

# 基于ARIMA-SVM组合模型的交通流量短时预测

陈欢

贵州大学, 数学与统计学院, 贵州 贵阳

收稿日期: 2022年6月4日; 录用日期: 2022年6月28日; 发布日期: 2022年7月5日

## 摘要

随着经济和社会的快速发展, 城市交通的拥堵问题日益严重, 有效的短时交通量预测可减少盲目出警与控制警力成本。为此, 本文采用ARIMA时间序列模型提取道路交通流量序列中线性特征, 得到交通流序列预测残差。SVM模型能提取道路交通流量的残差序列非线性特征, 对交通流预测残差进行修正。这两个模型组合能有效地提取时间序列全部特征, 预测性能更佳。同时采用ARIMA-SVM组合模型对交通流量时间序列数据进行短时预测, 其平均绝对误差和平均百分比误差分别为7.7%和12.7%, 说明ARIMA-SVM组合模型预测效果较好。在ARIMA、SVM、ARIMA-SVM模型中, SVM模型预测性能最差, 其平均绝对误差和平均百分比误差分别为28.2%和46.2%。

## 关键词

ARIMA模型, SVM模型, 组合模型, 交通流量预测, 道路交通

## Short-Time Traffic Forecasting Based on ARIMA-SVM Combined Model

Huan Chen

School of Mathematics and Statistics, Guizhou University, Guiyang Guizhou

Received: Jun. 4<sup>th</sup>, 2022; accepted: Jun. 28<sup>th</sup>, 2022; published: Jul. 5<sup>th</sup>, 2022

## Abstract

With the rapid development of economy and society, the congestion problem of urban traffic is becoming more and more serious, and effective short-time traffic prediction can reduce the cost of blind police dispatch and control police force. In this paper, the ARIMA time series model is used

to extract linear features from the road traffic flow series to obtain the traffic flow series prediction residuals, and the SVM model can extract the non-linear features of the road traffic flow residual series to correct the traffic flow prediction residuals. The combination of these two models can effectively extract all features of the time series, and the prediction performance is better. The combined ARIMA-SVM model is also used to predict the traffic flow time series data in short time, and its average absolute error and average percentage error are 7.7% and 12.7%, respectively, which indicates that the combined ARIMA-SVM model has better prediction performance. Among the ARIMA, SVM, and ARIMA-SVM models, the SVM model has the worst prediction performance, with its average absolute error and average percentage error of 28.2% and 46.2%, respectively.

## Keywords

ARIMA Model, SVM Model, Combinatorial Models, Traffic Flow Forecasting, Road Traffic

Copyright © 2022 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

随着经济和社会快速发展,城市交通的拥堵问题日益严重。交通的实时动态管理与交通道路控制已经成为必不可少的研究,交通道路控制的前提是做好短时交通量预测和交通信息采集等,来提高智能交通系统的运行效率[1]。做好交通控制和诱导系统必须要做好短时交通量预测,短时交通量预测是以几分钟为数据单元进行时间序列的分析预测,滚动实时预测未来短时段交通量。通过短时交通流量预测为交通管理部门提供参考,为交通的实时动态管理提供更好的依据[2]。

交通流量短时预测方法众多,大部分学者采用机器学习和深度学习方法进行预测,提高短时交通道路流量的预测精度,同时时间序列模型也被广泛运用,例如 ARIMA (autoregressive integrated moving average)模型。ARIMA 时间序列模型考虑了序列的有序性、时间性和随机因素的不确定性所造成的干扰因素,选用数据并不受约束与限制,适用范围广,应用性强,而且短期预测效果较好[3]。刘学刚等人同样采用 ARIMA 模型对交通道路进行短时预测,并且表明在短时交易量预测时有很大的应用价值[4]。徐翠翠提出基于 ARIMA 模型的城市道路交叉口交通流预测,提取现场每天 24 h 交通流数据,分析不同时间序列的交通流特征[5]。机器学习中 SVM (support vector machine)模型有着分类作用与非线性拟合功能,可以准确地拟合交通流量序列中的非线性变化特征[6]。最近几年混合模型相比于单一模型更受学者青睐,有学者采用时间序列模型与机器学习模型混合来预测交通流量[7]。大部分学者采用 SVM 模型与神经网络组合预测交通流,也有部分学者采用优化的 SVM 模型预测交通流。李媛媛在空间重构基础上分析混沌交通时间序列,采用 SVM 相同原理研究最小二乘支持向量机,并应用于智能交通数据作短期预测[8]。余涛分析了在较少数据集条件下,运用 SVM 模型具有更好的预测效果,因此在较大数据集条件下采用 SVM 模型与 BP 神经网络组合获得更好的预测效果[9]。何祖杰等人采用改进灰狼算法优化支持向量机来预测智能交通流,并通过实证数据与粒子群算法进行对比,结果表明改进灰狼算法优化支持向量机具有鲁棒性与泛化能力[10]。曾宪堂等人总结了不同文献短期预测交通流模型,将 ARIMA、KNN、SVM 短期预测模型应用于高速公路,并进行比较[11]。

城市交通拥堵状况与预测交通流分析一直是交通领域学者研究的热点话题,短期交通流预测能更好地描述某时段或某时刻的交通状态,因此本文采用贵州省贵阳市交通流量数据进行短期预测。本文采用

ARIMA 与 SVM 模型组合, 使用 ARIMA 模型, 能够很好地刻画交通流量序列中的线性变化特征, 但其对非线性变化特征的描述会产生一定的误差, 然而 SVM 模型可出色地拟合交通流量中非线性变化特征。最后使用平均绝对误差与平均百分比误差对结果进行分析。

## 2. 相关工作

### 2.1. ARIMA 模型

ARIMA 模型可分为自回归(autoregressive, AR)模型、滑动平均(moving average, MA)模型和 ARIMA( $p, d, q$ )。滞后项为  $p$  阶的 AR 模型记为 AR( $p$ ), AR( $p$ )模型如下公式(1)所示:

$$x_t = c + a_1 x_{t-1} + a_2 x_{t-2} + \cdots + a_p x_{t-p} + \varepsilon_t \quad (1)$$

其中,  $c$  为常数,  $a_1, a_2, \dots, a_p$  是 AR( $p$ )模型的自回归系数;  $\varepsilon_t$  为白噪声序列, 即随机误差项;  $x_t$  是时间序列  $t$  时刻的值, 即  $x_{t-1}, x_{t-2}, \dots, x_{t-p}$  是时间序列  $x_t$  的滞后序列, 即数据的自变量。滞后项为  $q$  阶的 MA 模型记为 MA( $q$ ), MA( $q$ )模型如下公式(2)所示。

$$x_t = c + \varepsilon_t - b_1 \varepsilon_{t-1} - b_2 \varepsilon_{t-2} - \cdots - b_q \varepsilon_{t-q} \quad (2)$$

其中,  $c$  为常数,  $b_1, b_2, \dots, b_q$  是 MA( $q$ )模型的自回归系数;  $\varepsilon_t$  为白噪声序列, 即随机误差项;  $x_t$  是时间序列  $t$  时刻的值, 即数据的因变量。

AR 模型可以刻画一个时间序列对过去自身的记忆, MA 模型可以刻画一个时间序列对过去冲击的记忆。如果一个时间序列的变化规律中不仅包含了对过去状态的记忆, 还包含了对过去冲击的记忆, 则此时间序列的变化规律可以被 ARMA 模型捕获, 滞后项分别为( $p, q$ )的 ARMA 模型[12]。ARMA 模型如下公式(3)所示:

$$x_t = a_1 x_{t-1} + a_2 x_{t-2} + \cdots + a_p x_{t-p} + \varepsilon_t + \varepsilon_t - b_1 \varepsilon_{t-1} - b_2 \varepsilon_{t-2} - \cdots - b_q \varepsilon_{t-q} \quad (3)$$

$$E(\varepsilon_t) = 0,$$

$$\text{Var}(\varepsilon_t) = \sigma_t^2,$$

$$E(\varepsilon_t, \varepsilon_s) = 0, \quad s \neq t,$$

$$E(\varepsilon_t, \varepsilon_s) = 0, \quad \forall s < t.$$

其中,  $x_t$  是  $t$  时刻样本序列值;  $\varepsilon_t$  是服从高斯分布的白噪声序列;  $a_1, a_2, \dots, a_p$  是自回归系数;  $b_1, b_2, \dots, b_q$  为移动平均系数, 其他为模型的约束条件。在 ARIMA 模型中若  $q$  为 0, 则该模型 ARIMA( $p, 0$ )退化为 AR( $p$ )。若  $p$  为 0, 则该模型 ARIMA( $p, q$ )退化为 MA( $q$ )。

若一个时间序列是非平稳的, 则不能直接用 ARMA 模型进行拟合(容易出现伪回归), 此时必须对此时间序列进行平稳化处理。差分方法是平稳化时间序列最常用的一种方法, 若一个非平稳时间序列经过  $d$  次差分后平稳, 则依据此时间序列构建的 ARMA( $p, q$ )模型称为 ARMA( $p, d, q$ )模型[13]。

### 2.2. SVM 模型

SVM (support vector machine)模型具有很好的分类和拟合能力, 通过使用空间转化, 将非线性问题变成线性问题, 从而可以解决高维非线性问题, 同时可以避免局部较小问题[14]。SVM 模型的基本思想是求解能够正确划分训练数据集并且几何间隔最大的分离超平面。

设有一训练数据样本集为  $\{y_i\} (i=1, 2, \dots, m)$ , 其中  $x_i \in R^n$  为  $n$  维输入向量,  $y_i \in R$  为相应的期望输出值。SVM 回归估计函数如下公式(4)所示:

$$f(x) = (w \times \phi(x)) + b \quad (4)$$

其中,  $\phi(x)$  将输入向量映射到高维特征空间;  $w$  和  $b$  分别为权重和偏差, 通过如下公式(5)和(6)求出:

$$\min \frac{1}{2} w^T \times w + C \times \sum_{i=1}^m L_{\varepsilon}(y_i - f(x), x_i) \quad (5)$$

$$L(y - f(x), x) = |y - f(x)|_{\varepsilon} = \begin{cases} 0 & |y - f(x)| \leq \varepsilon, \\ |y - f(x)| - \varepsilon & \text{其他.} \end{cases} \quad (6)$$

上述权重和偏差求解式子中,  $C$  为正则化参数, 用于控制经验误差和正则化项;  $L_{\varepsilon}$  为不敏感损失函数,  $\varepsilon$  为不敏感损失函数参数。

引入核函数  $k(x_i, x_j)$ , 结合拉格朗日函数和沃尔夫(Wolfe)对偶理论, 将权重与偏差求解公式转换为二次规划问题如下, 公式(7):

$$\begin{aligned} \min & \frac{1}{2} \times \sum_{i,j=1}^m (\alpha_i - \alpha_i^*) \times (\alpha_i - \alpha_i^*) \times k(x_i, x_j) + \varepsilon \times \sum_{i=1}^m (\alpha_i + \alpha_i^*) - \sum_{i=1}^m y_i (\alpha_i - \alpha_i^*) \\ \text{s.t.} & \sum_{i=1}^m y_i (\alpha_i - \alpha_i^*) = 0 \\ & 0 \leq \alpha_i, \alpha_i^* \leq C, i = 1, 2, \dots, m \end{aligned} \quad (7)$$

其中,  $\alpha_i$  和  $\alpha_i^*$  为拉格朗日乘子, 输入向量  $x_i$  对应的非零  $\alpha_i$  和  $\alpha_i^*$  为支持向量。因此, SVM 回归估计函数转换为回归函数如下公式(8)所示:

$$f(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) \times k(x_i, x_j) + b \quad (8)$$

通过以上 SVM 回归函数模型进行拟合和预测。

### 2.3. ARIMA-SVM 模型构建

ARIMA-SVM 模型建模思路为: 通过 ARIMA 模型预测交通道路流量序列中的线性特征, 得到预测残差。由于残差中包含了交通道路流量的非线性特征, 利用 SVM 强大的非线性映射能力对残差进行修正并预测, 最后将线性预测结果和残差修正结果进行组合, 得到交通道路流量序列的预测值。

ARIMA-SVM 模型短时预测交通道路流量的建模步骤如下:

**步骤 1:** 白噪声检验。采用 Q 统计量检验以及自相关函数和偏自相关函数判断是否为白噪声序列。

**步骤 2:** 序列的平稳性检验以及平稳化处理。序列平稳性采用单位根和序列相关图判断, 如果为平稳序列, 则可以构建 ARIMA 模型; 如果为非平稳序列, 则序列需进行  $d$  阶差分, 差分后为平稳序列才可构建 ARIMA 模型。

**步骤 3:** 模型识别与定阶。通过自相关系数图和偏自相关系数图的截尾性与拖尾性进行模型识别, 确定采用时间序列 AR, MA, ARIMA 其中一个模型。模型定阶同样根据自相关系数图和偏自相关系数图以及差分次数初步确定  $p, d, q$  的值。选择多组不同阶数模型进行拟合模型, 比较 AIC 准则, 确定最优  $p, d, q$  的值。

**步骤 4:** 参数估计与检验。参数估计采用最大似然估计法进行估计, 模型检验残差是否为白噪声序列。

**步骤 5:** ARIMA 模型预测。通过构建的 ARIMA 模型预测后 10 期预测值, 并获得残差序列。

**步骤 6:** SVM 模型构建并残差修正。设定 SVM 核函数, 将残差序列输入 SVM, 采用交叉验证法确定 SVM 的最佳参数值, 从而构建 SVM 模型。根据 SVM 预测残差序列, 获得残差预测值。

**步骤 7:** 组合预测值。将 ARIMA 模型的预测值与 SVM 的残差预测值进行加和, 得到最终交通道路流量的后 10 期预测值。

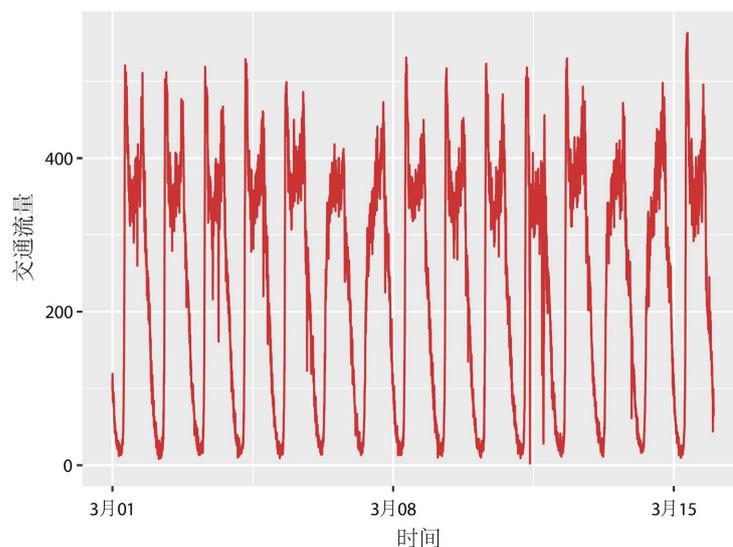
### 3. 实例验证

本文采用的数据是贵州省贵阳市观山湖区长岭北路与东林寺路交叉口的真实交通流量数据, 如下图 1 所示。采用 2021 年 3 月 1 日至 2021 年 3 月 16 日连续 16 天的短时交通流量数据, 数据采用 5 min 为时间间隔统计交通流量  $Q$ 。将 2021 年 3 月 1 日至 2021 年 3 月 15 日作为训练集, 2021 年 3 月 16 日前 10 个时间序列点作为测试集。将训练集可视化, 可得到长岭北路与东林寺路交叉口序列图, 如下图 2 所示。



**Figure 1.** Intersection of changling north road and donglinsi road

**图 1.** 长岭北路与东林寺路交叉口



**Figure 2.** Sequence diagram of daily traffic flow at the intersection of changling north road and donglinsi road

**图 2.** 长岭北路与东林寺路交叉口日流量序列图

### 3.1. ARIMA-SVM 模型构建与预测

在模型构建与预测之前，对训练序列数据进行时间序列分解，分解结果如下图 3 所示。从图中可看出序列具有规律的周期性以及带有一定的趋势性和波动。

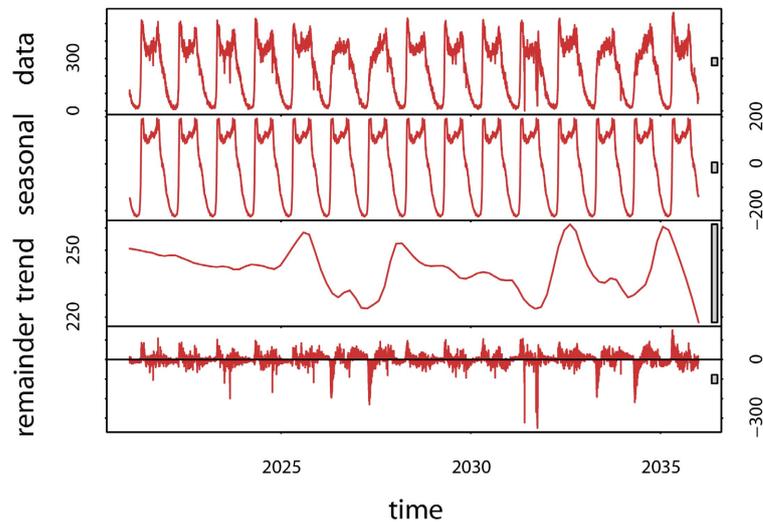


Figure 3. Time series decomposition plot

图 3. 时间序列分解图

从时间序列分解和序列图来看，该序列的在不同值附件有小范围波动，可以大致判断该序列不是一个平稳序列。使用自相关函数和偏自相关函数进一步判断是否为非平稳序列，自相关函数图和偏自相关函数图如下图 4 所示，该序列的自相关系数没有迅速下降为 0，也没有收敛到 0 的 2 倍标准差范围内，可以判断该时间序列不是平稳序列。进一步对该时间序列进行单位根检验和白噪声检验，单位根检验的  $p$  值和滞后 6 阶的纯随机性检验的  $p$  值分别为 0.01、0.000022，可见该序列为非白噪声序列。

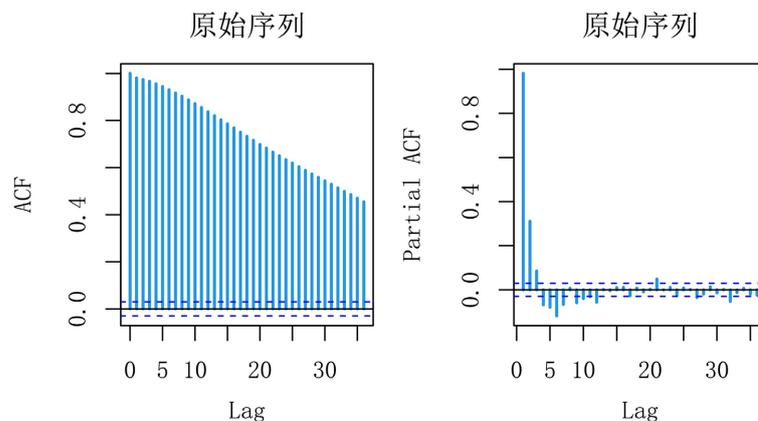


Figure 4. Time series ACF and PACF

图 4. 原始序列自相关系数图和偏自相关系数图

从以上方法判断该时间序列为非平稳序列，将该序列进行一次差分，并对差分后的序列进行可视化，得到差分后序列图，如下图 5 所示，比原序列更平稳。将差分后序列作自相关系数检验，从自相关系数

图上看, 该差分后序列平稳, 自相关系数图和偏自相关系数图如下图 6 所示。从自相关系数图看出, 差分后序列一阶后基本上衰减为 0, 到 6 阶之后都在 0 的 2 倍标准差范围内, 具有拖尾性质。从偏自相关系数来看, 差分后序列 6 阶之后大部分衰减为 0, 具有拖尾性质。

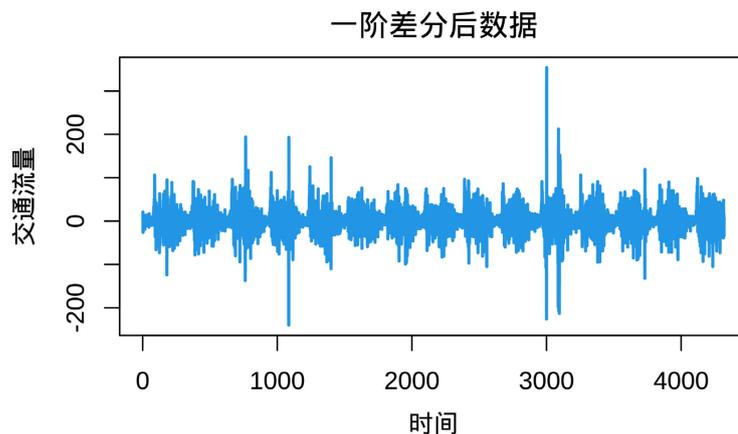


Figure 5. Sequence diagram after one difference

图 5. 一次差分后序列图

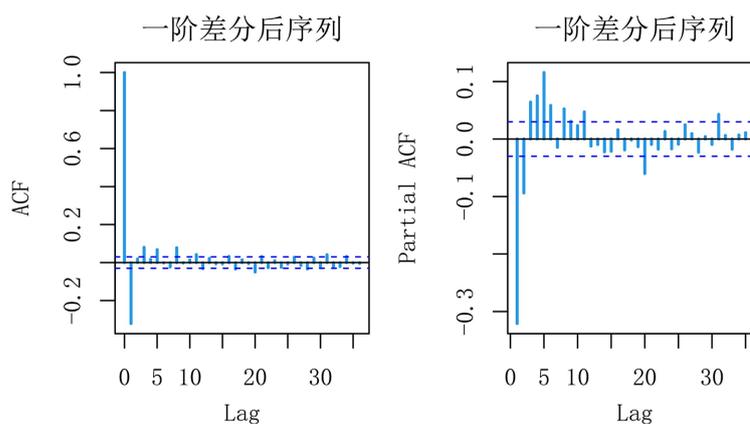


Figure 6. ACF and PACF after first difference

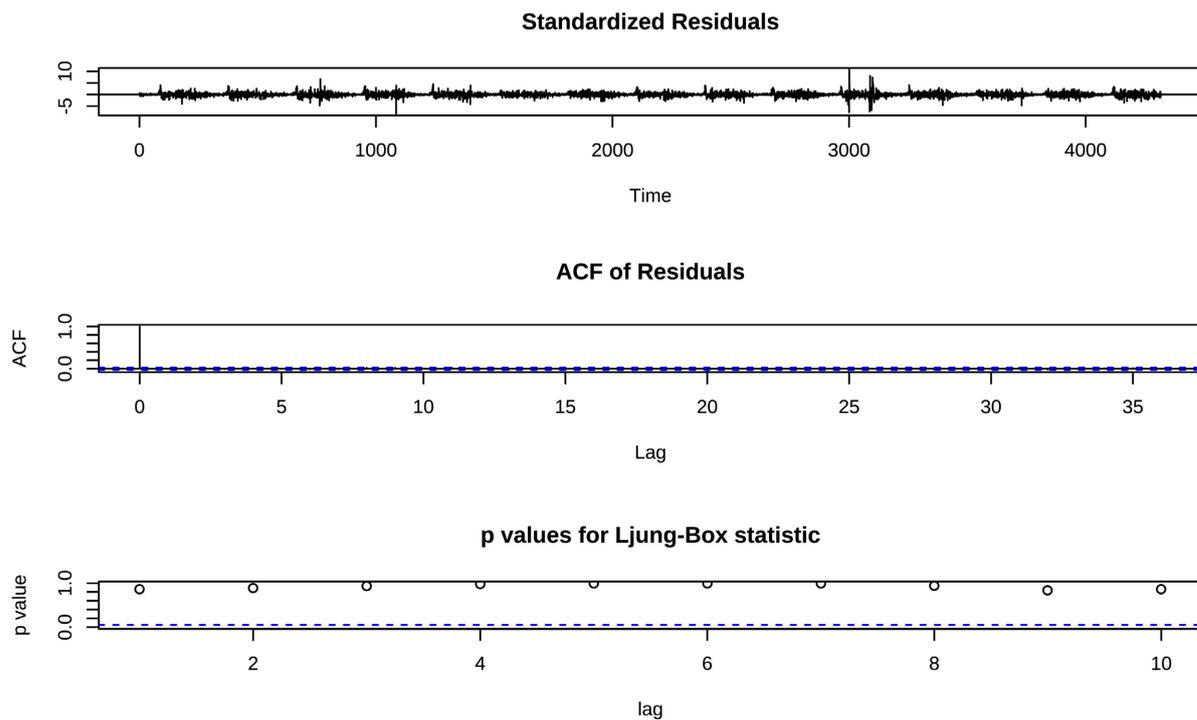
图 6. 一次差分后自相关系数图和偏自相关系数图

根据一次差分后自相关系数和偏自相关系数对模型进行识别与定阶, 从以上分析来看对该时间构建 ARIMA 模型, 并进行初步定阶为(6, 1, 6)。将定阶的附近取值同样构建模型, 并使用 AIC 准则选择一个最优 ARIMA 模型, 定阶过程如下表 1 所示。从表中的 AIC 准则可得出, ARIMA(5, 1, 6)时 AIC 值最小, 为 40914.99, 因此最终选择时间序列模型为 ARIMA(5, 1, 6)。

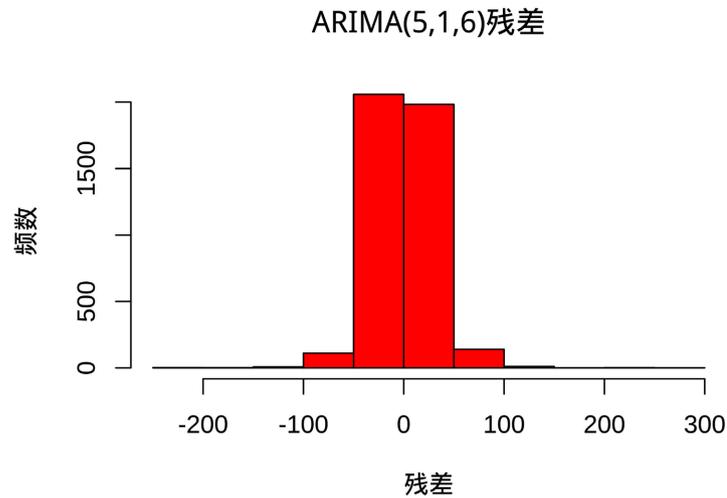
ARIMA(5, 1, 6)模型构建之后进行模型诊断和残差检验, 检验图如下图 7 所示。该差分序列的残差大致都在一个值附近波动, 并且残差的自相关系数图在开始就衰减为 0, Ljung-Box 检验的  $p$  值都在 0.05 以上, 说明模型构建合适。接着检验残差是否相关以及满足正态分布, Box.test 的  $p$  值为 0.8599, 证明残差还存在相关性。残差是否满足正态分布的直方图如下图 8 所示, 并不满足 0 均值的正态分布。QQ 图如下图 9 所示, 也证明了残差还有非线性特征未提取。将构建的 ARIMA(5, 1, 6)模型进行滞后 10 期预测, 可得到后 10 期的预测值。

**Table 1.** Sequence model construction selection criteria  
**表 1.** 序列模型构建选择准则

模型	AIC 值
ARIMA(4, 1, 1)	40942.84
ARIMA(4, 1, 2)	40941.54
ARIMA(5, 1, 2)	40937.11
ARIMA(5, 1, 1)	40935.94
ARIMA(5, 1, 3)	40929.03
ARIMA(5, 1, 4)	40930.49
ARIMA(5, 1, 5)	40930.52
ARIMA(5, 1, 6)	40914.99
ARIMA(6, 1, 6)	40916.78
ARIMA(6, 1, 5)	40916.50

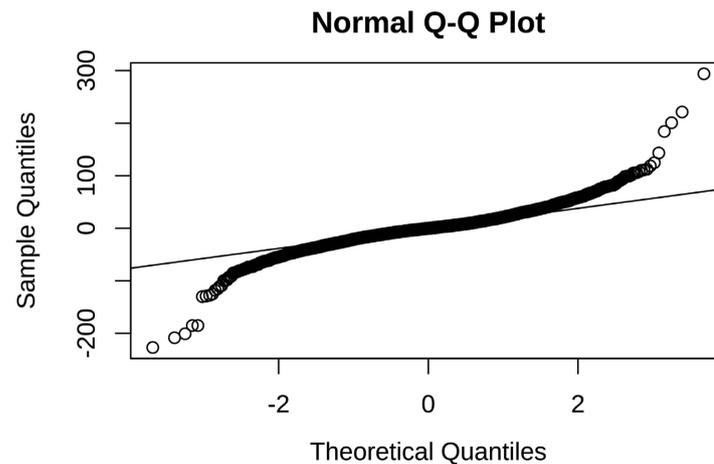


**Figure 7.** Model diagnostics and residuals test plots  
**图 7.** 模型诊断和残差检验图



**Figure 8.** Residual histogram

**图 8.** 残差直方图



**Figure 9.** Residual QQ plot

**图 9.** 残差 QQ 图

### 3.2. SVM 模型构建与预测

本文采用 SVM 对 ARIMA 模型的残差序列进行修正, 将 ARIMA 模型的训练序列的残差值作为输入, 后 10 期的序列残差值作为输出。核函数主要有线性核函数、多项式核函数、径向基核函数、多层感知机核函数、傅里叶核函数、小波核函数、混合核函数等。本文基于研究数据选择径向基核函数, 此核函数的参数较少, 并且性能不受数据样本大小的影响[15], 其表达式如下:

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (9)$$

其中,  $\sigma^2$  为核参数。从 SVM 回归函数可知, 正则化参数  $C$ 、不敏感损失函数  $L_\epsilon$ , 不敏感损失函数参数  $\epsilon$  三个参数需要确定, 此处采用 5 折交叉验证进行确定参数, 可得均方误差分别为 848.8907, 736.8186, 689.5426, 745.7129, 774.5315, 选取最小均方误差所对应的参数。

### 3.3. 结果分析

本文的道路交通流量使用 ARIMA-SVM 模型进行预测, 将序列后 10 期的预测值与 2021 年 3 月 16 日的 0 时 0 分至 0 时 45 分的真实值进行评价预测性能。此处采用平均绝对误差和平均百分比误差这 2 个指标进行评价, 其平均绝对误差 A 和平均百分比误差 P 表达式分别如下:

$$A = \frac{\sum_{i=1}^n |z_t - \hat{z}_t|}{n}$$

$$P = \frac{\sum_{i=1}^n \frac{|z_t - \hat{z}_t|}{z_t}}{n} \times 100\%$$

其中,  $z_t$  和  $\hat{z}_t$  分别表示长岭北路与东寺林路交叉口的真实值与预测值, 平均绝对误差和平均百分比误差越小, 则模型的预测精度越好。本文同时分别采用 ARIMA、SVM、ARIMA-SVM 三个模型预测交通流量, 并采用平均绝对误差 A 和平均百分比误差 P 评价模型预测性能。

预测结果如下表 2 所示, ARIMA 模型预测线性部分的值与真实值在 2021 年 3 月 16 日的 0 时 20 分、0 时 25 分、0 时 30 分相比, 预测值较大, 其他时间点预测值与真实值之间相差不大。将 ARIMA 模型预测的线性部分和 SVM 模型预测的非线性部分进行加和, 可得最终预测值。

**Table 2.** Forecast result

**表 2.** 预测结果

3 月 16 日	真实值	ARIMA	SVM (残差)	预测值
00:00	71	74.07438	-0.5524974	74
00:05	74	69.69853	-0.5533601	69
00:10	79	70.41181	-0.5542201	69
00:15	67	69.91677	-0.5550773	69
00:20	55	69.80018	-0.5559317	69
00:25	53	70.35147	-0.5567833	70
00:30	56	67.74376	-0.5576320	67
00:35	61	68.52844	-0.5584780	68
00:40	64	68.62046	-0.5593212	68
00:45	63	67.54696	-0.5601615	67

将预测结果使用评价预测性能指标即平均绝对误差 A 和平均百分比误差 P, 进行计算, 可得平均绝对误差 A 为 7.7, 平均绝对误差不大, 平均百分比误差 P 为 12.7%, 说明 ARIMA-SVM 混合模型预测效果较好。本文将 ARIMA、SVM 模型与 ARIMA-SVM 模型的预测性能作对比, 如下表 3 所示。三种模型预测性能 ARIMA-SVM 最佳, 其次是 ARIMA 模型, 最后是 SVM 模型。

**Table 3. Model evaluation**  
**表 3. 模型评价**

模型	A	P
ARIMA	8.1	13.5%
SVM	28.2	46.2%
ARIMA-SVM	7.7	12.7%

#### 4. 结束语

本文采用 ARIMA-SVM 模型对贵阳市长岭北路与东寺林路交叉口交通流量进行预测, 从预测结果来看, 此模型预测结果理想, 因此此模型作为短时预测效果较好。采用 ARIMA 模型预测序列线性部分特征, SVM 模型对 ARIMA 模型的残差进行修正并预测, 并通过贵阳市长岭北路与东寺林路交叉口交通流量数据验证了模型的有效性。通过短时交通量预测未来时间点的交通流量, 为交通管理部门提供思考与解决交通拥堵干预, 有效地减少交警盲目出警与人力成本。

#### 参考文献

- [1] 张腾飞, 袁鹏程. 基于 ARIMA 的短时交通量预测模型[J]. 智能计算机与应用, 2020, 10(7): 273-278.
- [2] 许倩倩, 许佳佳, 凤鹏飞. 基于 LM 神经网络的交叉口短时交通量预测[J]. 德州学院学报, 2019, 35(4): 40-43.
- [3] 程根伟. 1998 年长江洪水的成因与减灾对策[M]//许厚泽, 赵其国. 长江流域洪涝灾害与科技对策. 北京: 科学出版社, 1999: 32-36.
- [4] 刘学刚, 张腾飞, 韩印. 基于 ARIMA 模型的短时交通流预测研究[J]. 物流科技, 2019, 42(12): 91-94+102.  
<https://doi.org/10.13714/j.cnki.1002-3100.2019.12.024>
- [5] 徐翠翠. 基于 ARIMA 的城市交叉路口交通流预测建模[J]. 电子设计工程, 2022, 30(2): 20-23.  
<https://doi.org/10.14022/j.issn1674-6236.2022.02.005>
- [6] 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]: [硕士学位论文]. 北京: 北京交通大学, 2020.
- [7] 耿立艳, 张占福, 李达. 基于 ARIMA-SVM 的城际高铁客流量短期预测[J]. 交通与运输, 2020, 36(6): 42-45.
- [8] 罗川. 基于最小二乘支持向量机的短时交通流预测方法研究[D]: [硕士学位论文]. 太原: 太原理工大学, 2019.
- [9] 余涛. 基于 SVM 和 BP 神经网络的短时交通流预测与实现[D]: [硕士学位论文]. 南京: 南京邮电大学, 2018.
- [10] 何祖杰, 吴新辉, 刘中华. 基于改进灰狼算法优化支持向量机的短期交通流预测[J]. 厦门大学学报(自然科学版), 2022, 61(2): 288-297.
- [11] 曾宪堂, 孙昊. 高速公路短时交通流预测方法对比分析[J]. 公路, 2022, 67(2): 366-370.
- [12] 刘胜. 基于 ARIMA 与 SVM 组合模型的国内旅游市场预测研究[D]: [硕士学位论文]. 抚州: 东华理工大学, 2017.
- [13] 严宙宁, 牟敬锋, 赵星, 严燕, 罗文亮, 胡满达. 基于 ARIMA 模型的深圳市大气 PM<sub>2.5</sub> 浓度时间序列预测分析[J]. 现代预防医学, 2018, 45(2): 220-223+242.
- [14] 王俊龙. 基于支持向量机建模的非线性预测控制研究[D]: [硕士学位论文]. 北京: 北京交通大学, 2014.
- [15] 黄光群, 韩鲁佳. 基于非线性径向基核函数支持向量机的堆肥产品近红外光谱分析研究[J]. 光学学报, 2009, 29(12): 3556-3560.