

深度卷积神经网络对陕西地区气温预报误差订正效果研究

崔丛欣

陕西省气象局机关服务中心, 陕西 西安

收稿日期: 2023年4月19日; 录用日期: 2023年5月19日; 发布日期: 2023年5月26日

摘要

当前气象预报工作中, 数值模式预报处于核心地位, 气象预报结果对其依赖性很强, 但其预报结果存在一定误差。为了降低误差, 本文提出了一种基于卷积神经网络的深度卷积神经网络(DCNN)订正方法, 并基于欧洲中心的2 m温度预报资料和再分析资料在陕西地区进行了预报订正。通过对订正结果的分析表明, DCNN订正方法能有效提高预报准确率, 预报误差越大订正效果越明显; 其订正效果在一定范围内随着参数epoch的增大而提高; 其前期的订正效果要明显优于后期。

关键词

预报误差订正, 卷积神经网络, 深度卷积神经网络

Correction Effect of Deep Convolutional Neural Network on Temperature Forecast Error in Shaanxi Province

Congxin Cui

Shaanxi Meteorological Bureau Agency Service Center, Xi'an Shaanxi

Received: Apr. 19th, 2023; accepted: May 19th, 2023; published: May 26th, 2023

Abstract

In current meteorological forecasting work, numerical model forecasting is at the core, and the results of meteorological forecasting are highly dependent on it, but there are certain errors in its forecasting results. In order to decrease errors, the paper proposes a deep convolutional neural

network (DCNN) correction method based on convolutional neural networks, and conducts prediction correction in Shaanxi region based on the 2 m temperature prediction data and reanalysis data from the ECMWF. The analysis of the correction outcome shows that the DCNN correction method can significantly improve the prediction accuracy, and the larger the prediction error, the more obvious the correction effect; the correction effect increases with the increase of parameter epoch within a certain range; the correction effect in the early stage is significantly better than that in the later stage.

Keywords

Forecast Error Correction, CNN, DCNN

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

依托于计算机运算速度和储存能力的快速发展,人们深入研究大气运动状态所取得的结果得以更好的展示和实现。基于计算机技术发展和深入研究结果的数值预报方法已经在气象预报领域处于越来越重要的位置,气象预报对数值预报结果的依赖程度不断加深,数值预报已经成为气象预报业务的核心组成部分。数值预报结果随着预报方法的不断发展,预报要素的数量、时间和空间分辨率不断提高,时效不断延长,预报准确率也不断加强。但各个气象要素的数值预报结果仍然和实际状况存在差距,并且差距会随着时效延长而增加[1]-[6]。

结合误差产生的原因,提升数值模式预报结果准确率的方法有以下两种。一是通过修改各个物理过程的参数改善数值预报模式自身的性能,二是根据预报结果和实际数据之间的差异对数值模式结果进行一定的订正处理。第一种方法需要对模式本身进行一定的改动,对大气运动状态研究的深入程度要求极高。第二种方法根据统计学对模式预报结果进行分析订正,更便于使用,应用也更加广泛[6] [7] [8] [9] [10]。

随着计算机技术和人工智能的发展,机器学习的方法也开始逐渐更多的应用到模式预报数据的订正中,特别是BP神经网络,在预报订正领域已经有了一定的应用[11] [12] [13]。但BP神经网络所需的训练时间较长,输入每个神经元的数据需要处理为一维数据,输出的每个神经元的数据也为一维数据。除BP神经网络外,机器学习中还有卷积神经网络等深度学习方法。深度学习目前主要用于机器识别、图像分类领域,在自动驾驶、人脸检测、视觉搜索、目标跟踪和检测等领域也得到了广泛的应用[14] [15] [16]。其中,卷积神经网络因其结构可以直接将二维数据输入进行网络训练。杨文佳等人将卷积神经网络应用于天气现象识别方面,通过网络训练能有效识别图片中的晴、阴、雨、雪四种天气[17]。齐永锋和李占华将多尺度卷积神经网络结合分类统计方法应用到了去除雾霾对图像的影响方面,能较好的去除合成图和真实图像中雾霾的影响[18]。徐少平等人论证了深度卷积神经网络算法在图像降噪领域的技术优势,并梳理、总结、讨论了深度卷积神经网络算法降噪模型未来的发展限制和解决方案[19]。李传朋等人构建了深度卷积神经网络应用于图像去噪,能更有效的去除图像中的噪声,获得更好的视觉效果[20]。

2 m 气温在气象预报中是最重要的气象要素之一,准确预报该要素对人们的日常生活、生产活动有着极其重要的影响,是天气预报业务中一项重要的工作[10] [21]。本文利用2020年至2022年欧洲中心数值模式预报数据,基于深度卷积神经网络方法,对陕西地区2 m气温预报进行订正,研究其订正效果。

2. 资料与方法

2.1. 依据资料

本次研究所采用的模式温度预报资料为欧洲中心 ERA5 数据集中的每日 6 时(世界时)起报 8 小时 2 m 处温度预报数据,其水平分辨率为,区域范围为陕西及周边地区(北纬 31°~40°和东经 105°~112°)。温度实际资料采用的是欧洲中心 ERA5 数据集中的再分析数据。

2.2. 研究方法

卷积神经网络(Convolutional neural network, CNN)是近年发展起来、受高度重视的一种前馈式人工神经网络。最早针对二维图形识别问题提出,其二维拓扑结构可以处理具有类似网络结构的数据,多维图像数据可直接输入网络。其非全连接、权值共享和局部感受野这些特征可以极大减少网络训练所需参数、大幅降低网络复杂性、避免过拟合风险。这些特征还能在二维图像发生位移、比例扩大或缩小、倾斜、旋转或者其他形式的形变时具有高度的不变性。因此,卷积神经网络在图像处理中应用十分广泛[20] [22]。

深度卷积神经网络(Deep convolutional neural network, DCNN)广泛应用于图像去噪领域,通过构建对称式的卷积神经网络、调节卷积核的大小、深度,充分学习含噪图像具有的特征。李传朋等人还在网络构造中添加了反卷积层(如图 1 所示),构成含噪图像到去噪图像之间的非线性映射关系。其在构建时每层输出、输入图像尺寸一致,避免后续拼接工作和人工边界现象,并通过激活函数添加了映射关系之间的非线性因素,输出图像也不需要经过降维处理,所以在网络中没有添加池化层。该方法在卷积神经网络的基础上,可以通过网络训练,将输入数据中的噪声进行过滤,把过滤后的去噪数据作为输出数据输出[20] [23]。




Figure 1. Deep convolutional neural network structure for denoising [20]

图 1. 用于去噪的深度卷积神经网络结构[20]

在本文中,以模式预报数据作为输入数据,再分析数据作为输出数据,模式预报数据与再分析数据之间的误差看作影响模式预报结果的“噪声”,对深度卷积神经网络进行训练,使用训练结果订正模式预报数据。

3. 试验结果分析

3.1. DCNN 订正结果分析

本文以 2020~2021 年为订正期,将订正期内欧洲中心 ERA5 数据集的预报数据和再分析数据作为输入和输出数据,使用深度卷积神经网络对其进行网络训练次数(epoch)为 200 次的训练,得到训练后的模型。之后,使用训练后得到的网络模型对 2022 年 1~12 月份的欧洲中心 ERA5 数据集预报数据进行订正,计算订正后的误差并进行分析。

将订正后的预报误差绝对值记为 d_1 、实际的预报误差绝对值记为 d_2 。对图 2 进行分析可知，240 时次之前，大部分时次 d_1 在 d_2 之下， d_1 小于 d_2 ，两者之差即 d_1-d_2 大部分小于 0°C ，特别是一些原始预报误差较大的时次，订正后的预报误差明显缩小。240 时次之后，两者之差在 0°C 附近震荡。这表明深度卷积神经网络订正方法在前期即距离训练期较近的时次能有效降低预报误差，特别是原始预报误差偏大的时次，改善效果明显。




Figure 2. The spatial average changes of d_1 , d_2 and d_1-d_2 in 2022 using the revised DCNN method
图 2. 使用 DCNN 订正方法 d_1 、 d_2 以及 d_1-d_2 的空间平均在 2022 年的变化

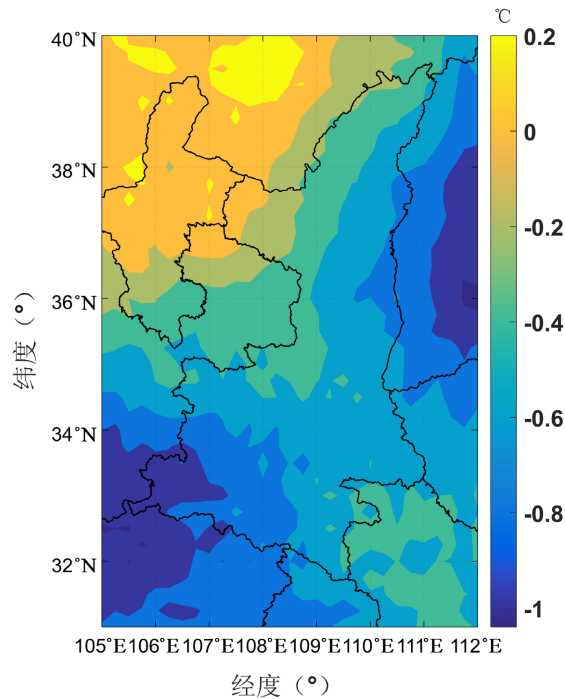


Figure 3. Spatial distribution of d_1-d_2 mean values in 2022 using the revised DCNN method
图 3. 使用 DCNN 订正方法 d_1-d_2 2022 年平均值的空间分布

从 2022 年 d_1-d_2 的时间平均数的空间分布(图 3)可以看出，陕西绝大部分区域该值为负，只有西北部

向一小片区域该值在 0℃左右，该值为正的区域主要在陕西西北方向的宁夏、内蒙古地区，不在陕西区域内。这表明在陕西绝大部分区域，订正后预报误差变小。根据图 4 可知，陕西及周边地区 55%的区域 $d_1 \sim d_2$ 的 2022 年平均值减少了 0.4℃以上，仅有 19%的区域该值大于 0℃，且结合对图 3 的分析，这些区域主要集中在陕西地区之外。总体而言，深度卷积神经网络订正方法对陕西地区预报误差有明显的订正效果，能够提高预报准确率。




Figure 4. The size distribution of $d_1 \sim d_2$ 2022 mean (d) using the revised DCNN method
图 4. 使用 DCNN 订正方法 $d_1 \sim d_2$ 2022 年平均值(d)的大小分布

陕西及周边地区 $d_2 \sim d_1$ 即订正后预报误差绝对值减少量的时间平均如表 1 所示，1 月份增加约 0.24℃、2 月份增加约 0.70℃、3 月份增加约 1.06℃、4 月份增加约 0.98℃、5 月份增加约 0.65℃、6 月份增加约 0.48℃、7 月份增加约 0.68℃、8 月份增加约 0.01℃、9 月份增加约 0.06℃、10 月份减少约 0.20℃、11 月份减少约 0.12℃、12 月份增加约 0.27℃、1 月份至 12 月份增加 0.40℃。这表示，深度卷积神经网络订正方法的订正效果受到时次延长的影响，在前期能有效减少陕西及周边地区预报误差的绝对值，提高预报准确率。

Table 1. The time average of the reduction in the absolute value of the forecast error using DCNN correction
表 1. 使用 DCNN 订正后预报误差绝对值减少量的时间平均值

时间	预报误差绝对值减少量(℃)
1 月	0.24035928
2 月	0.70446771
3 月	1.0635562
4 月	0.98287255
5 月	0.64749694
6 月	0.47777086
7 月	0.68357825
8 月	0.011200405
9 月	0.059040729

Continued

10月	-0.19779484
11月	-0.12238047
12月	0.2673358
1~12月	0.39953944

3.2. 不同 epoch 对 DCNN 订正结果的影响

在构造深度卷积神经网络模型时，需要设定参数 epoch 的数值，该参数是指在网络训练过程中训练集的所有输入数据全部输入模型进行一次完整网络训练的次数，上文中 epoch 为 200 的训练结果即为将全部数据集进行 200 次完整网络训练的结果。参数 epoch 的大小决定了搭建的网络模型在训练时的完整训练次数，进而影响了输入和输出数据之间映射关系的建立，最终影响训练后网络模型的效果。在本节中分别将 epoch 设置为 100、150 和 250 进行网络训练并和前文 epoch 为 200 的训练结果进行比较，分析不同 epoch 对训练结果的影响。

使用不同 epoch 训练出的 DCNN 分别对预报数据进行订正，陕西及周边地区订正后预报误差绝对值减少量(d_2-d_1)的时间平均如表 2 所示。参数 epoch 为 100 时除在个别月份外，在大部分月份其预报效果均没有 epoch 为其他数值时预报效果好，在 6~8 月订正效果为负，其 2022 年 1~12 月平均预报误差绝对值减少量约为 0.21℃。参数 epoch 为 150 时，在 3 月订正效果表现最优，其他大部分月份订正效果相似或略逊于 epoch 为 200 和 250 时的结果，在 8~11 月订正效果为负，其 2022 年 1~12 月平均预报误差绝对值减少量约为 0.28℃。参数 epoch 为 200 时，在 3 月订正最优，在 2 月相较于 epoch 为其他值时的订正结果订正效果明显提升，但其在 10~11 月订正效果为负，2022 年 1~12 月平均预报误差绝对值减少量约为 0.40℃。参数 epoch 为 250 时，3 月订正效果最优，大部分月份订正效果优于或近似于 epoch 为其他值订正效果，且全年订正效果无负值，8 月份之前订正效果好于之后，2022 年 1~12 月平均预报误差绝对值减少量约为 0.47℃。总体而言，epoch 为 250 时，DCNN 的订正效果更好，且 8 月之前订正效果更好。

Table 2. The time average of the reduction in the absolute value of the forecast error after correction by DCNN trained with different epochs

表 2. 使用不同 epoch 训练出的 DCNN 订正后预报误差绝对值减少量的时间平均值

时间	预报误差绝对值减少量(℃)			
	epoch = 100	epoch = 150	epoch = 200	epoch = 250
1月	0.32546225	0.24786177	0.24035928	0.24614832
2月	0.54214334	0.59945649	0.70446771	0.51034969
3月	0.59617621	1.07511	1.0635562	1.0023144
4月	0.39118481	0.98952866	0.98287255	0.93859738
5月	0.19950791	0.56355274	0.64749694	0.73942566
6月	-0.10433129	0.24012841	0.47777086	0.55636275
7月	-0.12119004	0.47153327	0.68357825	0.62442017
8月	-0.19207709	-0.42682162	0.011200405	0.22838543
9月	0.16690892	-0.15266386	0.059040729	0.31389496
10月	0.26664656	-0.27415982	-0.19779484	0.1118196

Continued

11 月	0.25281495	-0.15450431	-0.12238047	0.083999112
12 月	0.2655431	0.22952083	0.2673358	0.2374513
1~12 月	0.21347798	0.28203824	0.39953944	0.46565557

陕西及周边地区 $d_1 \sim d_2$ 2022 年平均值的分布统计如表 3 所示。参数 epoch 为 100 时, 有 256 个格点订正后 d_1 的年平均大于 d_2 的年平均, 订正后预报误差增加, 其在区域内占比 24%。其余格点均为经过 DCNN 订正预报误差减少, 其中 343 个格点减少了 0.4°C 以上, 占比 32%。参数 epoch 为 150 时, d_1 的年平均大于 d_2 的年平均的格点数量变化不大, 有 254 个, 占比 24%。经过订正后预报误差减少的格点中有 419 个格点减少了 0.4°C 以上, 占比 39%。参数 epoch 为 200 时, d_1 的年平均大于 d_2 的年平均的格点减少为 202 个, 占比 19%。经过订正后预报误差减少的格点中, 减少超过 0.4°C 的格点增加为 594 个, 占比 55%。参数 epoch 为 250 时, d_1 的年平均大于 d_2 的年平均的格点进一步减少为 146 个, 占比降低为 14%。670 个格点经过订正后预报误差减少了 0.4°C 以上, 占比达到 62%。综上所述, DCNN 的订正效果随着 epoch 的增加而提升, epoch 为 250 时订正效果最好。

Table 3. Size distribution statistics of $d_1 \sim d_2$ mean (d) in 2022 of DCNN model trained with different epochs

表 3. 使用不同 epoch 训练出的 DCNN 模型 $d_1 \sim d_2$ 2022 年平均值的分布统计

范围	格点数量(个)			
	epoch = 100	epoch = 150	epoch = 200	epoch = 250
$d > 0^\circ\text{C}$	256	254	202	146
$0^\circ\text{C} \geq d > -0.1^\circ\text{C}$	71	66	39	67
$-0.1^\circ\text{C} \geq d > -0.2^\circ\text{C}$	139	78	42	52
$-0.2^\circ\text{C} \geq d > -0.3^\circ\text{C}$	139	112	60	58
$-0.3^\circ\text{C} \geq d > -0.4^\circ\text{C}$	125	144	136	80
$d \leq -0.4^\circ\text{C}$	343	419	594	670

4. 结论

对于本文提出的深度卷积神经网络方法对陕西地区 2 m 气温预报订正效果研究, 通过上述统计分析可得出以下几点结论:

- 1) 深度卷积神经网络对陕西地区 2 m 气温预报订正效果明显, 在一定程度上能有效提高预报准确率。
- 2) 深度卷积神经网络在预报误差大、预报准确率低时订正效果更加明显, 能够显著降低预报误差。
- 3) 深度卷积神经网络的订正效果受到参数 epoch 和订正时次的影响。在一定范围内, epoch 越大订正效果越好。距离训练期近的时次整体订正效果更好一些, 距离训练期远的时次订正效果较差。

该结论是基于欧洲中心 2 m 温度预报数据在陕西地区的订正研究得出, 该方法在其他地区、应用其他数值预报数据的订正效果仍需进一步研究。

参考文献

- [1] Lorenz, E.N. (1982) Atmospheric Predictability Experiments with a Large Numerical Model. *Tellus A: Dynamic Meteorology and Oceanography*, **34**, 505-513. <https://doi.org/10.3402/tellusa.v34i6.10836>

- [2] Bengtsson, L. and Hodges, K.I. (2006) A Note on Atmospheric Predictability. *Tellus A: Dynamic Meteorology and Oceanography*, **58**, 154-157. <https://doi.org/10.1111/j.1600-0870.2006.00156.x>
- [3] 张兰慧, 尚可政, 程一帆, 等. 数值预报产品的误差订正方法[J]. 兰州大学学报: 自然科学版, 2011, 47(3): 44-49.
- [4] 穆穆, 陈博宇, 周非凡, 余堰山. 气象预报的方法与不确定性[J]. 气象, 2011, 37(1): 1-13.
- [5] 李仲梅. 气象预报的方法与不确定性[J]. 农业开发与装备, 2016(10): 54.
- [6] 蔡凝昊, 俞剑蔚. 基于数值模式误差分析的气温预报方法[J]. 大气科学学报, 2019, 42(6): 864-873.
- [7] 翟盘茂, 倪允琪, 陈阳. 我国持续性重大天气异常成因与预报方法研究回顾与未来展望[J]. 地球科学进展, 2013, 28(11): 1177-1188.
- [8] 万仕全, 何文平, 封国林, 等. 数值模式误差订正方法初探[J]. 高原气象, 2014, 33(2): 460-466.
- [9] 佟铃, 彭新东, 范广洲, 常俊. GRAPES 全球模式的误差评估和订正[J]. 大气科学, 2017, 41(2): 333-344.
- [10] 薛谡彬, 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.
- [11] 王焕毅, 谭政华, 杨萌, 等. 三种数值模式气温预报产品的检验及误差订正方法研究[J]. 气象与环境学报, 2018, 34(1): 22-29.
- [12] 黄凤新, 刘寿东, 祝赢, 等. 基于滚动极值处理的 BP 神经网络方法的 WRF 模式预报风速订正[J]. 科学技术与工程, 2013, 13(7): 1768-1772.
- [13] 梁志文. BP 神经网络方法对 T639 模式集宁站风速预报的订正[J]. 内蒙古气象, 2015(2): 36-38.
- [14] Xinyu, Z., Hongbo, G., Jianhui, Z., et al. (2018) Overview of Deep Learning Intelligent Driving Methods. *Journal of Tsinghua University*, **58**, 438-444.
- [15] Li, H.B., Xu, C.Y. and Hu, C.C. (2020) Improved Real-Time Vehicle Detection Method Based on YOLOV3. *Laser Laser & Optoelectronics Progress*, **57**, 332-338. <https://doi.org/10.3788/LOP57.101507>
- [16] Wang, D., Chen, X., Zhao F., et al. (2019) Vehicle Detection Algorithm Based on Convolutional Neural Network and RGB-D Images. *Laser & Optoelectronics Progress*, **56**, Article ID: 181003. <https://doi.org/10.3788/LOP56.181003>
- [17] 杨文佳, 朱海龙, 刘靖宇. 基于卷积神经网络的天气现象识别方法研究[J]. 智能计算机与应用, 2019, 9(6): 214-216.
- [18] 齐永锋, 李占华. 一种基于多尺度卷积神经网络和分类统计的图像去雾霾方法[J]. 红外技术, 2020, 42(2): 190-197.
- [19] 徐少平, 刘婷云, 林珍玉, 等. 深度卷积神经网络降噪模型的技术瓶颈与研究展望[J]. 2019, 24(8): 1207-1214.
- [20] 李传朋, 秦品乐, 张晋京. 基于深度卷积神经网络的图像去噪研究[J]. 计算机工程, 2017, 43(3): 253-260.
- [21] 王婧, 徐枝芳, 范广洲, 刘佩廷, 李泽椿. GRAPES_RAFS 系统 2 m 温度偏差订正方法研究[J]. 气象, 2015, 41(6): 719-726.
- [22] 王梓欣, 牟叶, 王德睿. 基于深度学习的单图像超分辨算法比较探究[J]. 电子技术与软件工程, 2018(7): 94-96.
- [23] Zhang, K., Zuo, W. and Zhang, L. (2018) FFDNet: Toward a Fast and Flexible Solution for CNN-Based Image Denoising. *IEEE Transactions on Image Processing*, **27**, 4608-4622. <https://doi.org/10.1109/TIP.2018.2839891>