

文章编号: 2095-2163(2021)06-0195-06

中图分类号: TP183

文献标志码: A

基于 GRA-LSTM 与 SARIMA 组合模型的季节性时间序列预测

罗广诚, 郜家珏, 蔡文学

(华南理工大学 电子商务系, 广州 510000)

摘要: 针对 LSTM 模型对季节性时间序列中的周期、趋势性变化不敏感的特点, 提出将 SARIMA 模型与 LSTM 模型进行组合, 以提高模型预测精度。该方法首先构建了以关键影响因素为非线性输入层和历史数据为线性输入层的多对一 LSTM 模型, 将经过 GRA 法筛选的关键影响因素及历史数据输入到该模型中得到初步预测结果, 使用 SARIMA 模型依据历史数据对季节性时间序列进行预测, 提取预测结果中单位节点的比例序列, 以实现和时间序列中周期、趋势信息的抽取, 最后根据 SARIMA 模型中提取的单位节点比例, 对 LSTM 得到的初步预测结果进行修正, 得到最终预测结果。实验选取某市民航春运客流量数据对组合模型精度进行验证, 通过与支持向量机、GRA 法、GRA-LSTM 模型、SARIMA 模型 4 种单模型进行比较, 验证了组合模型对于季节性时间序列预测的优越性。

关键词: LSTM 模型; SARIMA 模型; 组合模型; 季节性时间序列预测

Seasonal time series prediction

based on combination model of GRA-LSTM and SARIMA

LUO Guangcheng, GAO Jiajue, CAI Wenxue

(Department of Electronic Commerce, South China University of Technology, Guangzhou 510000, China)

[Abstract] In view of the insensitivity of LSTM model to periodic and trend changes in seasonal time series, this paper proposes to combine SARIMA model with LSTM model to improve the prediction accuracy of the model. The method firstly constructs a many-to-one LSTM model with key influencing factors as nonlinear input layer and historical data as linear input layer, and inputs the key influencing factors and historical data screened by GRA method into the model to obtain preliminary prediction results. then, the SARIMA model is used to predict seasonal time series according to historical data, and the proportion sequence of unit nodes in the prediction results is extracted to realize the extraction of cycle and trend information in time series. finally, the preliminary prediction results obtained by LSTM are corrected according to the proportion of unit nodes extracted in SARIMA model to obtain the final prediction. The accuracy of the combined model is verified by selecting the passenger flow data of a city's civil aviation Spring Festival travel rush. Compared with four single models, such as support vector machine, GRA method, GRA-LSTM model and SARIMA model, the superiority of the combined model for seasonal time series prediction is verified.

[Key words] LSTM model; SARIMA model; Combination model; Seasonal time series forecasting

0 引言

时间序列预测是通过历史观测数据建立模型以解释数据变化规律, 并对未来进行预测的技术, 广泛应用于水文气象、信号处理以及金融经济等诸多领域。时间序列数据分为平稳性时间序列和非平稳性时间序列。对于平稳时间序列, 尤其是线性模型的建模和预测, 已有许多成熟的技术和方法。但在实际问题中, 大多数序列并非平稳、线性的, 而目前对于这类时间序列的分析和处理上没有较为完善的方法。

随着人工智能技术的发展, 神经网络、支持向量机等模型以其良好的非线性预测和实用性, 被广泛应用于时间序列预测中。其中长短期记忆网络(Long

Short-term Memory, LSTM) 是应用最广泛的预测方法之一, 主要应用方面有交通流预测、故障时间预测、语义关系分类、文本分类、情感分类、股票预测等方面^[1-5]。LSTM 模型是一种时间递归神经网络, 对于时间序列的数据而言预测精度高, 并且 LSTM 模型拥有大量的非线性传输层, 不仅可以依据历史数据对未来变化趋势进行预测, 还可以通过输入影响因素等非线性数据敏锐捕捉非线性因素影响下的未来变化; 基于灰色关联度分析(Grey Relation Analysis, GRA)进行 LSTM 模型中非线性输入因素的选择是常用的方式^[6]。但其也存在对季节性时间序列中的周期、趋势性变化不敏感的特点^[7]。而季节性差分自回归移动平均模型(Seasonal Autoregressive Integrated Moving

作者简介: 罗广诚(1997-), 男, 硕士研究生, 主要研究方向: 交通信息、大数据分析; 郜家珏(1998-), 女, 硕士研究生, 主要研究方向: 交通信息、大数据分析; 蔡文学(1968-), 男, 博士, 教授, 主要研究方向: 交通信息、智能物流。

收稿日期: 2021-04-30

Average, SARIMA) 对于包含周期、趋势性变化的季节性时间序列预测具有良好的效果, 目前被广泛应用于城市交通流预测、价格预测、疾病预测、CPI 和 GDP 指数预测等方面^[8-10]。然而 SARIMA 模型仅适用于短期线性时间序列的预测并且预测精度较低^[11]。

综上所述, 若采用组合思想则能够充分利用二者的优势, 实现对序列更为准确的预测。针对 SARIMA 模型和 LSTM 模型的组合, 文献[12]中提出将两种模型进行串联组合, 将 SARIMA 模型预测后的结果作为输入层数据, 重新输入到 LSTM 模型中, 得到最终结果。而本文针对两种模型预测上的优劣势, 提出采用并联方式将两种模型进行组合, 即将数据分别输入 SARIMA 模型与 LSTM 模型, 然后再对两种预测结果进行合理并联, 以实现将 SARIMA 对周期、趋势性变化敏感的优点及 LSTM 预测精度高且可以用来非线性数据进行预测的优点相组合, 提高季节性时间序列预测精度。其中 GRA-LSTM 模型的输入数据需要基于 GRA 法选取关键影响因素作为非线性数据输入。本文以某民航公司春运数据为例, 对组合模型进行了验证。结果表明, 组合模型的预测精度高于支持向量机、灰色预测、GRA-LSTM 单模型以及 SARIMA 单模型。

1 GRA-LSTM 模型

GRA-LSTM 模型是由 GRA 和 LSTM 模型组合而成, 基本原理是先根据 GRA 法结果, 选择相关性高的因素作为关键影响因素, 然后将其作为非线性输入量输入到 LSTM 模型中进行预测。

1.1 GRA 法

GRA 法是一种基于各影响因素数据分析, 用灰色关联度来描述因素间关系的多因素统计分析方法。GRA 法原理简单, 不需要大量数据作为基础, 计算量小、运行速度快, 适用于分析各种影响因素与客流量之间存在的相关关系。因此, 采用 GRA 法求得各影响因素与民航客流量之间序列变化趋势的相似或相异程度, 从而删选出影响民航客流量的关键影响因素, 并作为 LSTM 模型的输入进行预测。

灰色关联度分析法具体步骤如下:

(1) 确定反映系统行为特征的参考序列 X_0 ; 影响系统行为的比较序列 X_1, X_2, \dots, X_n ; 其中 $X_i = \{X_i(k) \mid k = 1, 2, \dots, m\}$ 。

(2) 对参考序列和比较序列进行无量纲化处理:

$$x_i(k) = \frac{X_i(k)}{X_i(l)} \quad (i = 0, 1, \dots, n) \quad (k = 1, 2, \dots, m).$$

(3) 计算 $x_0(k)$ 和 $x_i(k)$ 的关联系数:

$$\xi_j(k) = \frac{\min_i \min_k |y(k) - x_i(k)| + \rho \max_i \max_k |y(k) - x_i(k)|}{|y(k) - x_i(k)| + \rho \max_i \max_k |y(k) - x_i(k)|}$$

其中, ρ 为分辨系数, 取值区间为 $(0, 1)$, 具体取值视情况而定, ρ 值越小, 分辨力越大。当 $\rho \leq 0.5463$ 时, 分辨力最好, 通常取 $\rho = 0.5$ 。

(4) 计算 X_0 序列和 X_i 序列的关联度 r_i :

$$r_i = \frac{1}{n} \sum_{k=1}^n \xi_i(k), \quad (i = 1, 2, \dots, n) \quad (k = 1, 2, \dots, m).$$

基于 GRA 法分析结果, 对灰色关联度 $r_i = 1, 2, \dots, p$ 按从大到小进行排序。若设灰色关联序列为 $r_1 > r_2 > \dots > r_p$, 则表明第一个比较序列对应的影响因素对参考序列影响最大, 第 p 个因素影响最小。对设定的最小关联度阈值 σ , 取 $\sigma \in (0, 1)$, 对满足 $r_i < \sigma$ 的比较序列则认为这些序列对网络输出的影响较小, 将其删除从而优化输入数据, 将余下的比较序列对应的影响因素作为关键影响因素输入到 LSTM 模型中。

1.2 LSTM 模型

LSTM 神经网络通过复杂的非线性单元构建, 具有长期记忆效应和深度学习的能力。LSTM 网络由 1 个输入层、1 个输出层以及多个隐藏层构成。其中隐藏层由记忆元组组成, 每个元组包含输入门、遗忘门和输出门, 门控制着元组和网络之间的信息流动, 其基本结构如图 1 所示。




图 1 LSTM 网络元组结构

Fig. 1 Tuple structure of LSTM network

图 1 中, C_{t-1} 和 C_t 表示细胞的旧状态和新状态, 细胞状态是 LSTM 网络的关键, 像传送带一样在整个链上运行。在 LSTM 中, 门结构可以决定信息是否通过, 以对细胞状态信息有选择地进行增删。其主要计算步骤如下:

第一步: 用来决定什么信息可以通过, 即遗忘

门。其中,输入为当前层的输入 x_t 和上一层的输出 h_{t-1} , 遗忘门状态输出 f_t 为:

$$f_t = \sigma(w_1^f \cdot x_t + w_h^f \cdot h_{t-1} + b_f),$$

第二步:产生需要更新的新信息并存储于细胞状态中,即输入门。新的细胞状态 C_t 首先通过旧的细胞状态 C_{t-1} 乘以 f_t 来忘记不需要的信息,然后加上新的候选信息 $i_t \cdot \bar{C}_t$ 。其中, i_t 为输入门状态。

$$i_t = \sigma(w_1^i \cdot x_t + w_h^i \cdot h_{t-1} + b_i),$$

$$\bar{C}_t = \tanh(w_1^c \cdot x_t + w_h^c \cdot h_{t-1} + b_c),$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \bar{C}_t,$$

第三步:输出门用来决定模型的输出。首先,通过 sigmoid 层得到初始输出状态值 o_t 后,使用 tanh 层将细胞状态的值缩放到 $[-1, 1]$ 之间,相乘得到输出值 h_t 。

$$o_t = \sigma(w_1^o \cdot x_t + w_h^o \cdot h_{t-1} + b_o),$$

$$h_t = \sigma \cdot \tanh(C_t).$$

其中, f_t, i_t, o_t 分别表征遗忘门、输入门和输出门的状态值; $w_1^f, w_1^i, w_1^o, w_1^c$ 为沟通输入 x_t 与元组的遗忘门、输入门、输出门以及元组输入的权重矩阵; $w_A^f, w_A^i, w_A^o, w_A^c$ 为连接上一层输出 h_{t-1} 与元组的遗忘门、输入门和输出门以及元组输入的权重矩阵; b_f, b_i, b_o, b_c 为遗忘门、输入门、输出门和元组输入的偏置向量; σ 为 sigmoid 激活函数。

1.3 GRA-LSTM 模型预测流程

首先,根据 GRA 法的分析结果选择合适的影响因素作为关键影响因素,然后对历史客流量数据和关键影响因素数据进行归一化处理,构成输入量输入到 LSTM 网络模型中。PCA-LSTM 预测模型的表达式如下:

$$h_{t+1} = f(h_t, h_{t-1}, \dots, h_{t-n}, x_{t+1}^i, x_t^i, \dots, x_{t-n}^i),$$

$$(i = 1, 2, \dots, m).$$

其中, h_{t+1} 为预测值; $h_t, h_{t-1}, \dots, h_{t-n}$ 是历史数据; $x_{t+1}^i, x_t^i, \dots, x_{t-n}^i$ ($i = 1, 2, \dots, m$) 是通过 GRA 法选出的 m 个关键影响因素数据。其中包括历史数据及预测值 h_{t+1} 对应的当前输入值 x_{t+1}^i 。根据设定目标误差不断训练模型,直至误差小于目标误差,此时输出预测结果。

2 SARIMA 模型

SARIMA 模型又称季节性差分自回归滑动平均模型,是在 ARIMA 模型的基础上演化出的一种针对具有季节性或周期性规律变化数据的预测模型,是

时间序列预测领域中的主要预测模型之一。该模型的通用表达式为:

$$SARIMA(p, d, q) \cdot (P, D, Q)_s.$$

其中, p 为自回归阶数; q 为移动平均阶数; d 为差分阶数; P, Q, D 分别为季节求和自回归移动平均模型中的自回归、移动平均和差分的值; S 为季节周期和循环长度。

SARIMA 模型的主要处理步骤为:

(1) 判定数据平稳性

首先将初始数据进行预处理,对处理后的数据构造时间序列折线图进行可视化,通过观察折线图对数据的平稳性进行初步判断。

(2) 数据差分

若初步判定为非平稳数据,则需要对数据进行差分,不断进行差分操作直到数据变为平稳时间序列。

(3) 通过 ACF(自相关函数)和 PACF(偏自相关函数)图形确定参数值引入 ACF 和 PACF 图形,通过判断可视化的图形是截尾还是拖尾来确定模型参数中 p, P, q 和 Q 的值。判定规则如下:若 ACF 拖尾且 PACF 截尾,通过可视化的阶数确定 p 和 P ; 若 ACF 截尾且 PACF 拖尾,通过可视化阶数确定 q 和 Q ; 若 ACF 和 PACF 均为拖尾,则通过可视化阶数可以确定 p 和 P, q 和 Q 。

(4) 确定 S 值

通过对季节性时间序列数据进行平均法、移动平均趋势剔除法等方法分解来确定 S 的值。

(5) 模型确定

得到所有参数后,需要使用参数估计对模型进行校验,直至确定最终模型。

3 组合模型设计

组合模型是在 SARIMA 和 LSTM 单模型预测结果的基础上设计了组合层,即基于 SARIMA 模型预测结果中提取的包含周期、趋势信息的单位节点比例序列,对 LSTM 得到的初步预测结果进行修正得到最终预测结果,实现了将 SARIMA 对周期、趋势性变化敏感的优点及 LSTM 预测精度高且可以用来对非线性数据进行预测的优点相结合。设计思路为:

(1) LSTM 单模型预测

将历史数据以及根据 GRA 法确定的关键影响因素数据输入 LSTM 模型,得到初步预测结果 L_i ($i = 1, 2, \dots, n$)。其中, n 为最小时间节点个数。

(2) SARIMA 单模型预测

将历史数据输入到 SARIMA 模型得到预测结果

$S_i(i = 1, 2, \dots, n)$ 。

(3) 组合设计

根据 SARIMA 模型中的预测结果 s_i 抽取包含周期、趋势信息的单位节点比例序列 θ_i ，对 LSTM 得到的初步预测结果进行修正以得到最终预测结果。

①首先根据 LSTM 模型初步预测结果，得到总时段预测结果数值总和 $L_{\text{总}}$ ：

$$L_{\text{总}} = \sum_{i=1}^n L_i$$

②提取 SARIMA 预测结果中单位节点 S_i 比例序列 $\theta_i(i = 1, 2, \dots, n)$ ，以抽取时间序列中周期、趋势信息，具体计算公式如下：

$$\theta_i = \frac{S_i}{\sum_{i=1}^n S_i}$$

③将 SARIMA 模型中的单位节点比例序列 θ_i 与总时段预测结果数值总和 $L_{\text{总}}$ 相乘，得到最终预测结果 $f_i(i = 1, 2, \dots, n)$ 。计算公式为：

$$f_i = L_{\text{总}} \cdot \theta_i$$

通过组合使得预测结果既可以很好地拟合时间序列中的周期、趋势性变化，也可以敏锐捕捉非线性因素影响下的变化。 f_i 的完整表达式为：

$$f_i = \sum_{i=1}^n L_i \cdot \frac{S_i}{\sum_{i=1}^n S_i}$$

组合模型处理步骤如图 2 所示。

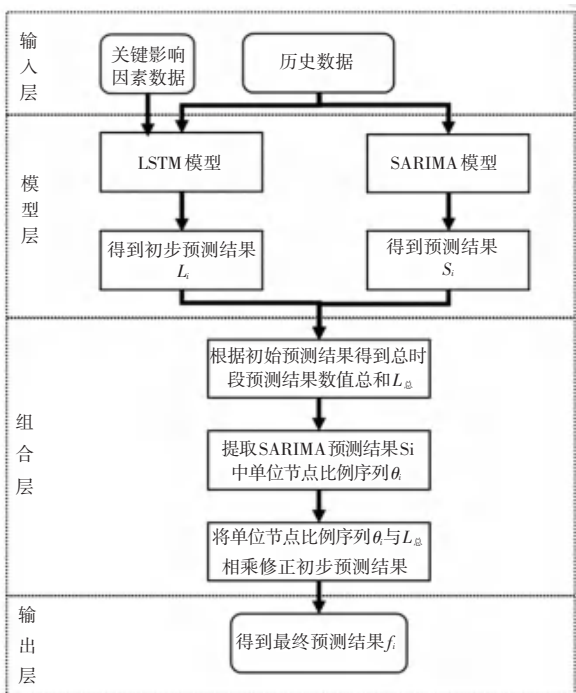


图 2 组合模型处理步骤

Fig. 2 Processing steps of combined model

4 实例分析

实例以某民航公司 2016~2018 年春运客流量数据作为测试数据，用于对模型进行训练；将 2019 年春运客流量数据作为预测数据判断模型预测准确度。

4.1 基于 GRA 法选取客流量关键影响因素

影响客运量的因素多种多样，为了更好地研究客运量的关键影响因素，参考相关文献[13-14]，提出以下影响航空客运量因素，见表 1。

表 1 民航春运客流量影响因素

Tab. 1 Influencing Factors of Air Spring Festival travel rush Passenger Flow

| 指标 | 因素 |
|----------|--------------|
| 经济社会发展 | GDP(亿元) |
| | CPI(元) |
| | 总人口(万人) |
| | 失业率 |
| 旅游发展 | 旅游业收入 |
| | 外国人入境游客数(万人) |
| 自身发展 | 航空客流量(万人) |
| | 航线事故征候 |
| | 航班正常率 |
| 其它运输方式竞争 | 铁路客流量(万人) |
| | 公路客流量(万人) |
| | 水路客流量(万人) |
| 其它因素 | 节假日属性 |
| | 周六日属性 |
| | 天气 |

从统计局官网上收集了 2016~2018 年春运典型日民航日出港旅客数以及影响因素数据，对其进行灰色关联度分析后，得到的分析结果见表 2。

表 2 关联度分析结果

Tab. 2 Correlation Analysis Results

| 民航影响因素 | 关联度(降序) |
|------------------|---------|
| 某市铁路客流量(万人次) | 0.99 |
| 某市 GDP(亿元) | 0.98 |
| 某市 CPI | 0.98 |
| 全国航线事故征候 | 0.98 |
| 某市航空客流量(万人次) | 0.97 |
| 某市外国人入境游客数(万人/次) | 0.97 |
| 某市公路客流量(万人/次) | 0.97 |
| 全国航班正常率 | 0.96 |
| 某市总人口(万人) | 0.96 |
| 某市失业率 | 0.96 |
| 节假日属性 | 0.95 |
| 某市旅游收入(亿元) | 0.95 |
| 某市水路客流量(万人次) | 0.93 |
| 天气 | 0.61 |
| 周六日属性 | 0.53 |

根据关联度分析结果可以得出:

(1) 经济社会发展、旅游发展、自身的发展以及其它相关运输方式的发展这 4 方面, 对航空客流的影响因素均在 0.9 以上。

(2) 其它因素中, 只有节假日属性对航空客流的影响因素大于 0.9; 天气因素、周六日属性航空客流的影响因素均小于 0.7。因此选取影响程度大于 0.7 的 13 项因素作为关键影响因素。

4.2 模型预测

将 2016~2018 年民航春运日出港旅客数以及 2016~2019 年关键影响因素数据输入到 LSTM 模型中, 得到图 3 预测结果。

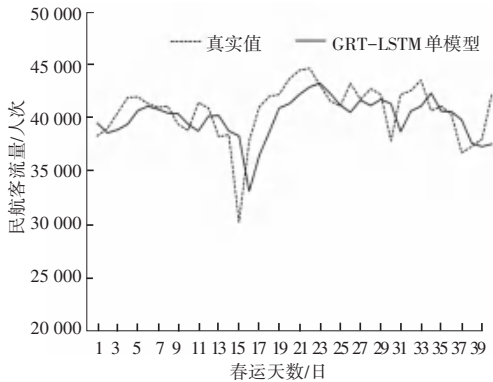


图 3 LSTM 单模型预测结果

Fig. 3 LSTM single model prediction results

由图 3 可以看出, LSTM 模型预测结果与真实值拟合度较高, 但与真实值相比预测趋势存在延迟。将 2016~2018 年民航春运日出港旅客数输入到 SARIMA 模型中, 得到图 4 预测结果:

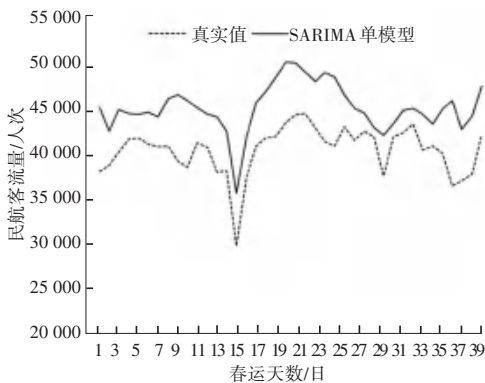


图 4 SARIMA 单模型预测结果

Fig. 4 Prediction results of single ARIMA model

SARIMA 模型的预测结果在趋势上与真实值基本吻合, 但预测精度不甚满意。根据组合模型设计思想, 将两种模型进行组合后, 得到的预测结果如图 5 所示。




图 5 组合模型预测结果

Fig. 5 Prediction results of combined model

可以看到组合模型无论是在预测精度和趋势变化上都比单模型效果要好。根据表 3 可知组合模型预测平均绝对百分比误差为 3.9%。

表 3 组合模型预测误差

Tab. 3 Prediction error of hybrid model

| 指标 | 值 |
|-----------------|-------|
| MAE(平均绝对误差) | 1 584 |
| RMSE(均方根误差) | 1 914 |
| MAPE(平均绝对百分比误差) | 3.9% |

4.3 与其它预测模型的对比

为检验和说明组合模型的预测性能, 采用支持向量机、灰色预测、GRA-LSTM 单模型以及 SARIMA 单模型等经典的预测模型与之进行对比, 其预测曲线如图 6 所示。同时采用 MAE(平均绝对误差)、RMSE(均方根误差)以及 MAPE(平均绝对百分比误差)作为误差衡量指标, 几种模型的预测误差见表 4。

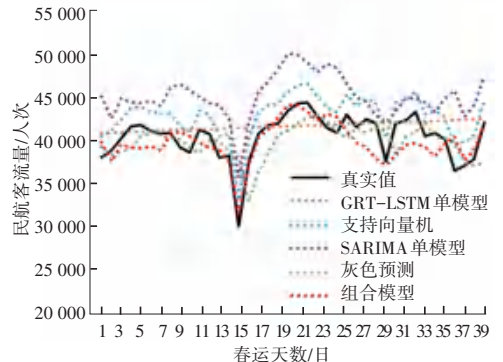


图 6 几种模型预测结果

Fig. 6 Prediction results of several models

由表 4 和图 6 可知, 本文提出的 GRA-LSTM+SARIMA 组合模型与真实值的拟合程度是最好的, 预测误差也是几种模型中最低的。其中, MAPE 比支持向量机、灰色预测、GRA-LSTM 单模型以及 SARIMA 单模型分别降低了 2.1%、1.1%、0.7%、6.7%。

表4 几种模型预测误差
Tab. 4 Prediction errors of several models

| 指标 | 支持向量机 | 灰色预测 | GRT-LSTM 单模型 | SARIMA 单模型 | GRT-LSTM+SARIMA 组合模型 |
|------------------|-------|-------|--------------|------------|-------------------------|
| MAE (平均绝对误差) | 2 426 | 1 885 | 1 804 | 4 655 | 1 584 |
| RMSE (均方根误差) | 2 436 | 2 882 | 2 459 | 5 021 | 1 914 |
| MAPE (平均绝对百分比误差) | 6.0% | 5.0% | 4.6% | 11.6% | 3.9% |

5 结束语

通过评估 LSTM 模型和 SARIMA 模型的优劣,提出将两种模型进行组合。通过实验表明,组合模型在预测上比单模型具有优越性。其次组合模型之一的 LSTM 模型的输入层不仅仅是历史数据,还有基于 GRA 法选取的关键影响因素,因此组合模型能够捕捉非线性时间序列的变化,更好地针对实际变化进行预测。

参考文献

- [1] 韩超,宋苏,王成红. 基于 ARIMA 模型的短时交通流实时自适应预测[J]. 系统仿真学报,2004(7):1530-1532,1535.
- [2] 彭燕,刘宇红,张荣芬. 基于 LSTM 的股票价格预测建模与分析[J]. 计算机工程与应用,2019,55(11):209-212.
- [3] MA X,TAO Z,WANG Y, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data [J]. Transportation Research Part C Emerging Technologies, 2015, 54:187-197.
- [4] 张真,李宁,田英爱. 基于双向 LSTM 网络的流式文档结构识别[J]. 计算机工程,2020,46(1):60-66.

- [5] JIAN Z, WANG Y, FU X, et al. Water quality prediction method based on IGRA and LSTM[J]. Water, 2018, 10(9):1148.
- [6] 闻克宇,赵国堂,何必胜,等. 基于改进迁移学习的高速铁路短期客流时间序列预测方法[J]. 系统工程,2020,38(3):73-83.
- [7] WANG Y B, XU C J, LI Y C, et al. An Advanced Data-Driven Hybrid Model of SARIMA-NNAR for Tuberculosis Incidence Time Series Forecasting in Qinghai Province, China.. 2020, 13: 867-880.
- [8] 许金炜. 基于虚拟变量回归与 SARIMA 组合模型的 GDP 预测[J]. 统计与决策,2016(24):38-41.
- [9] 王莹,韩宝明,张琦,等. 基于 SARIMA 模型的北京地铁进站客流量预测[J]. 交通运输系统工程与信息,2015,15(6):205-211.
- [10] 朱颜杰,樊顺厚,雷怀英. 基于 SARIMA 模型的居民消费价格指数的预测[J]. 统计与决策,2014(4):37-39.
- [11] 于静,王辉. 基于组合模型的网络流量预测[J]. 计算机工程与应用,2013(8):92-95.
- [12] 丁锐,李伟,王若舟. 基于 SARIMA 和 LSTM 组合预测模型[J]. 计算机与数字工程,2020,48(2):304-307.
- [13] 张永莉,张晓全. 我国城市间民航客运量影响因素的实证分析[J]. 经济地理,2007,27(4):658-660.
- [14] 纪跃芝,邓波,秦喜文. 民航客运量及相关因素分析[J]. 数学的实践与认识,2012,42(24):175-183.

(上接第 194 页)

理系统以 K60 单片机为核心,通过硬件模块完成 VAN 与 VANET 的搭建、车辆车队关键信息的精确感知与实时上传、换道汇入的处理决策、路径规划、协同驾驶、以及换道汇入过程的轨迹跟踪与姿态修正,通过软件模块完成无人智能物流车编队的远程监测与管理。在一定程度上解决了当前无人物流车系统对于物流行业实效性较低的问题,具备可行性。

参考文献

- [1] 程日盛. 公路运输业向现代物流业发展的对策[J]. 交通运输工程学报,2004(4):93-96.
- [2] 赵娜,袁家斌,徐哈. 智能交通系统综述[J]. 计算机科学,2014,(11):7-11.
- [3] 李思予. 基于 Platooning 技术的车队燃油控制及智能路径规划研究[D]. 西安:西安电子科技大学,2019.
- [4] 于丰华. 基于 K60 的智能汽车控制系统研究[D]. 长春:吉林农业大学,2014.
- [5] 张煜. 基于多传感器数据融合的无人车避障导航研究[D]. 西安:西安工业大学,2015.

- [6] 温阳东. 基于线阵 CCD 的智能小车路径识别系统[J]. 合肥工业大学学报,2009(9):1348-1353.
- [7] 周俊静. 基于激光雷达的智能车辆目标识别与跟踪关键技术研究[D]. 北京:北京工业大学,2014.
- [8] 豆菲菲. 基于多传感器数据融合的无人车行驶策略研究[D]. 西安:西安工业大学,2015.
- [9] 王丽欣. 基于 GPS/GSM 的车辆定位跟踪系统设计与实现[D]. 沈阳:沈阳工业大学,2013.
- [10] 陈鸿飞. 基于 ZigBee 与 GPRS 的远程抄表系统智能终端设计[D]. 长沙:中南大学,2009.
- [11] 张睿. 基于 K60 的智能小车控制系统设计与实现[D]. 杭州:杭州电子科技大学,2013.
- [12] 陈义. 基于 MC9S12XS128 单片机的智能车控制系统的研究[D]. 北京:华北电力大学,2011.
- [13] 刘大维. 基于嵌入式单片机的智能车控制系统研究[D]. 华南理工大学,2013.
- [14] 钟光文. 智能物流车队管理系统的设计与实现[D]. 电子科技大学,2012.
- [15] 张众华. 车队协同驾驶架构及其协同策略研究[D]. 成都:西华大学,2016.