

# 基于卷积神经网络的区域温度预报订正研究

董振<sup>1</sup>, 鲍艳松<sup>1,2,3</sup>, 林青<sup>4,5</sup>, 潘宁<sup>4,5</sup>

<sup>1</sup>南京信息工程大学大气物理学院, 江苏 南京

<sup>2</sup>南京信息工程大学气象灾害预报预警与评估协同创新中心, 江苏 南京

<sup>3</sup>南京信息工程大学中国气象局气溶胶-云-降水重点开放实验室, 江苏 南京

<sup>4</sup>福建省灾害天气重点实验室, 福建 福州

<sup>5</sup>福建省气象台, 福建 福州

收稿日期: 2023年2月20日; 录用日期: 2023年4月3日; 发布日期: 2023年4月10日

## 摘要

为提高ECMWF (European Centre for Medium-Range Weather Forecasts)模式2 m温度预报产品的预报精度, 选取2018年~2021年ECMWF模式2 m温度预报产品及CLDAS (CMA Land Data Assimilation System)格点融合数据, 进行了误差分析并使用卷积神经网络模型进行订正研究, 结果表明: 1) ECMWF模式2 m温度预报产品夏季预报精度要高于冬季, 且在转折性低温天气的情况下误差较大; 2) 经过卷积神经网络模型的订正, 2 m温度预报产品精度得到提高, 预报准确率整体提升约5%, 平均绝对误差和均方根误差均降低了0.5°C~0.8°C; 3) 对比传统使用历史长期资料的订正方式, 模型可以使用更少的数据, 达到较好的订正效果, 减少统计工作量。

## 关键词

温度预报, 卷积神经网络, 偏差订正

# Research on the Regional Temperature Forecast Correction Based on Convolutional Neural Network

Zhen Dong<sup>1</sup>, Yansong Bao<sup>1,2,3</sup>, Qing Lin<sup>4,5</sup>, Ning Pan<sup>4,5</sup>

<sup>1</sup>School of Atmospheric Physical, Nanjing University of Information Science & Technology, Nanjing Jiangsu

<sup>2</sup>Collaborative Innovation Center on Forecast and Evaluation of Meteorological Disasters, Nanjing University of Information Science & Technology, Nanjing Jiangsu

<sup>3</sup>Key Laboratory for Aerosol-Cloud-Precipitation of China Meteorological Administration, Nanjing University of Information Science & Technology, Nanjing Jiangsu

<sup>4</sup>Fujian Key Laboratory of Severe Weather, Fuzhou Fujian

<sup>5</sup>Fujian Meteorological Bureau, Fuzhou Fujian

Received: Feb. 20<sup>th</sup>, 2023; accepted: Apr. 3<sup>rd</sup>, 2023; published: Apr. 10<sup>th</sup>, 2023

文章引用: 董振, 鲍艳松, 林青, 潘宁. 基于卷积神经网络的区域温度预报订正研究[J]. 运筹与模糊学, 2023, 13(2): 557-565. DOI: 10.12677/orf.2023.132055

## Abstract

In order to improve the forecast accuracy of ECMWF (European Centre for Medium-Range Weather Forecasts) mode 2 m temperature prediction products, the 2 m temperature prediction products in ECMWF mode from 2018 to 2021 and CLDAS (CMA Land Data Assimilation System) lattice data were selected. The error analysis and the convolutional neural network model are used to carry out the revised research, and the results show that: 1) the summer forecast accuracy of ECMWF mode 2 m temperature prediction products is higher than that in winter, and the error is larger in the case of inflectional low temperature weather; 2) After the revision of the convolutional neural network model, the accuracy of the 2 m temperature prediction product has been improved, the overall prediction accuracy has been improved by about 5%, and the average absolute error and root mean square error have been reduced by 0.5°C~0.8°C; 3) Compared with the traditional revision method of using historical long-term data, the model can use less data, achieve better correction effect, and reduce statistical workload.

## Keywords

Temperature Forecasting, Convolutional Neural Networks, Deviation Correction

Copyright © 2023 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

大气温度变化和人类的活动密切相关, 精确的大气温度预测是天气预报的一个重要参考指标[1], 对人们的日常生产生活具有重要意义。高分辨率数值预报技术的快速发展带动了中小尺度天气预报能力的提高, 为我们提供了越来越精确的客观预报产品。但是大气是一个混沌系统, 由于模拟大气的数值模式初值场的不确定性、模式自身存在的缺陷, 造成了模式预报产品的不确定性和不准确性, 存在着无法避免的系统误差。即使数值模式发展至今, 系统误差依然存在[2]。

为了减小各种因素带来的误差以及提高数值预报的准确率, 国内外的学者已做了很多研究。一方面可以通过资料同化来改善初始场, 优化模式的辐射过程、微物理过程、边界层方案、积云对流过程、陆面过程等物理过程参数化方案等途径来提高数值模式的准确度; 另一方面可以利用误差订正技术对数值预报产品进行解释应用, 以降低高分辨率模式中的相对误差可能导致的模式低命中率和高虚假预警率[3]。随着计算能力的飞速发展以及数据的急速膨胀, 人工智能技术孕育而出, 在各个领域大放光彩。有些学者开始尝试将其应用于温度订正中。在一些研究中(如 Chattopadhyay 等[4], Ustaoglu 等[5]), 根据历史气温数据, 再通过考虑时间的滞后性来预测气温是单变量模型方法[6]; 另一种常见的方法是使用其他相关的气象要素变量。不同的输入变量会显著影响模型的性能, 如降雨量、空气湿度、风速、气压等作为预测气温的输入, 也就是多元模型[7]。因此, 人工神经网络模型可以分为两组: 第一组仅使用历史气温测量数据作为输入, 第二组使用气温和其他相关的气象要素变量。近年来, 人工智能迎来第 3 次发展浪潮并在多个领域大数据分析中取得巨大成功, 这为人工智能技术与数值天气预报结合提供了契机[8]。在过去的十几年里, 很多学者提出了几种深度学习的技术来预测或者订正气温数值预报, 如多层感知机 MLP (Multi-Layer Perception) [9]、卷积神经网络 CNN (Convolutional Neural Network) [10]、循环神经网络 RNN


(Recurrent Neural Network) [11]、长短期记忆神经网络 LSTM (Long short-term Memory Network) [12]、对抗神经网络(Generative adversarial network) [13]等。每种深度学习的技术都有其独特的结构,以更好的学习气温规律并进行预测或者订正。卷积神经网络可以与大气物理模式一起进行高分辨格点模型的构建,并将模型用于气象要素预报[14];循环神经网络的变体 LSTM 和 GRU,已被广泛的应用于处理时空序列的问题上,例如降水临近预报和温度预测[15]。由此可见,深度学习可挖掘气象要素之间的非线性关系,并进行预测或者预报订正,具有广阔的前景。

## 2. 数据及处理

### 2.1. 数据准备

本文使用的模式预报资料为 ECMWF 高分辨数值模式 2 m 温度数据。模式 2 m 温度预报为网格数据,格距为  $0.125^{\circ} \times 0.125^{\circ}$ 。起报时刻为每日 08:00、20:00 (北京时,下同),预报时效 72 h 以内间隔 3 h, 72~240 h 间隔 6 h。采用福建省台提供的中国气象局陆面数据同化系统(CLDAS-V2.0)近实时产品数据集中 2 m 气温融合产品作为参考真值[16],时间分辨率为 1 小时,空间分辨率为  $0.05^{\circ} \times 0.05^{\circ}$ 。

检验及订正的时间范围选取 2018 年 1 月~2021 年 12 月,空间范围选取  $115^{\circ}\text{E}\sim 121^{\circ}\text{E}$ 、 $23^{\circ}\text{N}\sim 29^{\circ}\text{N}$  的中国东南部福建地区(图 1)。福建地处我国东南沿海,山地、丘陵占据总面积的 90%,西部是武夷山脉,东部濒临台湾海峡,自西到东地形起伏较大。考虑到不同海拔高度的气温差异,所以将海拔高度加入到数据集中。



**Figure 1.** Research area for convolutional neural network model revision

**图 1.** 卷积神经网络模型订正的研究区域

为了使网格预报与实况资料在空间上一致,采用双线性插值法,将 2 m 温度的模式预报资料插值到空间分辨率为  $0.05^{\circ} \times 0.05^{\circ}$  的网格。

### 2.2. 数据集划分

试验选用 2018 年~2020 年数据制作训练数据集,其中选取 2021 年的独立样本制作验证集和测试集。在单个训练数据集中,输入数据为起报时刻的 ECMWF 模式未来 240 h 内的预报格点值以及 ECMWF

模式过去 72 h 温度预报与 CLDAS 实况温度的误差值，训练标签为未来 240 h 内的 CLDAS 实况温度值。ECMWF 数值预报数据每天起报两次，分别为 08 时与 20 时，采用上述方法制作数据集，共可以获得集合数目约为 2190 个。

### 3. 订正算法

#### 3.1. 卷积神经网络

卷积神经网络算法是为了提高图像识别效率而发展起来的，一旦经过训练，该算法可以从输入的图像中提取所需的特征来识别信息。卷积神经网络由卷积层、下采样层、全连接层等结构组成。它在结构上具有局部连接、权值共享、时间或空间上的下采样等特点。卷积层通过卷积核对像素进行加权求和，得到原始图像的特征映射，实现特征提取。为了更充分地提取不同的特征，可以在同一个网络中使用多个不同的卷积核。同一特征图中的每个神经元在与卷积核计算时共享权重，这大大减少了参数的数量和过拟合的风险。与传统的神经网络相比，使用卷积神经网络进行图像识别任务的最大优势是在参数较少的情况下，数据处理效率高。然而，卷积神经网络算法的应用并不局限于图像识别。如果可以将任何数据排列成二维或三维的数据数组，并且数组具有一定的信息意义，那么卷积神经网络就可以从特征提取意义上提取出有意义的信息。

#### 3.2. 建立订正模型

本文搭建了多个卷积层的卷积神经网络的结构，如图 2 所示。网络主体分为两个部分：首先将 input 1 进行图像降维和特征提取，再入 input 2 数据进行复制拼接，实现特征融合。核心处理为卷积层和池化层。卷积层采用二维卷积来提取输入的特征信息，例如输入大小为  $24 \times 121 \times 121$  的气象要素图片，经过  $128 \times 3 \times 3$  大小的卷积核，图像大小变为  $128 \times 121 \times 121$ ，为保持图片前后的长和宽不变，需要进行边界填充。池化层在模型中的作用为增强模型的泛化能力，在尽可能地保留输入气象要素主要特征的同时，减少模型的参数。

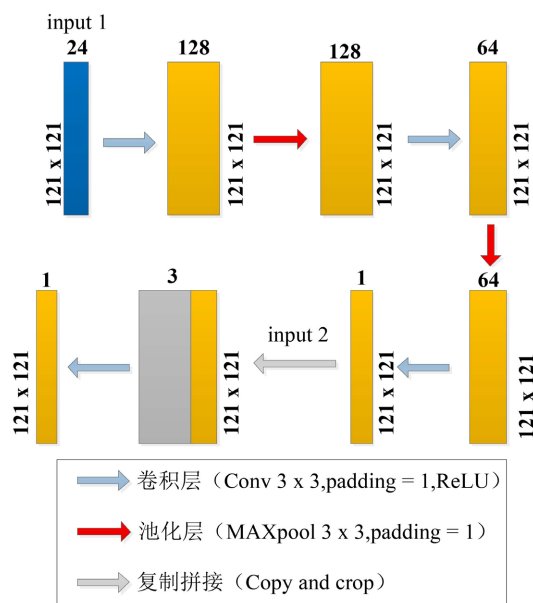


Figure 2. The network structure of CNN

图 2. 卷积神经网络结构

模型的订正流程如图 3 所示：首先将起报时刻前三天，每天 3 h、6 h、9 h、12 h、15 h、18 h、21 h、24 h 温度预报与 CLDAS 实况温度偏差输入到模型中，输入数据共 24 层，每层数据大小为  $121 \times 121$ 。经过三层卷积、池化，提取出前 3 天温度预报偏差的特征图；第二步将提取出的特征图与时报时刻温度预报和地形信息进行拼接，最后经过一层卷积层，进行特征融合得到数值预报订正结果。

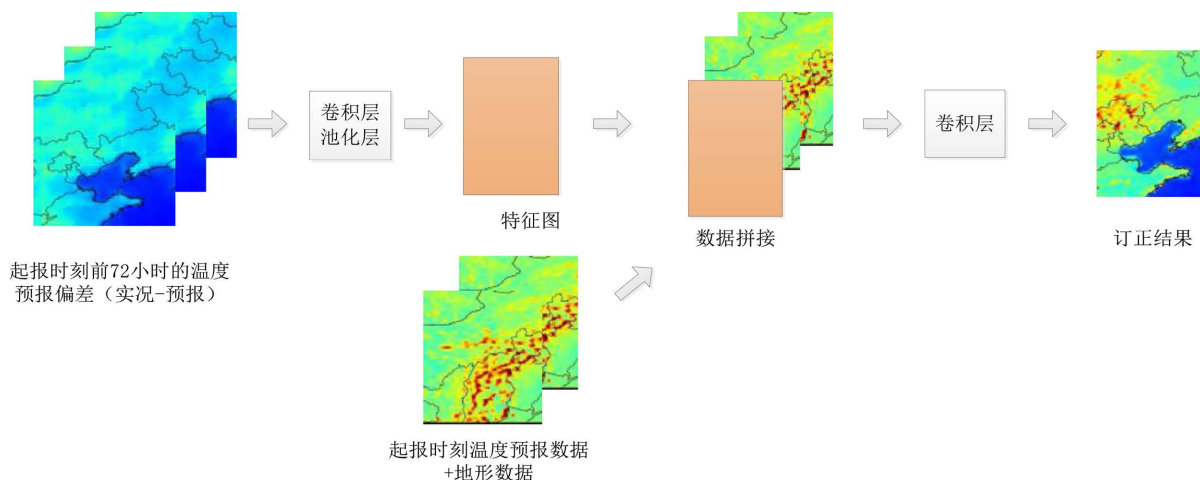


Figure 3. Process diagram for revision using a convolutional neural network

图 3. 使用卷积神经网络进行订正的流程图示意图

## 4. 模型订正结果及分析

### 4.1. 模型评价指标

本文采用气温预报的业务评价指标作为检验指标，包括平均绝对误差  $MAE$  (Mean Absolute Error)、均方根误差  $RMSE$  (Root Mean Squared Error) 以及预报准确率  $PC$  (Prediction Chance)，各指标计算方法如下：

a) 平均绝对误差

$$MAE = \frac{1}{n} \sum_{i=1}^n |T_i^f - T_i^o| \quad (1)$$

式(1)中， $n$  为预报气温的站(格)点个数， $T_i^f$  为第  $i$  个站(格)点的预报气温， $T_i^o$  为第  $i$  个站(格)点的 CLDAS 气温。

b) 均方根误差

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (T_i^f - T_i^o)^2} \quad (2)$$

式(2)中， $n$  为站(格)点个数， $T_i^f$  为第  $i$  个站(格)点的预报气温， $T_i^o$  为第  $i$  个站(格)点的 CLDAS 气温。

c) 预报准确率

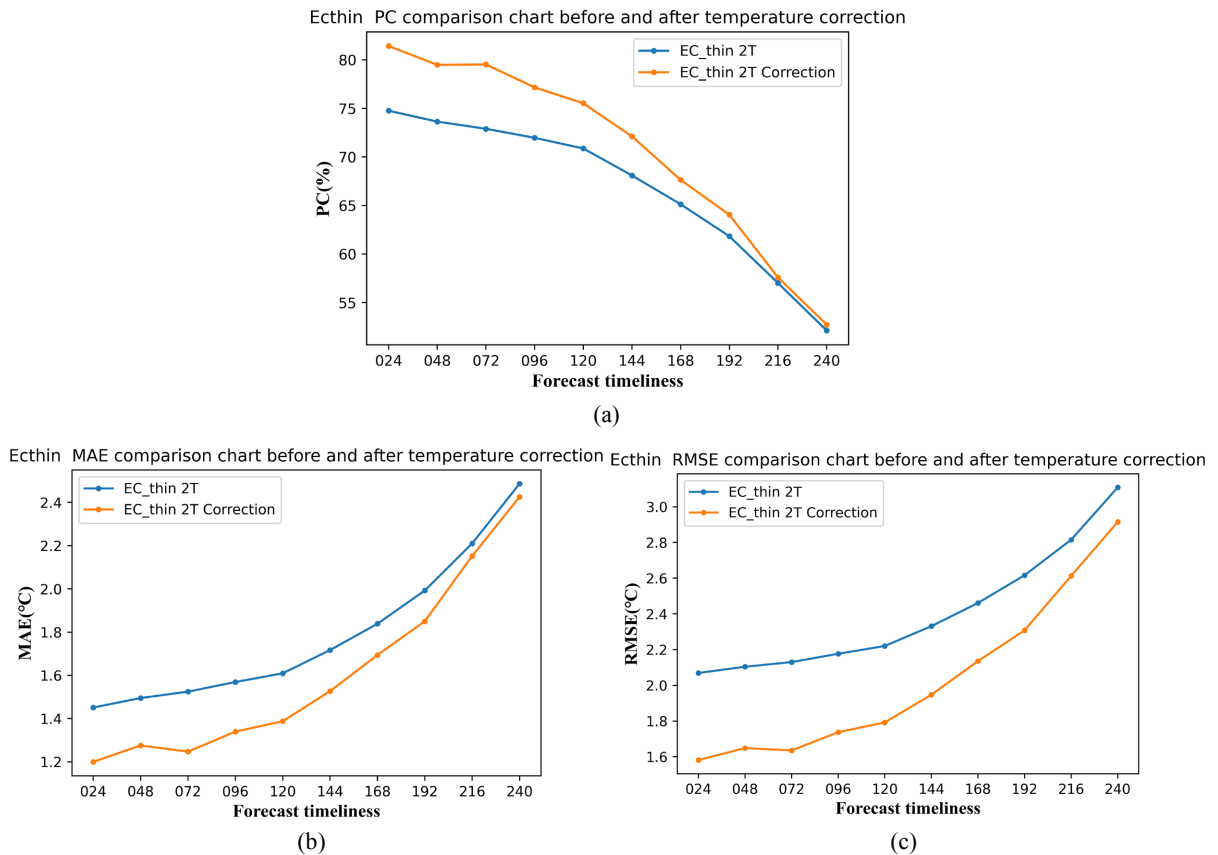
$$PC = (N_r / N_f) \times 100\% \quad (3)$$

式(3)中， $N_r$  为预报气温与 CLDAS 气温相差在  $\pm 2^\circ\text{C}$  以内的站(格)点个数， $N_f$  为预报气温总站(格)点个数。

### 4.2. 模型订正结果及分析

使用 2018~2021 年 ECMWF 模式的 2 m 气温预报数据与 CLDAS 地面温度数据集对卷积神经网络订

正模型进行训练,用验证集对模型检验。图4展示了订正结果的月均统计。总体来讲,ECMWF模式2 m气温预报产品准确率较高,在70%左右,0~192 h预报时效的平均绝对误差在2℃以内,19~240 h预报时效的平均绝对误差在2.2℃上下波动,均方根误差基本都在3℃以内。预报误差随着预报时效的增加而逐渐加大。经过模型订正后预报准确率都有明显的提升,平均绝对误差和均方根误差都显著减小,订正后ECMWF的2 m气温240 h预报时效内的预报精度均高于订正前精度。对比图4可以看出ECMWF的2 m气温预报在订正后预报准确率提升了5%左右,144 h预报时效前预报准确率均保持在75%以上。平均绝对误差下降了0.3℃左右,均方根误差下降0.5℃左右。

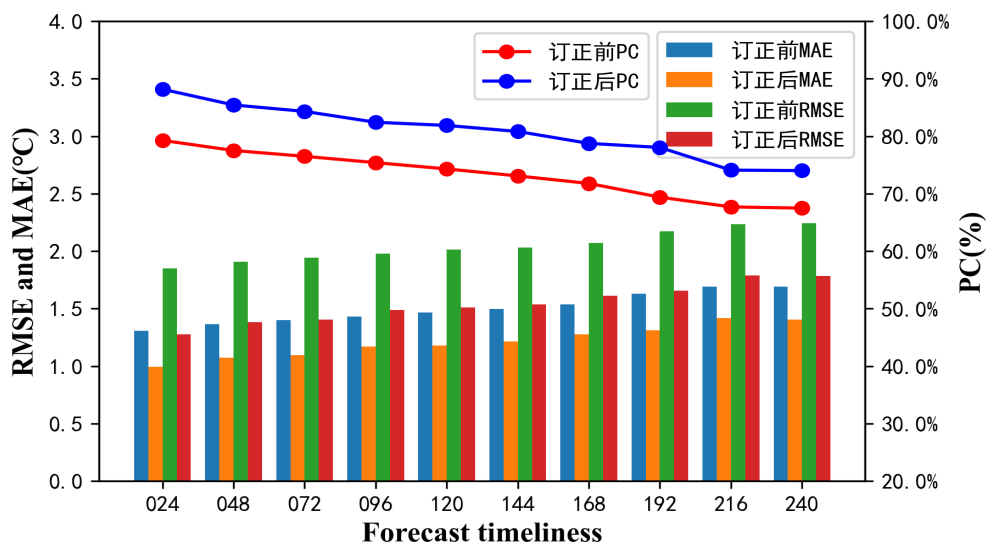


**Figure 4.** Comparison before and after ECMWF model temperature forecast revision: (a) PC; (b) MAE; (c) RMSE  
**图4.** ECMWF模式温度预报订正前后对比: (a) 预报准确率; (b) 平均绝对误差; (c) 均方根误差

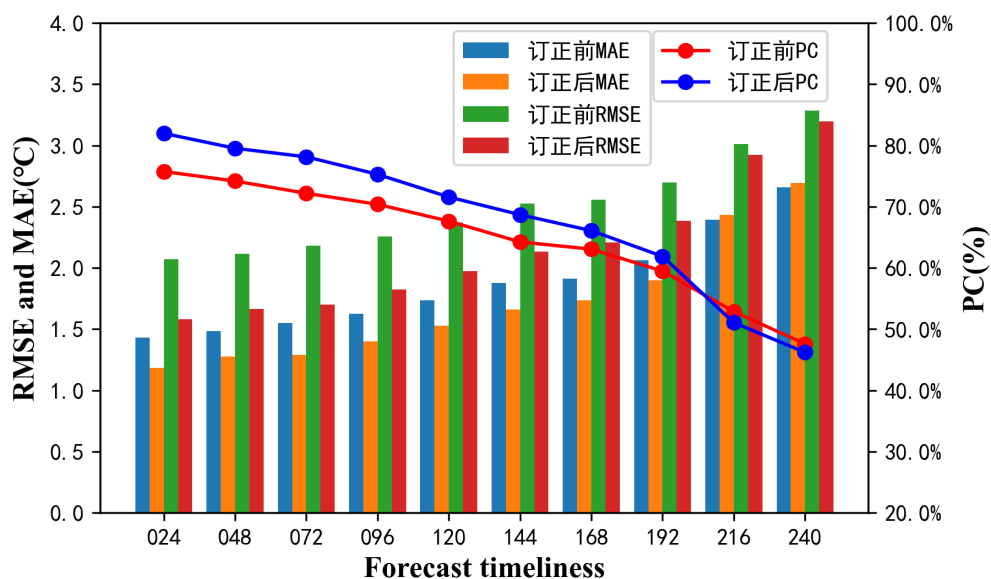
福建位于亚热带季风气候带,夏季高温而又多雨,冬季温和而又少雨,夏季与冬季的温度差异较大。为了分析模型对于不同季节的订正效果是否存在明显的差异,选取6月与11月两个月的月平均数据作为高温季节和低温季节的代表进行个例分析。图5和图6为2021年6月与11月ECMWF模式2 m温度订正结果的预报准确率、平均绝对误差、均方根误差与订正前的对比。可以看出订正前的温度模式预报产品6月精度高于11月,分析6月份处于炎热季节,气温变化不大,所以预报的精度稍好,而11月份处于秋冬交替,常有转折性低温天气,模式预报不能很好地预见此类事件发生,因而预报精度稍低。经过卷积神经网络模型的订正后,两个月份均取得了一定的订正效果。6月份温度的预报准确率提高了10%左右,平均绝对误差降低约0.35℃,均方根误差降低约0.5℃。11月份温度的预报准确率提升了3%左右,平均绝对误差降低了约0.25℃,均方根误差降低了约0.4℃,但是随着预报时效的增加,模型订正的效果

逐渐减弱。

结合验证集的检验结果和 2021 年 6 月、11 月的月均统计结果，经过卷积神经网络模型订正后，无论模式初始的预报精度是否较高，都会较原来精度有所提升。降低了模式预报误差，提升温度预报的准确率，这对实现福建精细化网格预报具有重要作用。



**Figure 5.** Revised ECMWF model 2 m temperature forecast in June 2021 compared to pre-revision  
**图 5.** 2021 年 6 月 ECMWF 模式 2 m 温度预报订正后与订正前的对比



**Figure 6.** Revised ECMWF model 2 m temperature forecast in November 2021 compared to pre-revision  
**图 6.** 2021 年 11 月 ECMWF 模式 2 m 温度预报订正后与订正前的对比

## 5. 结论与展望

本文结合 CLDAS 近实时产品地面温度数据集，使用卷积神经网络的方法对 ECMWF 模式温度预报格点产品进行了误差分析和订正研究。通过建立模型、选取输入要素、调整模型结构等步骤，得出的订

正模型可以较好地订正模式的系统偏差,从而提高 ECMWF 模式 2 m 温度预报的预报精度。同时研究结果发现模式预报对于转折性天气的预报能力较弱,此时的订正模型可以提高模式预报的预报精度。主要结论如下:

1) ECMWF 模式 2 m 温度预报产品具有低海拔地区偏低,高海拔区域偏高的系统性偏差,并且夏季预报精度高于冬季。整体预报准确率在 70%左右。使用卷积神经网络模型订正后,ECMWF 模式 2 m 温度预报产品的精度得到改善,预报准确率提升约 5%,平均绝对误差和均方根误差均降低了 0.5℃~0.8℃。

2) 在整个模型订正的试验中,气温的预报准确率随着预报时效的延长而逐渐下降,绝大部分的大值误差出现在转折性天气阶段,而模型的订正可以稳定地提高模式预报的精度。对比传统使用历史长期资料的订正方式,模型可以使用更少的数据,达到较好的订正效果,减少统计工作量。

综上所述,卷积神经网络模型在温度预报上有很好的订正能力,可以稳定地提高 ECMWF 模式 2 m 温度预报的预报精度。但是本研究还有需要改进的地方,CLDAS 近实时产品地面温度数据集并不能完全地代替观测数据,与温度的真实值还有些许出入;同时,本次试验仅使用了温度这一要素作为输入,是单变量模型。因而在接下来的工作中会继续开展使用与温度相关性高的气象要素作为输入,构建多元变量模型来对温度进行订正,进一步探索提高模式温度预报数据精度的方法。

## 致 谢

感谢福建省气象台提供的 ECMWF 预报数据及 CLDAS 近实时产品地面温度数据集。

## 基金项目

江苏省研究生科研实践项目(SJCX21\_0374)。

## 参考文献

- [1] 季彦东. 基于改进 LSTM 模型的大气温度预测[J]. 通化师范学院学报, 2020, 41(8): 82-86.  
<https://doi.org/10.13877/j.cnki.cn22-1284.2020.08.015>
- [2] 曾晓青, 薛峰, 赵瑞霞, 赵声蓉. 几种格点化温度滚动订正预报方案对比研究[J]. 气象, 2019, 45(7): 1009-1018.
- [3] 薛湛彬, 陈娴, 张瑛, 郑婧, 马晓华, 张雅斌, 潘留杰. ECMWF 高分辨率模式 2 m 温度预报误差订正方法研究[J]. 气象, 2019, 45(6): 831-842.
- [4] Chattopadhyay, S., Jhajharia, D. and Chattopadhyay, G. (2011) Univariate Modelling of Monthly Maximum Temperature Time Series Over Northeast India: Neural Network versus Yule-Walker Equation Based Approach. *Meteorological Applications*, **18**, 70-82. <https://doi.org/10.1002/met.211>
- [5] Ustaoglu, B., Cigizoglu, H.K. and Karaca, M. (2008) Forecast of Daily Mean, Maximum and Minimum Temperature Time Series by Three Artificial Neural Network Methods. *Meteorological Applications*, **15**, 431-445.  
<https://doi.org/10.1002/met.83>
- [6] Fahimi Nezhad, E., Fallah Ghalhari, G. and Bayatani, F. (2019) Forecasting Maximum Seasonal Temperature Using Artificial Neural Networks "Tehran Case Study". *Asia-Pacific Journal of Atmospheric Sciences*, **55**, 145-153.  
<https://doi.org/10.1007/s13143-018-0051-x>
- [7] Smith, B.A., McClendon, R.W. and Hoogenboom, G. (2006) Improving Air Temperature Prediction with Artificial Neural Networks. *International Journal of Computational Intelligence*, **3**, 179-186.
- [8] 孙健, 曹卓, 李恒, 等. 人工智能技术在数值天气预报中的应用[J]. 应用气象学报, 2021, 32(1): 1-11.
- [9] 邓梦娇, 徐新, 马盈盈, 等. 多层感知机结合辐射传输模型的复杂陆地表面云检测[J]. 电子学报, 2022, 50(4): 932-942.
- [10] Shelhamer, E., Long, J. and Darrell, T. (2017) Fully Convolutional Networks for Semantic Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **39**, 640-651.  
<https://doi.org/10.1109/TPAMI.2016.2572683>
- [11] Barker, H.W., Jerg, M.P., Wehr, T., Kato, S., Donovan, D.P. and Hogan, R.J. (2011) A 3D Cloud-Construction Algorithm for the EarthCARE Satellite Mission. *Quarterly Journal of the Royal Meteorological Society*, **137**, 1042-1058.



---

<https://doi.org/10.1002/qj.824>

- [12] Rocha Rodrigues, E, Oliveira, I., Cunha, R. and Netto, M. (2018) DeepDownscale: A Deep Learning Strategy for High-Resolution Weather Forecast. 2018 *IEEE 14th International Conference on E-Science (E-Science)*, Amsterdam, 29 October-1 November 2018, 415-422. <https://doi.org/10.1109/eScience.2018.00130>
- [13] Shi, W.Z., *et al.* (2016) Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 1874-1883. <https://doi.org/10.1109/CVPR.2016.207>
- [14] Cho, K., *et al.* (2014) Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, Doha, 25-29 October 2014, 1724-1734. <https://doi.org/10.3115/v1/D14-1179>
- [15] Shi, X.J., *et al.* (2015) Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. *Proceedings of the 28th International Conference on Neural Information Processing Systems*, Montreal, 7-12 December 2015, 802-810.
- [16] 张延彪, 陈明轩, 韩雷, 宋林焯, 杨璐. 数值天气预报多要素深度学习融合订正方法[J]. 气象学报, 2022, 80(1): 153-167.