

# 基于加权马尔科夫-ARIMA修正模型的区域物流需求预测

程元栋,喻可欣,李先洋

安徽理工大学经济与管理学院,安徽 淮南 232001

**摘要:**为准确预测区域物流需求,采用自回归移动平均(autoregressive integrated moving average, ARIMA)模型建立具有线性关系的时间序列,考虑时间外的非线性影响因素,基于加权马尔科夫模型修正残差状态,构建加权马尔科夫-ARIMA模型,以我国1990—2021年月度货运周转量为物流需求数据来源,验证加权马尔科夫-ARIMA模型的预测精度。结果表明:单一ARIMA模型和加权马尔科夫-ARIMA模型对12期货运周转量预测结果的平均绝对百分误差分别为3.15%、2.22%,后者的预测精度优于前者。

**关键词:**ARIMA模型;加权马尔科夫模型;物流需求;预测

**中图分类号:**U-9;F252

**文献标志码:**A

**文章编号:**1672-0032(2023)03-0022-07

**引用格式:**程元栋,喻可欣,李先洋.基于加权马尔科夫-ARIMA修正模型的区域物流需求预测[J].山东交通学院学报,2023,31(3):22-28.

CHENG Yuandong, YU Kexin, LI Xianyang. The regional logistical demand forecast based on weighted Markov-ARIMA modified model[J]. Journal of Shandong Jiaotong University, 2023, 31(3): 22-28.

## 0 引言

精准的物流需求预测能为政府、交通运输行业在物流规划、物流基础设施投资与建设、产业规划与布局等方面提供有力的决策依据,同时可帮助相关企业及经营者调节日常物流生产活动,指导作出最优决策。物流需求作为派生性需求,不仅与区域经济发展相关,还受多方面因素制约,难以从单一维度进行分析<sup>[1]</sup>。

目前物流需求预测研究多基于物流量的历史数据,采用单一或组合模型进行预测<sup>[2]</sup>。刘炯<sup>[3]</sup>、王迪<sup>[4]</sup>基于多项历史数据,采用多元线性回归模型对物流需求及其影响因素进行实证分析;吴玉国等<sup>[5]</sup>采用灰色-马尔科夫组合模型建立货运周转量预测体系;武亚鹏等<sup>[6]</sup>运用有效度法对线性回归模型、自回归移动平均(autoregressive integrated moving average, ARIMA)模型进行线性组合,预测武汉市的物流需求;张婉琳<sup>[7]</sup>将灰色关联预测与ARIMA模型预测组合,预测宁波港口物流需求。

ARIMA模型是计量经济学中的一类模型,能有效拟合预测对象的时间序列,但采用单一ARIMA模型预测时,可能会在部分时刻因外部因素冲击,导致预测数据与实际数据存在较大偏差,具体表现为残差的异方差性<sup>[8]</sup>。本文采用加权马尔科夫模型修正残差序列,构建加权马尔科夫-ARIMA修正模型,以国家统计局公布的我国1991年1月至2021年12月的货运周转量为物流需求数据进行实例分析,验证加权马尔科夫-ARIMA修正模型对区域物流需求预测的准确性,以为物流规划决策活动提供前提依据。

收稿日期:2022-09-12

基金项目:国家自然科学基金项目(71473001);安徽省哲学社会科学规划项目(AHSKY2017D35);安徽省高等学校省级自然科学研究计划项目(KJ2018A0088)

第一作者简介:程元栋(1979—),男,山东泰安人,副教授,管理学博士,主要研究方向为物流系统工程, E-mail: andoncheng@foxmail.com。

## 1 模型构建

### 1.1 ARIMA 模型

将自回归(auto regressive, AR)模型、移动平均(moving average, MA)模型和差分法结合构成 ARIMA 模型,采用 ARIMA 模型可将一组单变量的时间序列,采用差分等方式把不可预测的非平稳序列转化为平稳序列,通过构建数学模型进行统计描述<sup>[9]</sup>。假设自回归阶数为  $p$ ,原始数据差分后达到平稳的次数为  $d$ ,移动平均阶数为  $q$ ,则 ARIMA( $p, d, q$ )模型为:

$$\nabla^d y_t = \sum_{i=1}^p \alpha_i \nabla^d y_{t-i} + \sum_{j=1}^q \beta_j \varepsilon_{t-j} + \varepsilon_t,$$

式中:  $\nabla^d y_t$  为序列  $y_t$  的  $d$  阶差分,  $\alpha_i$  为第  $i$  项的自回归系数,  $\beta_j$  为第  $j$  项的移动平均系数,  $\varepsilon_t$  为  $y_t$  的残差。

### 1.2 加权马尔科夫模型

加权马尔科夫模型以残差序列的各阶自相关系数体现不同滞期各状态间相互影响的强弱,能有效利用历史数据<sup>[10]</sup>。实际货运周转量序列减去 ARIMA 模型预测的货运周转量序列,得到随机残差序列,将残差序列划分成多种状态,计算一步转移频数矩阵与一步转移概率矩阵,进行马氏性检验<sup>[11]</sup>。通过马氏性检验后,采用残差序列的各阶自相关系数确定各阶权重,加权求和后预测将来期数的状态。最后依据模糊集理论中的状态特征值,将预测状态转变为预测结果,实现修正残差序列的目的<sup>[12]</sup>。

构造  $\chi^2$  统计量,对残差序列进行马氏性检验,公式为:

$$\chi^2 = 2 \sum_{i=1}^m \sum_{j=1}^m f_{ij} |\ln(p_{ij}/p \cdot_j)|, \quad (1)$$

式中:  $f_{ij}$  为状态  $i$  一步转移至状态  $j$  的频数,  $p_{ij}$  为转移概率,  $p \cdot_j$  为边际概率,  $m$  为矩阵的行(列)数。

根据分级情况,计算对应阶数的自相关系数,  $k$  阶的自相关系数

$$r_k = \frac{\sum_{t=1}^{n-k} (\chi_t - \bar{\chi})(\chi_{t+k} - \bar{\chi})}{\sum_{t=1}^n (\chi_t - \bar{\chi})^2}, \quad (2)$$

式中:  $\chi_t$  为第  $t$  期的残差,  $\bar{\chi}$  为平均残差,  $n$  为残差序列长度。

将  $r_k$  归一化,得到  $k$  阶权重

$$w_k = |r_k| / \sum_{k=1}^m |r_k|. \quad (3)$$

状态  $i$  的加权和

$$P_i = \sum_{k=1}^m w_k p_i^k, \quad (4)$$

式中  $p_i$  为  $k$  阶滞期时状态  $i$  的转移概率。

依据最大概率隶属度原则,  $\max\{P_i\}$  对应状态为该期残差的预测状态。

采用模糊集理论中的状态特征值,将预测状态转化为预测结果,公式为:

$$d_i = P_i^\xi / \sum_{i=1}^m P_i^\xi, \quad (5)$$

$$H = \sum_{i=1}^m i d_i, \quad (6)$$

式中:  $d_i$  为本期预测的  $\max\{P_i\}$  状态权重;  $\xi$  为最大概率作用指数,一般  $\xi=2$  或  $\xi=4$ ,本文取  $\xi=2$ ;  $H$  为  $\max\{P_i\}$  时状态  $i$  对应的级别特征值。

预测残差

$$z = \begin{cases} T_i H / (i + 0.5), & H \geq i \\ B_i H / (i - 0.5), & H < i \end{cases} \quad (7)$$

式中  $T_i, B_i$  分别为预测状态  $i$  对应的区间上限、区间下限。

### 1.3 加权马尔科夫-ARIMA 修正模型

通过加权马尔科夫模型预测残差,修正 ARIMA 模型预测的第  $t$  期货运周转量

$$y_t^m = \hat{y}_t + z_t, \quad (8)$$

式中:  $\hat{y}_t$  为 ARIMA 模型预测的第  $t$  期货运周转量,  $z_t$  为加权马尔科夫模型预测的第  $t$  期残差。

## 2 实例分析

### 2.1 ARIMA 模型预测

#### 2.1.1 数据选取

货运量与货运周转量反映某地区在一定时间内的物流活动情况,货运量是一定时期内运输的实际货物总量,货运周转量包括货物数量和货物要求运输的距离,更能体现对物流运输的需求<sup>[13-15]</sup>。选取国家统计局公布的我国 1990 年 1 月至 2021 年 12 月的货运周转量数据进行分析,共计 384 期,每月为 1 期。货运周转量时序图如图 1 所示<sup>[16]</sup>。由图 1 可知:第 145 期(2002 年)前货运周转量平稳增长,之后出现大幅增长;每年 2 月的货运周转量均下降明显。我国的货运周转量呈非平稳的周期性增长。对货运周转量进行差分处理,经 1 阶差分及平稳性检验发现,序列的增长趋势消失,显示一定的平稳性。




图 1 货运周转量时序图

#### 2.1.2 模型识别

为确定模型阶数<sup>[17]</sup>,在统计应用软件 R 中绘制原货运周转量序列的自相关系数图和偏自相关系数图,如图 2 所示。




图 2 原货运周转量序列的自相关系数图和偏自相关系数

由图 2 可知:1 阶差分后自相关系数与偏自相关系数均拖尾,采用 ARIMA( $p, q$ ) 模型。根据最小信息准则,采用赤池信息准则 (Akaike information criterion, AIC) 和贝叶斯信息准则 (Bayesian information criterion, BIC) 确定  $p, q$ , 均支持原货运周转量序列的 ARIMA(2, 1, 2) 模型,即 1 阶差分序列的 ARIMA(2, 2) 模型最优。

#### 2.1.3 ARIMA 模型预测结果

确定模型阶数后,估计 ARIMA 模型的系数,拟合结果为:AR(1)、AR(2)、MA(1)、MA(2) 的系数分别为 1.489 3、-0.555 9、-1.909 8、0.937 7;标准差分别为 0.174 0、0.049 5、0.034 5、0.029 9。ARIMA 模型系数的绝对值大于 3 倍标准差,系数均显著。因此可得 ARIMA(2, 1, 2) 模型为:

$$y_t = 2.4893y_{t-1} - 2.0452y_{t-2} + 0.5559y_{t-3} + \varepsilon_t - 1.9098\varepsilon_{t-1} + 0.9377\varepsilon_{t-2}。$$

根据拟合的模型,可得 ARIMA 模型预测货运周转量序列。

### 2.2 加权马尔科夫模型残差修正

ARIMA 模型预测的货运周转量序列与实际货运周转量序列之差构成残差序列,该序列可看作一组具有平稳性与无后效性的随机变量<sup>[18-20]</sup>。采用加权马尔科夫模型修正残差序列,将修正后的残差序列与 ARIMA 模型预测的货运周转量序列相加,计算修正预测货运周转量。

#### 2.2.1 状态分级

经计算残差序列的均值为-41.6,标准差为456.3,依据均值-标准差法,将残差序列分为7个状态区间,如表1所示。

表1 残差序列的状态区间划分

状态	1	2	3	4	5	6	7
区间	[-1 865, -1 409)	[-1 409, -953)	[-953, -497)	[-497, -41)	[-41, 415)	[415, 877)	[877, 1 327]

#### 2.2.2 计算转移概率矩阵

根据残差序列的转移情况进行统计,得到一步转移频数矩阵  $p$ , 计算一步转移概率矩阵  $p_{(1)}$ , 结果为:

$$p = \begin{bmatrix} 2 & 1 & 4 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 & 1 & 0 \\ 0 & 1 & 1 & 8 & 1 & 0 & 0 \\ 4 & 0 & 4 & 159 & 28 & 0 & 0 \\ 1 & 0 & 1 & 20 & 79 & 16 & 2 \\ 1 & 1 & 0 & 5 & 10 & 20 & 3 \\ 0 & 0 & 0 & 0 & 1 & 4 & 2 \end{bmatrix}, p_{(1)} = \begin{bmatrix} 0.250 & 0.125 & 0.500 & 0.123 & 0 & 0 & 0 \\ 0 & 0 & 0.333 & 0.333 & 0 & 0.333 & 0 \\ 0 & 0.091 & 0.091 & 0.727 & 0.091 & 0 & 0 \\ 0.021 & 0 & 0.021 & 0.815 & 0.144 & 0 & 0 \\ 0.008 & 0 & 0.008 & 0.168 & 0.664 & 0.135 & 0.017 \\ 0.025 & 0.025 & 0 & 0.125 & 0.250 & 0.500 & 0.075 \\ 0 & 0 & 0 & 0 & 0.143 & 0.571 & 0.286 \end{bmatrix}。$$

$p \cdot_j$  为  $p$  的第  $j$  列之和除以各行各列总和,经计算边际概率  $p \cdot_1 = 0.2572, p \cdot_2 = 0.0574, p \cdot_3 = 0.2350, p \cdot_4 = 0.3050, p \cdot_5 = 0.1490, p \cdot_6 = 0.0780, p \cdot_7 = 0.0680, p \cdot_8 = 0.0500$ 。参照一步转移概率矩阵,同理可计算出二至七步转移概率矩阵  $p_{(2)} \sim p_{(7)}$ 。

#### 2.2.3 马氏性检验

一组随机序列是否具有马氏性是应用加权马尔科夫模型预测的前提,根据式(1)结合转移概率矩阵与边际概率,对残差序列进行马氏性检验<sup>[21]</sup>。经计算,  $\chi^2 \approx 555.136$ , 给定显著性水平  $\alpha = 0.005$ , 查表可知  $\chi_{\alpha}^2(m-1)^2 = \chi_{0.005}^2(36) = 61.58$ , 显然  $\chi^2 > \chi_{\alpha}^2(m-1)^2$ , 认为残差序列通过马氏性检验,可采用加权马尔科夫模型。

#### 2.2.4 预测残差

根据式(2)(3)计算残差序列的各阶自相关系数及归一化后的各阶权重,结果如表2所示。

表2 各阶自相关系数及权重

阶数	1	2	3	4	5	6	7
$r_k$	0.6170	0.3097	0.1056	-0.0210	-0.0809	-0.1290	-0.1988
$w_k$	0.4221	0.2118	0.0723	0.0144	0.0553	0.0883	0.1359

将归一化后的各阶权重作为对应滞期的权重,以第1~372期的残差数据为样本数据预测第373~384期的残差。例如预测373期残差状态如表3所示。根据式(4),结合表3数据计算可得状态1~7的  $P_i$  分别为0.0154, 0.0329, 0.0088, 0.1888, 0.2161, 0.4069, 0.1311,  $\max\{P_i\} = 0.4069$ , 依据最大概率隶属度原则判定,第373期的残差状态为6,分布在区间[415, 877)。

表3 预测第373期残差状态

期数	滞期	权重	$P_i$						
			状态1	状态2	状态3	状态4	状态5	状态6	状态7
366	7	0.135 9	0.015 4	0.010 2	0.015 4	0.661 5	0.230 8	0.056 4	0.010 3
367	6	0.088 2	0.005 1	0	0.010 2	0.702 5	0.205 1	0.051 3	0.025 6
368	5	0.055 3	0.025 6	0.008 6	0.051 3	0.324 8	0.452 9	0.119 7	0.017 0
369	4	0.014 3	0.153 8	0.051 3	0.076 9	0.153 8	0.282 1	0.256 4	0.025 6
370	3	0.072 2	0.128 2	0	0.025 6	0.230 8	0.230 8	0.307 7	0.076 9
371	2	0.211 8	0	0.143 4	0	0.143 0	0.143 0	0.571 0	0
372	1	0.422 0	0	0	0	0	0.142 9	0.571 4	0.285 7

通过式(5)计算状态1~7的 $d_i$ ,结果为: $d_1=0.008 9$ , $d_2=0.004 1$ , $d_3=0.008 8$ , $d_4=0.133 7$ , $d_5=0.175 2$ , $d_6=0.621 4$ , $d_7=0.064 5$ 。基于模糊集理论中的状态特征值,采用式(6)计算状态特征值 $H=5.600 31$ ,依据式(7),得第373期的预测残差 $z=422.569$ 亿 $t \cdot km$ 。

### 2.3 加权马尔科夫-ARIMA修正模型预测

ARIMA模型捕捉的是数据间的线性关系,只需内生变量,使用简单,但对外界的影响,如政策调控或突发事件造成的剧烈冲击很难预测。货运周转量具有明显的周期增长性,且易受外界影响,可采用加权马尔科夫模型预测的残差体现这种非线性变化。根据加权马尔科夫模型预测的第373期残差,采用式(8)将该残差与ARIMA模型预测的货运周转量相加,得到加权马尔科夫-ARIMA修正模型预测的第373期的货运周转量,为17 186.72亿 $t \cdot km$ 。依次计算第374~384期的残差及修正预测货运周转量,实际货运周转量 $F_p$ 与ARIMA模型、加权马尔科夫-ARIMA修正模型预测的货运周转量 $F_f$ 对比结果如表4所示。

表4 第373~384期的实际货运周转量与2种模型预测的货运周转量

期数	$F_p/$ (亿 $t \cdot km$ )	$F_f/$ (亿 $t \cdot km$ )		相对误差 $E/\%$	
		ARIMA模型	加权马尔科夫-ARIMA修正模型	ARIMA模型	加权马尔科夫-ARIMA修正模型
373	17 341.62	16 764.15	17 186.72	3.33	0.89
374	13 877.39	14 869.42	15 279.20	7.15	10.10
375	18 159.31	17 596.47	17 950.27	3.10	1.15
376	17 921.80	17 473.73	17 862.11	2.50	0.33
377	18 892.76	18 085.40	18 490.13	4.27	2.13
378	18 469.31	17 869.48	18 278.63	3.25	1.03
379	17 507.44	17 390.48	17 801.06	0.67	1.68
380	18 706.23	18 214.15	18 598.73	2.63	0.57
381	18 360.00	18 087.65	18 492.94	1.48	0.72
382	18 497.29	18 266.70	18 221.93	1.25	1.49
383	20 050.67	19 260.28	19 215.45	3.94	4.17
384	20 328.93	19 457.51	19 847.17	4.29	2.37

注: $E=|F_p-F_f|/F_p \times 100\%$ 。

ARIMA模型与加权马尔科夫-ARIMA修正模型的平均相对误差分别为3.15%、2.22%,经修正后提

高了模型的预测精度,加权马尔科夫-ARIMA修正模型的预测精度优于单一的ARIMA模型。

### 3 结论

本文以我国1990年1月至2021年12月的月度货运周转量为预测物流需求的基础数据,构建时间序列的ARIMA模型,采用加权马尔科夫模型修正残差序列,建立加权马尔科夫-ARIMA修正模型,以2021年1月至12月(即文中的373至384期数据)共12期货运周转量为例进行实证分析。结果显示加权马尔科夫-ARIMA修正模型的预测精度优于单一ARIMA模型。加权马尔科夫-ARIMA修正模型可提高区域物流需求预测结果的准确性,为物流决策人员提供可靠的决策依据,也可为其他领域的预测研究提供借鉴。

#### 参考文献:

- [1] 师琪. GL智慧物流园经济效益评估优化研究[D]. 徐州:中国矿业大学,2021.  
SHI Qi. Optimal study on economic benefit evaluation of GL intelligent logistics park[D]. Xuzhou: China University of Mining and Technology, 2021.
- [2] 孔繁辉. 全渠道供应链网络库存优化与定价策略研究[D]. 天津:天津理工大学,2020.  
KONG Fanhui. Study on the inventory optimization and pricing strategy of omnichannel supply chain network[D]. Tianjin: Tianjin University of Technology, 2020.
- [3] 刘炯. 基于多元线性回归的物流需求预测分析:以安徽省为例[J]. 四川文理学院学报,2022,32(2):51-58.  
LIU Jiong. Logistics demand forecasting analysis based on multiple linear regression;taking Anhui Province as an example [J]. Sichuan University of Arts and Science Journal, 2022, 32(2): 51-58.
- [4] 王迪. 基于多元线性回归模型的物流需求影响因素实证分析:以上海市为例[J]. 投资与创业,2022,33(14):58-60.
- [5] 吴玉国,李晓迪. 基于灰色-马尔科夫链的区域物流需求预测[J]. 南阳理工学院学报,2020,12(6):1-5.  
WU Yuguo, LI Xiaodi. Regional logistics demand forecast based on grey-Markov chain[J]. Journal of Nanyang Institute of Technology, 2020, 12(6): 1-5.
- [6] 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.  
WU Yapeng, LI Huiying, LI Ting, et al. A multi-model based combination prediction and analysis of logistics demand: taking Wuhan as example[J]. Logistics Technology, 2022, 41(6): 60-63.
- [7] 张婉琳. 基于GM(1,1)-ARIMA组合模型的宁波港口物流需求预测分析[J]. 物流工程与管理,2023,45(1):32-35.  
ZHANG Wanlin. Forecast and analysis of Ningbo Port logistics demand based on GM(1,1)-ARIMA combined model[J]. Logistics Engineering and Management, 2023, 45(1): 32-35.
- [8] 彭宇灿. 基于ARFIMA-GRACH-SVM模型的股指预测研究[D]. 济南:山东大学,2021.  
PENG Yucan. Research on stock index prediction based on ARFIMA-GRACH-SVM model[D]. Jinan: Shandong University, 2021.
- [9] 罗志丹. 数据驱动金融时间序列混合预测模型研究与实证分析[D]. 北京:对外经济贸易大学,2020.  
LUO Zhidan. The data-driven research and empirical analysis on hybrid models of financial time series forecasting[D]. Beijing: University of International Business and Economics, 2020.
- [10] CHEN Z H, TIAN B, ZHANG S Y, et al. Quantitative prediction of sea clutter power based on improved grey Markov model[J]. Atmosphere, 2022, 13(7): 1-11.
- [11] 张小波. 基于数据特征驱动分解的季节性时间序列预测模型研究及应用[D]. 大连:东北财经大学,2020.  
ZHANG Xiaobo. Research and application of seasonal time series forecasting model based on data feature driven decomposition[D]. Dalian: Dongbei University of Finance and Economics, 2020.
- [12] 陈丰. 区域物流能力评价研究[D]. 石家庄:石家庄铁道大学,2021.  
CHEN Feng. Research on evaluation of regional logistics ability development level[D]. Shijiazhuang: Shijiazhuang Tiedao University, 2021.
- [13] 梁子婧. 江苏区域物流空间非均衡态势及演变机制研究[D]. 徐州:中国矿业大学,2020.

- LIANG Zijiang. Research on regional logistics space disequilibrium situation and evolution mechanism in Jiangsu Province [D]. Xuzhou: China University of Mining and Technology, 2020.
- [14] 何佳奇. 基于 ARIMA-SVM 混合模型的城市宏观交通状态分析与预测[D]. 北京: 北京交通大学, 2020.  
HE Jiaqi. Analysis and forecast of urban macro traffic state based on ARIMA-SVM mixed model [D]. Beijing: Beijing Jiaotong University, 2020.
- [15] 徐唯祎. 基于特征选择和算法融合的铁路货运需求预测研究[D]. 南昌: 华东交通大学, 2020.  
XU Weiyi. Research on railway freight demand forecasting based on feature selection and algorithm fusion [D]. Nanchang: East China Jiaotong University, 2020.
- [16] 国家统计局. 中国统计年鉴[J]. 北京: 中国统计出版社, 1990-2021.
- [17] 赵永宁. 基于时空相关性的大规模风电功率短期预测方法研究[D]. 北京: 中国农业大学, 2019.  
ZHAO Yongning. Research on short-term large-scale wind power forecasting methods based on spatio-temporal correlation [D]. Beijing: China Agricultural University, 2019.
- [18] 肖玮. O2O 公路货运平台价格波动与短时预测研究[D]. 成都: 西南交通大学, 2020.  
XIAO Wei. Modeling and prediction of the volatility of highway freight rate with O2O-based freight transportation platform [D]. Chengdu: Southwest Jiaotong University, 2020.
- [19] 罗亚琼. 基于灰色马尔科夫模型的基坑开挖变形预测[D]. 昆明: 昆明理工大学, 2021.  
LUO Yaqiong. Deformation analysis of foundation pit excavation based on grey Markov model prediction [D]. Kunming: Kunming University of Science and Technology, 2021.
- [20] 陈尧. 基于异步混频数据的中国经济短期波动研究[D]. 武汉: 中南财经政法大学, 2021.  
CHEN Yao. Research on the short-term fluctuation of China's economy based on asynchronous mixing data [D]. Wuhan: Zhongnan University of Economics and Law, 2021.
- [21] 陈倩倩. 基于成分数据的灰色预测模型及其应用研究[D]. 无锡: 江南大学, 2020.  
CHEN Qianqian. The grey prediction model based on composition data and its application [D]. Wuxi: Jiangnan University, 2020.

## The regional logistical demand forecast based on weighted Markov-ARIMA modified model

CHENG Yuandong, YU Kexin, LI Xianyang

School of Economics and Management, Anhui University of Science and Technology, Huainan 232001, China

**Abstract:** To accurately predict regional business logistical demand, an auto-regressive integrated moving average (ARIMA) model with a linear relationship is established for series of timing, in the meantime, non-linear influences outside of timing are also considered, then, the residual statuses are modified based on the weighted Markov model, finally the weighted Markov-ARIMA model is constructed. To test the predicted accuracy of the weighted Markov-ARIMA model, China's monthly trucking turnovers from the year 1990 to 2021 as the source of business logistical data are employed. The results show that the average absolute percentage errors of the single ARIMA model and the weighted Markov-ARIMA model for the 12-period trucking turnovers forecasting results are 3.15% and 2.22% respectively, and the forecasting accuracy of the modified model is better than that of the single ARIMA model.

**Keywords:** ARIMA model; weighted Markov model; logistical demand; forecast

(责任编辑: 郭守真)