

物流网络分拣中心人员排班策略研究

段振江, 李洪毅*

吉首大学数学与统计学院, 湖南 吉首

收稿日期: 2025年2月11日; 录用日期: 2025年3月25日; 发布日期: 2025年4月2日

摘要

在电商物流网络中, 分拣中心货量预测及人员排班对整体网络运作意义重大。以K公司华南区SC1分拣中心为例, 确定人效、班次、人数限制等参数, 并进行数据采集和预处理。接着建立CNN-LSTM-AM预测模型对分拣中心每日和每小时货量进行预测, 同时基于预测货量建立人员排班模型, 求解得到最优排班方案。结果显示货量预测误差均值在7%, 且最优排班结果各班次实际小时人效均衡、正式工安排合理, 有助于提升分拣中心管理效率、降低成本。

关键词

物流网络, 货量预测, 人员排班, 人效均衡

Research on the Staff Scheduling Strategy of the Sorting Center in the Logistics Network

Zhenjiang Duan, Hongyi Li*

College of Mathematics and Statistics, Jishou University, Jishou Hunan

Received: Feb. 11th, 2025; accepted: Mar. 25th, 2025; published: Apr. 2nd, 2025

Abstract

In the e-commerce logistics network, the prediction of the volume of goods in sorting centers and the staff scheduling are of great significance to the overall network operation. Taking the SC1 sorting center in South China of Company K as an example, this paper determines parameters such as labor efficiency, shifts, and personnel limits, and conducts data collection and preprocessing. Then, a CNN-LSTM-AM prediction model is established to predict the daily and hourly volume of goods in the sorting center. Meanwhile, based on the prediction of the volume of goods, a staff scheduling model is established, and the optimal scheduling solution is obtained through solving. The results show that the average error of

*通讯作者。

文章引用: 段振江, 李洪毅. 物流网络分拣中心人员排班策略研究[J]. 运筹与模糊学, 2025, 15(2): 176-184.
DOI: 10.12677/orf.2025.152074

the prediction of the volume of goods is 7%, and the actual hourly labor efficiency of each shift in the optimal scheduling result is balanced, and the arrangement of full-time workers is reasonable, which helps to improve the management efficiency of the sorting center and reduce costs.

Keywords

Logistics Network, Prediction of the Volume of Goods, Staff Scheduling, Balanced Labor Efficiency

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

电商物流网络在订单履约中由多个环节组成,分拣中心的货量预测是电商物流网络重要的研究问题,对分拣中心货量的精准预测是后续管理及决策的基础,如果管理者可以提前预知之后一段时间各个分拣中心需要操作的货量,便可以提前对资源进行安排。而基于货量预测后的人员排班有助于分拣中心管理效率的提升,对整体网络的履约效率和运作成本起着十分重要的作用。

关于货量预测,许多学者从不同角度、不同方法进行了研究。朱毅丁等[1]提出了一种基于 CNN-LSTM-AM 的神经网络模型,用于多维长序列物流需求预测,为物流企业提供了一个有效的参考来更好地规划资源和降低成本。于凯丽[2]利用蚁群优化训练参数的支持向量机算法,得到优化后的支持向量机预测模型对区域物流需求进行预测。李雪梅和张凌[3]先确定货运量为预测指标,用灰色 GM(1, 1)模型预测五种运输方式货运量,求和得货运总量。武亚鹏[4]采用有效度法对线性回归、ARIMA 模型以及灰色预测模型进行线性组合,并对货运量进行预测分析。

基于分拣中心货量预测的人员排班是接下来要解决的重要问题,根据货量预测结果合理安排人员,在完成工作的情况下尽可能降低人员成本。韩旭[5]以总成本最小为目标,建立了优化模型,并采用近邻域搜索算法,求出了各个出库作业环节工作人员的班次及人数。谢传柳[6]利用外点法抽象出了拟合坐席预测曲线的数学模型,并基于粒子群优化机制对坐席预测结果进行了拟合,最后采用队列轮循法生成了班表。胡修武等[7]构建整数规划模型,分析数据特征及优化性质,提出启发式算法,经实例计算实验,得出模型与算法在不同规模排班问题中的适用性。

综上,已有的研究主要是单独针对货量预测或人员排班的研究,本文将同时结合这两个问题进行研究,再根据分拣中心的货量预测结果,在满足货量处理要求的前提下,实现安排人数最少,从而降低人员成本。

2. 物流网络分拣中心货量预测及人员排班策略

2.1. 问题描述

分拣中心的货量预测是电商物流网络的重要研究问题,货量预测目标一般有两个:一是根据历史货量、物流网络配置等信息预测每个分拣中心每天的货量;二是根据历史货量小时数据预测每个分拣中心每小时的货量。基于分拣中心货量预测的人员排班是接下来要解决的重要问题,分拣中心的人员包含正式工和临时工,需根据货量预测结果合理安排人员,以在完成工作的情况下尽可能降低人员成本。

2.2. 模型参数的讨论及确定

在建立模型前,各个参数符号及含义如表 1 所示。

Table 1. Notation
表 1. 符号说明

符号	定义
P_f	正式工人数
P_l	临时工人数
E_f	正式工平均人效(包裹/小时)
E_l	临时工平均人效(包裹/小时)
C_i	第 i 个时间段的货量($i=1,2,\dots,24$, 对应0:00~23:00每个小时)
$P_{k,f}$	安排在第 k 个班次的正式工人数($k=1,2,\dots,6$)
$P_{k,l}$	安排在第 k 个班次的临时工人数($k=1,2,\dots,6$)
e_k	第 k 个班次工人的开始工作时间($k=1,2,\dots,6$)
d_k	第 k 个班次工人的结束工作时间($k=1,2,\dots,6$)

2.3. 数据采集和预处理

本文调研的对象是 K 公司华南区的分拣中心。K 公司在华南 80 个城市建立了配送站和自提点, 覆盖了 220 个区(市)县。其在华南区的销售额由 2015 年的 4 亿多元跃升至上百亿元, 增幅近 24 倍; 员工人数从 2015 年年底的 500 多人增长到 8000 多人, 增幅逾 15 倍。本文选择的是华南龙岗区平湖园区的 SC1 分拣中心, 在数据采集完成后, 对 K 公司华南区 SC1 分拣中心 2024 年 8 月 1 日~2024 年 11 月 30 日的货量数据进行了全面的数据清洗。首先, 对数据可视化, 结合统计分析方法, 识别出明显偏离整体趋势的异常值。在某些日期, 货量出现大幅波动且与前后数据差异显著, 经核实为数据记录错误, 将这些异常值进行修正或删除。对于少量的缺失值, 采用时间序列插值法进行填补, 根据前后数据的趋势来估算缺失值。

(1) 人效: 小时人效指标为每人每小时完成分拣的包裹量(包裹量即货量), SC1 分拣中心的人员包含正式工和临时工两种: 正式工是场地长期雇佣的人员, 工作效率较高; 临时工是根据货量情况临时招募的人员, 每天可以任意增减但工作效率相对较低、雇佣成本较高。其平均人效如表 2 所示。

Table 2. Average labor efficiency
表 2. 平均人效

参数	用工人员种类	平均人效(包裹/小时)
E_f	正式工	25
E_l	临时工	20

(2) 班次: SC1 分拣中心时间窗的起止时间间隔为 8 小时, 排班班次为每天共 6 个班次, 分别为 00:00~08:00, 05:00~13:00, 08:00~16:00, 12:00~20:00, 14:00~22:00, 16:00~24:00, 具体如表 3 所示。每个人员(正式工或临时工)只能出勤一个班次。

Table 3. Shift situation
表 3. 班次情况

参数	工作班次	班次时间段
$[e_1, d_1]$	第一班次	00:00~08:00
$[e_2, d_2]$	第二班次	05:00~13:00
$[e_3, d_3]$	第三班次	08:00~16:00
$[e_4, d_4]$	第四班次	12:00~20:00

续表

$[e_5, d_5]$	第五班次	14:00~22:00
$[e_6, d_6]$	第六班次	16:00~24:00

(3) 人数限制。SC1 分拣中心目前有 60 名正式工, 在安排人员时将优先使用正式工, 若需要额外人员将使用临时工。则每天的正式工人数的下限是 0, 人数上限是 60; 而临时工人数根据货量情况可以任意增减。因此 P_f 和 P_l 的变化区间分别为 $[0, 200]$, $[0, +\infty)$, 具体定义如表 4 所示。

Table 4. Restriction on the number of scheduled personnel

表 4. 排班人数限制

参数	用工人员种类	人数变化区间
$[P_f^{\min}, P_f^{\max}]$	正式工	$[0, 200]$
$[P_l^{\min}, P_l^{\max}]$	临时工	$[0, +\infty)$

(4) 货量。SC1 分拣中心 2024 年 8 月 1 日~2024 年 11 月 30 日每日货量如图 2 所示。

2.4. CNN-LSTM-AM 货量预测模型

为了更好地处理物流需求预测问题, 根据 CNN、LSTM 和 AM 的特点以及输入数据的特点, 建立了基于 CNN-LSTM-AM 的预测模型。模型结构图如图 1 所示。




Figure 1. Structural diagram of the CNN-LSTM-AM model

图 1. CNN-LSTM-AM 模型结构图

该模型的主要结构包括 CNN、LSTM 和 AM, 涵盖了输入层、CNN 层(一维卷积层、池化层)、LSTM 层、AM 层(注意力机制层)、全连接层以及输出层。

2.5. 基于货量预测的人员排班模型

本模型旨在根据分拣中心的货量预测结果, 在满足货量处理要求的前提下, 实现安排人数最少, 从而降低人员成本。模型综合考虑了正式工和临时工的不同工作效率、各时间段货量以及排班班次等因素, 通过合理分配人员到不同班次来达成目标。

2.5.1. 模型假设

- (1) 正式工和临时工在工作时间内的工作效率保持稳定, 分别为每小时 25 个包裹和 20 个包裹。
- (2) 每个班次的工作时间严格按照规定执行, 人员中途不休息、不换班(除不同日期的班次轮转)。
- (3) 货量预测数据准确可靠, 可作为人员排班的依据。

(4) 若正式工数量充足则正式工优先排班, 若正式工数量不足则招募临时工补充。

2.5.2. 模型建立

(1) 定义决策变量

决策变量为: 各个班次安排的正式工人数 $P_{k,f}$ 和临时工人数 $P_{k,l}$, 以及各个班次的起止时间 e_k 和 d_k 。

(2) 目标函数

目标: 在完成货量要求的前提下, 使安排的总人数最少, 且每天的实际小时人效尽量均衡。

$$\min Z = P_f + P_l$$

(3) 货量处理约束

每个班次处理的货量应该不小于该班次时间段内的货量预测值:

$$\text{对于第一班次}[e_1, d_1]: \sum_{i=1}^8 (P_{1,f} \cdot E_f + P_{1,l} \cdot E_l) \geq \sum_{i=1}^8 C_i;$$

$$\text{对于第二班次}[e_2, d_2]: \sum_{i=5}^{13} (P_{2,f} \cdot E_f + P_{2,l} \cdot E_l) \geq \sum_{i=5}^{13} C_i;$$

$$\text{对于第三班次}[e_3, d_3]: \sum_{i=8}^{16} (P_{3,f} \cdot E_f + P_{3,l} \cdot E_l) \geq \sum_{i=8}^{16} C_i;$$

$$\text{对于第四班次}[e_4, d_4]: \sum_{i=12}^{20} (P_{4,f} \cdot E_f + P_{4,l} \cdot E_l) \geq \sum_{i=12}^{20} C_i;$$

$$\text{对于第五班次}[e_5, d_5]: \sum_{i=14}^{22} (P_{5,f} \cdot E_f + P_{5,l} \cdot E_l) \geq \sum_{i=14}^{22} C_i;$$

$$\text{对于第六班次}[e_6, d_6]: \sum_{i=16}^{24} (P_{6,f} \cdot E_f + P_{6,l} \cdot E_l) \geq \sum_{i=16}^{24} C_i。$$

(4) 人员数量约束

正式工人数不能超过分拣中心的正式工总数: $0 \leq P_f \leq 60$ ($j=1, 2, \dots, 6$), 且 $\sum_{k=1}^6 P_{k,f} = P_f$ 。

临时工人数不能为负: $P_l \geq 0$ ($j=1, 2, \dots, 6$), 且 $\sum_{k=1}^6 P_{k,l} = P_l$ 。

则上述人员排班问题的数学模型为:

$$\begin{aligned} \min Z &= P_f + P_l \\ \text{s.t.} \quad &\begin{cases} \sum_{i=1}^8 (P_{1,f} \cdot E_f + P_{1,l} \cdot E_l) \geq \sum_{i=1}^8 C_i \\ \sum_{i=5}^{13} (P_{2,f} \cdot E_f + P_{2,l} \cdot E_l) \geq \sum_{i=5}^{13} C_i \\ \sum_{i=8}^{16} (P_{3,f} \cdot E_f + P_{3,l} \cdot E_l) \geq \sum_{i=8}^{16} C_i \\ \sum_{i=12}^{20} (P_{4,f} \cdot E_f + P_{4,l} \cdot E_l) \geq \sum_{i=12}^{20} C_i \\ \sum_{i=14}^{22} (P_{5,f} \cdot E_f + P_{5,l} \cdot E_l) \geq \sum_{i=14}^{22} C_i \\ \sum_{i=16}^{24} (P_{6,f} \cdot E_f + P_{6,l} \cdot E_l) \geq \sum_{i=16}^{24} C_i \\ 0 \leq P_f \leq 60 \\ P_l \geq 0 \end{cases} \end{aligned}$$

其中 $\sum_{k=1}^6 P_{k,f} = P_f$, $\sum_{k=1}^6 P_{k,l} = P_l$ 。

3. 求解结果分析

3.1. 基于 CNN-LSTM-AM 预测模型的货量预测结果

在构建 CNN-LSTM-AM 模型时, 模型各部分参数的选择经过了反复试验和验证。对于 CNN 层, 卷积核大小选择为 3。这是因为经过多次实验对比, 卷积核大小为 3 时, 能够较好地捕捉货量时间序列中的局部短期特征, 如连续三天内货量的变化趋势。

LSTM 层的隐藏单元数量设置为 64。通过逐步调整隐藏单元数量并观察模型在验证集上的表现, 发现 64 个隐藏单元能够在模型复杂度和拟合能力之间达到较好的平衡。

注意力机制(AM)层的参数设置是基于对不同时间步特征重要性的考量。通过设置合适的权重矩阵, 使模型能够更加关注对货量预测有重要影响的时间步。

将训练好的 CNN-LSTM-AM 神经网络模型进行保存, 并根据历史货量、物流网络配置等信息, 利用 CNN-LSTM-AM 神经网络模型对 SC1 分拣中心的货量进行预测, 其每天的货量如图 2 所示。




Figure 2. Daily cargo volume forecast chart of SC1 sorting center
图 2. SC1 分拣中心每天的货量预测图

结果表明, 当实际单量比较稳定时, 预测结果效果比较佳, 误差均值在 7%。

根据历史货量小时数据, 预测 SC1 分拣中心每小时的货量数据如表 5 所示, 并将其进行可视化如图 3 所示。

Table 5. Predicted cargo volume per hour for SC1

表 5. SC1 每小时预测货量

参数	时间段	参数值(货量)
C_1	0:00~0:59	3179
C_2	1:00~1:59	3332
C_3	2:00~2:59	2984
C_4	3:00~3:59	2651
C_5	4:00~4:59	2794

续表

C_6	5:00~5:59	2690
C_7	6:00~6:59	26
C_8	7:00~7:59	756
C_9	8:00~8:59	1547
C_{10}	9:00~9:59	1413
C_{11}	10:00~10:59	1546
C_{12}	11:00~11:59	1598
C_{13}	12:00~12:59	2770
C_{14}	13:00~13:59	3305
C_{15}	14:00~14:59	155
C_{16}	15:00~15:59	93
C_{17}	16:00~16:59	712
C_{18}	17:00~17:59	643
C_{19}	18:00~18:59	946
C_{20}	19:00~19:59	1746
C_{21}	20:00~20:59	2409
C_{22}	21:00~21:59	2772
C_{23}	22:00~22:59	2946
C_{24}	23:00~23:59	3026




Figure 3. Model predicted cargo volume per hour of the SC1 sorting center

图 3. SC1 分拣中心每小时的预测货量

3.2. 基于货量预测的人员排班结果

将所求得的 SC1 每小时预测货量数据导入本文所建立的人员排班模型中, 并结合平均人效、班次情况、排班人数限制等数据, 通过 Matlab 编程求解, 得到如表 6 所示的最优排班结果。

根据表 6 所示, 每个班次的实际小时人效较为均衡, 正式工人员安排班次较为合理, 满足最初的安排目标。

Table 6. Staff scheduling for each shift at the SC1 sorting center
表 6. SC1 分拣中心各班次人员排班

工作班次	班次时间段	正式工人数	临时工人数
第一班次	00:00~08:00	0	71
第二班次	05:00~13:00	0	29
第三班次	08:00~16:00	60	7
第四班次	12:00~20:00	0	8
第五班次	14:00~22:00	0	13
第六班次	16:00~24:00	0	97

4. 误差检验与敏感性分析

为了验证模型的泛化能力，在 K 公司多个不同区域的分拣中心进行了实验。除了华南区的 SC1 分拣中心，还选取了华东区的 SC4 分拣中心和华北区的 SC5 分拣中心。在这些分拣中心收集了相同时间段的货量数据、人员信息等，并应用本文所建立的货量预测和人员排班模型进行实验。

实验结果显示，在 SC4 分拣中心，货量预测的误差均值为 8%，人员排班方案使得各班次实际小时人效差异在 10%以内；在 SC5 分拣中心，货量预测误差均值为 7.5%，人员排班方案有效降低了人员成本。这表明模型在不同区域的分拣中心均能保持较好的性能，具有一定的泛化能力。

在敏感性分析方面，对模型中的关键参数进行了调整并观察模型输出的变化。在货量预测模型中，将学习率分别调整为 0.001、0.01 和 0.1，发现当学习率在 0.001~0.01 之间时，模型的预测误差变化较小，保持在 7%~8%之间；但当学习率增大到 0.1 时，预测误差迅速上升至 12%。在人员排班模型中，调整不同工种的人效系数，当系数在±10%的范围内变化时，人员排班方案的总成本变化在 5%以内，说明模型在一定参数变化范围内具有较好的鲁棒性。

5. 结论

本研究将分拣中心货量预测与人员排班相结合，区别于以往单独针对货量预测或人员排班的研究。基于 CNN-LSTM-AM 的预测模型在处理物流网络分拣中心货量预测问题上具有一定有效性。以 K 公司华南区 SC1 分拣中心为例，通过采集和预处理相关数据，利用该模型对每日和每小时货量进行预测，结果显示当实际单量稳定时，预测效果较好，每日货量预测误差均值在 7%。

构建的基于货量预测的人员排班模型综合考虑多种因素，包括正式工和临时工工作效率、各时间段货量及排班班次等。将预测货量数据导入模型并结合其他相关数据，通过 Matlab 编程求解得到最优排班方案，该方案使各班次实际小时人效较为均衡，正式工人员安排班次合理，达到了在满足货量处理要求前提下安排人数最少从而降低人员成本的目标。

上述研究为电商物流网络分拣中心管理提供了一种有效的方法，有助于提升分拣中心管理效率，进而对整体网络的履约效率和运作成本产生积极影响，也为物流行业在相关问题上的研究与实践提供了参考范例。

基金项目

2024 年度国家级大学生创新创业训练计划项目(S202410531020)。

参考文献

[1] 朱毅丁, 张云川, 马云峰, 等. 基于 CNN-LSTM-AM 神经网络的多维长序列物流需求预测[J]. 物流科技, 2024,

47(18): 49-56+64.

- [2] 于凯丽. 基于支持向量机的区域物流需求预测研究[J]. 中国经贸导刊, 2022(5): 85-87.
- [3] 李雪梅, 张凌. 灰色系统预测模型在广东省物流需求预测中的应用[J]. 物流科技, 2023, 46(17): 11-15.
- [4] 武亚鹏, 李慧颖, 李婷, 等. 基于多模型组合的物流需求预测分析——以武汉市为例[J]. 物流技术, 2022, 41(6): 60-63.
- [5] 韩旭. 带时间窗的 J 公司仓储出库作业人员排班优化问题研究[D]: [硕士学位论文]. 北京: 北京交通大学, 2017.
- [6] 谢传柳, 王俊峰, 夏正洪, 等. 大型呼叫中心排班算法的研究[J]. 计算机工程与设计, 2010, 31(23): 5108-5112.
- [7] 胡修武, 徐悦, 王秀利. 呼叫中心坐席人员排班问题优化模型与算法研究[J]. 运筹与管理, 2021, 30(8): 44-51.