

基于时间序列模型的停车场泊位特性预测研究

张 雷

(重庆交通大学数学与统计学院, 重庆 400074)

[摘要] 基于某行政服务中心的停车场进出车辆数据, 讨论了传统停车需求预测方法特征, 分析其适用范围, 判断预测实时停车需求的可行性. 在此基础上, 引入经济学中常用的时间序列模型, 明确构建模型的关键步骤和检验方法, 在 Eviews 9.0 工作平台上进行模型检验与预测. 并举例对模型进行了仿真实验, 验证了模型的有效性, 取得了理想的效果.

[关键词] 时间序列, 车辆特性预测, 泊位利用率

[中图分类号] U121 [文献标志码] A [文章编号] 1001-4616(2017)02-0024-07

Research on Parking Berth Characteristics Prediction Based on Time Series Model

Zhang Lei

(College of Mathematics and Statistics, Chongqing Jiaotong University, Chongqing 400074, China)

Abstract: In this paper, based on the data of vehicle parking in and out of an administrative service center, the characteristics of traditional parking demand forecasting methods are discussed. On this basis, the paper introduces the time series model which is used in economics, and makes clear the key steps and methods of building the model. The model is tested and predicted on the Eviews 9.0 platform. Finally, the simulation experiments are carried out to verify the validity of the model.

Key words: time series, vehicle performance prediction, berth utilization

“停车难”是世界各大城市中心区面临的普遍问题, 为了缓解城市中心区的机动车泊位供需矛盾, 进行实时有效的停车泊位特性预测, 进而优化停车路径诱导, 是智能化停车管理的手段之一. 通过对有效停车泊位进行预测, 可以使更多的车辆在到达之前就能够掌握到就近停车场的泊位使用信息以及发展趋势, 从而使得需求车辆能够在就近的停车场进行合理分配^[1]. 可靠而准确有效的停车泊位预测是进行有效共享停车的重要前提. 近年来, 使用数学规划模型分析停车需求与停车管理对策^[2], 利用“停车生成率模型”进行停车需求预测, 提出基于区域性的预测问题模型等^[3], 国内外的研究主要集中在系统规划上, 对如何利用公共区域停车资源方面缺乏研究^[4].

对于此类不规则预测的统计方法, 是对时间轴上的随机表里建立统计模型而进行的, 基于不规则数据的预测方法种类繁多, 从马尔科夫预测、差微分方程预测、灰色预测法到目前的时间序列预测模型. 灰色预测模型及马尔代夫模型都不适宜于系统的中长期预测, 且对于数据系统的稳定性提出了很高的要求; 差微分方程预测模型由于方程的建立是以局部规律的独立性假定为基础, 当进行长期预测时, 误差较大. 而时间序列预测法就是通过编制和分析时间序列, 根据时间序列所反映出来的发展过程、方向和趋势, 进行类推或延伸, 借以预测下一段时间或以后若干年内可能达到的水平.

本文基于某行政服务中心区的停车场为研究对象, 通过对其周边停车场整体特征及泊位使用特征的调查, 分析城市中心区配建停车场的特性, 引入时间序列模型, 有针对性地建立了有效的停车需求预测模型, 并在 Eviews 9.0 工作平台上进行模型检验与预测, 取得了较好的效果.

收稿日期: 2017-03-15.

基金项目: 国家自然科学基金(11501065、11401061)、重庆市基础与前沿研究计划基金(cstc2015jcyjA00033)、重庆市教委项目(KJ1600504、KJ1600512).

通讯联系人: 张雷, 讲师, 研究方向: 优化算法、控制理论研究. E-mail: zhangleicqjtu@163.com

1 传统泊位需求预测方法

传统的停车泊位需求预测模型主要有:需求量生成率模型、相关分析模型、交通量停车需求模型、静态交通发生率模型。需求量生成率模型是以停车场作为停车吸引源,根据单位面积的停车需求比例计算停车需求;相关分析模型针对大型的停车区域,根据停车场与停车需求量之间建立函数关系,以此进行预测^[5];交通量停车需求模型按通过停车场流量的一定比例预测停车需求,主要是进行宏观的需求预测;静态交通发生率模型是在大量的调查结果中构建算法模型,进行抽样分析,再进行停车需求预测。传统的停车需求预测模型宏观性强、计算复杂度高、数据获取难度大,不能进行实时的、微观的车辆需求变化预测^[6]。

本文为了根据泊位实时状态做出最优的共享停车决策,必须能够对下一个,或几个时段将要发生的停车需求做出预判,以提前制定下一个时段的共享策略,做出是否开放,以及确定可提供的共享泊位数等策略。

2 时间序列实时需求预测模型

2.1 时间序列的预处理

第一步:平稳性检验。作为时间序列分析中的重要内容和关键步骤,运用给定的时间序列模型对平稳的序列进行分析预测,记为平稳性检验^[7]。现有的检验方法主要有两种,借助图形的特征判断序列的平稳性特征;或是通过建立检验统计量来进行序列的假设检验。常用的方法是借助图形特征并辅助以单位根统计的检验办法来进行平稳性检验。

第二步:纯随机性检验。纯随机性检验是用于验证序列是否为纯随机性序列。如果序列相互间并无任何联系,那么它就是纯随机序列,但是因为序列的人为判断误差而致使它的样本自相关系数不绝对为零时,可以选择自相关系数在零值周围时,将其定义为纯随机序列。

第三步:单位根检验。首先,计算出序列的特征根后,通过特征根是否分布在单位圆内来验证序列的稳定性。但是该方法只适用于1阶的平稳性检验。

为了使 p 阶的过程能够更加适用于本检验方法,需要对单位根检验方法进行修正,得到增广检验(Augmented Dickey-Fuller),简记为ADF检验。保证上述通过修正的 p 阶序列存在单位根,且自回归系数之和恰好等于1。ADF检验主要分为以下3种类型:

- ①无常均值的 p 阶无趋势自回归过程: $x_t = \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + \varepsilon_t$.
- ②有常均值的 p 阶无趋势自回归过程: $x_t = \mu + \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + \varepsilon_t$.
- ③有常均值的 p 阶有趋势自回归过程: $x_t = \mu + \beta t + \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + \varepsilon_t$.

第四步:BIC准则(Bayesian Information Criterion)定阶。

设 $\{x_t, 1 \leq t \leq N\}$ 为随机序列,对ARMA(p, q)模型,假设 σ^2 是拟合残差方差,如果已知 p 的上界 P_0 和 q 的上界 Q_0 ,对每一组 $(k, j) 0 \leq k \leq P_0, 0 \leq j \leq Q_0$,定义BIC准则函数如下:

$$\text{BIC}(k, j) = \ln(\sigma^2(k, j)) + \frac{(k+j) \ln N}{N},$$

$\text{BIC}(k, j)$ 的最小值点称为 (p, q) 的BIC定阶。

2.2 基本方法和模型

2.2.1 ARMA(Auto Regressive and Moving Average)模型

ARMA模型又称自回归移动平均模型,在不同条件下,可细分为AR模型、MA模型和ARMA模型3大类,是目前最常用的拟合平稳序列的模型。

AR模型:具有如下结构的模型称为 p 阶自回归模型,记为AR(p)。

$$\begin{cases} x_t = \phi_0 + \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + \varepsilon_t, & \phi_p \neq 0, \\ E(\varepsilon_t) = 0, \text{Var}(\varepsilon_t) = \sigma_\varepsilon^2, E(\varepsilon_t \varepsilon_s) = 0, & s \neq t, \\ E x_s \varepsilon_t = 0, & \forall s < t. \end{cases}$$

特别当 $\phi_0 = 0$ 时,称为中心化AR(p)模型。而非中心化AR(p)模型可以通过下列转换为中心化AR(p)模型:

$$\mu = \frac{\phi_0}{1 - \phi_1 - \dots - \phi_p} y_t = x_t - \mu.$$

称 $\{y_t\}$ 为 $\{x_t\}$ 的中心化序列. 引进延迟算子, 中心化 AR(p) 模型又可简记为: $\varnothing(B)x_t = \varepsilon_t$, 其中, $\varnothing(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ 称为 p 阶自回归系数多项式.

MA 模型: 具有如下结果的模型称为 q 阶移动平均模型, 简称为 MA(q):

$$\begin{cases} x_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}, \theta_q \neq 0, \\ E(\varepsilon_t) = 0, \text{Var}(\varepsilon_t) = \sigma_\varepsilon^2, E(\varepsilon_t \varepsilon_s) = 0, s \neq t. \end{cases}$$

当 $\mu = 0$ 时, 简称为中心化 MA(q) 模型. 对非中心化 MA(q) 模型只要做一个简单的位移 $y_t = x_t - \mu$, 就可以转化为中心化 MA(q) 模型. 引进延迟算子, 中心化 MA(q) 模型又可以简记为: $x_t = \Theta(B)\varepsilon_t$, 式中, $\Theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ 称为 q 阶移动平均系数多项式.

ARMA 模型: 具有如下结构的模型称为自回归平均模型^[8], 简记为 ARMA(p, q):

$$\begin{cases} x_t = \phi_0 + \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}, \\ \phi_p \neq 0, \theta_q \neq 0, \\ E(\varepsilon_t) = 0, \text{Var}(\varepsilon_t) = \sigma_\varepsilon^2, E(\varepsilon_t \varepsilon_s) = 0, s \neq t, \\ Ex_s \varepsilon_t = 0, \forall s < t, \\ \varnothing(B)x_t = \Theta(B)\varepsilon_t. \end{cases}$$

特别当 $\phi_0 = 0$ 时, 称为中心化 ARMA(p, q) 模型. 引进延迟算子, 中心化 ARMA(p, q) 模型又可简记为: $\varnothing(B)x_t = \Theta(B)\varepsilon_t$, 式中, $\varnothing(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$, 称为 p 阶自回归系数多项式. $\Theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$, 称为 q 阶移动平均系数多项式.

2.2.2 ARIMA(Autoregressive Integrated Moving Average) 模型

具有如下结构的模型称为求和自回归移动平均模型^[8], 记为 ARIMA(p, d, q):

$$\begin{cases} \varnothing(B) \nabla^d x_t = \Theta(B)\varepsilon_t, \\ E(\varepsilon_t) = 0, \text{Var}(\varepsilon_t) = \sigma_\varepsilon^2, E(\varepsilon_t \varepsilon_s) = 0, s \neq t, \\ Ex_s \varepsilon_t = 0, \forall s < t. \end{cases}$$

根据 ARMA(p, q) 模型与 ARIMA(p, d, q) 模型的关系可得:

$$\text{ARIMA}(p, d, q) = \begin{cases} \text{ARMA}(p, q), d = 0, \\ \text{ARMA}(d, q), p = 0, \\ \text{ARMA}(p, d), q = 0, \\ \text{random}, d = 1, p = q = 0. \end{cases}$$

2.2.3 ARIMA 模型的建模步骤

时间序列的平稳性检验作为预测模型的重要组成部分, 且上述模型的理论基础都是建立在成熟的平稳性假设基础上的. 实际上, 任意给定的时间序列都可以通过一定阶数的差分形式使得该序列能够通过平稳性检验, 为后续的 ARMA(p, q) 数据处理奠定基础, ARIMA(p, d, q) 建模的过程可分为 3 个步骤.

步骤一: 数据平稳性检验. 利用给定时间序列的数据散点图作一个初步的平稳性预测判断, 然后利用 ADF 单位根检验来进一步判断时间序列的性质. 如果遇到存在一些可见的增长或下降趋势的序列, 就需要对序列的数据进行取对数或者差分处理, 再次进行判断. 反复上述过程, 直到任意序列都过渡为平稳序列. 此时差分的次数即为 ARIMA(p, d, q) 模型中的阶数 d .

步骤二: 对差分后平稳序列进行 ARMA 拟合. 步骤一得到了差分处理或者对数处理后的 ARMA 模型, 然后依据步骤一结果在 Eviews 9.0 上计算序列的自相关系数(Auto Correlation Function, 简记为 ACF)和偏自相关系数(Partial Auto Correlation Function, 简记为 PACF), 并依照 ACF 和 PACF 的值由上述所提的判断依据估算自相关系数 p 和移动平均阶数 q 值.

步骤三: 模型检验. 模型检验是为了验证预测序列与原始序列的偏差程度, 检验整个 ARMA 模型对于原始数据的规律性的提取程度, 也即是检验 ARMA 模型的残差序列是否满足为白噪声序列. 若残差序

列不是白噪声序列,就要重新定义 ARMA 模型的差分阶数并再次进行数据拟合,如果残差序列是白噪声序列,那么模型检验通过,预测模型比较理想地满足原始序列的规律.

3 时间序列模型实例

以某行政服务中心区停车场为例说明城市中心区域配建停车设施共享停车预测中时间序列实时需求预测模型的建模过程. 首先对行政服务中心的一天进行了进出车辆调查,以 2016 年 12 月 13 日 7:00 至 22:00 为例,地点为行政服务中心停车场的 1 号、2 号出入口,每隔 15 min 对进入和离去的车辆进行统计,获取 15 h 共 60 个时段的进出车辆情况,其特征曲线如图 1.

由图 1 可知,行政中心区调查当天驶入高峰在 7:30~8:30,驶离高峰在 16:30~17:30 之间,其余时段驶离及驶入变化不大,总而言之数据序列符合中心区停车特征. 本文结合软件进行时间序列模型的构建和预测,以调查时段的前 52 个观测量(即 7:00~20:00)为样本量训练模型,后 8 个观测量(即 20:00~22:00)检验模型精度.




图 1 进出车辆特征曲线
Fig. 1 Vehicle characteristic curve

3.1 数据平稳性检验

3.1.1 数据的 ADF 检验

对进出车辆数据进行 ADF 检验,结果如表 1,由各序列的 ADF 检验结果可知,驶入车辆序列单位根统计量为-2.491 419,大于 1%、5%、10%显著水平的 ADF 临界值, P 值大于 0.05,因此接收原假设,需要对原序列做差分处理. 同理,驶出车辆序列单位根统计量应做差分处理.

一阶差分后对数据再次进行 ADF 检验,检验结果如表 2,各数据的 ADF 检验单位根统计量-4.931 198,小于 1%、5%、10%显著水平的 ADF 临界值,且 P 值小于 5%,因此拒绝原假设,经过一阶差分后数据成为了平稳序列.

表 1 驶入车辆数 ADF 检验

Table 1 Number of vehicles entering ADF inspection		
	t -Statistic	Prob. *
Augmented Dickey-Fuller test statistic	-2.491 419	0.122 6
Test critical values: 1% level		-3.544 063
5% level		-2.910 860
10% level		-2.593 090

表 2 一阶差分后驶入车辆数 ADF 检验

Table 2 First order differential rear entry vehicle number ADF test		
	t -Statistic	Prob. *
Augmented Dickey-Fuller test statistic	-4.931 198	0.000 2
Test critical values: 1% level		-3.596 616
5% level		-2.933 158
10% level		-2.604 867

3.1.2 模型的定阶与白噪声检验

经过自相关和偏自相关函数检验,由图 2 看出,驶入车辆 Q 统计量的 p 值在 5% 范围内,可知原假设不成立,该序列为非白噪声序列^[9];该序列的自相关系数一直处于零的区域范围内,为平稳序列,由 ARMA 模型的特征描述可以看出,驶入车辆的自相关系数为渐变式,而偏自相关系数可看作在第二个阶数区段时进入有效范围内,序列的自相关系数在维系 2 阶后全部衰减到了规定的范围内上下波动,该自相关系数可以当做不连续截断,而偏自相关图初始的系数会大于规定的 2 倍标准差之外,初始范围之外的其他系数都在小幅度的上下随机波动,且从 2 倍标准差突变到 0 值周围只有 1 阶的过渡期,所以其偏自相关系数可以作为 1 阶截尾处理. 可以考虑拟合模型 AR(1), AR(2), ARMA(1,1), ARMA(1,2), ARMA(2,1), ARMA(2,2).

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.748	0.748	26.337	0.000
		2 0.384	-0.399	33.441	0.000
		3 0.107	0.011	34.011	0.000
		4 -0.044	-0.020	34.107	0.000
		5 -0.061	0.089	34.299	0.000
		6 -0.030	-0.039	34.345	0.000
		7 -0.021	-0.052	34.369	0.000
		8 -0.007	0.062	34.371	0.000
		9 0.008	-0.001	34.375	0.000
		10 0.008	-0.022	34.379	0.000
		11 0.043	0.105	34.490	0.000
		12 0.048	-0.084	34.636	0.001
		13 0.003	-0.054	34.637	0.001
		14 -0.008	0.102	34.641	0.002
		15 -0.008	-0.039	34.646	0.003
		16 -0.026	-0.054	34.695	0.004
		17 -0.039	-0.010	34.807	0.007
		18 -0.034	0.050	34.899	0.010
		19 -0.018	-0.001	34.926	0.014
		20 -0.017	-0.080	34.950	0.020

图 2 驶入车辆自相关与偏相关函数检验
Fig. 2 Autocorrelation and partial correlation function test of vehicle

上述只是初步确定了模型,还需通过以下判断进一步确定具体模型.

残差方差图:分别估计上述模型,并将每个模型估计结果的残差方差记录下来,然后在 Matlab 平台上运行数据处理得到下列残差方差图,如图 3 所示. 模型选取应遵循“残差方差最小”原则来加以确定,由残差方差图可以确定为 ARMA(1,2)模型.

信息准则函数:根据 AIC 和 SC 信息最小原则,对驶入车辆分别估计 ARMA(1,1)、ARMA(1,2)、ARMA(2,1)、ARMA(2,2)模型,并将每个模型估计结果中的 AIC 和 SC 信息准则值记录下来,然后复制到统计软件 Excel 中作为一列,并在 Matlab 中能够以模型阶数为横轴,以模型残差方差为纵轴绘制散点图,即可得到下列 AIC 和 SC 信息准则图,如图 4 所示.




图 3 残差方差图
Fig. 3 Residual variance plot




图 4 AIC 与 SC 信息准则确定图
Fig. 4 AIC and SC information criterion

由图 4 可知,AIC 给出的阶数是 2 阶,IC 准则给出的模型阶数为 2 阶. 因此,ARMA(1,2)模型的残差方差最小,其次是 ARMA(1,1)和 AR(2)模型的残差方差;而模型 AR(2)的 AIC 和 BIC 信息准则都小于 ARMA(1,1)和 ARMA(1,2)模型的 AIC 和 BIC 信息准则,且在估计的模型中,AR(2)模型的 AIC 和 BIC 信息准则最小,而且由各个模型系数的 t 检验统计量的 p 值可知,AR(2)模型中所有模型的系数都显著不为零. 所以,最佳模型是 AR(2)模型.

3.1.3 模型的参数估计

通过最小二乘法,对驶入车辆各序列前 52 个数据进行参数估计,运行 Eviews 9.0 软件对数据进行参数估计,由 Eviews 9.0 的求解结果知,驶入车辆序列的常数项为 15.401 35,AR(1)系数为-0.383 808,AR(2)系数为 0.344 568,且 p 值显著,模型合理.

3.1.4 模型显著性检验与优化

预测得到的各序列在经过白噪声检验之后,得出序列 ACF 和 PACF 基本没有显著异于零,且 Q 统计量的 p 值都远远大于 0.05,可以确定序列为白噪声序列,且相关信息提取充分. 由于常数、滞后一阶和二阶参数的 p 值都很小,可见模型的参数显著,过程精简,效果较好.

通过残差序列检验证明了时间序列的估计结果可接受. 因此,将表 3 中不同模型的各参数数值带入公式,即可建立行政服务中心区停车场驶入车辆的时间序列模型如下:

$$IN_{it} = 15.401\ 35 - 0.383\ 808 IN_{it-1} + 0.344\ 568 IN_{it-2} + \varepsilon_t.$$

表 3 驶入参数估计表

Table 3 Parameter estimation table

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	15.401 35	11.524 59	1.336 390	0.189 4
AR(1)	-0.383 808	0.172 750	-2.221 760	0.032 3
AR(2)	0.344 568	0.269 066	1.280 607	0.208 1
SIGMASQ	104.375 6	372.630 1	0.280 105	0.780 9

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.054	0.054	0.1389		
2	0.053	0.050	0.2731		
3	-0.107	-0.113	0.8409	0.359	
4	-0.086	-0.078	1.2184	0.544	
5	-0.057	-0.037	1.3869	0.709	
6	0.058	0.061	1.5637	0.815	
7	-0.024	-0.043	1.5954	0.902	
8	-0.017	-0.039	1.6124	0.952	
9	0.053	0.067	1.7768	0.971	
10	-0.070	-0.074	2.0671	0.979	
11	0.050	0.046	2.2181	0.988	
12	0.102	0.110	2.8708	0.984	
13	-0.087	-0.114	3.3632	0.985	
14	0.002	0.008	3.3635	0.992	
15	0.025	0.056	3.4067	0.996	
16	-0.003	0.002	3.4072	0.998	
17	-0.026	-0.047	3.4591	0.999	
18	-0.013	-0.027	3.4726	1.000	
19	0.002	0.051	3.4731	1.000	
20	0.028	0.009	3.5381	1.000	

图 5 驶入车辆显著性检验

Fig. 5 Significance test of vehicle

3.2 模型的验证

据估计结果显示,本时段的到达车辆数与其前两

个时段的到达车辆数有关,以及与前两个时间段的预测误差有关,由两个序列残差检验,证明了所构建的时间序列模型对序列信息提取均比较充分,模型也比较精简. 通过时间序列实时需求模型的求解,找到了停车场驶入车辆的实时需求方程,通过 Eviews 9.0 将其与原数据进行对比验证. 通过误差分析图可看出,预测效果与实际值除个别数据点突出外,总体的预测效果十分明显,行政中心停车场驶入车辆预测的 R^2 值为 0.89(预测值与实际值的拟合程度),达到了预期的目的.

3.3 模型的预测

在预测时,样本内预测选用静态预测,样本外预测选用动态预测.

(1) 进行样本内静态预测,在方程估计窗口点击 forecast 并选择“Static forecast”预测方法得到序列预测图,如图 7 所示.




图 7 序列预测图

Fig. 7 Sequence prediction graph

Forecast: NEI
Actual: IN2
Forecast sample: 1 52
Adjusted sample: 3 52
Included observations: 50
root Mean Squared Error 11.492 110
Mean Absolute Error 6.010 219
Mean Abs. Percent Error 38.890 520
Theil Inequality Coefficient 0.261 752
Bias Proportion 0.001 947
Variance Proportion 0.092 700
Covariance Proportion 0.905 353

(2) 进行样本外动态预测,在方程估计窗口点击 forecast 并选择“Dynamic forecast”预测方法得到序列预测图,如图 8 所示.

(3) 将得到的预测值按照新的序列保存,再次进行预测,绘图得到驶入车辆实际值与预测值的拟合效果图,如图 9 所示.




图 8 序列预测图

Fig. 8 Sequence prediction graph




图 9 停车场驶入车辆预测

Fig. 9 Parking lot vehicle forecast

通过时间序列模型的仿真实例,在系统误差范围内充分利用了不规则数据所包含的有用信息. 通过实例中的建模过程和模型预测效果分析发现:①时间序列模型能由历史观测值预测得到未来可能值,并且预测效果良好;②由于停车场短时需求波动性较大,不同模型拟合参数也不尽相同,实际运用中可对比选择使用预测效果较好的时间序列模型. 时间序列模型在停车场实时停车需求预测中具备可行性和一定的优越性.

4 结语

时间序列预测方法对于短期和中长期预测具有很强的可行性,时间序列模型能够很好地契合到停车场的泊位数量研究上. 由于该模型的广泛适用性以及对于数据的不依赖性,使得时间序列分析除了能够应用于常见的数量分析及本文涉及的停车场车位预测分析外,也可以应用于国民经济宏观控制、区域综合

发展规划、企业经营管理、市场潜量预测、气象预报、水文预报、地震前兆预报、农作物病虫害灾害预报、环境污染控制、生态平衡、天文学和海洋学等方面。

[参考文献]

- [1] 屈昌辉. 当前我国城市住宅小区车辆停放存在的问题及管理对策[J]. 城市发展研究, 2015(3): 23-26.
- [2] 冯淑媛, 李阳生. 智能停车管理系统建设方案和发展对策[J]. 中国建设信息化, 2016(10): 54-57.
- [3] 孙吉瑞. 城市混合用地停车需求预测模型研究与实践[J]. 交通与运输(学术版), 2016(1): 62-66.
- [4] 单博文. 基于道路服务水平的停车需求预测[J]. 武汉理工大学学报, 2012, 36(3): 541-544.
- [5] 温旭丽, 孙垚飞, 罗婷. 基于交通特征的停车需求预测模型构建研究[J]. 公路交通科技, 2014(4): 297-299.
- [6] 周岩, 董瑞娟, 杨伟. 现代化居住社区停车特性与需求分析[J]. 交通科技与经济, 2014(2): 4-8, 12.
- [7] 王娜. 时间序列建模、预报的原理[J]. 吉林工程技术师范学院学报, 2012, 28(3): 78-80.
- [8] 林慧君, 徐荣聪. 组合 ARMA 与 SVR 模型的时间序列预测[J]. 计算机与现代化, 2009(8): 19-22.
- [9] 吕树龙. ARIMA 模型在降水量预测中的应用[J]. 水科学与工程技术, 2012(2): 6-8.

[责任编辑: 陆炳新]

(上接第11页)

- [11] SONG Q, CAO J, YU W. Second-order leader-following consensus of nonlinear multi-agent systems via pinning control[J]. Systems and control letters, 2010, 59(9): 553-562.
- [12] YU W, ZHENG W X, CHEN G, et al. Second-order consensus in multi-agent dynamical systems with sampled position data[J]. Automatica, 2011, 47(7): 1 496-1 503.
- [13] LI T, ZHANG J F. Consensus conditions of multi-agent systems with time-varying topologies and stochastic communication noises[J]. IEEE transactions on automatic control, 2010, 55(9): 2 043-2 057.
- [14] LIU S, XIE L, ZHANG H. Distributed consensus for multi-agent systems with delays and noises in transmission channels[J]. Automatica, 2011, 47(5): 920-934.
- [15] MA C, LI T, ZHANG J. Consensus control for leader-following multi-agent systems with measurement noises[J]. Journal of systems science and complexity, 2010, 23(1): 35-49.
- [16] HU A, CAO J, HU M, et al. Event-triggered consensus of multi-agent systems with noises[J]. Journal of the franklin institute, 2015, 352(9): 3 489-3 503.
- [17] YE Z, ZHANG H, ZHANG H, et al. Mean square stabilization and mean square exponential stabilization of stochastic BAM neural networks with Markovian jumping parameters[J]. Chaos, solitons and fractals, 2015, 73: 156-165.
- [18] ZHAO H, DING N. Dynamic analysis of stochastic bidirectional associative memory neural networks with delays[J]. Chaos, solitons and fractals, 2007, 32(5): 1 692-1 702.

[责任编辑: 陆炳新]