

# 基于ARIMA和LSTM模型的建筑安全事故预测

徐虎博, 史东辉

(安徽建筑大学电子与信息工程学院, 安徽 合肥 230601)

✉1144024636@qq.com; donghui\_shi@163.com



**摘要:** 研究比较差分自回归移动平均模型(Autoregressive Integrated Moving Average model, 简称ARIMA)与长短期记忆神经网络(Long Short Term Memory, LSTM)模型在建筑安全事故预测中的效果。采用2012—2018年全国建筑安全事故快报数据训练ARIMA及LSTM模型, 并对全国每年、每月发生的建筑安全事故次数进行预测, 使用RMSE和MAE作为评价指标对比两种模型的预测准确率。ARIMA(1,1,0)模型和LSTM模型的RMSE、MAE值分别为8.1318、6.5911和16.4341、14.5534。结果表明, ARIMA模型比LSTM模型更适于预测建筑安全事故发生次数。

**关键词:** 时间序列; ARIMA模型; LSTM模型; 建筑安全事故; 预测

**中图分类号:** TP311 **文献标识码:** A

## Prediction of Construction Safety Accidents based on ARIMA and LSTM Models

XU Hubo, SHI Donghui

(School of Electronics and Information Engineering, Anhui Jianzhu University, Hefei 230601, China)

✉1144024636@qq.com; donghui\_shi@163.com

**Abstract:** This paper proposes to study and compare the construction safety accident prediction effect of the Autoregressive Integrated Moving Average (ARIMA) model and the Long Short Term Memory (LSTM) model. The ARIMA and LSTM models are trained with the datasets of the national construction safety accident report from 2012 to 2018, and the number of construction safety accidents that occur every year and every month in China is predicted. RMSE and MAE are used as evaluation indicators to compare the prediction accuracy of the two models. The RMSE and MAE values of ARIMA (1,1,0) model and LSTM model are 8.1318, 6.5911 and 16.4341, 14.5534, respectively. The results show that ARIMA model is more suitable for predicting the number of construction safety accidents than LSTM model.

**Keywords:** time series; ARIMA model; LSTM model; construction safety accident; prediction

### 1 引言(Introduction)

近年来, 随着我国经济的迅速发展, 建筑业发展规模不断扩大, 但与此同时建筑安全事故发生率逐步提升。虽然我国历来非常重视安全生产问题, 并且政府有关部门为了应对建筑安全事故发生率不断上升的问题, 研究并采取了不少的对策和措施<sup>[1-2]</sup>, 但是建筑安全事故仍然层出不穷。建筑安全事故频发, 不仅会影响建筑从业人员的心理健康状况, 还会

影响我国国民经济的稳定增长。因此, 建筑安全事故预测对提前预防事故的发生具有重要的意义。

通常, 对建筑安全事故的研究大多集中在事故分析和预警管理分析方面, 利用模型对建筑安全事故发生次数进行预测的研究较少, 而使用ARIMA与LSTM模型对建筑安全事故预测的研究基本没有。所以, 本文将建筑安全事故发生次数作为研究对象, 使用ARIMA和LSTM模型对其进行预测分析。

## 2 研究现状(Research status)

国内外使用ARIMA模型进行事故预测的案例不断增多。2012年,甘旭升等<sup>[3]</sup>构建ARIMA模型预测美国空军飞行事故的万时率,平均相对误差在7%以内。2015年,郑向阳等<sup>[4]</sup>为了减少生产作业中由不确定性因素导致错误决策引发的风险,通过ARIMA模型对安全生产事故发生次数进行预测,研究表明其模型用于预测企业安全生产事故发生的情况与企业的实际情况基本吻合。2015年,KARIMLOU等<sup>[5]</sup>构建ARIMA模型用于预测伊朗受保工人的工伤事故数量,该数据拟合模型的预测结果平均绝对百分比误差(MAPE)为20.942。2019年,LI<sup>[6]</sup>研究民航领域不同飞行阶段发生飞行事故和人员伤亡的变化趋势,根据ARIMA(1,0,1)模型对全球民航飞行事故和伤亡人数进行预测,预测未来飞行事故可能发生的变化,为航空安全研究提供数据参考。

随着神经网络的发展,近几年使用LSTM进行预测的研究案例显著增多。2019年,张志豪等<sup>[7]</sup>使用LSTM神经网络对影响交通安全水平的指标进行预测,准确地反映交通事故安全发生率。2020年,RADAIDEH等<sup>[8]</sup>以冷却剂损失事故为分析特征,采用核电站设计基准事故的时间序列数据进行建模和预测。LSTM模型在预测测试和基本情况场景预测方面表现出优异的性能,预测准确率高达99%。2020年,MOHANTY等<sup>[9]</sup>使用LSTM模型预测一个区域内的社区交通拥堵情况,并且开发了一个更好解释输入对其输出贡献的模型框架。2021年,ESSIEN等<sup>[10]</sup>将双向LSTM模型用于多步交通流预测,该模型在英国大曼彻斯特的城市道路网上进行了评估,结果证明了该方法在提高预测精度方面的有效性。2022年,曾航等<sup>[11]</sup>提出一种改进的LSTM模型进行航空安全预测,实验结果表明该模型预测误差较现有方法降低了28%以上,同时具有较好的泛化能力和鲁棒性。

综上,使用ARIMA和LSTM模型均能对时间序列数据进行预测,但是单个模型的预测较难看出其优势和劣势,所以为了能够选择对时间序列数据拟合更好的模型,近几年开始对两个模型进行对比研究。2020年,景楠等<sup>[12]</sup>对新型冠状病毒肺炎引起的网络舆情进行分析,使用ARIMA和LSTM模型对其网络关注度趋势进行预测,两个模型都能较好地模拟疫情网络舆情关注度的变化趋势。2020年,WANG等<sup>[13]</sup>使用ARIMA和LSTM模型预测使用共享汽车频次高、中、低三类用户的短期需求,发现LSTM模型对每种类型的用户具有更高的需求预测精度,但是ARIMA模型的整体预测精度更高。2021年,王淑平等<sup>[14]</sup>使用ARIMA和LSTM模型对医院月出院人次进行预测,结果表明ARIMA模型的预测效

果要好于LSTM模型。2021年,徐映梅等<sup>[15]</sup>使用ARIMA和LSTM模型对2019年中国的生产总值GDP进行预测,得出在样本量相对较少的情况下,并且针对简单时间序列的数据时,使用ARIMA模型进行预测更具优势的结论。2021年,MAHADIK等<sup>[16]</sup>研究对特定公司数据集进行拟合时哪种模型更适合,并且在预测股票未来趋势上ARIMA模型具有更高的精度。2021年,MEJRI等<sup>[17]</sup>将ARIMA和LSTM模型用于家用洗涤剂工业生产的需求预测,研究表明LSTM模型具有更好的整体性且具有更高的预测精度。2021年,WAN等<sup>[18]</sup>使用ARIMA和LSTM模型对玉米期货的日收盘价进行预测,研究发现LSTM模型的预测能力更好。

可以看出,ARIMA和LSTM模型对不同数据集的预测效果各不相同,所以为了能够找到对建筑安全事故预测更加准确的模型,本文采用对比研究的方法,通过对比实验选取能够更加准确地预测建筑安全事故发生的规律。这对建筑行业风险管理具有重要意义,并且能为建筑安全事故预防提供参考。

## 3 建筑安全事故预测模型(Prediction model of construction safety accidents)

### 3.1 时间序列

时间序列主要包括自回归模型(AR)、移动平均模型(MA)和自回归移动平均模型(ARMA)的平稳时间序列模型,以及差分自回归移动平均模型(ARIMA)的非平稳的时间序列模型。

时间序列模型在进行时间序列分析时起关键作用,可以表示出时间序列的特性。每个时间的数值表示某一现象在该时间的观测值,其中相邻点的时间间隔可以不同。假设有时间序列,则有公式(1):

$$X = \{(t_1, x_1), \dots, (t_i, x_i), \dots, (t_n, x_n)\}, \quad t_i < t_{i+1} (i = 1, \dots, n-1) \quad (1)$$

其中,  $t_i$  表示时间,  $x_i$  表示观测值,  $(t_i, x_i)$  表示在时间  $t_i$  的观测值为  $x_i$ 。

### 3.2 ARIMA

ARIMA模型,对非平稳时间序列进行  $d$  阶差分处理时,首先使其变为平稳数列,然后将其数据输入ARMA模型进行拟合,简记为  $ARIMA(p, d, q)$ , 见公式(2):

$$x_t = \varphi_1 x_{t-1} + L + \varphi_p x_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + L + \theta_q \varepsilon_{t-q} \quad (2)$$

其中,  $\varphi_1, \varphi_2, \dots, \varphi_p$  为自回归系数,  $\theta_1, \theta_2, \dots, \theta_q$  为移动平均系数,  $q$  为移动平均阶数,  $p$  为自回归阶数,  $\varepsilon_t$  为白噪声过程。

ARIMA的建模步骤如图1所示。首先判断时间序列数据是否为平稳数据,如果不是平稳数据,就需要对数据进行差分运算,使其变为平稳数据。其次在判断是否为平稳数据之后,需要进行白噪声检测,白噪声检测是为了使数据符合模型拟合要求。最后对通过白噪声检测的数据选择合适的ARIMA模型进行拟合。

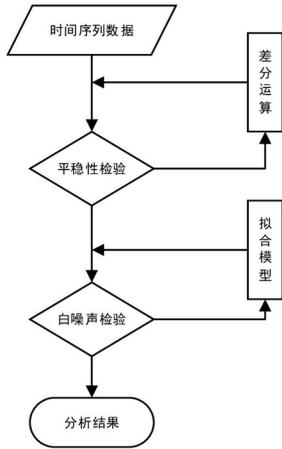


图1 ARIMA建模步骤

Fig.1 ARIMA modeling steps

### 3.3 LSTM

LSTM神经网络是循环神经网络(Recurrent Neural Network, RNN)的扩展,解决了长期依赖的问题。一个LSTM单元的基本结构由遗忘门、输入门和输出门组成,门实现遗忘或记忆的功能,其单元基本结构如图2所示。

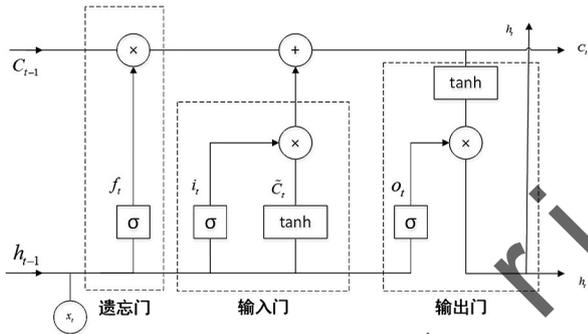


图2 LSTM单元基本结构

Fig.2 Basic structure of LSTM unit

遗忘门中将当前时刻的输入和上一时刻的输出作为sigmoid函数的输入,用来控制上一单元状态被遗忘的程度。输入门和tanh函数结合组成,用来控制新输入信息的量。输出层决定输出的信息,主要利用tanh函数处理当前细胞状态,接着结合sigmoid函数得到的权值来过滤部分细胞状态信息,并获得下一时刻的输出。

$$f_t = \sigma(W_f \times [h_{(t-1)}, x_t] + b_f) \quad (3)$$

$$i_t = \sigma(W_i [h_{(t-1)}, X_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_c [h_{(t-1)}, X_t] + b_c) \quad (5)$$

$$O_t = \sigma(W_o [h_{(t-1)}, X_t] + b_o) \quad (6)$$

$$C_t = f_t * C_{(t-1)} + i_t * \tilde{C}_t \quad (7)$$

$$h_t = O_t * \tanh C_t \quad (8)$$

公式(3)—公式(8)中,  $f_t$  为遗忘门的输出;  $i_t$  为输入门的输出;  $O_t$  为输出门的输出;  $\tilde{C}_t$  为当前输入的记忆;  $C_{(t-1)}$  为上一时刻的细胞状态;  $C_t$  为当前时刻的细胞状态;  $h_{(t-1)}$  为当前时刻的输出;  $W_f$ 、 $W_i$ 、 $W_o$ 、 $W_c$  分别为遗忘门、输入门、输出门和输入门中间变量与当前时刻输入  $X_t$  和上一时刻输出  $h_{(t-1)}$  作乘法运算的权重;  $b_f$ 、 $b_i$ 、 $b_o$ 、 $b_c$  为偏置向量;  $\sigma$  为 sigmoid 函数。

一时刻的细胞状态;  $C_t$  为当前时刻的细胞状态;  $h_{(t-1)}$  为当前时刻的输出;  $W_f$ 、 $W_i$ 、 $W_o$ 、 $W_c$  分别为遗忘门、输入门、输出门和输入门中间变量与当前时刻输入  $X_t$  和上一时刻输出  $h_{(t-1)}$  作乘法运算的权重;  $b_f$ 、 $b_i$ 、 $b_o$ 、 $b_c$  为偏置向量;  $\sigma$  为 sigmoid 函数。

LSTM建模过程分三步。一是对将进入输入层的样本数据进行数据归一化,将满足LSTM输入要求的数据输入隐含层。二是将隐含层输出的多个结果在输出层通过映射输出模型期望的结果,接着进行模型训练,在设定迭代周期内进行安全事故数据训练,以更好地预测安全事故发生量的变化趋势。三是利用训练好的模型预测和分析测试集数据,通过计算误差函数值评估模型的拟合效果。

## 4 算法分析(Algorithm analysis)

### 4.1 数据来源与分析

研究使用2012—2018年《全国建筑安全事故快报》中的建筑安全事故发生的时间序列数据,其中使用2012—2017年的死亡一人以上的安全事故案例作为训练模型,然后使用2018年的数据进行验证,其中对建筑安全事故时序数据使用ARIMA和LSTM模型进行拟合,并对拟合完成的模型通过RMSE和MAE进行比较,分析两种模型的优势和劣势后,选择最适合预测的模型。

### 4.2 基于ARIMA模型的数据预测

本研究是对建筑安全事故发生次数进行预测,统计每年、每月建筑安全事故(死亡1人以上)发生次数作为时序数据,得到2012—2018年建筑安全事故发生次数的时序变化折线图(图3)。通过图3可以看出,建筑安全事故发生次数总体呈现增长趋势。

由于模型要求时序数据为稳定数据,因此要先判断时序数据是否稳定,通过单位根检验(ADF检验)进行判断。该方法通过查看是否存在单位根,判断序列是否平稳,即检验的假设为存在单位根,查看显著性检验统计量是否小于三个置信度(10%,5%,1%)。

对原始时序数据进行ADF检验,通过表1得出ADF检验的p值为0.980842,显著水平一般为0.05,因此p值大于显著水平,说明并不能拒绝原假设。由于Test Statistic Value的值大于三种置信水平下的值,因此数据是不稳定的。

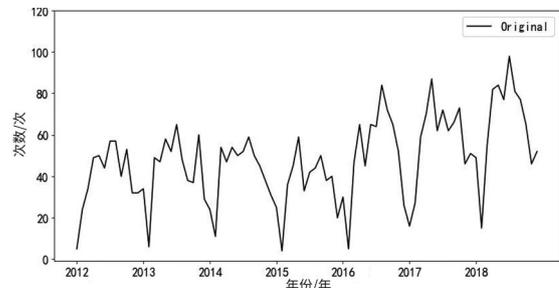


图3 时序数据折线图

Fig.3 Line chart of time series data

表1 时序数据平稳化过程ADF检验结果

Tab.1 ADF test results of time series data stabilization process

参数	原始数据	对数变换
Test Statistic Value	0.382835	0.626917
p-value	0.980842	0.988261
Lags Used	11	12
Number of Observation Used	72	71
Critical Value(1%)	-3.52462	-3.526
Critical Value(5%)	-2.90261	-2.9032
Critical Value(10%)	-2.58868	-2.58899

由于原始时序数据为非平稳数据，因此需要通过处理并再次判断数据是否已经平稳化。原始时序数据的数值都大于0，所以先对其进行对数变换。通过表1发现，对数变换后的时序数据进行ADF检验可知p值为0.988261，仍然大于显著水平且在任何置信水平下，Test Statistic Value的值表明不能拒绝原假设，因此对数变换后的时序数据也是非平稳数据。

经过对数变换后仍为非平稳数据，接着对时序数据进行差分运算处理，该方法主要是对等周期间隔的数据进行线性求减。对时序数据进行一阶和二阶差分处理，通过对表2中的数据进行对比，可以得出两种差分处理后的时序数据均是平稳数据。可以看出，ADF检验的p值明显低于显著水平，并且在三种置信水平下都拒绝原假设，即序列不具有单位根。又因为均值和标准差的数值相差不大，所以选取一阶差分后的时序数据，将差分次数定为1。

表2 时序数据差分化过程ADF检验结果

Tab.2 ADF test results of differential differentiation process of time series data

参数	一阶差分	二阶差分
Test Statistic Value	-10.2301	-10.5194
p-value	5.05452e-18	9.77081e-19
Lags Used	10	9
Number of Observation Used	72	72
Critical Value(1%)	-3.52462	-3.52462
Critical Value(5%)	-2.90261	-2.90261
Critical Value(10%)	-2.58868	-2.58868

经过一阶差分后的数据为平稳序列。对序列进行白噪声检验，得到统计量和p值两个数值，分别为10.2648925和0.00135586，可以得出p值明显小于显著水平，因此一阶差分后的时序序列为平稳非白噪声序列。

通过图4确定模型参数，经过分析选定范围内的p、q参数，然后对选取的各个参数进行评估，根据评估结果选择效果最好的一个参数模型。评估的标准按照赤池信息准则(AIC)及贝叶斯信息准则(BIC)。表3为截取效果较好的部分参数的结果，并确定使用参数(1,1,0)进行模型拟合。

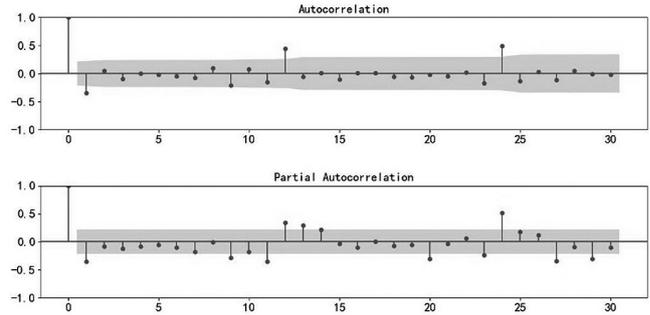


图4 自相关图和偏自相关图

Fig.4 Autocorrelation diagram and partial autocorrelation diagram

表3 选取参数结果表

Tab.3 Selected parameter result table

模型参数	AIC	BIC
(0,1,0)	714.374	719.211
(1,1,0)	711.951	719.207
(0,1,1)	712.001	719.258
(2,1,0)	713.934	723.609
(1,1,1)	713.863	723.538

### 4.3 基于LSTM模型的数据预测

在模型训练之前，为了使数据更好地拟合模型，需要对数据进行归一化处理。其功能是使用数据的最大值和最小值对当前值进行缩放，使数据的值在0—1，归一化公式见公式(9)：

$$x'_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \tag{9}$$

公式(9)中， $x_i$ 为未处理的数据， $\min(x)$ 为整体最小数据， $\max(x)$ 为整体最大数据。对归一化后的数据进行划分，将2012—2017年的建筑安全事故发生次数作为LSTM的训练集，2018年的数据作为测试集。

构建LSTM模型，采用单向编码方式，隐藏层数设置为2，隐藏层神经元的数量设置为64个，全链接层数设置为1。同时，设置输入数据批次大小为10，每次选取12个数据进行训练，时间长度为12个月，训练次数为2,000次。使用Adam优化器对模型进行调优，并使用Pytorch搭建模型结构。

### 4.4 评价指标

为了评价模型的预测效果，选取RMSE和MAE作为模型评价指标。RMSE用于衡量预测值与实际值之间的偏差，误差越小，则表明精度越高。MAE是预测值与实际值之间绝对误差的平均值，能直观地反映预测值误差的实际情况，其值越接近于0，则表示预测越准确。计算见公式(10)和公式(11)：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i)^2} \tag{10}$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |x_i - \hat{x}_i| \tag{11}$$

公式(10)—公式(11)中， $\hat{x}_i$ 为预测值， $x_i$ 为真实值， $n$ 为预测次数。

### 4.5 结果分析

为了更好地分析和对比ARIMA和LSTM模型预测建筑安全事故次数的效果，加入Holt-Winter(霍尔特-温特)模型，并用相同的数据进行预测，该模型适用于任何呈现某种趋势具有季节性的数据集。三种模型对2018年安全事故次数预测结果如图5所示。

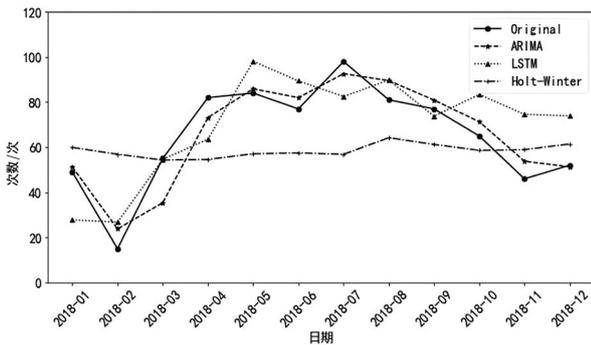


图5 3种模型的预测结果

Fig.5 Prediction results of three models

ARIMA、LSTM、Holt-Winter三种模型的预测曲线、预测结果如图5和表4所示，在预测准确率上，ARIMA模型的预测效果明显优于其他两种模型，能够很好地拟合建筑事故发生次数曲线；而LSTM模型的预测结果的变化趋势和原始数据的振动情况虽然基本吻合，但是预测值与实际值在部分月份有较大差距，并且误差值是ARIMA的两倍。对于Holt-Winters模型，虽然建筑事故发生次数在一定时间段内呈现相似的周期性，但是预测结果表明建筑事故发生次数并不是呈现某种趋势的季节性数据。

表4 三种模型的预测误差及时长

Tab.4 Prediction error and time length of three models

模型	RMSE	MAE
Holt-Winter	22.8188	19.1435
ARIMA	8.1318	6.5911
LSTM	16.4341	14.5534

### 5 结论(Conclusion)

本文为了验证ARIMA和LSTM两种模型在建筑安全事故发生次数预测的效果，通过对比研究，得出两种模型在拟合预测上均有良好的表现，都能对安全事故发生次数进行较好的预测，但在准确度上，ARIMA模型比LSTM模型要高，在数据处理方面，ARIMA模型所需的步骤比LSTM模型多。尽管ARIMA模型在训练之前需要对数据进行多步处理，但是高准确率对建筑安全事故能进行有效预警，能够在事故高发期

提前做出应对措施，对建筑工人的人身安全起到更好的保障。

### 参考文献(References)

- [1] 王颖,胡双启,池致超,等.建筑安全事故成因分析及预警管理的研究[J].中国安全生产科学技术,2011,7(07):112-115.
- [2] 马小玲.2009—2018年我国建筑施工安全事故统计分析[J].居舍,2019(24):191.
- [3] 甘旭升,端木京顺,高建国,等.基于ARIMA模型的航空装备事故时序预测[J].中国安全科学学报,2012,22(03):97-102.
- [4] 郑向阳,李正君.基于ARIMA的安全生产事故预测与实证研究[J].工业安全与环保,2015,41(03):78-80.
- [5] KARIMLOU M, SALEHI M, IMANI M, et al. Work-related accidents among the Iranian population: a time series analysis, 2000-2011[J]. International Journal of Occupational and Environmental Health, 2015,21(4):279-284.
- [6] LI Y. Analysis and Forecast of Global Civil Aviation Accidents for the Period 1942-2016[J]. Mathematical Problems in Engineering, 2019(4):5710984.
- [7] 张志豪,杨文忠,袁婷婷,等.基于LSTM神经网络模型的交通事故预测[J].计算机工程与应用,2019,55(14):249-253.
- [8] RADAIDEH M I, PIGG C, KOZLOWSKI T, et al. Neural-based time series forecasting of loss of coolant accidents in nuclear power plants[J]. Expert Systems with Applications, 2020,160:113699.
- [9] MOHANTY S, POZDNUKHOV A, CASSIDY M. Region-wide congestion prediction and control using deep learning[J]. Transportation Research Part C: Emerging Technologies, 2020,116:102624.
- [10] ESSIEN A, PETROUNIAS I, SAMPAIO P, et al. A deep-learning model for urban traffic flow prediction with traffic events mined from twitter[J]. World Wide Web, 2021,24(4):1345-1368.
- [11] 曾航,张红梅,任博,等.基于改进LSTM模型的航空安全预测方法研究[J].系统工程与电子技术,2022,44(02):569-576.
- [12] 景楠,胡怡,韩喜双.基于ARIMA与LSTM的新冠肺炎网络关注度趋势研究[J].中国安全科学学报,2020,30(12):37-42.
- [13] WANG Y, MI X. A Comparative Study on Demand Forecast of Car Sharing Users Based on ARIMA and LSTM[C]// IEEE. 2020 5th International Conference on Electromechanical Control Technology and Transportation (ICECTT), Nanchang, China: IEEE, 2020:565-574.

[14] 王淑平,李敏,杜敏,等.ARIMA与LSTM模型在医院出院人次预测中的比较研究[J].公共卫生与预防医学,2021,32(01):18-21.

[15] 徐映梅,陈尧.季节ARIMA模型与LSTM神经网络预测的比较[J].统计与决策,2021,37(2):46-50.

[16] MAHADIK A, VAGHELA D, MHAISGAWALI A. Stock Price Prediction using LSTM and ARIMA[C]// IEEE. 2021 Second International Conference on Electronics and Sustainable Communication Systems (ICESC), Coimbatore, India: IEEE, 2021:1594-1601.

[17] MEJRI I, BOUZID A, BACHA S, et al. Forecasting Demand Using ARIMA Model and LSTM Neural Network: a Case of Detergent Manufacturing Industry[C]// IEEE. 2021

International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT), Zallaq, Bahrain: IEEE, 2021:346-353.

[18] WAN H, ZHOU Y. Neural Network Model Comparison and Analysis of Prediction Methods Using ARIMA and LSTM Models[C]// IEEE. 2021 IEEE International Conference on Advances in Electrical Engineering and Computer Applications (AEECA), Dalian, China: IEEE, 2021:640-643.

作者简介:

徐虎博(1998-),男,硕士生.研究领域:机器学习,人工智能.

史东辉(1966-),男,博士,教授.研究领域:知识工程,数据挖掘,机器学习,人工智能.本文通信作者.

(上接第17页)

表2 模型性能对比结果

Tab.2 Model performance comparison results

模型	mAP/%	推理时间/ms	参数量
YOLOv5s	88.3	4.7	7,020,913
改进后模型	91.2	5.1	7,022,601

由表1可以看出,模型的改进提升效果主要体现在对小目标的识别上.由表2可以看出,改进后模型较原YOLOv5s模型,平均精度提高2.9%,并且几乎不增加模型大小和模型推理时间,改进后模型检测效果如图3所示.



图3 检测效果示意图

Fig.3 Schematic diagram of detection effect

5 结论(Conclusion)

针对传统油库监测系统采用人工观察视频监控方式存在的缺陷,本文提出了一种基于深度学习的油库监测方法,该方法基于表现优秀的YOLOv5网络模型,通过对原始的YOLOv5模型的部分结构进行改进,在油库安全监测中取得了较原始YOLOv5模型更好的监测效果.最终实验结果表明,改进后模型的平均精度mAP达到了91.2%,推理速度只需要5.1 ms,能很好地完成油库安全监测工作,不但节省了大量人力资源,保证了油库安全监测效果,而且进一步推动了智慧油库的建设.

参考文献(References)

[1] 潘浩.基于深度学习的卸油口监控目标检测研究与实现[D].成都:西南交通大学,2021.

[2] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// IEEE. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Columbus, OH, USA: IEEE, 2014:580-587.

[3] GIRSHICK R. Fast R-CNN[C]// IEEE. Proceedings of the

IEEE International Conference on Computer Vision, Boston, MA, USA: IEEE, 2015:1440-1448.

[4] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6):1137-1149.

[5] HE K, GKOXARI G, DOLLAR P, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2):386-397.

[6] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]// Springer. Proceeding of the 2016 European Conference on Computer Vision, Amsterdam, Netherlands: Springer, 2016:21-37.

[7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// IEEE. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 779-788.

[8] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design[C]// IEEE. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021:13713-13722.

[9] 陈一潇,阿里甫·库尔班,林文龙,等.面向拥挤行人检测的CA-YOLOv5[J].计算机工程与应用,2022,58(09):238-245.

[10] 王玲敏,段军,辛立伟.引入注意力机制的YOLOv5安全帽佩戴检测方法[J].计算机工程与应用,2022,58(09):303-312.

[11] 韩逸,舒小华,杨明俊.一种基于改进YOLOv5s的车道线检测方法[J].湖南工业大学学报,2022,36(03):51-58.

作者简介:

林海(1998-),男,硕士生.研究领域:图像处理.

胡旭晓(1965-),男,博士,教授.研究领域:图像处理,深度学习.

吴跃成(1966-),男,博士,副教授.研究领域:人机交互.

汪燕超(1999-),男,硕士生.研究领域:图像处理.