第 41 卷第 3 期 山东航空学院学报 2024 年 12 月
Vol. 41, No. 3 Journal of Shandong University of Aeronautics Dec., 2024

【航空管理与安全】

基于 ARIMA-LSTM 的长三角航空物流需求预测

金　真，孙　旭，宋　果

（郑州航空工业管理学院 管理工程学院，河南 郑州 450046）

摘　要：航空物流作为高效、快速的物流方式，在推进长三角一体化发展的过程中发挥着重要作用。随着物流需求的增加，科学、准确地预测未来的航空物流需求量成为地区经济规划和物流战略制定的关键问题。针对当前长三角一体化航空物流的发展现状，基于现有的物流需求预测方法，综合考虑数据的线性与非线性特征，构建了差分整合移动自回归-长短时记忆网络组合模型。以长三角地区 2000—2023 年的航空货邮吞吐量为数据来源，分别使用差分整合移动自回归模型、长短时记忆网络以及两者的组合模型进行了预测，并对比分析了它们的预测效果。结果表明，该组合模型相较于传统的单一模型具有更高的预测精度，能够有效捕捉数据的复杂特征和趋势变化，对物流需求预测具有更好的效果，并以此模型预测了未来五年长三角航空物流的需求量情况。

关键词：长三角一体化；航空物流；ARIMA 模型；LSTM 模型；需求预测

中图分类号：F 56　　**文献标识码**：A　　DOI：10.13486/j.issn.2097-4973.2024.03.004

0 引言

长三角地区是我国经济发展最活跃、开放程度最高、创新能力最强的区域之一。随着我国经济的发展，区域经济一体化成为长三角发展的必由之路。在实现区域经济一体化的过程中，物流一体化是关键前提[1]。航空物流作为物流业的重要组成部分，在长三角一体化发展中有着独特的地位与作用。受疫情影响，2022 年长三角航空货邮吞吐量迅速下降，但随着疫情防控的解除，民航业逐渐复苏，2023 年长三角航空货邮吞吐量已达 561.812 万吨，同比增长 13.62%，且伴随长三角一体化发展战略的深入推进，未来，传统的航空物流模式将难以应对不断增长的物流需求。因此，加快产业结构升级，助推航空物流一体化发展势在必行。在此背景下，物流需求预测显得尤为迫切，它将有助于企业和政府部门更好地规划资源配置[2]，从而满足未来物流需求的变化。

目前，用于物流需求预测的理论方法分为线性预测和非线性预测两种[3]。线性预测简单直观，容易理解，具有良好的稳定性与广泛的适用性，常用方法包括线性回归、指数平滑、差分整合移动自回归模型（ARIMA）等。彭婷等[4]基于机器学习下的线性回归对武汉天河机场的货邮吞吐量进行了预测；Weng 等[5]建立 ARIMA 模型，对不同物流线路的货运量进行了预测。然而，线性预测在处理复杂问题时表现较

收稿日期：2024-08-02

基金项目：河南省高等学校重点科研项目（22A87008）

第一作者简介：金　真（1963—　），女，湖南邵阳人，教授，主要从事供应链与物流管理、航空物流研究。
E-mail：892418545@qq.com

差，且容易受到异常值的影响。因此，许多学者更倾向于采用非线性预测方法。非线性预测的拟合能力强，能够捕捉数据中的复杂关系，并且支持多种模型和算法，常用方法包括灰色预测、支持向量机（SVM）、长短时记忆神经网络模型（LSTM）等。盛朝霖[6]构建 SSA-XGBoost-LSTM 模型对水产品冷链物流企业的物流需求进行了预测；Huang 等[7]运用 GM (1,1)和 BP 神经网络模型对广东省物流需求进行了对比预测等。尽管非线性预测通常具有更好的预测效果，但其模型结构复杂，内部机制较难理解，所需资源与计算时间较大，且易过度拟合。为了充分发挥两者的优势，减少单一模型带来的偏差或错误，许多研究者考虑将两类模型结合使用，从而提高模型的鲁棒性和稳定性，更灵活地适应各种数据情况。李思聪等[8]构建灰色-回归组合模型，对我国农产品冷链物流需求量进行了预测，验证了该组合模型较两个单一模型具有更高的预测精度；杨建成[9]建立 ARIMA-SVM 模型，通过实证分析预测了某地的物流需求，证明了该组合模型的优越性；Wang 等[10]采用 ARIMA 与 BPNN 相结合的方法对“十四五”期间的物流总量状况进行了预测，结果表明，该组合模型能够兼顾各单一模型的优势，预测效果更为理想。

综上，考虑到物流需求预测数据影响因素的复杂性，而 ARIMA 与 LSTM 模型分别能够很好地捕捉数据中的线性与非线性特征，因此本文提出构建 ARIMA-LSTM 组合模型，并验证该组合模型对航空物流需求预测的可行性，为长三角一体化航空物流体系的构建及政策制定提供参考。

1 模型介绍

1.1 差分整合移动自回归模型

ARIMA 模型是一种被广泛使用的传统预测模型，它主要由自回归（AR）模型、移动平均（MA）模型与它们的差分（I）过程三部分组成，常表现为 ARIMA(p,d,q)结构。其中，p 为自回归阶数，d 为差分次数，q 为移动平均阶数[11]。AR 模型是对时间序列进行预测的一种方法，它通过分析变量自身的过去数据来描述当前值与历史值之间的关系，并利用这种关系进行预测，其数据必须满足平稳性要求。

一般 p 阶 AR 模型的公式定义为 $X_t = \mu + \sum_{i=1}^{p} \phi_i X_{t-i} + \varepsilon_t$。式中：$X_t$ 为时间序列在 t 时刻的观察值；μ 为常数项；ϕ_i 为自回归系数；X_{t-i} 为时间序列在 $t-i$ 时刻的观察值；ε_t 为 t 时刻误差值，即白噪声。

MA 模型关注的是 AR 模型中误差项的累加，即时间序列当前值与历史值没有关系，其只依赖于历史白噪声的线性组合。一般 q 阶 MA 模型的公式定义为 $X_t = \mu + \sum_{j=1}^{q} \theta_j \varepsilon_{t-j} + \varepsilon_t$。式中：$\theta_j$ 为移动平均系数，ε_{t-j} 为 $t-j$ 时刻的误差值。

自回归移动平均（ARMA）模型结合了 AR 和 MA 两种模型的特性，用于描述时间序列数据中的趋势和周期性。其表达式为 $X_t = \mu + \sum_{i=1}^{p} \phi_i X_{t-i} + \varepsilon_t + \sum_{j=1}^{q} \theta_j \varepsilon_{t-j}$。

ARIMA 模型除了自回归和移动平均部分，还包括数据差分。当原数据并不平稳时，需要通过差分（I）过程使其变为平稳序列[12]，再应用于 ARMA 模型中。ARIMA 模型预测流程如图 1 所示。

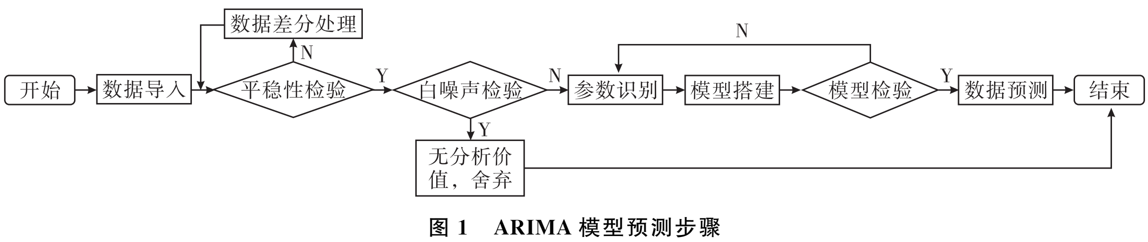

图 1　ARIMA 模型预测步骤

1.2 长短时记忆神经网络模型

LSTM 模型是一种特殊的循环神经网络（RNN）模型。LSTM 模型能够学习和记忆长期依赖信息，通

过引入记忆细胞和门控机制，解决了传统 RNN 模型在处理长序列数据时容易出现的梯度消失和梯度爆炸的问题[13]。它主要由遗忘门、输入门与输出门三部分组成，这些门控机制通过不同的公式和函数共同作用，来控制信息的流动，其工作原理如图 2 所示。

遗忘门利用 sigmoid 激活函数将上一个时间步的隐藏状态 h_{t-1} 和当前输入 x_t 转化为全是 0～1 的数。越接近 0 越容易被忘记，越接近 1 则越容易被记住。遗忘门输出值

$$f_t=\sigma(W_f\cdot[h_{t-1},x_t]+b_f)。$$

式中：W_f 为权重矩阵，b_f 为偏置项，σ 为 sigmoid 函数。输入门先通过一个 sigmoid 激活函数决定哪些数据将被更新，再通过一个 tanh 函数生成候选记忆单元，创建新的候选值，输入门输出值与候选记忆的公式分别为

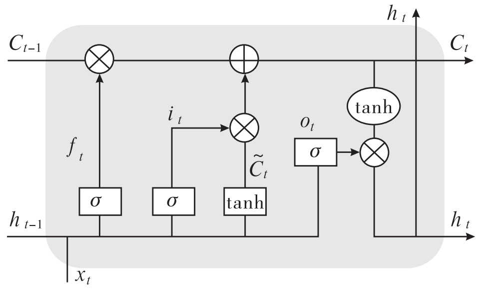

图 2　LSTM 模型结构单元

$$i_t=\sigma(W_i\cdot[h_{t-1},x_t]+b_i),\tilde{C}_t=\tanh(W_C\cdot[h_{t-1},x_t]+b_C)。$$

式中：W_i 与 W_C 为权重矩阵，b_i 与 b_C 为偏置项。

随后综合遗忘门和输入门的输出，更新当前的记忆单元

$$C_t=f_t*C_{t-1}+i_t*\tilde{C}_t。$$

式中：* 为元素逐乘法。输出门通过 sigmoid 函数确定输出数据，再将更新后的细胞状态通过 tanh 函数进行处理，最后将这两部分相乘，输出当前隐藏状态 h_t。输出门输出值与隐藏状态的函数表达式分别为

$$o_t=\sigma(W_o\cdot[h_{t-1},x_t]+b_o),h_t=o_t*\tanh(C_t)。$$

式中：W_o 为权重矩阵，b_o 为偏置项。

1.3　ARIMA-LSTM 组合模型

ARIMA-LSTM 组合模型是 ARIMA 模型与 LSTM 模型的组合。它先利用 ARIMA 提取出时间序列中的线性特征，并生成初步预测结果 L_t。再由 LSTM 模型对 ARIMA 模型的预测残差进行处理，提取出其中所包含的非线性信息[14]，得到预测结果 N_t。最后两者的预测结果相加，得到整体的最终预测值 D_t，该组合模型预测流程见图 3。其中，ARIMA 模型的残差 $e_t=Y_t-L_t$。式中：Y_t 为时间序列原始数据。残差预测值

$$N_t=f(e_{t-1},e_{t-2},\cdots,e_{t-m})+\varepsilon_t。$$

式中：$f(\cdot)$为 LSTM 模型建立的关系函数，ε_t 为误差值。

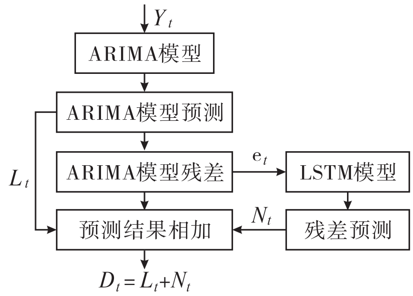

图 3　ARIMA-LSTM 组合模型预测过程

2　实例分析

2.1　数据来源

为了预测长三角地区的航空物流需求量，本研究以长三角地区所涉及的 27 个城市为调查对象，通过搜集中国民用航空局官网公布的 2000—2023 年全国机场年度生产公报数据，对长三角 27 个城市现有的 17 个机场的历年航空货邮吞吐量进行了统计，并将 17 个机场的货邮吞吐量逐年相加，得到长三角地区 2000—2023 年航空货邮吞吐量数据，以此衡量长三角地区近 24 年航空物流需求情况。其时序排布情况如图 4 所示。

2.2　ARIMA 模型航空货邮量预测

2.2.1 数据预处理

ARIMA 模型在预测时要求数据为平稳序列，需要先对原始数据进行平稳性检验。通过图检验法发

现时序图中航空货邮吞吐量随着时间的变化而变化，表现为非平稳状态。但该方法过于主观，无法充分证明其非平稳性。进一步用增广迪基-福勒（ADF）检验得到 ADF 统计值为 -2.992，超过了 1%（-4.012）与 5%（-3.104）的拒绝原假设临界值，且 p 值为 0.036 不接近于 0，确认了数据的非平稳状态。对非平稳的数据进行一阶差分，而后再次进行 ADF 检验，结果为 -5.883，小于最小的 1%（-3.770）拒绝原假设的临界值，p 值为 3.042×10^{-7} 接近于 0，这说明数据已经趋于平稳。随后进行白噪声检验以验证序列的随机性。若数据是白噪声序列，则表明其中没有有用的信息和结构可供分析，应该予以舍弃[15]。检验结果为 7.670×10^{-6}，即在显著水平 0.05 下，数据为非白噪声序列。

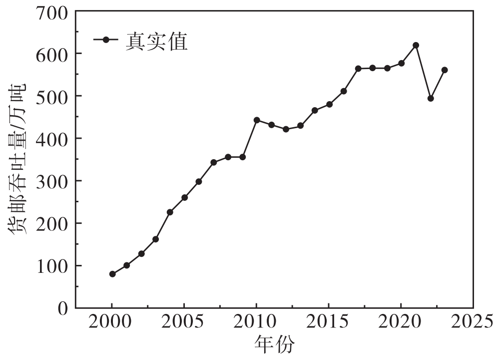

图 4　2020—2023 年长三角航空货邮吞吐量时序图

2.2.2　模型定阶

通过一阶差分结果确认了时间序列已达到平稳状态，所以参数 $d=1$。作出时间序列的自相关（ACF）和偏自相关（PACF）图，如图 5、图 6 所示。通过分析两图发现，ACF 呈现拖尾，而 PACF 显示 1 阶截尾，该结果表明，可能适合使用 AR 模型，因此考虑 p 的取值为 1 或 0，q 的取值为 0。然而，此方法较为主观，未必能获得最佳模型参数，需要采用赤池信息准则（AIC）进行更进一步的参数选择。设定 p 值和 q 值的范围均为(0,3)，进行网格搜索寻优，结果显示 ARIMA(0,1,0)具有最小的 AIC 值，确定其为最优模型结构。

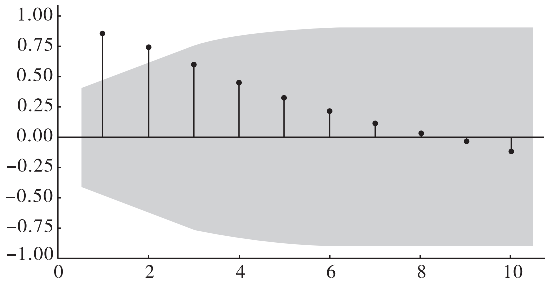

图 5　一阶差分数据 ACF 图

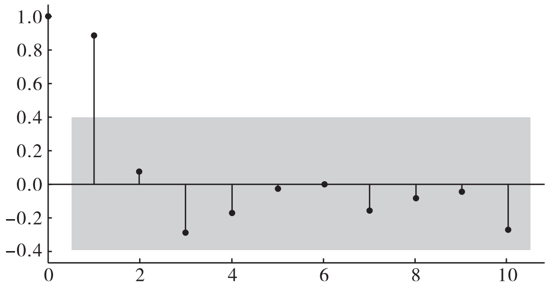

图 6　一阶差分数据 PACF 图

2.2.3　ARIMA 模型预测

选择 ARIMA(0,1,0)模型对 2000—2023 年长三角航空物流货邮吞吐量进行预测。设置 75% 的样本数据作为模型的训练数据，将训练完成的模型用于数据预测。

2.3　LSTM 模型航空货邮量预测

2.3.1　数据归一化

原始数据无法直接输入 LSTM 模型，需要对数据进行归一化处理，使其全部落在(0,1)或(−1,1)。归一化处理可以增加数值的稳定性以及帮助模型加快收敛速度等，有助于 LSTM 模型更好地拟合。常用的数据归一化方法为 Min-Max 归一化与 Z-score 归一化。本文数据采用 Min-Max 方法进行归一化处理，其表达式为

$$x'=\frac{x-x_{\min}}{x_{\max}-x_{\min}}。$$

式中：x 为原始数据，x' 为归一化后的数据，$x_{\min}$ 为数据集中的最小值，$x_{\max}$ 为数据集中的最大值。

2.3.2　LSTM 模型预测

使用 Pycharm 软件，在 Tensorflow 环境下搭建 LSTM 神经网络模型。将归一化后的数据导入模型

中,设定75%数据量为训练集,通过反复调参寻优,最终确定了以下模型参数设置:时间步长为4,即用前4个时间步的数据来预测下一个时间步的数据;LSTM包含一个隐藏层,神经单元为128个;引入Dropout层,丢弃率为0.2;全连接层输出维度为1。设置迭代次数为100,每次更新权重时的批量大小为16。其中,损失函数设置为均方误差(MSE),优化函数为Adam,当迭代次数达到30次左右时,损失趋于平稳,达到较好效果,如图7所示。

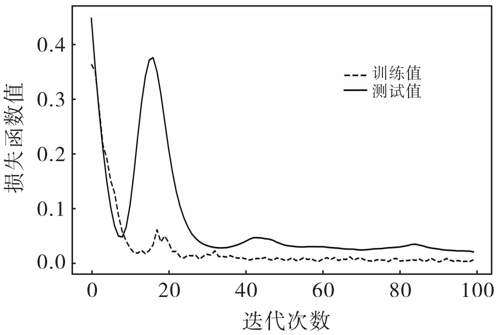

图7　LSTM模型迭代过程

利用训练完成的模型进行数据预测,得到LSTM模型初步预测结果。将该结果进行反归一化处理,使其还原为原始数据的范围,最终预测结果见表1。

表1　各模型预测结果

年份	真实值	ARIMA	LSTM	ARIMA-LSTM
2004	226.372	167.482	246.319	217.177
2005	261.604	232.977	267.663	272.121
2006	298.108	269.454	299.196	312.834
2007	345.101	307.152	329.813	351.433
2008	356.958	355.663	355.513	399.842
2009	358.917	367.570	374.427	402.697
2010	444.013	369.209	390.400	397.791
2011	432.846	456.975	421.339	488.059
2012	422.405	444.976	435.450	470.393
2013	428.947	433.783	452.880	455.881
2014	466.709	440.169	472.691	460.391
2015	481.516	478.761	491.519	486.396
2016	511.051	493.651	513.097	508.753
2017	564.469	523.698	545.457	546.460
2018	566.029	578.280	585.549	608.211
2019	565.290	579.500	629.583	605.652
2020	576.783	578.377	683.488	601.841
2021	619.096	589.828	706.650	607.705
2022	494.451	632.892	723.702	645.816
2023	561.812	504.786	682.951	504.932

2.4　ARIMA-LSTM组合模型航空货邮量预测

在初步得到ARIMA预测结果后,使用真实数据值减去该预测结果,得到ARIMA模型的预测残差。设置组合模型中的LSTM部分与单独LSTM预测时具有相同的参数。将训练好的LSTM模型用于预测这些残差值,以提取其中所包含的非线性信息,生成残差预测序列。通过LSTM模型预测得到的残差序列与ARIMA模型的预测结果相加以得出最终的ARIMA-LSTM组合模型预测结果,见表1。由于设置的LSTM模型时间步长为4,前四年的吞吐量无法预测,因此只分析2004—2023年结果。

2.5 模型对比分析

根据 ARIMA、LSTM 与 ARIMA-LSTM 三种模型的预测结果，绘制各模型预测结果对比图，如图 8 所示。观察图 8 发现，ARIMA-LSTM 组合模型的预测曲线与真实值的贴合度最高，表现出最佳的拟合效果。但仅凭图像观察难以准确地评估各模型的优劣，因此需要对预测结果进行误差评价，进一步确定各模型的预测精准度。

2.6 模型评价

为了更直观地比较各模型的预测效果，本文采用均方误差(MSE)、均方根误差(RMSE)与平均绝对误差(MAE)[16]三种常用的误差评估方法。它们的函数表达式分别为

$$E(\mathrm{MSE})=\frac{1}{N}\sum_{i=1}^{N}(Y_i-\widetilde{Y}_i)^2, E(\mathrm{RMSE})=\sqrt{\frac{1}{N}\sum_{i=1}^{N}(Y_i-\widetilde{Y}_i)^2}, E(\mathrm{MAE})=\frac{1}{N}\sum_{i=1}^{N}|Y_i-\widetilde{Y}_i|。$$

式中：N 为样本数据容量，Y_i 为实际值，$\widetilde{Y}_i$ 为预测值。各模型评价结果见表 2。从表 2 中可以看出，ARIMA 模型的 MSE、RMSE 和 MAE 均为最高，相比其他两个模型，ARIMA 模型的预测精度最低，效果最差。LSTM 作为非线性的预测模型相较于线性的 ARIMA 模型，虽然各项误差评价值都有所降低，但其与真实值之间仍存在较大的偏差。而将两者结合的 ARIMA-LSTM 组合模型在各项误差评价值上均显著低于两个单一模型，拥有最佳的预测精度，体现了该组合模型的优越性。究其原因，当 ARIMA 模型对数据进行拟合时，它可以解释大部分的线性结构。但由于其对非线性模式的敏感度较低，任何无法通过线性关系解释的部分都会反映在残差中，而 LSTM 模型通过门控机制，在 ARIMA 模型留下的残差中可以学习到数据中未捕捉的非线性模式，与 ARIMA 模型的预测结果相加后，可以使其与真实值之间的误差更小，进一步提高预测的准确性。因此，ARIMA-LSTM 组合模型的预测精度才会比两个单一模型更高。

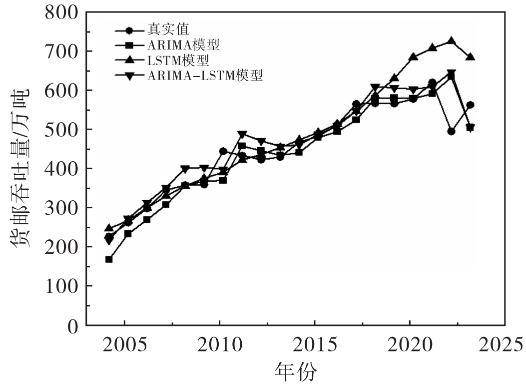

图 8 各模型预测结果

表 2 各模型评价结果

模型	MSE	RMSE	MAE
ARIMA	12 658.769	112.511	50.902
LSTM	4 789.996	69.210	41.389
ARIMA-LSTM	3 077.793	55.478	39.470

2.7 未来航空物流需求量预测

在模型对比中验证了 ARIMA-LSTM 组合模型较之于 ARIMA 与 LSTM 模型在物流需求预测上的优越性，证明了其用于物流预测的可行性。以短期的未来五年为例，使用该组合模型对长三角 2024—2028 年的航空物流需求量进行预测，为将来的航空物流政策制定、资源配置及体系构建等提供参考价值，预测结果见表 3。

表 3 2024—2028 年预测结果

年份	2024	2025	2026	2027	2028
航空货邮吞吐量/万吨	505.595	517.428	524.934	563.327	565.371

表 3 显示，未来五年长三角地区的航空货邮吞吐量虽未达到 2021 年最高的 619 万吨，但均处在

500 万吨以上的高水平，并伴随有逐年增长的趋势。

3　结语

在长三角一体化发展的背景下，本文从数据的线性和非线性特征角度出发，提出一种基于 ARIMA-LSTM 的航空物流需求预测模型。通过对长三角航空物流吞吐量进行实验研究与分析可知，该组合模型相较于传统的单一 ARIMA 与 LSTM 模型，具有更高的预测精度，在物流需求预测上具有更好的效果。其在预测精度上的提升极大地提高了物流量数据预测的准确性，将有利于航空物流业进行更加合理的资源整合与调度。然而，由于该组合模型中的 LSTM 部分属于神经网络类模型，其在神经网络优化上仍有进一步改进的空间。未来的研究将探索更有效的神经网络优化策略，或寻找其他更适用于航空物流需求预测的新模型。

参考文献：

[1] 张兵. 长三角一体化背景下区域物流业发展的联动效应研究[J]. 商业经济研究，2020(22)：88-91.

[2] SUH D Y，RYERSON M S. Forecast to grow：aviation demand forecasting in an era of demand uncertainty and optimism bias[J]. Transportation research part E：logistics and transportation review，2019，128：400-416.

[3] 汪勇，廖倩茹，艾学轶，等. 基于 Markov-BP 神经网络的武汉市物流需求预测[J]. 物流技术，2023，42(9)：24-27.

[4] 彭婷，邓旭东. 基于机器学习的天河机场物流预测研究[J]. 物流科技，2023，46(5)：97-100.

[5] WENG Y Q，WANG Z R. ARIMA time series based logistics route cargo volume forecasting research[J]. Academic journal of computing & information science，2023，6(8)：95-104.

[6] 盛朝霖. 基于 SSA-XGBoost-LSTM 的水产品冷链运输企业物流需求预测研究[D]. 大连：大连海事大学，2023.

[7] HUANG L J，XIE G J，ZHAO W D，et al. Regional logistics demand forecasting：a BP neural network approach[J]. Complex & intelligent systems，2021：1-16.

[8] 李思聪，叶静. 基于灰色回归模型的农产品冷链物流需求分析及预测[J]. 公路交通科技，2022，39(5)：166-174.

[9] 杨建成. ARIMA-SVM 的物流需求预测模型[J]. 现代电子技术，2018，41(9)：182-186.

[10] WANG J J，XING Y Q，ZHANG S，et al. A HYBRID total logistics forecasting method combined with ARIMA and BPNN[J]. Journal of physics：conference series，2021，1769(1)：012051.

[11] 曹莹，陈旭，张跃博，等. 基于 ARIMA-BP 神经网络组合预测的港口吞吐量预测[J]. 物流技术，2023，42(12)：84-91.

[12] 孙学波，刘宁，王元杰，等. 时间序列 ARIMA 模型在煤矿地音监测系统中的应用[J]. 煤炭工程，2023，55(10)：111-117.

[13] 李浩，赵青，崔辰州，等. 基于 CNN 与 LSTM 复合深度模型的恒星光谱分类算法[J]. 光谱学与光谱分析，2024，44(6)：1668-1675.

[14] 李如仁，李梦晨，葛永权，等. 基于多源因素融合回归和 ARIMA-LSTM 的露天矿地表形变趋势分析[J/OL]. 金属矿山，(2024-04-22)[2024-07-30]. http://kns.cnki.net/kcms/detail/34.1055.TD.20240419.1826.002.html.

[15] 陈浩，胡静茹，王寿兵，等. 基于 ARIMA-LEAP 模型的中国钢铁行业二氧化碳排放特征和减排路径研究[J/OL]. 中国环境科学，(2024-01-25)[2024-07-30]. https://doi.org/10.19674/j.cnki.

issn1000-6923.20240024.004.
[16] CAO Y S,LIU G,LUO D H,et al. Multi-timescale photovoltaic power forecasting using an improved Stacking ensemble algorithm based LSTM-Informer model[J]. Energy,2023,283:128669.

Research on Demand Forecast of Air Logistics in Yangtze River Delta Based on ARIMA-LSTM

JIN Zhen,SUN Xu,SONG Guo
(*School of Management Engineering,Zhengzhou University of Aeronautics,*
Zhengzhou 450046,*China*)

Abstract:As an efficient and rapid logistics approach,air logistics assumes a significant role in facilitating the integrated development of the Yangtze River Delta. With the escalation of logistics demands and the imbalance in development,scientifically and accurately predicting future air logistics demands has emerged as a crucial issue in regional economic planning and logistics strategy formulation. Considering the current development status of integrated air logistics in the Yangtze River Delta and the existing logistics demand forecasting methods,this paper comprehensively takes into account the linear and nonlinear characteristics of the data and constructs a autoregressive integrated moving average-long short term memory model. The air cargo throughput in the Yangtze River Delta region from 2000 to 2023 is adopted as the data source. The autoregressive integrated moving average model (ARIMA),the long short-term memory (LSTM),and the combination of the two models were employed for prediction,and their prediction effects were compared and analyzed. The results demonstrate that,in contrast to the traditional single model,the combined model possesses higher prediction accuracy,can effectively capture the complex characteristics and trend variations of the data,and yields a better effect on the logistics demand forecast. This model predicts the demand of air logistics in the Yangtze River Delta for the next five years.

Keywords:Yangtze River Delta integration;air logistics;ARIMA model;LSTM model;demand forecasting

(责任编辑:唐立平)

引用格式 金真,孙旭,宋果.基于 ARIMA-LSTM 的长三角航空物流需求预测研究[J].山东航空学院学报,2024,41(3):31-38. JIN Z,SUN X,SONG G. Research on demand forecast of air logistics in Yangtze River Delta based on ARIMA-LSTM[J]. Journal of Shandong University Aeronautics,2024,41(3):31-38.