

## 基于 WOA-BP 神经网络的多趋势机场间 OD 需求预测

赵箫, 杨文东, 胡俊成

(南京航空航天大学民航学院, 南京 211106)

**摘要:** 机场间的起始地-目的地(OD, origin-destination)需求预测对于航线分析和销售决策具有重要意义。基于中国 2 143 条机场间 OD 需求时间序列, 提出结合鲸鱼优化算法(WOA, whale optimization algorithm)与反向传播(BP, back propagation)神经网络的 WOA-BP 神经网络模型。通过趋势聚类与步长优化, WOA-BP 模型在统一训练流程下自动适应不同序列趋势形态。实验结果表明, 与传统 BP 神经网络模型相比, WOA-BP 神经网络模型的平均绝对百分比误差降低 8.0%, 相关系数提高 2.1%, 均方误差降低 82.9%。在多个典型机场间 OD 需求预测中, 模型表现出良好的鲁棒性和泛化能力, 可显著提高航空公司销售决策过程中的预测效率, 具有良好的应用价值。

**关键词:** 时间序列聚类; OD 需求预测; WOA-BP 神经网络; 鲸鱼优化算法

中图分类号: V354; F562

文献标志码: A

文章编号: 1674-5590(2026)02-0088-09

### Multi-trend inter-airport OD demand forecasting based on WOA-BP neural network

ZHAO Xiao, YANG Wendong, HU Juncheng

(College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

**Abstract:** Inter-airport OD demand forecasting plays a crucial role in route analysis and sales decision. Based on 2,143 inter-airport OD demand time series from China, this paper proposes a WOA-BP neural network model that integrates the whale optimization algorithm (WOA) with a back-propagation (BP) neural network. Through trend clustering and step size optimization, the model automatically adapts to different sequence trend patterns under a unified training process. The experimental results show that the mean absolute percentage error of the WOA-BP neural network is reduced by 8.0%, the correlation coefficient is improved by 2.1%, and the mean square error is reduced by 82.9% compared with the traditional BP neural network. The model shows good robustness and generalization ability in several typical inter-airport OD demand forecasts, which can significantly improve the prediction efficiency in the airline sales decision-making process and has good application value.

**Key words:** time series clustering; OD demand forecasting; WOA-BP neural network; whale optimization algorithm

机场间的起始地-目的地(OD, origin-destination)需求反映了经济、人口和文化等因素对航空市场的影响, 具有重要的市场分析意义。预测机场间 OD 需求有助于航空公司优化航班计划、座位供应和营销策略, 也是航空运输业相关时间序列分析研究的重要组成部分。目前, 交通运输业相关的需求预测(含 OD 需求预测)研究主要分为两大类: 单一模型预测方法和多模型组合预测方法。单一模型预测方法可进一步划分

为基于统计学原理的传统模型, 如回归分析和移动平均; 基于机器学习的算法, 如线性回归、支持向量机和神经网络等。多模型组合预测方法通过集成多种模型的优势, 旨在提高预测的准确性与稳健性。

在基于统计学原理的研究中: 周叶等<sup>[1]</sup>与陈斌等<sup>[2]</sup>采用回归模型对中国航空货运量进行预测; Taylor<sup>[3]</sup>和 Cottrell 等<sup>[4]</sup>提出了模糊时间序列预测模型, 发现该模型在对观测样本区间之外进行趋势外推时的表现优

于传统模型。在基于机器学习的研究中:Dougherty<sup>[5]</sup>指出其在交通数据分析中的巨大潜力;高伟等<sup>[6]</sup>和廖成等<sup>[7]</sup>通过优化反向传播(BP,back propagation)神经网络预测机场客运量,展示了其在非线性预测中的优势;裴同松等<sup>[8]</sup>通过在 BP 神经网络中引入马尔可夫链进行修正,提高了对公路客运量与货运量的预测精度,表现为平均相对误差的下降;赵颀等<sup>[9]</sup>则对交通流量序列先进行小波分解,再对各分量采用 BP 神经网络预测并重构,显著提升了交通流量预测的准确性。

多模型组合预测方法将多种预测方法结合:Bunn<sup>[10]</sup>发现组合预测模型的性能优于单一模型;杨新涅等<sup>[11]</sup>使用 3 种预测方法对珠三角地区的航空运输需求进行组合预测;Li<sup>[12]</sup>结合自回归积分移动平均模型(ARIMA, autoregressive integrated moving average model)和回归模型提出了基于多准则决策算子构建组合预测方案,显著增强了对民航客运量变化趋势的预测能力;蔡婉贞等<sup>[13]</sup>通过 BP-径向基函数(RBF, radial basis function)组合神经网络减少了港口吞吐量预测误差;刘铭基等<sup>[14]</sup>使用 ARIMA 和 Prophet 组合模型对民航客货运量进行预测,模型应用前景良好。

综上所述,现有关于交通运输需求预测的研究已较为完善,但仍存在待改进之处:①现有研究通常忽视不同 OD 需求时间序列的特征差异,在拟合后缺乏对不同形态特征时间序列预测结果的深入分析,如预测结果是否与客观的外界因素相符,从而可能导致某些序列的预测结果不理想;②采用 BP 神经网络进行预测,多存在易陷入局部最优和对初始权重与偏置参数设置过于敏感等问题。为弥补上述不足,本文基于形态特征分类的 OD 需求时间序列聚类分析,提出了一种结合鲸鱼优化算法(WOA, whale optimization algorithm)和 BP 神经网络需求预测模型。该模型能够对不同形态特征的时间序列进行较高精度的预测;此外,WOA 的全局搜索能力可有效克服 BP 神经网络易陷入局部最优的局限性。基于 OAG(Official Airline Guide)官网的原始数据集,深入挖掘 2012—2019 年机场间 OD 需求数据的潜在规律,预测新冠肺炎疫情后 2023—2025 年机场间 OD 需求,为航空公司市场营销决策提供更加精准的支持。

## 1 机场间 OD 需求时间序列的聚类分析

在构建 BP 神经网络预测模型前,需分析机场间 OD 需求时间序列,以全面了解其特征。时间序列的特

征分析通常涵盖形态特征、结构特征及模型特征 3 种。其中,形态特征能够直观反映时间序列的特性,为数据分析提供直接的视觉支持。

形态特征描述了时间序列的变化模式,涵盖了趋势、平稳性和波动幅度等方面的特性<sup>[15-16]</sup>。本实验所用的原始数据集,包含中国境内 2012—2019 年间共 2 143 条机场间 OD 需求时间序列;每条序列记录对应机场在 2012—2019 年每年 1 月的座位数。根据曼-肯德尔(MK, Mann-Kendall)检验及时间序列分析,得到不同机场间 OD 需求趋势特征。

### 1.1 MK 检验

MK 检验的基本思想是,如果数据中存在上升趋势,则较晚时间点的数值应大于较早时间点的数值,反之亦然。使用 MK 检验对 2 143 条机场间 OD 需求时间序列进行趋势检验,步骤如下。

#### 1) 计算时间插值

设  $U$  为机场集合,  $W = \{2012, 2013, \dots, 2019\}$  为年份集合。对任意有序机场对  $(i, j)$ ,  $i \in U, j \in U$ , 第  $m$  年 1 月 OD 需求(座位数)记为  $q_{ij}^m$ ,  $m \in W$ 。对于给定的时间序列  $Q_{ij} = (q_{ij}^{2012}, q_{ij}^{2013}, \dots, q_{ij}^{2019})$ , 计算每一对数据点的差值  $d_{ij}^{mn}$ , 即

$$d_{ij}^{mn} = q_{ij}^m - q_{ij}^n \quad m > n, n \in W \quad (1)$$

#### 2) 计算 $S$ 统计量及 $P$ 值

对时间序列中的所有差值  $d_{ij}^{mn}$  取符号函数  $\text{sgn}(\cdot)$ , 将所有符号值相加的代数和定义为  $S$  统计量, 则机场对  $(i, j)$  的统计量  $S_{ij}$  表示为

$$S_{ij} = \sum_{n=2012}^{2018} \sum_{m=n+1}^{2019} \text{sgn}(d_{ij}^{mn}) \quad (2)$$

式中,  $\text{sgn}(\cdot)$  的定义为

$$\text{sgn}(x) = \begin{cases} 1 & x > 0 \\ 0 & x = 0 \\ -1 & x < 0 \end{cases} \quad (3)$$

由于记录年份总数  $N = 8 < 10$ , MK 检验需计算  $P$  值来判断其显著性。使用 Python 库中的 `kendalltau` 函数计算各时间序列的  $P$  值, 当  $P < 0.05$  时, 认为该时间序列存在显著趋势。

经检验, 2 143 条机场间 1 月 OD 需求时间序列按趋势特征分为 3 类: 正趋势 OD 需求、负趋势 OD 需求及平稳趋势 OD 需求, 如表 1 所示。

### 1.2 OD 需求趋势特征及其表现

为进一步理解 3 种时间序列趋势特征及其表现,

表 1 2012—2019 年有记录的中国机场间 1 月 OD 需求时间序列分类

Tab.1 Classification of time series OD demand between Chinese airports in January, 2012–2019

趋势特征	数量/条	占比/%
正趋势	1 173	54.74
负趋势	20	0.93
平稳趋势	950	44.33

绘制了机场间 OD 各类趋势需求折线图,如图 1—图 3 所示。




图 1 2012—2019 年青岛—南宁、厦门—兰州 1 月 OD 正趋势需求  
Fig.1 Positive trend of OD demand for Qingdao–Nanning and Xiamen–Lanzhou routes in January, 2012–2019




图 2 2012—2019 年深圳—长沙、厦门—深圳 1 月 OD 负趋势需求  
Fig.2 Negative trend of OD demand for Shenzhen–Changsha and Xiamen–Shenzhen routes in January, 2012–2019




图 3 2012—2019 年杭州—长沙、大连—哈尔滨 1 月 OD 平稳趋势需求  
Fig.3 Volatile trend of OD demand for Hangzhou–Changsha and Dalian–Harbin routes in January, 2012–2019

正趋势 OD 需求表明市场前景乐观, 尽管存在波动, 但总体趋势向上, 如 2019 年青岛—南宁 1 月 OD

需求为 2012 年的 460%, 而厦门—兰州的为 384%。负趋势 OD 需求反映市场逐渐萎缩, 如深圳—长沙 2019 年 1 月 OD 需求为 2012 年的 21%, 而厦门—深圳的为 0.68%。平稳趋势 OD 需求表现为市场稳定, 如杭州—长沙、大连—哈尔滨等。

正趋势和平稳趋势时间序列占比较大, 预测其未来趋势准确度较乐观; 负趋势样本较少, 预测其未来趋势时可能存在较大不确定性。因此, 选择合适的预测模型尤为重要, 需保证模型能够适应多种趋势类型, 并提供准确且可靠的预测结果。

## 2 机场间 OD 需求预测模型

将 WOA 的自适应、全局搜索等优点用于弥补 BP 神经网络对初始权重与偏置参数设置敏感、易陷入局部最优等缺陷, 提出 WOA-BP 神经网络模型。

### 2.1 BP 神经网络算法原理

BP 神经网络通过输入层、隐含层和输出层之间的前向传播和误差反向传播两阶段, 不断迭代调整权重与偏置参数, 最小化误差直到满足预期, 如图 4 所示。其中:  $u_1, u_2, \dots, u_n$  为输入节点;  $w_1, w_2, \dots, w_z$  为输出节点。




图 4 BP 神经网络 3 层结构  
Fig.4 Three-layer structure of the BP neural network

### 2.2 WOA-BP 神经网络模型

为克服 BP 神经网络对初始权重与偏置参数设置敏感、易陷入局部最优等缺陷, Mirjalili 等<sup>[17]</sup>于 2016 年提出了 WOA, 该算法具备卓越的全局搜索能力, 可有效防止陷入局部最优。同时, 该算法可以迅速完成模型训练并实现参数自适应调整。

为充分发挥该算法对 BP 神经网络模型的全局寻优优势, 并保证输入数据的质量与格式一致, 算法执行前先对原始 OD 需求时间序列进行归一化, 即

$$\tilde{q} = \frac{q - \min(Q)}{\max(Q) - \min(Q)} \quad (4)$$

式中:  $q$  为原始观测值;  $\bar{q}$  为归一化处理后的 OD 需求值;  $Q$  为原始观测序列;  $\max(Q)$ 、 $\min(Q)$  分别为原始观测序列的最大值和最小值。

归一化后, 再用长度为  $\beta$  的滑动窗口从序列开始位置逐步切取子序列, 每个窗口包含  $\beta$  个连续时刻的数据, 用以构建 BP 神经网络的单次输入。整个序列可生成的输入条数记为  $\delta$ , 其与序列总长度  $\mu$  和滑动窗口长度  $\beta$  之间的关系为

$$\delta = \mu - \beta \quad (5)$$

算法的执行过程分为包围猎物、气泡网攻击和随机搜索 3 个阶段, 其中, 前两阶段通过取值范围为  $[0, 1]$  的随机数  $M$  交替选择执行(当  $M < 0.5$  时, 进行包围猎物, 否则进行气泡网攻击)。具体过程如下。

### 1) 包围猎物

当  $M < 0.5$  时, 算法模拟座头鲸围猎行为, 通过当前种群中的最优个体引导其他鲸鱼个体向其靠拢, 即

$$D^{(t)} = |C \cdot X^{*(t)} - X^{(t)}| \quad (6)$$

$$X^{(t+1)} = X^{*(t)} - A \cdot D^{(t)} \quad (7)$$

式中:  $t$  为当前的迭代次数;  $D^{(t)}$  为包围猎物阶段第  $t$  代鲸鱼个体与目标之间的距离;  $X^{(t)}$  和  $X^{(t+1)}$  分别为第  $t$  代和第  $t+1$  代鲸鱼个体, 即一组完整的 BP 神经网络模型参数序列;  $X^{*(t)}$  为第  $t$  代中最优的 BP 神经网络模型参数序列;  $| \cdot |$  为绝对值; 点乘号  $\cdot$  为逐元素相乘;  $A$  与  $C$  为参数向量, 用于调节鲸鱼的运动轨迹, 分别表示为

$$A = 2a \cdot r - a \quad (8)$$

$$C = 2 \cdot r \quad (9)$$

式中:  $r$  为  $[0, 1]$  的随机向量;  $a$  为控制参数, 即

$$a = 2 - \frac{2t}{T_{\max}} \quad (10)$$

式中,  $T_{\max}$  为设定算法的最大迭代次数。

### 2) 气泡网攻击

当  $M \geq 0.5$  时, 算法模拟座头鲸的气泡网攻击, 将个体沿对数螺旋路径逼近最优解, 即

$$D^{(t)} = |X^{*(t)} - X^{(t)}| \quad (11)$$

$$X^{(t+1)} = D^{(t)} \cdot e^{bl} \cdot \cos(2\pi l) + X^{*(t)} \quad (12)$$

式中:  $D^{(t)}$  为气泡网攻击阶段第  $t$  代鲸鱼与目标猎物的距离;  $b$  为常量, 决定对数螺旋的具体形态, 默认取 1;  $l$  为取值范围  $[-1, 1]$  的随机数。

图 5 展示了 WOA 在  $x, y$  二维平面上的两种搜索机制。图 5(a) 为包围猎物搜索方式,  $x^*, y^*$  表示当前最优解  $X^*$  在平面坐标系下的横、纵分量, 鲸鱼个体沿近

似直线路径向其收缩; 图 5(b) 为气泡网攻击搜索方式, 以螺旋参数  $l$  驱动鲸鱼绕最优解呈对数螺旋轨迹收敛。


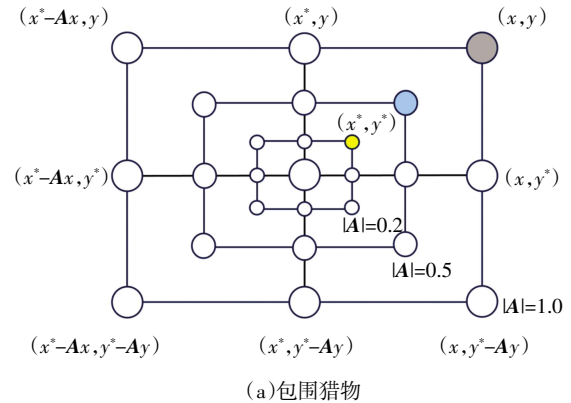


图 5 收缩包围与螺旋更新位置机制

Fig.5 Shrinking encircling mechanism and spiral updating position mechanism

### 3) 随机搜索

当  $|A| \geq 1$  时, 鲸鱼个体会随机远离最优个体位置, 扩大搜索范围, 有助于发现更优的权重与偏置参数, 进一步优化 BP 神经网络模型。

以上 3 个阶段交替执行, 共同构成 WOA 对 BP 神经网络参数的优化过程, 实现对 OD 需求时间序列的多趋势拟合。

## 2.3 预测模型框架

采用长度为  $\beta$  的滑动窗口将原始 OD 需求时间序列切分为若干训练样本, 并输入 BP 神经网络模型, 利用 WOA 生成初始权重与偏置参数。基于初始化结果训练 BP 神经网络, 采用随机抽样方法评估鲸群解的适应度。随后通过 WOA 更新鲸群位置和速度, 优化权重与偏置参数。训练过程持续迭代, 直至满足收敛条件(达到目标误差阈值或最大迭代次数)。最终生成的收敛模型将用于机场间 OD 需求的预测。WOA-BP 神经网络的优化及预测流程图如图 6 所示。

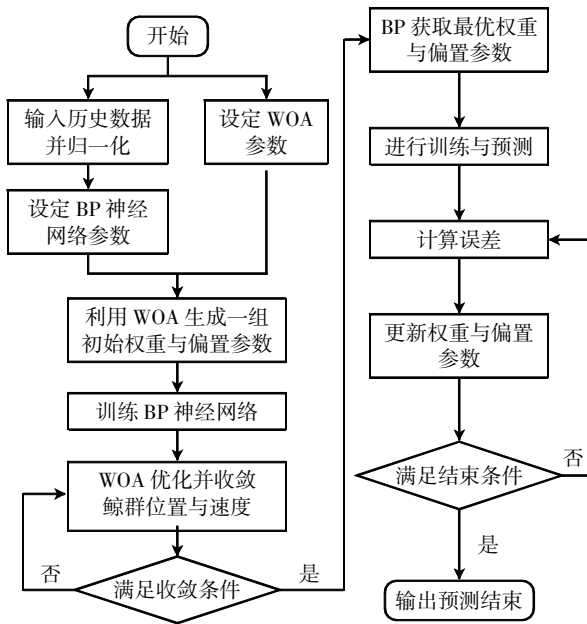


图 6 WOA-BP 神经网络模型的优化及预测流程图

Fig.6 Flowchart of the optimization and prediction process for the WOA-BP neural network model

### 3 机场间 OD 需求预测模型应用

#### 3.1 滑动窗口长度 $\beta$ 的选取

在确定机场间 OD 需求滑动窗口长度  $\beta$  时,需关注切片数和 BP 神经网络模型的拟合效果。切片数越多, BP 神经网络模型的拟合效果越好,因此,应尽量增加切片数量,但也要防止过拟合。序列总长度  $\mu = 8$ , 即 2012—2019 年共 8 年, 则  $\beta$  的适宜长度在 3~5 之间。当  $\beta = 5$  时,可整合的数据较少,且数据波动性强,因此,不再考虑。向 BP 神经网络模型分别输入  $\beta = 3$ 、 $\beta = 4$  的历史数据,选择相关系数较高的长度作为最终的滑动窗口长度,如表 2 所示。

表 2 当  $\beta=3$ 、 $\beta=4$  时 BP 神经网络模型相关系数值

Tab.2 Correlation coefficients of the BP neural network model at  $\beta=3$  and  $\beta=4$

滑动窗口长度 $\beta$	训练集	验证集	测试集	总体
3	0.940 02	0.946 82	0.775 26	0.932 56
4	0.946 82	0.934 50	0.910 37	0.940 76

当  $\beta = 4$  时, BP 神经网络的相关系数更高,因此,选定滑动窗口长度  $\beta = 4$ , 将 4 年的历史数据作为输入数据,第 5 年的历史数据作为目标数据,共得到 149 个机场间共 8 572 条有效客运量样本,将其按照训练集 70%、验证集 15%、测试集 15% 的比例拆分,进行 BP 神经网络训练。

#### 3.2 模型参数设定

##### 3.2.1 BP 神经网络

设定 BP 神经网络的最大训练次数为 1 000 次,学习率为 0.01,目标误差阈值设定为 0.000 1。根据滑动窗口长度  $\beta$  确定 BP 神经网络输入层节点数为 4,输出层节点数为 1。通过式(13)一式(15),进一步确定隐含层节点数的取值范围,即

$$l_1 = \sqrt{fh} \tag{13}$$

$$l_2 = \sqrt{f+h} + d \tag{14}$$

$$l_3 = \log_2 f \tag{15}$$

式中: $l_1$ 、 $l_2$ 、 $l_3$  分别为隐含层节点数的均值、上界与下界; $h$  为输入层节点数; $f$  为输出层节点数; $d$  为 1~10 之间的任意常数。

经计算, BP 神经网络隐含层节点数取值范围为 2~13,经多次对隐含层节点数的调整与训练,节点为 9 时可获得最优拟合结果。

##### 3.2.2 WOA-BP 神经网络

WOA-BP 神经网络的最大训练次数、学习率、目标误差阈值与 BP 神经网络相同。设定 WOA 的初始种群规模为 30,最大迭代次数为 50。通过逐步迭代优化,动态调整 BP 神经网络的权重与偏置参数。

#### 3.3 评估结果对比分析

##### 3.3.1 BP 神经网络模型评估结果

从相关系数和均方误差(MSE, mean squared error)两方面进行 BP 神经网络训练情况的初步评估。

图 7 为 BP 神经网络模型在各类数据集上的相关系数:训练集 0.946 82、验证集 0.934 50、测试集 0.910 37、总体 0.940 76,均接近 1,可见该 BP 神经网络模型在机场间 OD 需求预测中的拟合效果较好。

BP 神经网络模型通常以 MSE 作为训练目标,即


$$e_{MSE} = \frac{1}{U} \sum_{k=1}^U (Y_k - \hat{Y}_k)^2 \tag{16}$$

式中: $U$  为样本数; $Y_k$  为真实值; $\hat{Y}_k$  为预测值。该指标用于评估预测值与真实值间的误差, MSE 值越小,则模型预测精度越高。


图 8 为 BP 神经网络模型的 MSE 迭代情况。在第 4 次迭代时,模型 MSE 达到最佳值 0.019 19,表明充分训练后,模型的预测精度显著提高。

##### 3.3.2 WOA-BP 神经网络模型评估结果


图 9 为 WOA-BP 神经网络模型的相关系数:训练集 0.965 43,验证集 0.953 59,测试集 0.955 48,总体 0.961 87。与 BP 神经网络模型相比, WOA-BP 神经网络模型的相关系数显著提高,表现出更佳的预测性能。




(a)训练集:相关系数=0.946 82



(b)验证集:相关系数=0.934 50



(c)测试集:相关系数=0.910 37



(d)总体:相关系数=0.940 76

图 7 BP 神经网络模型的相关系数

Fig.7 Correlation coefficients of the BP neural network model






图 8 BP 神经网络模型的 MSE 迭代情况


Fig.8 MSE iteration process of the BP neural network model




(a)训练集:相关系数=0.965 43



(b)验证集:相关系数=0.953 59



(c)测试集:相关系数=0.955 48



(d)总体:相关系数=0.961 87

图 9 WOA-BP 神经网络模型的相关系数

Fig.9 Correlation coefficients of the WOA-BP neural network model

WOA-BP 神经网络模型的 MSE 迭代情况如图 10 所示。该模型的 MSE 在多次迭代后逐渐达到稳定状态。在第 99 次训练迭代中,WOA-BP 神经网络模型表现最佳,其 MSE 为 0.003 29,较 BP 神经网络模型的 0.019 19 更小,因此,WOA-BP 神经网络模型提高了预测精度,优化效果显著。

### 3.3.3 模型结果对比

为体现 BP 神经网络模型与 WOA-BP 神经网络模型在机场间 OD 需求预测中的适应性,对 1 000 个





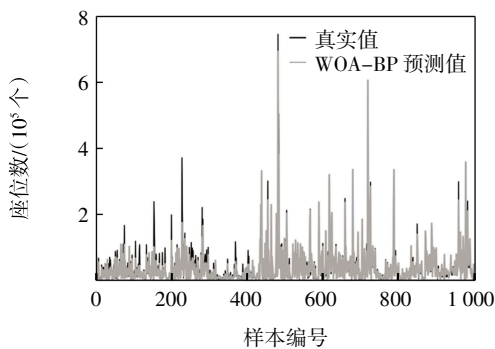
图 10 WOA-BP 神经网络模型的 MSE 迭代情况

Fig.10 MSE iteration process of the WOA-BP neural network model

随机测试样本进行优化前后结果的比较,如图 11 所示。从图 11 中可发现,与 BP 神经网络模型相比,WOA-BP 神经网络模型的预测值与真实值的吻合度更高,但仍需通过客观指标进一步验证两者的表现。



(a)BP 神经网络模型



(b)WOA-BP 神经网络模型

图 11 BP 神经网络模型与 WOA-BP 神经网络模型预测结果对比

Fig.11 Prediction comparison of BP neural network model and WOA-BP neural network model

图 12 中进一步展示了在 1 000 个随机测试样本中 BP 神经网络模型与 WOA-BP 神经网络模型的误差表现,其中,纵轴“频率”表示落入相应平均绝对百分比误差 (MAPE, mean absolute percentage error) 区间的样本个数,并使用 MAPE 进行量化评估,即

$$e_{MAPE} = \frac{1}{U} \sum_{k=1}^U \left| \frac{\hat{Y}_k - Y_k}{Y_k} \right| \times 100\% \quad (17)$$

当 MAPE = 0 时,表明预测结果与真实值完全一致;当 MAPE > 100%时,则反映模型的预测精度存在较大问题。




图 12 BP 神经网络模型与 WOA-BP 神经网络模型的 MAPE 对比

Fig.12 Comparison of MAPE between BP neural network model and WOA-BP neural network model

由图 12 可知,优化前的 BP 神经网络模型有 300 个以上的测试样本的 MAPE 较大,使用 WOA 优化后,超过 800 个测试样本的 MAPE 控制在 40% 以下,且大多集中在 30% 以下。

表 3 为 BP 神经网络模型与 WOA-BP 神经网络模型的各误差指标对比情况。由表 3 可以看出,经过优化的 BP 神经网络模型整体 MAPE 提升 8.0%,相关系数提高 2.1%,MSE 优化幅度达 82.9%,表明 WOA 对 BP 神经网络模型的优化效果显著。

表 3 BP 神经网络模型与 WOA-BP 神经网络模型的总体误差指标对比

Tab.3 Comparison of overall error metrics between BP neural network model and WOA-BP neural network model

模型	MSE	MAPE/%	相关系数
BP 神经网络	0.019 19	29	0.940 76
WOA-BP 神经网络	0.003 29	21	0.961 87

### 3.4 WOA-BP 神经网络模型应用分析

为验证所构建 WOA-BP 神经网络模型在多类型时间序列中的适应性与预测效果,本文选取 3 对具有代表性的机场对进行案例分析:深圳—南京、长治—北京和杭州—厦门,分别对应正趋势、负趋势与平稳趋势 3 类 OD 需求特征。其中,深圳—南京和杭州—厦门均涉及一线城市,长治—北京则为典型的干支机场对。

#### 3.4.1 正趋势 OD 需求预测与分析

##### 1)深圳—南京 1 月 OD 需求现状

表 4 为深圳—南京 1 月 OD 需求历史数据。2012 年深圳—南京 1 月的座位数为 58 635 个,至 2017 年座位数呈缓慢上升趋势,到 2019 年为 163 837 个,较

表 4 深圳—南京 2012—2019 年 1 月 OD 需求历史数据

Tab.4 Historical data of OD demand for Shenzhen-Nanjing in January, 2012-2019

年份	座位数/个	年份	座位数/个
2012	58 635	2016	73 543
2013	65 628	2017	68 523
2014	59 436	2018	128 881
2015	72 728	2019	163 837

2012 年增加了 179.4%。

深圳—南京 1 月 OD 需求逐年上升,主要原因包括经济发展推动商务往来不断增多,两地政策利好推动航空需求,以及高铁对民航需求的影响。深圳—南京约 1 389 km,高铁时长约 8 h,票价 700 元左右,相比飞机 2 h 的航程及以 800 元为基础的浮动票价,民航运输具有明显优势。

综上所述,深圳—南京 1 月 OD 需求的持续上涨是多种因素共同作用的结果,因此,长远来看将呈持续上涨趋势。

2)深圳—南京 1 月 OD 需求的预测结果

新冠肺炎疫情期间(2020—2022 年)的机场间 OD 需求虽受到外部因素的影响而产生较大波动,但时间序列的总体趋势并不会改变。因此,选择滚动预测,即将 2020—2022 年的预测值输入,以便进行 2023—2025 年的需求预测,如表 5 所示。预测座位数从 195 654 个增加到 243 588 个,涨幅 24.5%。

表 5 深圳—南京 2023—2025 年 1 月 OD 需求预测值

Tab.5 Forecasted OD demand for Shenzhen-Nanjing in January, 2023-2025

年份	座位数/个
2023	195 654
2024	208 237
2025	243 588

3.4.2 负趋势 OD 需求预测与分析

1)长治—北京 1 月 OD 需求现状

表 6 为长治—北京 1 月 OD 需求的历史数据。2012 年长治—北京 1 月的座位数为 9 765 个,至 2019 年呈逐渐下降趋势,降至 2 294 个,较 2012 年降低了 76.5%。

表 6 长治—北京 2012—2019 年 1 月 OD 需求历史数据

Tab.6 Historical data of OD demand for Changzhi-Beijing in January, 2012-2019

年份	座位数/个	年份	座位数/个
2012	9 765	2016	5 053
2013	9 734	2017	5 053
2014	9 583	2018	2 940
2015	9 734	2019	2 294

从表 6 中可以看出,长治—北京间的 OD 需求呈波动下降趋势,分析主要原因为长治—北京距离 627.26 km,小于 1 000 km,高铁时长约 4 h,票价 300 元左右;直达航班票价相近,1.5 h 的乘坐时间在加入登机、托运及自北京大兴国际机场前往目的地的时间后,来自高铁的竞争仍处于有利范围<sup>[8]</sup>。

2)长治—北京 1 月 OD 需求的预测结果

将 2012—2019 年 OD 需求时间序列输入已训练的 WOA-BP 神经网络模型中,得到 2023—2025 年预测结果如表 7 所示。预测结果仍保持下降趋势,座位数从 2 078 个降低至 905 个,跌幅 56.4%。

表 7 长治—北京 2023—2025 年 1 月 OD 需求预测值

Tab.7 Forecasted OD demand for Changzhi-Beijing in January, 2023-2025

年份	座位数/个
2023	2 078
2024	1 604
2025	905

3.4.3 平稳趋势 OD 需求预测与分析

1)杭州—厦门 1 月 OD 需求现状

表 8 为杭州—厦门 1 月 OD 需求的历史数据。2012 年杭州—厦门 1 月的座位需求为 39 800 个,至 2019 年为 48 923 个,没有明显上升、下降趋势,其原因与市场接近饱和、高铁竞争关联密切。

表 8 杭州—厦门 2012—2019 年 1 月 OD 需求历史数据

Tab.8 Historical data of OD demand for Hangzhou-Xiamen in January, 2012-2019

年份	座位数/个	年份	座位数/个
2012	39 800	2016	46 615
2013	44 237	2017	41 562
2014	55 175	2018	72 312
2015	30 880	2019	48 923

2)杭州—厦门 1 月 OD 需求的预测结果

将 2012—2019 年 OD 需求时间序列输入已训练的 WOA-BP 神经网络模型中,得到 2023—2025 年预测结果如表 9 所示,预测结果仍保持稳定,符合平稳趋势。

表 9 杭州—厦门 2023—2025 年 1 月 OD 需求预测值

Tab.9 Forecasted OD demand for Hangzhou-Xiamen in January, 2023-2025

年份	座位数/个
2023	58 234
2024	49 271
2025	52 984

### 4 结语

机场间 OD 需求预测是对特定起讫机场在一定时间尺度内的旅客出行需求进行分析和预测的过程,选择合适的预测方法对航空公司的市场分析及航班计划制定均至关重要。本文通过对中国 2 143 条机场间 OD 需求时间序列按形态特征进行聚类,构建了 BP 神经网络模型和 WOA-BP 神经网络模型。基于不同形态特征机场间 OD 需求数据展开验证,结果表明,WOA-BP 神经网络模型在拟合过程中能够有效捕捉不同样本趋势的差异,表现出更强的泛化能力与稳健性,具有显著的应用价值。

本文的研究结论可分为以下 3 点:①通过 MK 检验将 2 143 条机场间 OD 需求时间序列按形态分类为正趋势、负趋势和平稳趋势型,发现正趋势与平稳趋势占比近半,市场前景较为可观;②建立了 BP 神经网络模型和 WOA-BP 神经网络模型,并对两种模型进行训练与测试后,验证了二者都适用于中国机场间 OD 需求预测,并通过多个指标的对比分析发现 WOA-BP 神经网络模型的预测精度更高;③将 WOA-BP 神经网络模型应用于深圳—南京、长治—北京和杭州—厦门 3 种典型机场间 OD 需求预测中,预测结果符合预期,证明该模型能够在统一训练下预测不同趋势的时间序列,具有较高的适应性与统一性。

### 参考文献:

[1] 周叶,肖灵机.基于 ARIMA 模型的我国航空货运量预测分析[J].南昌航空大学学报(社会科学版),2010,12(3):22-27.  
 [2] 陈斌,吴瑾.基于大样本数据的机场业务量需求预测方法[J].系统工程与电子技术,2023,45(12):3887-3895.  
 [3] TAYLOR J G. Neural network: applications[M]. London: Chapman and

Ha11, 1992.  
 [4] COTTRELL M, GIRARD B, ROUSSET P. Forecasting of curves using a Kohonen classification[J]. Journal of Forecasting, 1998, 17(5/6): 429-439.  
 [5] DOUGHERTY M. A review of neural networks applied to transport[J]. Transportation Research Part C: Emerging Technologies, 1995, 3(4): 247-260.  
 [6] 高伟,殷小曼.基于熵值-BP 神经网络的机场旅客吞吐量预测[J].计算机仿真,2021,38(10):64-67.  
 [7] 廖成,刘鲁,晓斌.机场旅客吞吐量的人工神经网络预测方法[J].小型微型计算机系统,2002,23(12):1500-1502.  
 [8] 裴同松,裴彧.基于马尔科夫链-BP 神经网络模型对公路运量的预测研究[J].重庆交通大学学报(自然科学版),2021,40(2):35-41.  
 [9] 赵颀,沈玲宏,马健霄,等.综合小波分解和 BP 神经网络的交通小区生成交通短时预测[J].重庆交通大学学报(自然科学版),2021,40(11):60-66.  
 [10] BUNN D W. Combining forecasts[J]. European Journal of Operational Research, 1988, 33(3): 223-229.  
 [11] 杨新涅,王翩然.基于组合预测的民航运输量分析:以珠三角地区为例[J].数学的实践与认识,2019,49(8):301-310.  
 [12] LI C. Combined forecasting of civil aviation passenger volume based on ARIMA-REGRESSION[J]. International Journal of System Assurance Engineering and Management, 2019, 10(5): 945-952.  
 [13] 蔡婉贞,黄翰.基于 BP-RBF 神经网络的组合模型预测港口物流需求研究[J].郑州大学学报(工学版),2019,40(5):85-91.  
 [14] 刘铭基,田雅楠,张亮,等.基于 Prophet-ARIMA 模型的民航周转量预测研究[J].计算机技术与发展,2022,32(2):148-153,160.  
 [15] BALASUBRAMANIYAN R, HÜLLERMEIER E, WESKAMP N, et al. Clustering of gene expression data using a local shape-based similarity measure[J]. Bioinformatics, 2005, 21(7): 1069-1077.  
 [16] 宋辞,裴韬.基于特征的时间序列聚类方法研究进展[J].地理科学进展,2012,31(10):1307-1317.  
 [17] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.  
 [18] 王姣娥,景悦,杨浩然.中国高铁-民航竞争网络的空间演化模式及影响因素[J].地理科学,2020,40(5):675-684.

(责任编辑:孟欣)