

基于ConvLSTM的四川省逐小时气温预报模型

李雨虹¹, 赵 涛¹, 刘 娜², 肖梓涵^{3*}

¹四川省绵阳市三台县气象局, 四川 绵阳

²成都信息工程大学大气科学学院, 四川 成都

³成都信息工程大学光电工程(人工影响天气)学院, 四川 成都

收稿日期: 2026年6月22日; 录用日期: 2026年8月25日; 发布日期: 2026年9月2日

摘 要

准确的逐小时气温预报对于农业生产、能源调度、灾害预警等领域具有重要意义。四川省地形复杂多样, 气候特征区域差异显著, 传统数值预报方法在该区域的预报精度面临挑战。本研究基于ERA5再分析数据, 构建了轻量级卷积长短期记忆网络(LightConvLSTM)模型, 对四川省逐小时2米气温进行预报。模型输入包括历史24小时的气温、纬向风、经向风和比湿数据, 输出未来1小时的气温预报。研究采用2000~2023年数据进行模型训练, 以2024年全年数据进行独立验证。结果表明: 模型在测试集上的平均绝对误差(MAE)为0.608℃, 均方根误差(RMSE)为0.892℃, 相关系数(R)达到0.997。模型在夏季(6~8月)表现最优, 逐月MAE为0.16℃~0.27℃; 冬季(12~2月)相对较差, 逐月MAE为0.47℃~0.51℃。空间分析显示, 模型在四川盆地东部和南部地区预报精度较高, 而在西部高原地区误差略大。结果表明, LightConvLSTM对四川复杂地形下逐小时气温具有良好预报能力, 可为精细化气温预报提供技术参考。

关键词

气温预报, ConvLSTM, 深度学习

ConvLSTM-Based Hourly Temperature Forecast Model for Sichuan Province

Yuhong Li¹, Tao Zhao¹, Na Liu², Zihan Xiao^{3*}

¹Santai County Meteorological Bureau, Mianyang City, Sichuan Province, Mianyang Sichuan

²School of Atmospheric Sciences, Chengdu University of Information Technology, Chengdu Sichuan

³College of Optoelectronic Engineering (College of Weather Modification), Chengdu University of Information Technology, Chengdu Sichuan

Received: June 22, 2026; accepted: August 25, 2026; published: September 2, 2026

*通讯作者。

文章引用: 李雨虹, 赵涛, 刘娜, 肖梓涵. 基于 ConvLSTM 的四川省逐小时气温预报模型[J]. 自然科学, 2026, 14(5): 563-572. DOI: 10.12677/ojns.2026.145060

Abstract

Accurate hourly temperature forecasting holds significant importance for agricultural production, energy dispatch, and disaster early warning. Sichuan Province features complex and diverse topography, with substantial regional variations in climatic characteristics, posing challenges to the forecast accuracy of traditional numerical prediction methods in this region. This study develops a lightweight Convolutional Long Short-Term Memory (LightConvLSTM) model based on ERA5 reanalysis data for hourly 2-meter temperature forecasting in Sichuan Province. The model inputs comprise historical 24-hour data of temperature, zonal wind, meridional wind, and specific humidity, with outputs being 1-hour-ahead temperature forecasts. The model was trained using data from 2000 to 2023 and independently validated against data from the entire year of 2024. The results demonstrate that the model achieves a Mean Absolute Error (MAE) of 0.608°C, a Root Mean Square Error (RMSE) of 0.892°C, and a correlation coefficient (R) of 0.997 on the test set. The model exhibits optimal performance during summer (June–August), with monthly MAE ranging from 0.16°C to 0.27°C, whereas relatively inferior performance is observed in winter (December–February), with monthly MAE ranging from 0.47°C to 0.51°C. Spatial analysis reveals that the model attains higher forecast accuracy in the eastern and southern regions of the Sichuan Basin, while slightly larger errors are found in the western plateau region. These results indicate that the LightConvLSTM model possesses robust forecasting capability for hourly temperature under the complex terrain of Sichuan Province, offering a technical reference for refined temperature prediction.

Keywords

Temperature Forecasting, ConvLSTM, Deep Learning

Copyright © 2026 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

气温是关键气象要素，高精度逐小时气温预报对农业生产、能源调度、交通运营及灾害预警具有重要支撑作用。随着全球气候变化加剧和极端天气事件频发，对高精度、高时效性的气温预报需求日益迫切。

传统的数值天气预报(Numerical Weather Prediction, NWP)方法基于大气物理方程组，通过超级计算机求解复杂的偏微分方程来实现天气预测。Hersbach 等[1]指出，ERA5 作为最先进的再分析产品之一，水平分辨率约 31 km 且逐小时输出，但 NWP 方法计算成本高、对初始条件敏感、参数化存在不确定性，复杂地形区预报精度受限。

ConvLSTM (Convolutional LSTM)作为一种融合卷积神经网络(CNN)和长短期记忆网络(LSTM)的深度学习架构，能够有效捕捉气象要素的时空特征。Shi 等[2]将 ConvLSTM 应用于降水预报，把降水预测重构为时空序列预测任务，实验结果表明，该模型相比全连接 LSTM 及传统业务算法(ROVER)，能更有效捕捉时空依赖关系，预报性能显著提升。Lin 等[3]将 ConvLSTM 网络应用于数值温度预报的释用，构建了面向温度偏差的时空预测模型(PredTemp)，显著提升了温度预报精度。

在国内气象预报领域，杨绚等[4]指出深度学习方法在气象要素预报中具有巨大潜力。范宇恩等[5]和赵琳娜等[6]别利用 BP 神经网络和全连接神经网络开展气温预报研究，验证了深度学习的有效性。本研

研究与上述结论相互印证,进一步证明了深度学习在气象预报中的应用价值。

四川省位于中国西南部,地形复杂多样,包括四川盆地、川西北高原和川西南山地三大地貌单元,研究表明,这种复杂的地形条件导致四川省气候特征区域差异显著,气温变化规律复杂,气温预报难度较大[7][8]。

ERA5 再分析数据是 ECMWF 发布的全球第五代再分析产品,具有时空分辨率高、数据质量优等特点,已被广泛应用于气象研究和业务预报,在描述中国区域气候特征方面具有良好表现[9]。

本研究基于 ERA5 再分析数据,构建了适用于四川省的轻量级 LightConvLSTM 逐小时气温预报模型,系统评估了该模型在不同季节和不同区域的预报性能,深入分析了季节变化对预报精度的影响机制,并开展了详细的空间误差分析,探讨了模型在不同地形区域的预报能力差异及其可能原因。

2. 数据与方法

2.1. 研究区域

研究区域为四川省,地理范围为 26.0°N~34.5°N, 97.5°E~108.5°E。四川省地形复杂,东部为四川盆地,海拔约 300~700 米,盆地内丘陵平原交错,属亚热带湿润季风气候,四季分明,夏季炎热多雨,冬季温和少雪;西部为青藏高原东缘和横断山脉,海拔多在 3000 米以上,地形起伏剧烈,属高原山地气候,冬季漫长寒冷,夏季凉爽,昼夜温差大。巨大的地形落差导致区域气候差异显著,局地小气候多样,山谷风效应明显,气温垂直梯度大。

2.2. 数据来源与预处理

本研究使用 ERA5 再分析数据作为训练和验证样本。ERA5 是 ECMWF 发布的全球第五代再分析产品,提供从 1940 年至今的全球大气、陆地和海洋气候数据。本研究选取以下变量:(1) 2 米气温(t2m),单位为 K;(2) 纬向风(u),单位为 m/s;(3) 经向风(v),单位为 m/s;(4) 比湿(q),单位为 kg/kg。数据空间分辨率为 0.25°×0.25°,时间分辨率为 1 小时。选取上述变量的依据是:2 米气温是预报目标变量;风场变量能够表征大气平流输送过程,对温度变化具有重要的动力和热力作用;比湿变量与大气中的相变过程和辐射传输密切相关,间接影响温度变化。四变量联合输入有助于模型全面捕捉影响温度变化的物理过程。

研究时间跨度为 2000 年 1 月 1 日至 2024 年 12 月 31 日,共 25 年数据。其中 2000~2023 年数据用于模型训练(前 70%的数据作为训练集用于模型参数优化,中间 15%作为验证集用于超参数调优与早停策略,最后 15%作为测试集用于模型泛化性能评估),2024 年全年数据作为独立测试集,用于评估模型的泛化能力和实际预报性能。

对原始 ERA5 数据进行以下预处理:(1) 空间裁剪:提取四川省范围内的格点数据;(2) 单位转换:将气温从开尔文转换为摄氏度;(3) 标准化:对各变量进行 Z-score 标准化处理,消除不同变量量纲差异对模型训练的影响。标准公式为:

$$x' = \frac{x - \mu}{\sigma} \quad (1)$$

其中 μ 和 σ 分别为各变量的均值和标准差,基于训练集数据计算得到,并应用于验证集和测试集,以确保数据处理的统一性和可比性。

2.3. LightConvLSTM 模型

LightConvLSTM 是卷积神经网络(CNN)和长短期记忆网络(LSTM)的结合体,与传统 LSTM 不同,LightConvLSTM 在状态转换中使用卷积操作代替全连接操作,能够同时捕捉时间序列的时间依赖性和空

间数据的空间相关性，非常适合处理具有时空耦合特征的气象数据。

本研究构建的 LightConvLSTM 模型具有以下优势：(1) 轻量级设计：模型参数量少，训练和推理速度快，适合业务化应用；(2) 端到端学习：直接从原始气象数据学习预报规律，无需人工特征工程；(3) 时空特征融合：ConvLSTM 架构能够同时捕捉时间依赖性和空间相关性；(4) 可扩展性强：模型架构易于扩展到多要素预报和多步预报任务。

核心方程如下：

$$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + b_i) \quad (2)$$

$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + b_f) \quad (3)$$

$$o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + b_o) \quad (4)$$

$$g_t = \tanh(W_{xg} * X_t + W_{hg} * H_{t-1} + b_g) \quad (5)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ g_t \quad (6)$$

$$H_t = o_t \circ \tanh(C_t) \quad (7)$$

式中， $*$ 表示卷积操作， $\circ$ 表示 Hadamard 积(逐元素乘法)， $\tanh$ 为双曲正切激活函数。 i_t 、 f_t 、 o_t 分别表示输入门、遗忘门和输出门的激活值， C_t 和 H_t 分别表示细胞状态和隐藏状态， X_t 为 t 时刻的输入特征， W 和 b 分别为卷积核权重和偏置项。

本研究构建的 LightConvLSTM 模型采用轻量级设计思路，在保证预报精度的前提下尽量降低模型复杂度，以提高训练和推理效率。主要参数如下：输入序列长度为 24 小时，即利用过去 24 小时的气象数据预报未来 1 小时的气温；预测步长为 1 小时；输入特征维度为 4(气温、纬向风、经向风、比湿)；隐藏层维度为 16，在模型表达能力和计算效率之间取得平衡；卷积核大小为 3×3 ，能够有效捕捉局部空间特征；模型层数为 1 层。模型输出层采用 1×1 卷积将隐藏状态映射为单通道的气温预报，模型架构示意图如图 1 所示。

2.4. 模型训练




Figure 1. LightConvLSTM model architecture diagram
图 1. LightConvLSTM 模型架构示意图

模型训练采用 Adam 优化器，初始学习率设置为 0.001，批次大小为 32，最大训练轮次设置为 30 个 epoch。损失函数采用均方误差(MSE)，以衡量预报值与实况值之间的偏差。训练过程中使用学习率衰减策略，当验证集损失连续 5 个 epoch 未下降时，将学习率减半，以提升模型收敛稳定性。同时设置早停机制，当验证集损失连续 10 个 epoch 未下降时，则终止训练并保存验证集损失最低的模型权重，避免过度拟合。模型在 PyTorch 2.0 深度学习框架下实现，使用 NVIDIA RTX 4090 GPU 进行加速训练。

2.5. 评估指标

为全面评价模型预报性能，选取以下 5 项指标：

(1) 平均绝对误差(MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

(2) 均方根误差(RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

(3) 决定系数(R^2):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (10)$$

(4) 平均偏差(Bias):

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

(5) 相关系数(R):

$$R = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \cdot \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}} \quad (12)$$

式中， y_i 为实况值， $\hat{y}_i$ 为预报值， $\bar{y}$ 为实况平均值， $\bar{\hat{y}}$ 为预报平均值， N 为样本总数。

MAE、RMSE、Bias 越接近 0 表示预报精度越高， R^2 和 R 越接近 1 表示预报值与实况值一致性越好。

3. 结果与分析

3.1. 整体预报性能

Table 1. Overall forecast error metrics on the 2024 independent validation set

表 1. 2024 年独立验证集预报误差指标

评估指标	数值
MAE	0.608℃
RMSE	0.892℃
R	0.997℃
R^2	0.994℃
Bias	0.121℃

模型在 2024 年独立测试集上的整体预报性能如表 1 所示。由表可知, 该模型综合预报表现良好: MAE 为 0.608°C , 平均误差约 0.6°C ; RMSE 为 0.892°C , 误差分布整体集中, 仅存在少量极端值; R 为 0.997 , R^2 为 0.994 , 表明预报值与观测值线性相关性极强, 可解释 99.4% 的气温变异; Bias 为 0.121°C , 存在轻微系统性正偏差, 但在实际应用中可接受。

3.2. 模型对比验证

为进一步验证 LightConvLSTM 模型的预报技巧, 本研究引入 Persistence 预报和 LightGBM 模型作为基准, 在 3 h、6 h、12 h、24 h 四个预报步长下进行对比试验。




Figure 2. (1) Comprehensive Metrics Comparison by Forecast Lead Time: (a) MAE; (b) RMSE; (c) R^2 ; (d) Pearson correlation coefficient. (2) Variation trends of MAE and RMSE for different models at various forecast lead times: (e) MAE; (f) RMSE

图 2. (1) 不同预报时效下的综合指标对比: (a) MAE; (b) RMSE; (c) R^2 ; (d) Pearson 相关系数。 (2) 模型性能比较: (e) MAE; (f) RMSE

图 2(e)、图 2(f)展示了不同预报步长下各模型的 MAE 与 RMSE 变化趋势。Persistence 预报的 MAE 稳定在 12.3℃左右, RMSE 约为 14.4℃, 几乎无预报技巧; LightGBM 的 MAE 约为 6.5℃, RMSE 约为 7.7℃, 虽优于 Persistence, 但由于缺乏时空建模能力, 其误差随预报步长增加无明显改善; ConvLSTM 的 MAE 从 3 h 的 2.4℃递增至 24 h 的 3.6℃, RMSE 从 4.1℃增至 5.0℃, 在所有步长上均显著优于两个基准模型, 充分体现了深度学习架构在时空建模方面的必要性。

图 2(a)~(d)进一步从四个维度对模型性能进行了综合验证。MAE 与 RMSE 柱状图显示, ConvLSTM 在各步长上的误差均显著低于 Persistence 和 LightGBM。 R^2 子图中, Persistence 为负值, 表明其不具备解释气温变异的能力; LightGBM 约为 0.53, ConvLSTM 则达到 0.87 (3 h)至 0.80 (24 h)。Correlation 子图显示, ConvLSTM 的 Pearson 相关系数保持在 0.93 以上, 远高于 LightGBM 的 0.73。综上所述, ConvLSTM 在多步气温预报中展现了优越的时空建模能力与预报技巧。

3.3. 逐月预报性能

为进一步分析模型在不同季节的预报性能, 对 2024 年各月的预报结果进行了详细评估。图 3 展示了模型在 2024 年各月的区域平均时间序列预报结果。结果表明, 该模型能够较好地捕捉气温的日变化和季节变化特征, 预报曲线与观测曲线吻合度高。各月 MAE 范围为 0.16℃~0.51℃, R 均在 0.985 以上, 表明模型在全年各月均保持了较高的预报精度。




Figure 3. The time series of regional average forecast temperature and observed temperature in each month of 2024; the black solid line is the ERA5 live curve, and the red dotted line is the forecast curve

图 3. 2024 年各月区域平均预报气温与观测气温时间序列; 黑色实线为 ERA5 实况曲线, 红色虚线为预报曲线

季节差异方面, 夏季(6~8 月)模型表现最优, MAE 分别为 0.16℃、0.17℃和 0.27℃, R 分别为 0.996、0.995 和 0.994。这可能与夏季气温变化相对平稳、日较差较小有关, 模型更容易学习气温的变化规律。冬季(12~2 月)误差相对较大, MAE 为 0.47℃~0.51℃, 这可能与冬季冷空气活动频繁、气温波动剧烈有

关,增加了预报难度。

3.4. 空间误差分布

图 4 展示了 MAE、RMSE 和 Bias 的空间分布特征和误差直方图分布情况。整体而言,模型误差呈现显著的空间异质性,且误差分布接近对称,系统性偏差较小。

由图 4(a)和图 4(b)可知,模型误差表现出明显的东低西高的空间格局,在四川盆地东部和南部地区预报精度较高(MAE、RMSE 约 $0.4^{\circ}\text{C}\sim 0.6^{\circ}\text{C}$);而在西部高原地区误差略大(MAE、RMSE 达 $0.8^{\circ}\text{C}\sim 1.2^{\circ}\text{C}$)。造成这一空间差异的原因主要包括三方面:高原高海拔导致气温垂直梯度显著,复杂下垫面催生的局地小气候加大了预报难度;ERA5 数据分辨率有限,对地形区中小尺度过程刻画不足;高原观测稀疏,资料同化精度偏低,数据源存在一定误差。图 4(c) Bias 空间分布可知,川西高原北部及西北边缘表现为正偏差,而四川盆地中东部部分区域偏差小,存在轻微负偏差。这种偏差分布与不同下垫面的热力属性差异有关,整体系统性误差控制在可接受范围内。




Figure 4. The spatial distribution characteristics of the test set in 2024; (a) is the spatial distribution of MAE; (b) is the spatial distribution of RMSE; (c) is the spatial distribution of mean deviation; (d) is the distribution of error histogram

图 4. 2024 年测试集空间分布特征; (a) 为 MAE 空间分布, (b) 为 RMSE 空间分布, (c) 为 Bias 空间分布, (d) 为误差直方图分布

图 4(d)误差直方图显示,预报误差近似服从正态分布,均值为 0.121°C ,大部分误差集中在 -1°C 至 1°C 之间,表明模型预报较为稳定,极端误差较少。误差分布的峰值集中在 0 摄氏度附近,说明模型在大多

数情况下能够给出较为准确的预报。图 4(d)中可看出, 误差分布呈现轻微的右偏, 即正向极端误差略多于负向极端误差, 这与图 4(c)中高原地区正偏差的分布特征相呼应。综合来看, 模型在绝大多数格点和时次上能够提供可靠的气温预报, 且不存在明显的系统性偏向。

3.5. 散点图分析




Figure 5. The scatter distribution of regional average hourly temperature forecast and ERA5 observation
图 5. 区域平均逐时气温预报值与 ERA5 实况的散点分布

图 5 为 LightConvLSTM 模型在整个温度范围内均表现出较高的预报精度, 散点整体紧密分布于 1:1 线附近, 仅低端负值区存在偏差。各温度区间的预报稳定性差异并不显著, 0℃~20℃区间点密度高主要源于样本量大, 而非该区间模型性能特别优于其他区间, 同时, 模型对低温的预报能力偏弱, 这可能与极端温度样本占比较少、模型对极端温度特征学习不充分有关。

4. 讨论

4.1. 误差来源分析

模型误差主要来源于以下几个方面: (1) 数据不确定性: ERA5 再分析数据本身存在误差, 数据质量对模型精度有直接影响; (2) 模型简化: LightConvLSTM 作为数据驱动方法, 未能显式融入大气物理约束, 在某些物理过程显著的场合可能表现不足; (3) 预报时效: 本研究仅进行 1 小时预报, 随着预报时效延长, 误差可能累积增大; (4) 极端天气影响: 在强对流天气、寒潮等极端天气过程中, 气温变化剧烈且

物理机制复杂, 模型对极端样本学习不足, 预报精度下降。

4.2. 研究局限性

本研究仍存在一定局限性: (1) 预报时效较短, 仅实现未来 1 小时气温预报, 未评估中长期性能, 后续可扩展至多步预报; (2) 要素单一, 输入涵盖气温、风场、比湿等多要素, 但输出仅气温, 尚未实现多要素联合预报; (3) 模型未考虑地形高程的影响, 对西部高原复杂地形刻画不足, 影响预报精度。

5. 结论

本研究基于 ERA5 再分析数据, 构建了轻量级 LightConvLSTM 模型, 开展四川省逐小时气温预报, 系统评估了模型的整体性能、季节变化特征与空间分布差异。主要结论如下:

(1) 模型在 2024 年独立测试集上整体预报效果表现优异, MAE 为 0.608°C , RMSE 为 0.892°C , R 达 0.997, 表明 LightConvLSTM 能够准确捕捉四川省气温的时空演变规律, 具有预报有效性和可靠性。

(2) 模型在不同季节表现存在差异, 夏季(6~8 月)表现最优, 预报精度最高(MAE 约 0.16°C ~ 0.27°C), 冬季(12~2 月)相对较低(MAE 约 0.47°C ~ 0.51°C), 这与气温变化的季节性特征密切相关。

(3) 空间误差分布呈东低西高格局, 模型在四川盆地东部、南部预报精度较高, MAE 集中在 0.4°C ~ 0.6°C , 而在西部高原地区误差略大, MAE 介于 0.8°C ~ 1.2°C , 主要受地形复杂度和数据质量等影响。

(4) 模型轻量高效、泛化能力强, 可为农业生产、能源调度及灾害预警提供逐小时气温支撑。

基金项目

成都信息工程大学大学生创新创业训练计划项目(X202510621135)。

参考文献

- [1] Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., *et al.* (2020) The ERA5 Global Reanalysis. *Quarterly Journal of the Royal Meteorological Society*, **146**, 1999-2049. <https://doi.org/10.1002/qj.3803>
- [2] Shi, X.J., Chen, Z.R., Wang, H., *et al.* (2015) Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. *29th Annual Conference on Neural Information Processing Systems (NIPS)*, Montreal, 7-12 December 2015, 802-810.
- [3] Lin, H., Hua, Y.Z., Ma, L.M. and Chen, L. (2019) Application of ConvLSTM Network in Numerical Temperature Prediction Interpretation. *Proceedings of the 2019 11th International Conference on Machine Learning and Computing*, Zhuhai, 22-24 February 2019, 109-113. <https://doi.org/10.1145/3318299.3318381>
- [4] 杨绚, 代刊, 朱跃建. 深度学习技术在智能网格天气预报中的应用进展与挑战[J]. 气象学报, 2022, 80(5): 649-667.
- [5] 范宇恩, 宋智, 杨雪, 等. 基于 BP 神经网络拟合四川南部山区焚风过程气温变化的方法[J]. 高原山地气象研究, 2024, 44(3): 95-101.
- [6] 赵琳娜, 卢姝, 齐丹, 等. 基于全连接神经网络方法的日最高气温预报[J]. 应用气象学报, 2022, 33(3): 257-269.
- [7] Ning, G.C., Yim, S.H.L., Wang, S.G., Duan, B., Nie, C., Yang, X., *et al.* (2019) Synergistic Effects of Synoptic Weather Patterns and Topography on Air Quality: A Case of the Sichuan Basin of China. *Climate Dynamics*, **53**, 6729-6744. <https://doi.org/10.1007/s00382-019-04954-3>
- [8] Bannister, D., Herzog, M., Graf, H., Hosking, J.S. and Short, C.A. (2017) An Assessment of Recent and Future Temperature Change over the Sichuan Basin, China, Using CMIP5 Climate Models. *Journal of Climate*, **30**, 6701-6722. <https://doi.org/10.1175/jcli-d-16-0536.1>
- [9] Jiang, Q., Li, W.Y., Fan, Z.D., He, X., Sun, W., Chen, S., *et al.* (2021) Evaluation of the ERA5 Reanalysis Precipitation Dataset over Chinese Mainland. *Journal of Hydrology*, **595**, Article 125660. <https://doi.org/10.1016/j.jhydrol.2020.125660>