位数回归理论来研究物流货运量预测的文献并不多，本文利用分位数回归对物流中心货运量进行预测，促进分位数回归在国内的推广，也更符合物流场景中对货量波动风险的评估需求，更有利于现实生活中对物流资源的调度和利用。

2.2. 问题描述

近年来，互联网技术普及、消费需求升级、物流与支付体系创新及多元化商业模式共同驱动了中国电子商务的爆发。消费者对物流服务的要求日益严苛，不仅追求更快的配送速度(如“当日达”“次日达”)，还期望更高的服务准确性(如精准的时间窗口配送)。分拣中心是物流网络中的关键节点，负责将海量包裹按流向分类并发往下一场地。其管理效率直接影响整体履约效率(如订单处理时效)和运作成本(如人力、设备投入)。然而，分拣中心货量具有显著的波动性和不确定性(如促销季、节假日货量激增)，导致资源调配困难，易出现人力过剩或不足的情况。这要求物流网络必须具备高效的分拣能力，以快速响应订单并确保包裹准确流向下一环节。本文基于公开的 57 个分拣中心过去 3 个月每天的货运量数据，采用分位数回归 + 随机森林和分位数回归 + LSTM 的复合模型，分别对未来 7 天货运量进行预测，既能为物流分拣中心精准调配人力与设备资源、实现降本增效，也能助力优化分拣流程、缩短包裹停留时间以提升服务效率，最终增强客户满意度与市场竞争力。

3. 模型构建以及相应算法

传统的方法在货物量预测中仅关注其点估计的结果，但是在关于货物调度中理应更关注区间预测，量化不确定性程度。本文选择分位数随机森林(QRF)和分位数 LSTM(Q-LSTM)两种方法(见表 1)。前者是基于集成学习，擅长捕捉时间序列中的非线性关系，能天然地提供条件分布函数；后者基于深度学习，专为时间序列数据设计，自动学习长期时间依赖关系。

3.1. 分位数随机森林模型

普通随机森林通过组合多个决策树的预测结果(平均值)来提升预测准确性。分位数随机森林在此基础上扩展到估计条件分位数，而不仅仅是条件均值。步骤如下：

- 对于每个分拣点，穿过森林中的每一棵决策树，得到一系列预测值， T 为树的数量。
- 将 T 个预测值排序，形成经验分布函数：

$$\hat{F}(y) = \frac{1}{T} \sum_{t=1}^T I(y_t \leq y)$$

- 对于给定的分位数，其预测值就是这个经验分布的分位数，即：

$$\hat{y}_\tau = \inf \{y : \hat{F}(y) \geq \tau\}$$

分位数随机森林无需改变模型结构或损失函数，就能直接、非参数地获取预测区间，非常直观和稳定。

Table 1. Comparison of Q_RF vs. Q_LSTM

表 1. Q_RF 与 Q_LSTM 的对比

	分位数随机森林(Q_RF)	分位数 LSTM (Q_LSTM)
模型类型	集成学习(Bagging)	深度学习(循环神经网络)
核心原理	经验分布，汇总所有树的预测	分位数损失，优化分位数输出
训练效率	高，训练决策树	较低，序列训练，耗时长
数据要求	相对较少，表现稳定	需要大量数据，防止过拟合

续表

超参数调优	相对简单，参数较少	复杂(层数、单元数、学习率等)
可解释性	高，提供特征重要性	低，黑盒模型，解释性差
序列建模能力	较弱，依赖滞后特征	强，内置记忆功能，捕捉复杂序列模式
不确定性估计	非参数，更稳健	参数化，依赖模型拟合能力和损失函数
在本文中适用性	特征工程丰富，表现更优	理论上潜力大，受数据量限制

3.2. 分位数 LSTM 模型

LSTM 通过其门控机制(输入门、遗忘门、输出门)解决长期依赖问题，适合做时间序列预测。而分位数 LSTM 模型通过修改损失函数，模型直接输出不同分位数的预测值。过程如下：

流程：

- 1) 网络结构：使用 LSTM 层捕捉时序特征，最后连接多个并行的全连接层(Output Layer)，每个层对应一个目标分位数($\tau = 0.1, 0.5, 0.9$)的输出。
- 2) 损失函数：采用分位数损失函数(Pinball Loss)。对于每个分位数，其损失为：

$$\mathcal{L}_{\tau}(y, \hat{y}_{\tau}) = \begin{cases} \tau(y - \hat{y}_{\tau}), & \text{if } y \geq \hat{y}_{\tau} \\ (1 - \tau)(y - \hat{y}_{\tau}), & \text{if } y < \hat{y}_{\tau} \end{cases}$$

总损失是所有分位数损失之和。当预测值低于真实值时，较高的分位数(0.9)的高估惩罚更大；当预测值高于真实值时，较低的分位数(0.1)的低估惩罚更大。通过反向传播和梯度下降，同时优化所有分位数输出层的参数，是端到端的深度学习模型，能自动学习复杂特征，理论上拟合能力更强。

基于以上对比，本研究将同时采用两种方法进行实验，以评估其在货物量预测中的性能，并深入分析其优劣及适用场景。

3.3. 分位数随机森林(QRF)的特征工程

- 1) 时间戳特征编码

提取星期几、月中第几天、月份、是否周末、是否月初、是否月末，使用正弦(sin)和余弦(cos)变换对周期性特征进行编码，直接将时间的周期性(如一周 7 天、一月 31 天)映射到模型更容易学习的连续循环空间，避免了“第 7 天”和“第 1 天”在数值上相距甚远但语义上相邻的问题。

- 2) 滞后特征

创建过去 1, 2, 3, 7, 14, 21 的货物量作为新的特征，lag_1, lag_2, lag_3 捕捉短期趋势；lag_7, lag_14 捕捉每周的周期性；lag_21 捕捉三周的周期。这是将序列建模的责任交给特征工程，为模型提供历史信息，捕捉短期和周期性的依赖关系。

- 3) 滚动统计特征

计算过去一个窗口期(3 天, 7 天, 14 天)的统计量，均值反映近期平均水平，标准差反映近期波动大小。

- 4) 差分与比率特征

计算一阶差分，计算一阶差分的值与最近一周平均水平的比值，将绝对量转化为相对量，使序列更平稳，更容易建模。

- 5) 特征选择与高相关过滤

计算特征间的相关系数，移除高度相关($\text{corr} > 0.95$)的特征，降低过拟合风险，提高模型训练效率。

随机森林的特征重要性如下图所示：




Figure 1. Example of feature importance for each sorting center

图 1. 各分选点特征重要性示例

如图 1 展示四个分选中心的随机森林中的特征重要性，由图可以看出各分选点对各特征的侧重点不同，应分别进行货物量预测的建模。

3.4. 分位数 LSTM 的特征输入处理

1) Q-LSTM 中使用了一些特征，如星期几、月中第几天、月、是否周末，以及一些简单的滞后特征(lag_1 到 lag_14)和滚动特征(rolling_mean_7)，与 QRF 相比，缺乏了精细化的周期性编码、复杂的滚动统计、差分和比率特征。这是因为期望 LSTM 能通过其门控机制自动学习到这些模式。

2) LSTM 对输入数据的尺度非常敏感，使用梯度下降算法优化，需要对特征向量(X)和目标(y)进行标准化。

3) 在 LSTM 的输出上加一个注意力层，计算每个时间步的权重，然后生成一个加权的上下文向量作为最终表示。

4. 模型验证与结果分析

结果基于分位数 LSTM(长短期记忆网络)和分位数随机森林两种预测模型，对 57 典型物流分选中心(SC1~SC57)的货量进行建模，并对其未来货量进行了预测模型评估，旨在为实际管理提供数据支持与决策依据。

4.1. 时序图分析

由于文章篇幅影响，仅对四个典型物流分选中心(SC8, SC31, SC37, SC56)的货运量进行分析，以下图 2~5 是 4 个分选中心 8 月到 12 月的时序图。




Figure 2. Time series plot of sorting center SC8

图 2. 分拣中心 SC8 时序图




Figure 3. Time series plot of sorting center SC31

图 3. 分拣中心 SC31 时序图




Figure 4. Time series plot of sorting center SC37

图 4. 分拣中心 SC37 时序图




Figure 5. Time series plot of sorting center SC56
图 5. 分拣中心 SC56 时序图

表 2 总结了图 2~5 从 2023 年 8 月到 2023 年 11 月的每天的货物量的特征：

Table 2. Typical sorting center logistics volume characteristics
表 2. 典型分拣中心物流量特征

分拣中心	平均日货物量	主要特点	可能原因
SC8	4140.7	日货物量波动较大，11 月有极高峰值；	11 月极高峰值可能与重大促销活动(如“双 11”)有关，该中心可能有地理或运营优势，属于大型的一个分拣中心；
SC31	1167.2	日货物量波动较大，11 月有非常高的峰值；	11 月高峰可能与大型促销活动(如“双 11”)有关，其他波动可能与业务周期和工作日/休息日节奏有关；
SC37	833.9	日货物量波动频繁且幅度大，多个高峰和低谷交错；	处理货物类型可能有时效性强、订单量不稳定的情况，运营策略或客户订单不确定性大；
SC56	1946.7	日货物量波动较大，但总体在平均值上下波动，但有特别明显高峰或低谷；	受每周工作日和休息日影响，部分小高峰可能与小规模促销活动有关

为进行常规货物量预测，本文避免 11 月份的“双十一”活动的影响，将 2023 年 8 月 1 日到 2023 年 10 月 24 日的货物量作为训练集，将 2023 年 10 月 25 日到 2023 年 11 月 31 日的货物量作为测试集进行预测。

4.2. 预测精度评估

通过两种模型对 57 典型物流分拣中心的货运量进行建模，下面表 3 给出了详细结果。

总的来看：在整体性能上：RF 在所有指标上显著优于 LSTM(误差降低约 50%)，尤其是 MAPE 降低了近 7 个百分点。在预测绝对误差方面，分位数 LSTM 均值为 2483.4，分位数随机森林均值为 1263.1，整体误差分布比分位数 LSTM 更集中在较低值区域。总的来说，分位数随机森林在预测绝对误差分布、

相对误差分布表现优于分位数 LSTM。这表明分位数随机森林在该预测场景下具有更高的准确性和稳定性。

Table 3. Accuracy evaluation of the two models
表 3. 两种模型精度评估

对比维度	LSTM 模型	RF 模型
整体性能	MAE = 2483.36 RMSE = 2890.04 MAPE = 20.32%	MAE = 1263.06 RMSE = 1539.37 MAPE = 13.39%
最佳表现分拣中心	SC24 (MAPE = 7.7%) SC17 (MAPE = 7.85%) SC14 (MAPE = 8.77%)	SC8 (MAPE = 3.84%) SC4 (MAPE = 3.97%) SC25 (MAPE = 4.22%)

其次，分别从 4 个物流分拣中心来看：图 6~9 依次呈现了分位数 LSTM (Q_LSTM)与分位数随机森林(Q_RF)在物流分拣中心 SC8、SC31、SC37、SC56 货运量上的预测值与实际值对比情况。从各图可见，分位数随机森林在短期货物量预测中表现更为出色，能够精准捕捉到短期内货物量的波动特征；相比之下，分位数 LSTM 的表现欠佳，其各分位点预测值呈现出近乎恒定的状态，难以有效反映货物量的动态变化。




Figure 6. Comparison plot of SC8
图 6. SC8 对比图





Figure 7. Comparison plot of SC31
图 7. SC31 对比图






Figure 8. Comparison plot of SC37
图 8. SC37 对比图




Figure 9. Comparison plot of SC56
图 9. SC56 对比图

这是由于分位数随机森林无需依赖强时序连续性，能借助多棵树对样本特征的随机选择与划分，直接学习货物量和各类影响因素的非线性关系，即便货物量短期随机波动，也可捕捉到变化；而分位数 LSTM 更擅长长周期且有明确时序依赖的数据，在货物量受突发短期因素影响、呈现短周期无强连续时序依赖的波动时，因数据量有限等问题，易欠拟合，且对随机波动型不确定性表达能力弱，难以学习到稳定规律，致使预测结果趋于恒定。

5. 结果与讨论

本文聚焦于 57 个物流分拣中心的货运量预测问题，构建了分位数随机森林与分位数 LSTM 组合预测模型，并开展相关研究。通过对货运量数据进行建模分析，实验结果清晰表明：在短期物流数据的应用场景下，分位数随机森林在预测绝对误差分布、相对误差分布以及预测区间覆盖比例等方面，均展现出优于分位数 LSTM 的性能。分位数随机森林能够有效地对数据进行拟合，进而实现对未来货运量的精准预测。

本文的分位数预测方法的应用，破解了传统预测“仅有单点值，缺乏风险区间”的局限，所得到的 80%置信区间(0.1~0.9 分位数)，可精准应用于物流资源调度工作，例如按照 90%分位数来准备运力，以此应对货运量峰值情况；采用按分拣中心单独建模的策略，规避了不同分拣中心货量分布差异(各分拣点的日均货物量不同)所引发的模型偏差问题；实现了动态序列长度与数据的适配，自动调整序列长度，有效解决了小数据量分拣中心样本不足的难题，极大地提升了模型的鲁棒性。其四，运用分层缺失值填补方法，结合线性插值与 KNN 插值，同时兼顾了时间连续性与相似性，使得填补结果更为合理。这些技术亮点为物流货运量的精准预测以及物流资源的高效调度提供了有力的技术支撑。

参考文献

- [1] 李锐天. 基于 ARIMA 时间序列模型解决分拣中心货物量预测问题[J]. 电气时代, 2024(11): 44-46.
- [2] 王德胜. 河北省铁路货运影响因素分析及运量预测研究[D]: [硕士学位论文]. 石家庄: 石家庄铁道大学, 2024.
- [3] 伍信怡, 南航, 史富存, 等. 基于指数平滑法模型的三峡船闸货运量预测研究[J]. 中国水运(下半月), 2021, 21(10): 13-15.
- [4] 俞小凤. 机器学习理论在铁路货运量预测中的应用研究[D]: [硕士学位论文]. 北京: 北京交通大学, 2016.
- [5] 邓联涛. 基于机器学习组合模型的江西省物流需求预测及发展对策研究[D]: [硕士学位论文]. 福州: 福州大学, 2021.
- [6] 汪孝健. 基于谱聚类和随机森林算法的长三角地区快递业务量的预测研究[D]: [硕士学位论文]. 杭州: 杭州电子科技大学, 2024.
- [7] 辜勇, 杨泽昭. 基于随机森林的集装箱多式联运货运量预测[J]. 武汉理工大学学报, 2023, 45(1): 35-44.
- [8] 王泽宇, 张志清. LSTM 和 GRU 模型对湖北省物流需求预测性能比较研究[J]. 物流工程与管理, 2024, 46(4): 10-14.
- [9] 刘梦聪, 郭协潮, 王伟任. 基于 ARIMA-LSTM 组合模型的短途运输货物量预测研究[J]. 现代信息科技, 2025, 9(9): 43-47+52.
- [10] 江帆, 刘利民. 基于 GM-LSTM 的港口物流需求预测[J]. 物流科技, 2024, 47(24): 25-28+50.
- [11] 程肇兰, 张小强, 梁越. 基于 LSTM 网络的铁路货运量预测[J]. 铁道学报, 2020, 42(11): 15-21.
- [12] 叶晓龙, 罗瑞, 刘金培, 等. 基于 X11-WT-LSTM 的物流货运量多尺度组合预测研究[J]. 武汉理工大学学报(信息与管理工程版), 2022, 44(2): 263-269.
- [13] 燕学博, 曹雨. 基于多模型的铁路货运量预测对比[J]. 物流科技, 2023, 46(21): 74-78.
- [14] Koenker, R. and Bassett, G. (1978) Regression Quantiles. *Econometrica*, 46, 33-50. <https://doi.org/10.2307/1913643>
- [15] 郝令昕, 丹尼尔·Q·奈曼. 分位数回归模型[M]. 肖东亮, 译. 上海: 格致出版社, 2017.