

基于 TOPSIS 准则和 SARIMA 模型的江苏省 快递业务量短期预测

周翔宇, 李 思

(安徽建筑大学 数理学院, 合肥 230601)

摘要:物流产业与诸多产业都有非常密切的联系,在推动 GDP 增长和提高社会经济发展方面具有不可忽视的作用。利用过去的快递业务量预测未来值,有利于反映物流产业的发展趋势。基于江苏省 2013 年 5 月至 2021 年 4 月的快递业务量数据,选用简单季节 ARIMA(差分自回归移动平均)模型和乘积季节 ARIMA 模型以及基于 TOPSIS(逼近理想解排序)准则的两种 ARIMA 组合模型进行拟合,并预测 2021 年 5 月至 2022 年 2 月的快递业务量数据。发现 3 种模型预测的平均相对误差均较小,且组合预测模型的预测效果优于其他两种季节 ARIMA 模型。

关键词:快递业务量;简单季节模型;乘积季节模型;TOPSIS(逼近理想解排序)准则

中图分类号:O212 **文献标志码:**A **文章编号:**1671-1807(2023)17-0136-07

随着社会经济的发展,物流产业作为新时代政治经济活动的重要组成部分,它的发展水平高低逐渐作为衡量国家综合实力强弱和国际现代化水平高低的关键指标。物流产业作为国家新型战略产业,对经济区域发展起推动作用。

国内外学者在物流技术、物流需求精度等方面做出了大量评价。Fuqua 和 Hespeler^[1]认为运输管理系统(transportation management system, TMS)等信息技术的使用对于改善公司的运输流程至关重要,可以提供潜在的结果,包括优化运输、提高成本节约和客户满意度。Salais-Fierro 和 Martínez^[2]提出了一种使用在线鲁棒主成分分析(robust principal component analysis, RPCA)模型,结合长短期记忆(long short term memory, LSTM)递归网络来对人道主义后勤需求进行预测,预测效果要优于传统的 LSTM 和 GRU(门控循环单元)拟合预测模型。Ribeiro 等^[3]以爱尔兰的一家非冷藏物流设施 2020 年 1—11 月数据为例,提出的极度梯度提升树(XGBoost)模型在短期负荷预测方面要优于差分自回归移动平均(autoregressive integrated moving average, ARIMA)、LSTM 和 RNN(循环神经网络)模型。Farhan 和 Ong^[4]使用 SARIMA(季节性差分自回归滑动平均)模型预测国际港口的季节性集装箱吞吐量。

国内学者也开展了诸多研究。王向前等^[5]以天津港为例,构建了基于 ARIMA-SVR(差分自回归移动平均-支持向量机回归)的组合预测模型,提高了港口物流规模的预测精度。黄建华和张迪等^[6]面对具有不平稳、非线性特征的区域物流需求预测问题时,提出了改进 GM-BPNN(误差反向传播神经网络)组合预测模型来提高物流需求预测的精确度。黄洁和花培鹏^[7]基于 2003—2019 年云南省物流业年度时序数据,通过构建 VAR(向量自回归)模型研究云南省物流业和经济发展的关系。陈敏^[8]、高雪雪^[9]、蔡婉贞和黄翰^[10]将 BP 神经网络应用于对城市未来物流需求的预测。

从研究的角度来看,以往的研究往往基于原始数据运用单一的预测方式直接建模。然而,单单使用一种模型对数据进行预测,其对数据的规律性要求较高,然而现实数据中往往缺乏明显的规律性,因此预测结果的拟合效果不太理想。为了解决这个问题,国内外学者采用多种模型进行组合预测^[11-18],使得拟合结果更好。通过对多个模型进行组合建模,可以提高预测的精度和准确性,并且在实际应用中得到了广泛的应用。虽然学者们在组合预测模型方面已经取得了丰硕的研究成果,但目前将决策方法应用到组合预测模型的研究成果较少。将决策学科和预测学科相结合,在组合预测中应用逼近理想解排序(technique

收稿日期:2023-05-24

作者简介:周翔宇(1999—),男,江苏南京人,安徽建筑大学数理学院,硕士研究生,研究方向为应用统计学;李思(1998—),女,安徽宿州人,安徽建筑大学数理学院,硕士研究生,研究方向为应用统计学。

for order preference by similarity to ideal solution, TOPSIS)决策方法来确定各单项预测方法的权重,进而获得最终的组合预测模型,对于多目标优化组合预测具有重要意义。

本文选取江苏省 2013 年 5 月至 2022 年 2 月的快递业务量数据作为反映江苏省物流产业的重要依据。快递业务量数据的季节性和趋势性会受到季节变动和经济发展的影响,因此需要使用季节性 ARIMA 模型进行拟合和预测。对快递业务量分别进行简单季节 ARIMA 模型和乘积季节 ARIMA 模型拟合,并进行了残差的自相关检验,以判断拟合的模型是否有效提取信息,拟合效果是否良好。在此基础上,引入 TOPSIS 准则,构建一个组合模型。在短期预测部分,对 3 种模型的预测结果进行相对误差的计算,根据得到的预测精度比较结果来判断哪种预测模型能够取得更好的预测效果。

1 研究理论基础

1.1 ARIMA 模型

ARIMA 预测模型是时间序列预测模型中的一种,在统计学和计量经济学等多种学科中都有所应用,其本质是随着时间序列逐步呈现稳定化的时候,来预测模型因变量生成的推迟量、模型产生的不确定偏差后生成的推迟量和模型的当前量。

ARIMA(p, d, q) 实际上是自回归移动平均(auto regressive and moving average, ARMA)模型的一种扩展形式,是计量经济学常用的建模方法。其中,AR 为自回归模型,MA 为移动平均模型, p, q 分别为自回归项和移动平均项, d 为需要将原始时间序列转变为平稳的序列所需要的差分次数。由于快递量数据受节假日、购物节、优惠折扣等因素影响,历史快递量数据并非为平稳的时间序列数据,因此提出 ARIMA 模型。ARIMA(p, d, q) 模型的数学表达式为

$$\nabla^d x_t = \frac{\Theta(B)}{\Phi(B)} \epsilon_t \quad (1)$$

式中: $\nabla^d x_t = (1 - B)^d x_t$ 为原始序列 x_t 经过 d 次差分后的序列; B 为后移算子; $\Phi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p$ 为自回归系数多项式, φ_i 为自回归系数; $\Theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ 为移动平均系数多项式, θ_j 为移动平均系数; ϵ_t 为 t 时刻的随机误差,为零均值白噪声序列。

1.2 简单季节模型

通常认为提取完季节信息和趋势信息之后的序列是一个平稳序列,可以采用 ARMA 模型进行拟合^[19]。

需要先行对序列进行 d 阶差分消除其趋势项,再对其进行 S 步差分消除周期项,然后采用 ARMA 模型对其进行拟合。简单季节模型的数学表达式为

$$\nabla_s \nabla^d x_t = \frac{\Theta(B)}{\Phi(B)} \epsilon_t \quad (2)$$

式中: $\nabla_s x_t = (1 - B^S) x_t$ 。

1.3 乘积季节模型

在简单季节模型中,如果残差序列 ϵ_t 检验效果不好,说明某些时间序列既有季节性成分,又含有非季节性成分,简单加法模型不能重复提取序列中的季节效应、随机效应和趋势效应信息。通常使用乘积季节模型^[20],其数学表达式为

$$\nabla_s^D \nabla^d x_t = \frac{\Theta(B)V(B^S)}{\Phi(B)U(B^S)} \epsilon_t \quad (3)$$

式中: $\nabla_s^D x_t = (1 - B^S)^D x_t$; $U(B) = 1 - \varphi'_1 B^S - \varphi'_2 B^{2S} - \dots - \varphi'_P B^{PS}$ 为季节性自回归系数多项式, P 为季节性自回归阶数; $V(B) = 1 - \theta'_1 B^S - \theta'_2 B^{2S} - \dots - \theta'_Q B^{QS}$ 为季节性移动平均系数多项式, Q 为季节性移动平均阶数。

2 基于 TOPSIS 的组合预测模型

2.1 季节 ARIMA 模型建模步骤

1) 处理时间序列数据,需要先绘制时序图,然后通过时序图初步判断序列的平稳性、趋势性和周期性。接下来绘制时间序列数据的自相关和偏自相关图。为了使时序趋于稳定,采用的方法是单位根检验方法。

2) 处理非平稳序列数据让这些数据也能逐步平稳,需要使用多步差分和多阶差分法,分别消除时间序列的周期性和趋势性。

3) 使用差分法后,根据时间序列数据的自相关和偏自相关图,并且根据 AIC (赤池信息准则) 和 BIC (贝叶斯信息准则) 确定模型的阶数,其中 AIC 或 BIC 的值越小表明模型越好,比较多个模型进而建立效果最好的模型。

4) 需要对模型的参数进行评价估计,判断其是否通过显著性检验,如不通过则需要将检验的参数剔除,并用剩下的参数变量重新进行拟合。

5) 最后要对拟合模型的残差值进行白噪声检测。

6) 上述检验全部通过,进行最终确立模型的运行以及预测结果分析。

2.2 基于 TOPSIS 的组合预测模型步骤

将所有可能的权重的单项预测方法构成的各组合预测作为备选方案,以可以衡量预测效果好坏

的指标(如 MAPE)作为属性,将组合预测最优权重系数的选取问题转化为在一系列评判标准下的一个多属性决策问题,进而可以运用多属性决策中的思想来确定各单项预测方法的最优权重,从而得到最终的组合预测模型。这种基于 TOPSIS 决策方法的组合预测模型适用于可以用两种或两种以上的单一预测模型拟合原始时间序列的情况。

观测序列记为 $\{x_t\}_{t=1}^n$, 如果存在两种单项方法对其进行预测,这两种预测方法 i 的预测值序列记为 $\{x_{it}\}_{t=1}^n, i=1,2$ 。令 w_1, w_2 满足 $w_1 + w_2 = 1, w_1 \geq 0, w_2 \geq 0$, 为各预测方法的加权比例,那么对应每个预测时刻 t , 组合预测模型的预测值为 $\hat{x}_t = w_1 x_{1t} + w_2 x_{2t}$ 。

步骤 1 确定组合预测模型精度序列的均值和标准差。

把 e_{it} 称作预测方法 i 在预测时刻 t 的相对误差,那么

$$e_{it} = \begin{cases} \frac{x_t - x_{it}}{x_t}, & \left| \frac{x_t - x_{it}}{x_t} \right| \leq 1 \\ 1, & \left| \frac{x_t - x_{it}}{x_t} \right| > 1 \end{cases} \quad (4)$$

定义组合预测在预测时刻 t 的预测精度为 A_t , 精度序列 $\{A_t\}_{t=1}^n$ 的均值为 $E(A)$, 标准差为 $S(A)$, 由文献[21]的求解方法简化计算。

$$A_t = 1 - |e_t| = 1 - \left| \frac{x_t - \hat{x}_t}{x_t} \right| = 1 - \left| w_1 \frac{x_t - \hat{x}_{1t}}{x_t} + w_2 \frac{x_t - \hat{x}_{2t}}{x_t} \right| = 1 - |w_1 e_{1t} + w_2 e_{2t}| \quad (5)$$

$$E(A) = \frac{1}{n} \sum_{t=1}^n A_t = \frac{1}{n} \sum_{t=1}^n (1 - |w_1 e_{1t} + w_2 e_{2t}|) = a_0 [w_1 E(A_1) + w_2 E(A_2)] + 1 - a_0 \quad (6)$$

$$S(A) = \sqrt{\frac{1}{n} \sum_{t=1}^n [A_t - E(A)]^2} = \sqrt{\sum_{t=1}^n \frac{1}{n} A_t^2 - [E(A)]^2} = a_0 \sqrt{w_1^2 S^2(A_1) + w_2^2 S^2(A_2) + 2w_1 w_2 \rho_{12} S(A_1) S(A_2)} \quad (7)$$

式中: $\rho_{12} = \frac{1}{n} \sum_{t=1}^n \frac{[A_{1t} - E(A_1)][A_{2t} - E(A_2)]}{S(A_1) S(A_2)}$, 为方法 1 和方法 2 精度序列 $\{A_{1t}\}_{t=1}^n$ 和 $\{A_{2t}\}_{t=1}^n$ 的相关系数, $a_0 \in [0, 1]$ 。

步骤 2 计算各组合预测模型到正、负理想点的加权距离。

显然 $E(A)$ 和 $S(A)$ 都是各单项预测方法权重的函数,分别记为 $E(w_1, w_2)$ 和 $S(w_1, w_2)$, 且有 $0 \leq E(A) \leq 1, 0 \leq S(A) \leq 1$ 。取绝对正、负理想点为 $X^+ = [1, 1]$ 和 $X^- = [0, 0]$ 。并且让属性权重 (l_1, l_2) 满足 $l_1 + l_2 = 1, l_1 \geq 0, l_2 \geq 0$, 那么各方案到正、负理想预测方法的加权距离为

$$d^+(w_1, w_2) = l_1 [E(w_1, w_2) - 1]^2 + l_2 [S(w_1, w_2)]^2 \quad (8)$$

$$d^-(w_1, w_2) = l_1 [E(w_1, w_2)]^2 + l_2 [S(w_1, w_2) - 1]^2 \quad (9)$$

步骤 3 构建各组合预测模型的贴适度并求解得到权重。

构造贴适度最大模型并求解:

$$\begin{aligned} \max [c(w_1, w_2)] &= \frac{d^-(w_1, w_2)}{d^+(w_1, w_2) + d^-(w_1, w_2)} \\ \text{s. t. } &\begin{cases} E(w_1, w_2) = a_0 [w_1 E(A_1) + w_2 E(A_2)] + 1 - a_0 \\ S(w_1, w_2) = a_0 \sqrt{w_1^2 S^2(A_1) + w_2^2 S^2(A_2) + 2w_1 w_2 \rho_{12} S(A_1) S(A_2)} \\ w_1 + w_2 = 1, w_1 \geq 0, w_2 \geq 0 \end{cases} \end{aligned} \quad (10)$$

步骤 4 由权重计算得到组合预测模型在预测时间 t 的预测值,其中 $t = 1, 2, \dots, n$ 。

3 实例验证与分析

本文所选取的数据为江苏省 2013 年 5 月至 2022 年 2 月的快递业务量数据。将 2013 年 5 月至 2021 年 4 月的数据作为实验训练集,2021 年 5 月至 2022 年 2 月的数据作为拟合模型预测准确率的测试集。全部数据来源于江苏省邮政管理局。

3.1 序列观察

首先绘制江苏省快递业务量的时序图(图 1),从而初步判断序列平稳与否。从图 1 可以看出,江苏省 2013 年 5 月至 2022 年 2 月快递业务量数据序列具有明显的增长趋势和季节性波动特点:每年接近年末都会出现峰值,推测大量商家在“双十一”“双十二”会进行降价促销,商品销量激增,因而快递量大量增加;每年年初会出现明显的下降特征,推测由于春节放假,大量快递员休假过年,人们购买商品意愿下降,从而导致快递量下降。可以观测出,时序具有季节性和趋势性特征,是非平稳的时间序列。

使用 R 软件时间序列包的 `decompose` 函数对该序列数据进行分解,得到图 2。

由图 2 可知,江苏省快递包裹量呈指数级增长,以 12 个月为周期且季节性特征显著。因此该序列为同时带有趋势性、季节性和随机性的非平稳时间




图 1 2013 年 5 月至 2022 年 2 月江苏省快递业务量时序图




图 2 2013 年 5 月至 2022 年 2 月原数据、趋势、季节效应及随机波动项

序列,从而选取 SARIMA 模型是合适的。

3.2 模型的建立和检验

通过 ADF(时间序列平稳性)检验可以验证时序平稳与否。对原序列进行 ADF 检验,发现 $P=0.095\ 3>0.05$,说明原序列存在单位根,为非平稳时间序列。对原始数据进行一阶差分 and 12 步差分,发现处理后的序列 $P=0.01<0.05$,通过 ADF 检验,为平稳序列。

序列经过一阶差分 and 12 步季节差分后,其周期性和季节性基本得到消除。因此选取 $d=1, D=1$ 。根据自相关图(图 3)和偏自相关图(图 4),辅以 R 软件 forecast 包的 auto.arima 函数和 AIC、BIC 最小信息准则,得到两个最佳备选模型:简单季节模型 $ARIMA(1,1,2)\times(0,1,0)_{12}$ 和乘积季节模型 $ARIMA(1,1,1)\times(1,1,2)_{12}$ 。




图 3 差分后序列自相关图




图 4 差分后序列偏自相关图

对这两种模型进行 Ljung-Box 残差检验,由表 1 可知,两者残差自相关检验的 P 均大于 0.05,认为不能拒绝残差没有相关性的原假设,即表明残差无自相关性,表明两种 SARIMA 模型均能较好地拟合本文数据。

简单季节模型 $ARIMA(1,1,2)\times(0,1,0)_{12}$ 的表达式为

$$(1-B)(1-B^{12})x_t = \frac{1+1.027\ 2B-0.115B^2}{1-0.484\ 1B}.$$

乘积季节模型 $ARIMA(1,1,1)\times(1,1,2)_{12}$ 的表达式为

$$(1-B)(1-B^{12})x_t = \frac{(1+0.852\ 5B)(1+1.338\ 4B^{12}-0.847\ 4B^{24})}{(1-0.357\ 4B)(1-0.687\ 3B^{12})}.$$

表 1 残差自相关检验结果

ARIMA(1,1,2)×(0,1,0) ₁₂			ARIMA(1,1,1)×(1,1,2) ₁₂		
滞后阶数	卡方	P	滞后阶数	卡方	P
6	4.786 3	0.571 5	6	3.633 5	0.726 1
12	14.116 0	0.293 4	12	7.162 8	0.846 7
18	15.508 0	0.626 8	18	9.015 3	0.959 4
24	17.878 0	0.808 9	24	9.795 6	0.995 3

3.3 组合预测模型的建立

分别将两个拟合模型对 2021 年 5 月至 2022 年 2 月的数据进行预测,下标 $1t$ 与 $2t$ 分别代表 $ARIMA(1,1,2) \times (0,1,0)_{12}$ 和 $ARIMA(1,1,1) \times (1,1,2)_{12}$ 。结果见表 2。

步骤 1 由式(5)、式(7)可得 $E(A_1) = 0.939\ 0$, $E(A_2) = 0.948\ 4$, $S(A_1) = 0.048\ 1$, $S(A_2) = 0.041\ 1$, $\rho_{12} = 0.423\ 5$ 。

由表 2 可知,在 10 个预测时刻,两种单项方法有 7 个时刻的相对误差保持序号相同,取 $a_0 = 0.7$,则组合预测的精度均值 $E(A)$ 和标准差 $S(A)$ 为 $E(w_1, w_2) = 0.7(0.939\ 0w_1 + 0.948\ 4w_2) + 0.3$,

$$S(w_1, w_2) = 0.7\{2.3 \times 10^{-3}w_1^2 + 1.7 \times 10^{-3}w_2^2 + 1.752\ 3 \times 10^{-3}w_1w_2\}^{1/2}。$$

步骤 2 预测精度的均值和标准差同等重要,取 $l_1 = l_2 = 0.5$,由式(8)、式(9)可得各组合预测到正、负理想点的加权距离为

$$\begin{cases} d^+ = \frac{1}{2} [E(w_1, w_2) - 1]^2 + \frac{1}{2} [S(w_1, w_2)]^2 \\ d^- = \frac{1}{2} [E(w_1, w_2)]^2 + \frac{1}{2} [S(w_1, w_2) - 1]^2 \end{cases}。$$

步骤 3 由式(10)得到最大贴近度模型为

$$\max[c(w_1, w_2)] = \frac{1/2E^2(w_1, w_2) + 1/2S^2(w_1, w_2) - S(w_1, w_2) + 1/2}{E^2(w_1, w_2) + S^2(w_1, w_2) - E(w_1, w_2) - S(w_1, w_2) + 1}$$

s. t.
$$\begin{cases} E(w_1, w_2) = 0.7(0.939\ 0w_1 + 0.948\ 4w_2) + 0.3 \\ S(w_1, w_2) = 0.7\{2.3 \times 10^{-3}w_1^2 + 1.7 \times 10^{-3}w_2^2 + 1.7523 \times 10^{-3}w_1w_2\}^{1/2} \\ w_1 + w_2 = 1, w_1 \geq 0, w_2 \geq 0 \end{cases}$$

利用 Lingo 软件求解可得 $w_1 = 0.147\ 4$, $w_2 = 0.852\ 6$ 。

步骤 4 由该方法构成的最优组合预测为 $\hat{x}_t = w_1x_{1t} + w_2x_{2t} = 0.147\ 4x_{1t} + 0.852\ 6x_{2t}$ 。
 $t = 1, 2, \dots, 10。$

3.4 3 种模型对比分析

将简单季节模型 $ARIMA(1,1,2) \times (0,1,0)_{12}$ 、乘积季节模型 $ARIMA(1,1,1) \times (1,1,2)_{12}$ 以及组合预测模型对 2021 年 5 月至 2022 年 2 月的数据进行预测,并将预测值和实际值进行比较,采用均方根误差(RMSE)、平均绝对误差(MAE)和平均绝对百分比误差(MAPE)来评价模型的预测效果,结果见表 3。从表 3 可以看出,3 种模型的平均绝对百分比误差 MAPE 均在 10% 以下,预测效果较好,乘积季节模型的 3 种误差值均比简单季节模型值要小,说明在快递业务量这个数据上,采用乘积季节模型拟合效果要比简单季节模型好;而组合预测模型的均方根误差、平均绝对误差和平均绝对百分比误差值都是最小的,说明组合预测模型在江苏省快递业务量数据上,其预测准确度比单一的简单季节模型和乘积季节模型更高,拟合效果要更好。

4 结论与建议

使用简单季节 ARIMA 模型、乘积季节 ARIMA 模型以及基于 TOPSIS 的组合预测模型对江苏省快递业务量数据进行短期预测,结果表明这 3 种模型拟合效果均良好。在时间序列分析中,季节变动对预测效果有着至关重要的作用。当时间序列数据的季节变动大致相等时,可以采用使用简单季

表 2 各单项预测结果

时间	实际值	单项方法预测值		相对误差序列		预测精度序列	
		x_{1t}	x_{2t}	e_{1t}	e_{2t}	A_{1t}	A_{2t}
2021-05	71 794.30	74 520.37	72 866.27	-0.038 0	-0.014 9	0.962 0	0.985 1
2021-06	76 821.20	75 518.02	75 460.07	0.017 0	0.017 7	0.983 0	0.982 3
2021-07	68 065.70	68 168.96	68 905.77	-0.001 5	-0.012 3	0.998 5	0.987 7
2021-08	65 136.50	72 085.86	70 526.81	-0.106 7	-0.082 8	0.893 3	0.917 2
2021-09	71 856.00	78 989.68	75 881.39	-0.099 3	-0.056 0	0.900 7	0.944 0
2021-10	82 253.70	79 261.40	77 629.43	0.036 4	0.056 2	0.963 6	0.943 8
2021-11	97 891.90	100 398.26	97 310.12	-0.025 6	0.005 9	0.974 4	0.994 1
2021-12	78 628.70	89 560.28	87 560.33	-0.139 0	-0.113 6	0.861 0	0.886 4
2022-01	74 936.20	84 307.82	72 631.12	-0.125 1	0.030 8	0.874 9	0.969 2
2022-02	52 217.50	53 354.80	45 657.03	-0.021 8	0.125 6	0.978 2	0.874 4

表 3 各模型预测结果

模型	RMSE	MAE	MAPE
简单季节模型	5 763.499	4 515.471	0.061 0
乘积季节模型	4 458.881	3 569.210	0.051 6
组合预测模型	4 358.028	3 324.998	0.047 9

节模型即可。这种模型具有表达和计算较为简洁的优点。但其预测效果稍弱,精度较低。因此,当季节变动与长期趋势大致成正比或同向变化时,应该采用乘积模型进行预测。乘积模型可以更加准

确地刻画季节变动与趋势对于时间序列预测的影响,使得预测结果更加精准可靠。相较于单一模型,使用组合预测方法的预测精度更高。对于时间序列预测,组合预测方法可以将多个模型的结果进行结合,从而克服单一模型可能存在的缺陷和偏差。基于 TOPSIS 的组合预测模型的预测效果正说明了这一点。

根据预测数据,江苏省快递业务量的月度数据表现出趋势性和季节性。在趋势性方面,自 2015 年起江苏省快递业务量逐年递增,表明物流产业有持续健康发展的趋势,进一步表明江苏经济在不断快速发展。在季节性方面,每年江苏省快递业务量呈现大致相同的周期性,在 2 月和 3 月最低,在 11 月和 12 月最高。这是因为春节假期和众多商家的“双十一”“双十二”促销活动对快递量的影响。春节假期期间,许多商家企业停工放假,快递员休过过年,人们购买商品的意愿下降,快递量也相应减少。而“双十一”“双十二”促销活动则刺激了国民消费,导致快递量剧增。总的来说,江苏省快递业务量的趋势性和季节性变化提供了重要的信息,有助于对江苏省物流产业的发展趋势进行分析和预测,进而促进经济的健康可持续发展。

在《江苏省“十三五”物流业发展规划》和《长江三角洲一体化发展规划纲要》的带动下,物流业规模效率稳步提升,全省社会物流总额达 23 万亿元,“十二五”期间年均增长 14.7%。与此同时,物流主体逐步壮大,全省共有国家 A 级物流企业 421 家,占全国 A 级物流企业数量的 13%。并且,随着“一带一路”和长江经济带战略的深入实施,南京与长江流域其他地区的物流联动不断增强,已经形成了良好的区域物流联动发展格局。

根据上述提到的江苏省区域物流发展的现状,提出以下几点建议:①加强物流基础能力建设和发展;②支持物流技术创新、积极拓展物流市场并发展绿色物流;③发展物流资源交易电子商务服务和着重发展制造业物流的信息管理、条形码采集与处理、系统设计等高端物流服务;同时物流产业部门可以利用基于 TOPSIS 的组合模型对未来数月的快递业务量数据进行预测,制定相应的经营策略及政策,促进社会经济的绿色可持续发展。

参考文献

[1] FUQUA D, HESPELER S. Commodity demand forecasting using modulated rank reduction for humanitarian lo-

gistics planning[J]. Expert Systems with Applications, 2022,206:117753.

[2] SALAIS-FIERRO T E, MARTÍNEZ J A S. Demand forecasting for freight transport applying machine learning into the logistic distribution[J]. Mobile Networks and Applications, 2022,27(5):2172-2181.

[3] RIBEIRO A M N C, DO CARMO P R X, ENDO P T, et al. Short-and very short-term firm-level load forecasting for warehouses: a comparison of machine learning and deep learning models[J]. Energies, 2022,15(3):750.

[4] FARHAN J, ONG G P. Forecasting seasonal container throughput at international ports using SARIMA models[J]. Maritime Economics & Logistics, 2018,20(1):131-148.

[5] 王向前, 吴东隆, 郑健彤. 货物吞吐量预测的改进 ARIMA 方法:以天津港为例[J]. 运筹与管理, 2022,31(3):138-144.

[6] 黄建华, 张迪. 面向不确定物流需求的改进 GM-BPNN 组合预测方法[J]. 统计与决策, 2022,38(16):26-29.

[7] 黄洁, 花培鹏. 物流大通道背景下云南省物流业与经济发展的互动关系研究[J]. 科技和产业, 2022,22(3):325-331.

[8] 陈敏. 基于 BP 神经网络的成都市的物流需求预测[J]. 中国储运, 2021(5):107-108.

[9] 高雪雪. 基于 BP 神经网络的海南省物流需求预测[J]. 物流技术, 2018,37(1):87-90.

[10] 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.

[11] BAISARIYEV M, BAKYTZHANULY A, SERIK Y, et al. Demand forecasting methods for spare parts logistics for aviation: a real-world implementation of the Bootstrap method[J]. Procedia Manufacturing, 2021,55:500-506.

[12] SHIBASAKI R, WATANABE T. Future forecast of trade amount and international cargo flow in the APEC region: an application of trade-logistics forecasting model[J]. Asian Transport Studies, 2012,2(2):194-208.

[13] VAN DER LAAN E, VAN DALEN J, ROHRMOSER M, et al. Demand forecasting and order planning for humanitarian logistics: an empirical assessment[J]. Journal of Operations Management, 2016,45:114-122.

[14] 陈长英. 基于改进的灰色-马尔可夫链模型的广西物流需求预测研究[J]. 西部交通科技, 2019(10):152-155.

[15] 李明书, 刘仁云, 胡姝祺, 等. 基于时间序列分析的长春市物流研究及预测[J]. 科技创新与应用, 2020(32):34-36.

[16] 刘庆庆, 郑琰, 孙萌, 等. 基于灰色系统理论的物流需求预测:以连云港港为例[J]. 物流工程与管理, 2022,44(3):8-11.

[17] 崔毅, 徐伟, 张松涛. 基于灰色马尔科夫模型的青岛冷链物流需求预测[J]. 物流科技, 2019,42(10):78-82, 87.

[18] 杨铁军, 杨娜, 朱春华, 等. 一种新的基于 ARIMA 模型的

粮食产量预测[J]. 河南工业大学学报(自然科学版), 2015,36(5):19-22.

[19] 王燕. 应用时间序列分析[M]. 北京:中国人民大学出版社,2005.

[20] 赵喜仓,周作杰. 基于 SARIMA 模型的我国季度 GDP 时间序列分析与预测[J]. 统计与决策,2010,26(22):20-22.

[21] 陈华友. 基于预测精度的多目标组合预测优化模型研究[J]. 大学数学,2003(2):1-7.

Short-term Forecast of Express Business in Jiangsu Province Based on TOPSIS
Criteria and SARIMA Model

ZHOU Xiangyu, LI Si

(College of Mathematics and Physics, Anhui Jianzhu University, Hefei 230601, China)

Abstract: Logistics industry is closely related to many industries, and it plays an important role in promoting GDP growth and improving social and economic development. Using the past express business volume to forecast the future value is helpful to reflect the development trend of logistics industry. Based on the express business volume data of Jiangsu province from May 2013 to April 2021, a simple seasonal ARIMA (autoregressive integrated moving average) model and a multiplicative seasonal ARIMA model as well as two combined ARIMA models based on TOPSIS (technique for order preference by similarity to ideal solution) criterion are selected to fit and forecast the express business volume data from May 2021 to February 2022. The average relative errors of the three models' forecasts are found to be smaller, and the combined forecasting model outperform the other two seasonal ARIMA models.

Keywords: express business volume; simple seasonal model; product seasonal model; TOPSIS (technique for order preference by similarity to ideal solution) criterion