

基于深度学习对茅台机场降水量预测的研究

余涛涛¹, 江 柯², 高 鹏¹

(1. 中国民用航空飞行学院 空中交通管理学院, 四川 广汉 618307; 2. 峨眉山市气象局, 四川 乐山 614200)

摘要:强降水等恶劣天气对于民航的正常运行有着极大的危害,降水量的准确预测有助于民航等企业安全稳定运行。通过对机场跑道自动气象观测系统(AWOS)收集的降水时序数据进行预处理,为深度学习提供训练和测试的样本集,然后分别构建长短期记忆模型(LSTM)和时序卷积网络(TCN)模型,实现对未来1~3 h降水量的预测,并对两个模型的预测精度进行比较分析。结果表明,TCN模型的预测效果优于LSTM模型。其中,对未来1~3 h降水量的预测中,TCN模型的 R^2 分别为0.96、0.91和0.86。

关键词:降水量预测;长短期记忆模型(LSTM);时序卷积网络(TCN)

中图分类号:TP183;TP391.4 **文献标志码:**A **文章编号:**1671-1807(2023)07-0235-06

近年来,强降水等恶劣天气频发,造成了很大的经济损失甚至威胁人民的生命安全,而降水问题本身就是一个随机事件,且受到地理位置、气候等多重因素的影响。降水预报的准确性越高,越有利于企业和地区获悉强降水的状况,进而对可能的灾情进行提前布控,防灾防涝。对于民航等企业,“未来两小时内某目的地有强降雨”比“今天某目的地有雨”更加有意义,从中也凸显降水预报的价值。

现有的预报模式主要是数值预报,其模型大多数是基于线性的,这样就无法真实地模拟降水系统的生消演变,且时效性短,故而传统方法在降水短临预报的准确性上难以取得新的突破^[1-2]。随着人工智能迅速发展,其日渐渗透到生活的方方面面,气象领域也开始注重这方面的研究。将人工智能技术与气象研究相结合,并利用其“黑匣子”机制,能够从海量的气象数据中获取有用的信息,通过数据寻求降水系统的规律,这无疑能够为降水短临预报提供了新的可靠的方向^[3]。

人工智能方法分为机器学习方法和深度学习方法。机器学习方法诸如随机森林^[4]、BP神经网络^[5]、支持向量机^[6]等,已经被用于降水量的预测,并取得了不错的效果,但是它们很难对降水这种时序问题进行识别,故其预测精度有待提高。而深度学习方法中长短期记忆模型(LSTM)^[7]恰好可以解决这一问题。张丽婷等^[8]针对扬州市区1960—2019年8种气象基

本要素数据,采用LSTM对降水量进行预报,结果表明效果优于传统季节性自回归积分滑动平均模型。沈皓俊等^[9]采用LSTM预测2014—2015年中国夏季降水,结果表明LSTM效果优于BP神经网络。同时近年来很多研究实验表明,特定的卷积神经网络可以达到很好的效果^[10],其中时序卷积网络(TCN)对于MNIST数据集,在多种任务上能够达到甚至优于标准LSTM的效果^[11],并在语音识别^[12]、天气预报^[13]等领域取得了不错的实验效果。鉴于此,通过构建LSTM和TCN两种预测模型对茅台机场未来1~3 h降水量进行预测。

自动气象观测系统(AWOS)提供了茅台机场3年(2017—2019年)的降水数据,即收集了1 min 4次的能见度、风速和风向数据,1 min 1次的湿度、温度和机场修正海平面气压数据,其时间分辨率较高。针对数据出现缺测、异常等情况,利用前向填充和均值平滑法对数据进行处理,其中对于1 min 4次的时间分辨率较高的数据,采用前向填充法即用前一值代替后面的缺测值,而对于1 min 1次的的数据,采用均值平滑法,即用临近时间的均值来代替中间的缺省值^[14]。最终,通过Python等工具将原有的数据处理成逐小时的观测数据,以便模型使用。

选取茅台机场2017年1月至2019年12月的逐小时实测降水量数据作为研究对象。其变化曲线以及月降水量如图1所示。受诸多因素的影响,

收稿日期:2022-10-10

作者简介:余涛涛(1996—),男,河南信阳人,中国民用航空飞行学院空中交通管理学院,硕士研究生,研究方向为航空气象、人工智能;江柯(1996—),女,四川成都人,峨眉山市气象局,硕士,研究方向为航空气象、数据分析;高鹏(1997—),男,四川成都人,中国民用航空飞行学院空中交通管理学院,硕士研究生,研究方向为航空气象、人工智能。

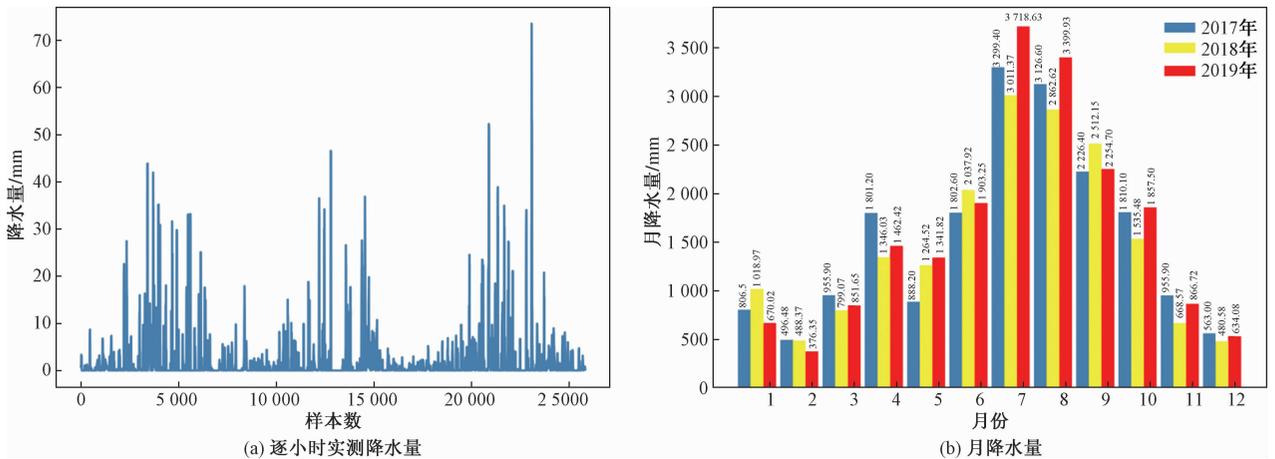


图 1 2017—2019 年逐小时实测降水量以及月降水量分布

降水量随机性较强,该地每年降水集中于 7 月和 8 月,2017—2019 年 7 月和 8 月的平均降水量分别为 3 343.13 mm 和 3 129.72 mm。

1 研究方法原理和模型建立

1.1 LSTM 神经网络

LSTM 与 RNN(循环神经网络)的本质区别是前者利用 LSTM 细胞将后者的隐含层单元进行替换^[7]。长时序预测采用 RNN 会导致逐步偏导项相乘产生梯度爆炸和梯度消失的问题,而采用 LSTM 则可以避免该问题产生。LSTM 的结构如图 2 所示,该模型主要包含细胞状态、输入门、输出门、遗忘门等 4 个部分。

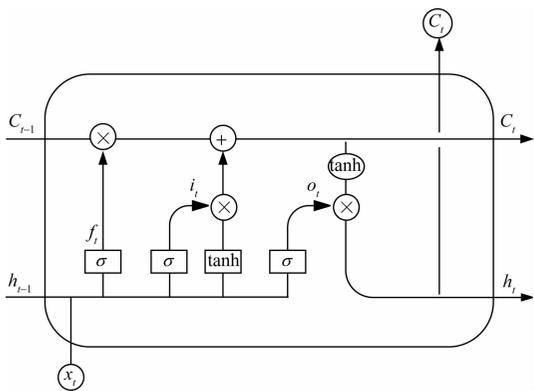


图 2 LSTM 结构单元

1) 遗忘门(forget gate)决定细胞状态信息的遗忘与丢弃程度,公式为

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

2) 输入门(input gate)可以决定当前时刻保存至单元状态的某些信息内容,公式为

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (3)$$

3) 细胞状态(cell state)。更新细胞状态 C_t 主

要由细胞输出门和模型遗忘门两部分的输出结果决定,公式为

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (4)$$

4) 输出门(output gate)。最后 LSTM 的输出内容主要有两部分,一是 LSTM 细胞在当前时刻的状态,二是在当前时刻 LSTM 细胞的隐藏状态,公式为

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = O_t \tanh C_t \quad (6)$$

1.2 TCN 神经网络

TCN 是利用卷积网络来处理时序数据的一种新方法^[11],可以作为 RNN 的替代处理序列任务,其模型结构如图 3 所示。

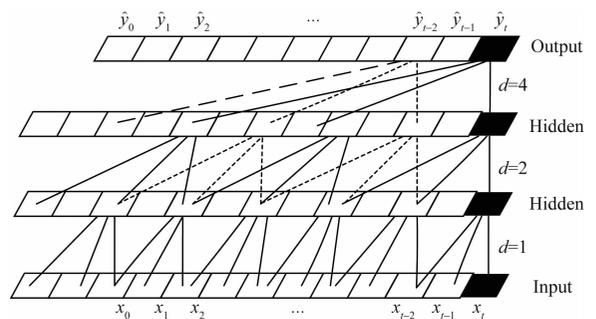


图 3 TCN 模型结构

1) 因果卷积(causal convolution)。因果卷积只对当前时刻之前的数据作出响应,从而避免普通卷积可能导致信息泄露的发生,公式为

$$p(x) = \prod_{i=1}^T p(x_i/x_1, x_2, \dots, x_{i-1}) \quad (7)$$

2) 因果膨胀卷积(causal dilated convolution)。膨胀卷积通过在标准的卷积核中注入“空洞”,达到增加模型的感受域的目的^[14],即在不增加参数的基础上减少因果卷积的深度,公式为

$$F(s) = (x_d^* f)(s) = \sum_{i=0}^{k-1} f(i)x_{s-di} \quad (8)$$

式中: d 为每层的膨胀系数; k 为卷积核的大小; $s-di$ 为对之前时频信息的索引。

3) 残差连接(residual connections)。残差连接可使网络以跨层方式传递信息,在一定程度上消除了深度网络部分梯度消失和爆炸的影响,且这样设计的 TCN 结构提高了泛化能力,公式为

$$o = \text{Activation}[x + F(x)] \quad (9)$$

式中: o 表示残差模块以 x 作为输入,经过一系列变换与 $F(x)$ 相加,作为整个残差模块的输出。

1.3 模型构建

降水量时间序列预测考虑了能见度、风向、风速、温度、湿度、气压以及历史降水信息等 7 个同频气候因子,并以逐小时降水量为目标变量,构造样本集。

降水量预测模型构建步骤如下。

1) 将处理过的站点数据进行归一化,这样可以避免样本之间的量纲差异带来的不必要误差,公式为

$$X = \frac{X - X_{\text{mean}}}{X_{\text{std}}} \quad (10)$$

式中:得到变换后的 X 即为样本数据归一化的结果。

2) 初始化模型参数。将样本数据划分为训练集和测试集,将训练样本加载至工作环境后分别设置目标变量与解释变量,并进行初始学习。对于 LSTM 和 TCN 模型,设定其神经元数量 C 及学习率 ϵ 和训练迭代次数 k 的区间。

3) 利用 LSTM 和 TCN 的内置精度评估函数确定模型关键参数。运用 Adam 优化算法最终确定 LSTM 和 TCN 模型中的 C 、学习率 ϵ 、训练迭代次数 k ,便于分析比较。

4) 选择参数优化过的模型作为预测模型,预测验证样本。

5) 导出预测结果并将其反标准化,得到最终预测结果。

6) 对两个模型进行可视化分析和性能评估。

2 实验结果及分析

2.1 实验设置

实验基于 Pytorch 深度学习框架,使用 python 语言在 Jupyter notebook 上实现。将处理好的降水数据划分为训练集和测试集共 25 800 个,训练集和测试集的比例设置为 8:2,即将 2017 年 1 月至 2019 年 4 月作为训练样本,用于模型的训练,2019 年 5 月至 2019 年 12 月作为测试样本,用于模型的验证和评估。

其中,为了更好地看出两个模型的效果,将 2019 年 7—8 月的测试样本进行实测值和观测值展示。同时,为了保证实验的公正性,将各对比优化算法的初始参数设置为相同的值,用同样的数据集进行实验。其中将两个模型的神经元个数设置为 64,使用了 Adam 优化器^[15-16],采用了 MSE loss 损失函数^[17]引导模型去学习,学习率设置为 0.000 1,迭代次数设置为 60,dropout 为 0.1。这里窗口长度 L 设置为 3,利用前 3 h 的温度、湿度、风向、气压、风速、能见度以及降水量作为两个模型的输入,去预测第 4~6 小时降水量的大小,即利用过去 3 h 的降水序列数据去预测未来 1~3 h 降水量的变化。

对于模型预测性能的衡量,采用均方根误差(RMSE)、平均绝对误差(MAE)、 R^2 相关系数进行误差分析,计算公式分别为

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (11)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (12)$$

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (13)$$

式中: y_i 和 \hat{y}_i 分别对应预测值和真实值,其中 RMSE 和 MAE 取值范围在 $[0, +\infty)$,其值越小表明模型越好, R^2 相关系数范围在 $[0, 1]$,其值越接近 1,模型越好。

2.2 LSTM 和 TCN 模型效果对比分析

为了证明 LSTM 和 TCN 降水预测模型的有效性和预测精度,实验采用了对比的方式,将 TCN 模型和 LSTM 在训练和测试中的表现进行了比较,即在训练中比较两个模型的损失迭代图,以验证方法的有效性,在测试中比较两个模型的评价指标,并使用 2019 年 7—8 月共计 1 460 个样本进行可视化结果分析。

2.2.1 LSTM 和 TCN 模型对未来 1 h 降水量的预测效果

利用过去 3 h 的降水序列数据去预测未来 1 h 降水量,两个模型在训练集和验证集上的 loss 曲线、实测值和预测值拟合曲线以及性能评价结果分别如图 4、图 5 和表 1 所示。

从图 4、图 5 可见,两个模型在对未来 1 h 降水量的预测都能取得不错的效果;从表 1 可见,TCN 模型的 R^2 可达 0.96, MAE 和 RMSE 值分别为 0.65、2.04 mm,均优于 LSTM。

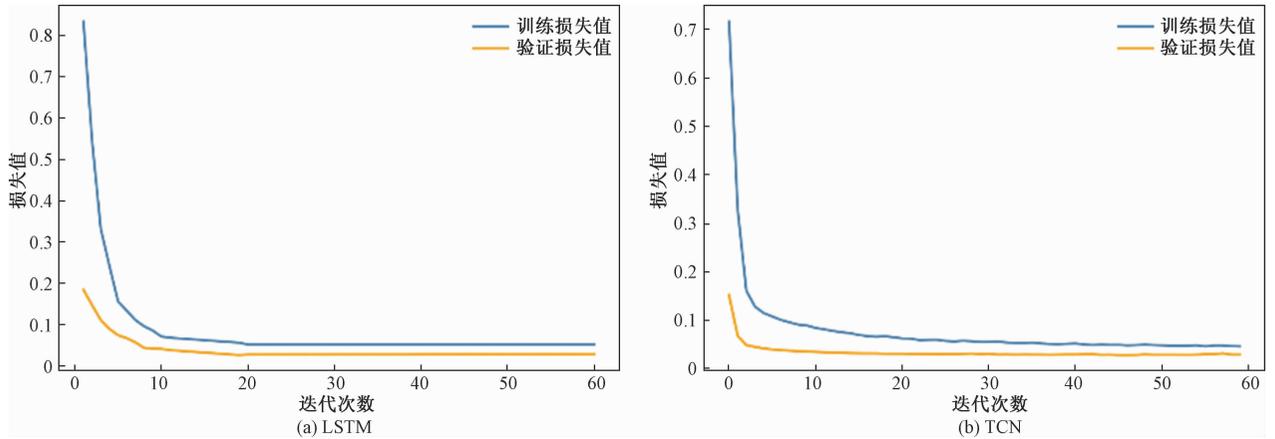


图 4 LSTM 和 TCN 模型预测未来 1 h 的损失迭代图

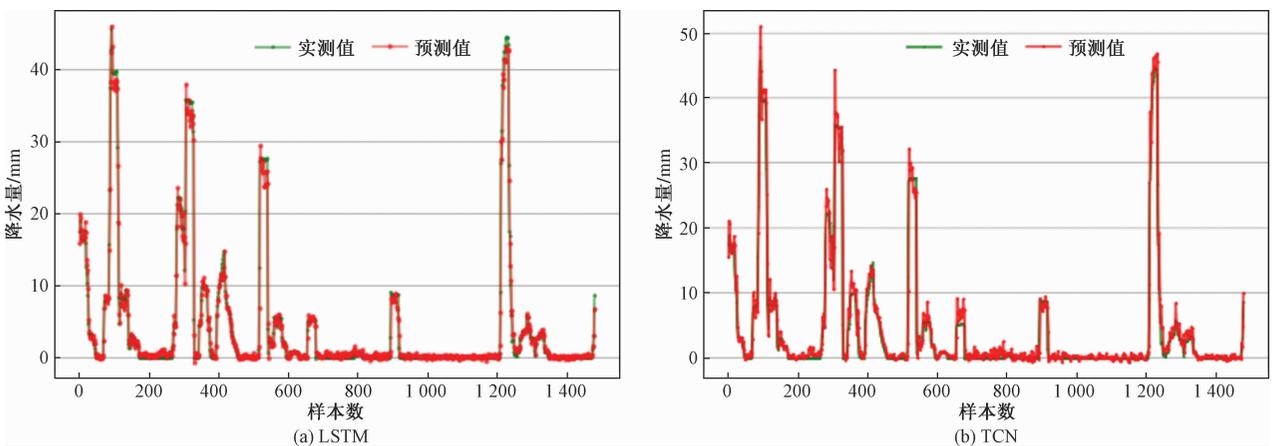


图 5 LSTM 和 TCN 模型未来 1 h 的降水量预测值与实测值拟合曲线对比

表 1 模型预测评价结果

模型	MAE	RMSE	R^2
LSTM	0.67	2.20	0.95
TCN	0.65	2.04	0.96

2.2.2 LSTM 和 TCN 模型对未来 2 h 降水量的预测效果

利用过去 3 h 的降水序列数据去预测未来 2 h 降水量,两个模型在训练集和验证集上的 loss 曲线、

实测值和预测值拟合曲线以及性能评价结果分别如图 6、图 7 和表 2 所示。

从图 6、图 7 可以看出,两个模型仍能保证良好的效果,但是在峰值处会出现偏高预测;从表 2 可见,两个模型的性能均在变差,TCN 模型的 MAE、RMSE、 R^2 分别为 0.97 mm、2.84 mm 和 0.91,其表现仍优于 LSTM。

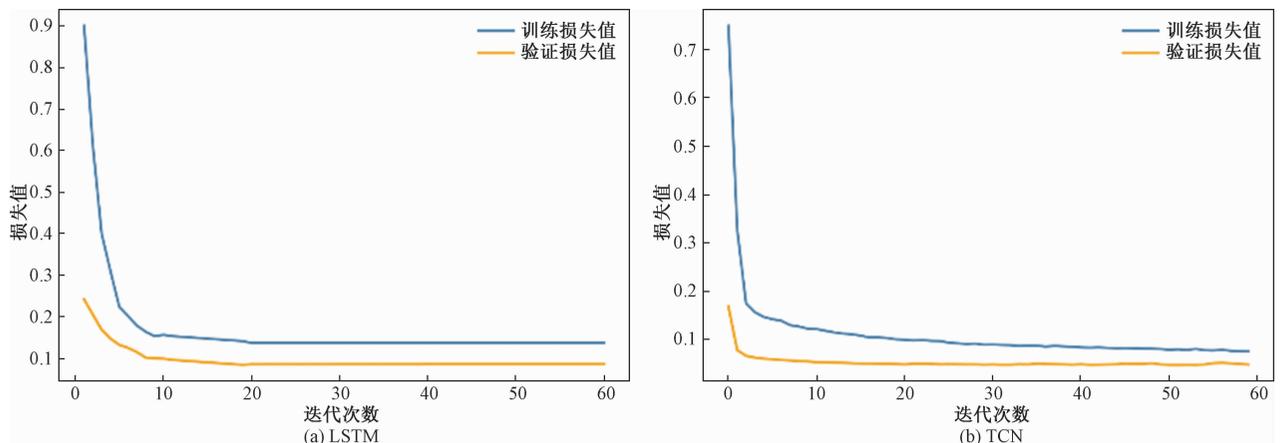


图 6 LSTM 和 TCN 模型预测未来 2 h 的损失迭代图

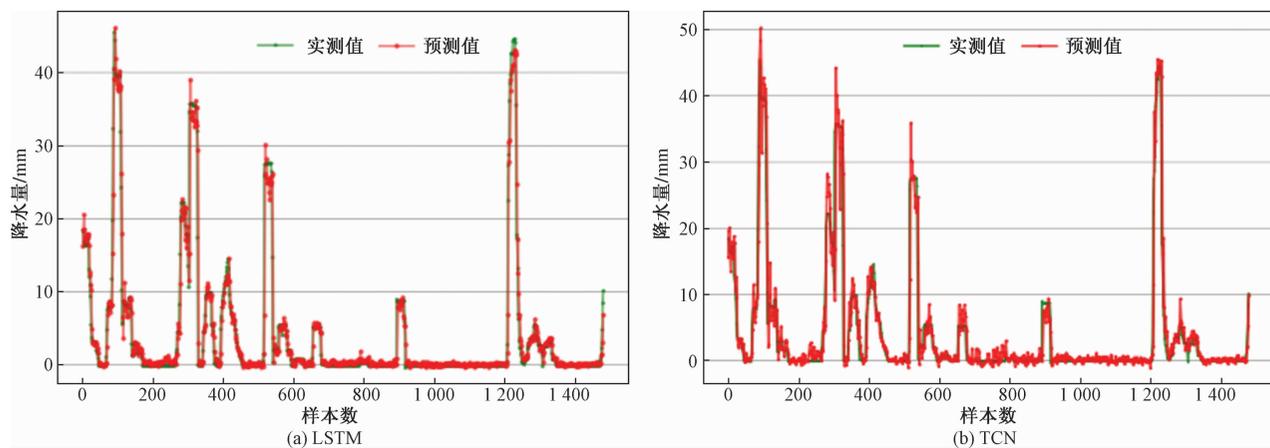


图7 LSTM和TCN模型未来2h的降水量预测值与实测值拟合曲线对比

表2 模型预测评价结果

模型	MAE	RMSE	R^2
LSTM	1.02	3.10	0.89
TCN	0.97	2.87	0.91

2.2.3 LSTM和TCN模型对未来3h降水量的预测效果

利用过去3h的降水序列数据去预测未来3h

降水量,两个模型在训练集和验证集上的 loss 曲线、实测值和预测值拟合曲线以及性能评价结果分别如图8、图9和表3所示。

从图8、图9可以看出,两个模型可视化的结果在峰值处的偏差加大,整体仍然可观;从表3可见,两个模型的性能变得很差,但在 R^2 上的表现仍能满足需要,LSTM可达0.84,而较优的TCN模型可达0.86。

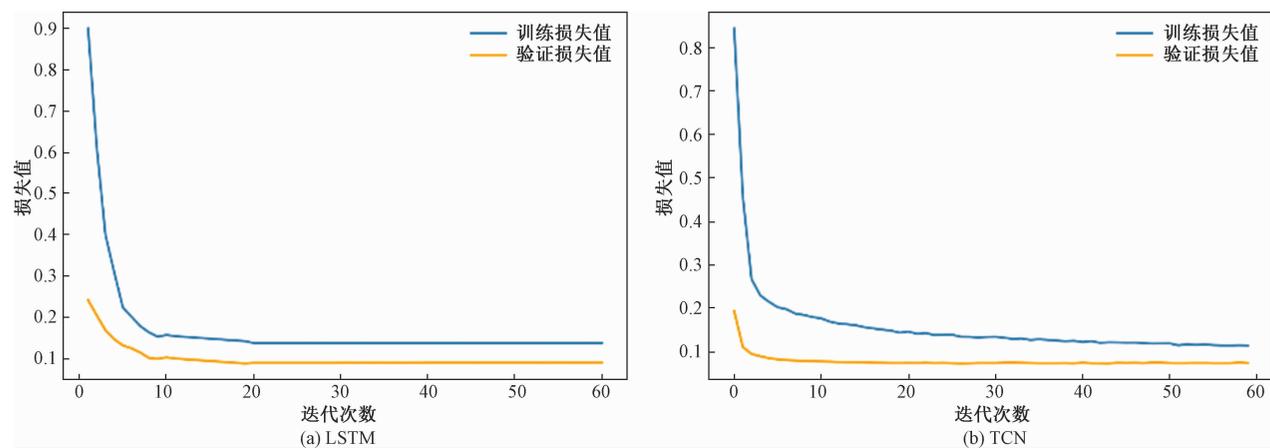


图8 LSTM和TCN模型预测未来3h的损失迭代图

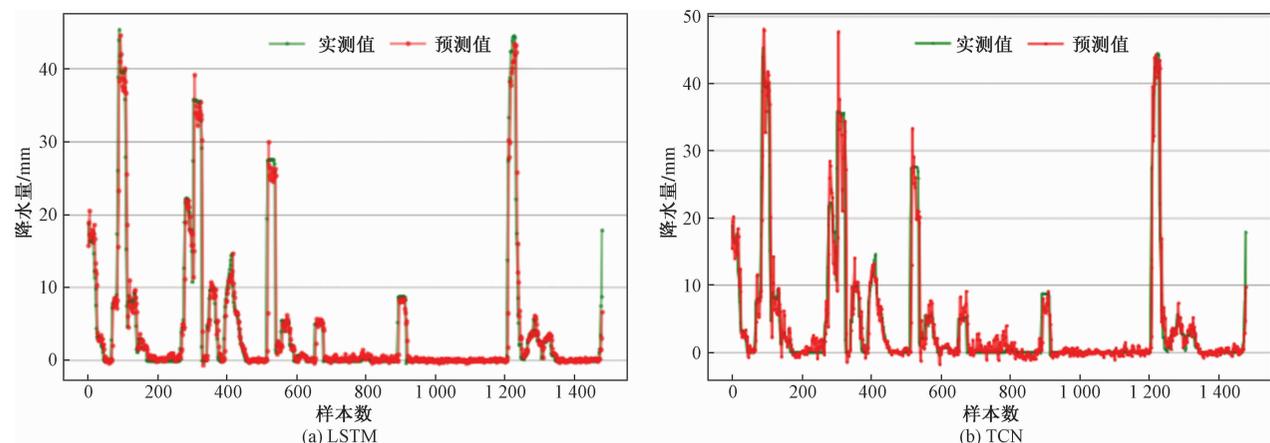


图9 LSTM和TCN模型未来3h的降水量预测值与实测值拟合曲线对比

表3 模型预测评价结果

模型	MAE	RMSE	R^2
LSTM	1.31	3.83	0.84
TCN	1.23	3.76	0.86

3 结论

以降水量为研究对象,分别构建 LSTM 和 TCN 预测模型,为了评估提出的方法的有效性,基于茅台机场 AWOS 系统采集构建的数据集对两个模型进行训练,并根据 MAE、RMSE 和 R^2 指标对模型进行评价。实验结果表明,两个模型在对未来 1~3 h 的降水量的预测上都表现出了良好效果,且 TCN 模型在 RMSE、MAE、 R^2 上的结果要优于 LSTM,这为降水预测提供了一种可靠有效的方法。通过两模型对机场降水量的有效预测,有助于提高对降水量预测的正确率,有利于机场稳定可靠地运行,进而对民航业的发展有着重要意义。

参考文献

- [1] 刘雅忱. 人工智能下深度学习在气象预报中应用综述[J]. 计算机产品与流通, 2020(11): 121, 135.
- [2] 方巍, 庞林, 王楠, 等. 人工智能在短临降水预报中应用研究综述[J]. 南京信息工程大学学报(自然科学版), 2020, 12(4): 406-420.
- [3] SAINATH T N, VINYALS O, SENIOR A, et al. Convolutional, long short-term memory, fully connected deep neural networks[C]//2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). South Brisbane: IEEE, 2015: 4580-4584.
- [4] PRIMAJAYA A, SARI B N. Random forest algorithm for prediction of precipitation[J]. Indonesian Journal of Artificial Intelligence and Data Mining, 2018, 1(1): 27-31.
- [5] GUAN Z, TIAN Z, XU Y, et al. Rain fall predict and comparing research based on Arcgis and BP neural network [C]//2016 3rd International Conference on Materials En-

gineering, Manufacturing Technology and Control. Atlantis: Atlantis Press, 2016: 1509-1514.

- [6] YU P S, YANG T C, CHEN S Y, et al. Comparison of random forests and support vector machine for real-time radar-derived rainfall forecasting[J]. Journal of Hydrology, 2017, 552: 92-104.
- [7] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [8] 张丽婷, 李鹏飞, 庞文静, 等. 基于季节性自回归积分滑动平均与深度学习长短期记忆神经网络的降水量预测[J]. 科学技术与工程, 2022, 22(9): 3453-3463.
- [9] 沈皓俊, 罗勇, 赵宗慈, 等. 基于 LSTM 网络的中国夏季降水预测研究[J]. 气候变化研究进展, 2020, 16(3): 263-275.
- [10] OORD A, DIELEMAN S, ZEN H, et al. Wavenet: a generative model for raw audio[J]. arXiv Preprint arXiv, 2016: 1609. 03499.
- [11] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. arXiv Preprint arXiv, 2018: 1803. 01271.
- [12] KISHORE V, TIWARI N, PARAMASIVAM P. Improved speech enhancement using TCN with multiple encoder-decoder layers[J]. Interspeech, 2020: 4531-4535.
- [13] HEWAGE P, BEHERA A, TROVATI M, et al. Temporal convolutional neural (TCN) network for an effective weather forecasting using time-series data from the local weather station [J]. Soft Computing, 2020, 24(21): 16453-16482.
- [14] 江柯. 茅台机场雾天气的客观预报方法研究[D]. 广汉: 中国民用航空飞行学院, 2022.
- [15] 黄颖, 杨会杰. 基于 XGBoost 和 LSTM 模型的金融时间序列预测[J]. 科技和产业, 2021, 21(8): 158-162.
- [16] 王愈轩, 梁沁雯, 章思远, 等. 基于 LSTM-XGboost 组合的超短期风电功率预测方法[J]. 科学技术与工程, 2022, 22(14): 5629-5635.
- [17] 王欣, 孟天宇, 周俊曦. 基于注意力与 LSTM 的航空发动机剩余寿命预测[J]. 科学技术与工程, 2022, 22(7): 2784-2792.

Research on Precipitation Prediction of Maotai Airport Based on Deep Learning

YU Taotao¹, JIANG Ke², GAO Peng¹

(1. School of Air Traffic Management, Civil Aviation Flight University of China, Guanghan 618307, Sichuan, China;

2. Emeishan Meteorological Bureau, Leshan 614200, Sichuan, China)

Abstract: Severe weather such as heavy precipitation is of great harm to the normal operation of civil aviation. The accurate prediction of precipitation is helpful to the safe and stable operation of civil aviation and other enterprises. By preprocessing the precipitation time series data collected by automatic meteorological observation of airport runway system(AWOS), training and testing sample sets are provided for deep learning. Then, long short-term memory model (LSTM) and time series convolution network (TCN) models are constructed respectively to realize the prediction of precipitation in the next 1 to 3 hours. Then, the prediction accuracy of the two models is compared and analyzed. The results show that the prediction performance of TCN model is better than that of LSTM model. The R^2 of TCN model is 0.96, 0.91 and 0.86 for the forecast of precipitation in the next 1 to 3 hours, respectively.

Keywords: precipitation forecast; long short-term memory model(LSTM); time series convolution network(TCN)