

# Research on Correction Method of Model Temperature Forecast Error Combining EOF and BP Neural Network

Congxin Cui<sup>1,2</sup>, Xiaogong Sun<sup>2</sup>, Suping Zhang<sup>1</sup>

<sup>1</sup>Ocean University of China, Qingdao Shandong

<sup>2</sup>Nanjing Joint Institute for Atmospheric Sciences, Nanjing Jiangsu

Email: ccx@stu.ouc.edu.cn, xgsun@cma.gov.cn

Received: May 30<sup>th</sup>, 2020; accepted: Jun. 10<sup>th</sup>, 2020; published: Jun. 17<sup>th</sup>, 2020

---

## Abstract

Due to the error of the initial field of the model, the physical process of the model and the algorithm, there is always a certain gap between the prediction results of the numerical model and the actual situation. In order to reduce the forecast error of the numerical model and improve the accuracy of the numerical forecast result, post-processing the forecast result of the numerical model, the model forecast error correction is a commonly used post-processing method of model forecast results. In this regard, this paper proposes a model prediction error correction method combining empirical orthogonal function (EOF) and BP neural network, and based on the 2015-2018 GRAPES\_Meso numerical model 2 m temperature prediction data and ERA-interim reanalysis data for correction Forecast test. The test results show that the correction method combining EOF and BP neural network has strong timeliness, which can effectively improve the forecast effect and improve the forecast accuracy in the first few months; compared with the BP neural network correction method, the effect of the previous correction is obviously better than the correction effect of BP neural network.

## Keywords

Forecast Error Correction, EOF, BP Neural Network

---

# EOF和BP神经网络相结合的模式温度预报误差订正方法研究

崔丛欣<sup>1,2</sup>, 孙效功<sup>2</sup>, 张苏平<sup>1</sup>

<sup>1</sup>中国海洋大学, 山东 青岛

<sup>2</sup>南京气象科技创新研究院, 江苏 南京

## 摘要

由于受模式初始场、模式物理过程和算法等的误差影响, 数值模式预报结果与实际情况总是存在一定差距。为了降低数值模式的预报误差, 提高数值预报结果的准确性, 对数值模式的预报结果进行后处理, 模式预报误差订正就是一种常用的模式预报结果后处理方法。对此, 本文提出了一种经验正交函数(EOF)与BP神经网络相结合的模式预报误差订正方法, 并基于2015-2018GRAPES\_Meso数值模式的2 m温度预报资料和欧洲中心的再分析资料进行了订正预报试验。试验结果表明, EOF与BP神经网络相结合的订正方法具有较强的时效性, 在前几个月能有效改善预报效果, 提高了预报精度; 与BP神经网络订正方法相比, 其前期的订正效果要明显地优于BP神经网络的订正效果。

## 关键词

预报误差订正, 经验正交分解, BP神经网络

Copyright © 2020 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

随着计算机运算速度的提高、存储能力的上升以及人们对大气运动状态的深入研究, 数值预报方法在气象预报中的应用越来越成熟、越来越重要, 现代气象预报对数值预报结果的依赖度不断提升, 其已然成为业务预报的核心。模式预报的要素不断增多、时间分辨率和空间分辨率不断提高、预报时效也不断延长、各个气象要素的预报准确率也不断升高。但是, 各个气象要素的数值模式预报结果仍然与实际气象情况存在一定的差距, 预报结果不可能完全精确[1] [2] [3]。

数值模式预报结果的不准确性可以由以下三个方面讨论。一是初始场存在一定的误差。在数值预报中, 模式初始值的准确性是十分重要的。但由于观测过程的误差、测站覆盖不全面、背景信息不准确以及同化过程产生的误差, 模式的初始场总是会存在一定误差。二是模式本身的误差。大气运动是个连续复杂的非线性过程, 模式对其物理、动力过程的描述不全面, 不是完全准确。并且, 模式在求解的过程中也会产生一定的计算误差。三是天气与气候本身的可预报性。即使是在初始场完全接近实况、模式本身完美无缺的情况下, 大气状况的可预报性也是存在限度的[1] [4] [5] [6] [7]。

提高数值模式预报的准确性、改善模式预报性能可以从两个途径来实现。一种途径是改善模式自身性能。比如, 提高模式初始场的准确性或者优化模式的辐射过程、陆面过程、微物理过程、积云对流过程、边界层方案等物理过程参数。另一种途径是对模式预报结果进行后处理。根据长时期模式预报数据与实际气象数据之间的偏差对模式预报数据进行订正, 以此来提高模式预报水平。第一种途径需要对数值模式和大气运动的物理过程进行深入的研究, 对数理基础要求较高; 第二种途径多采用统计学方法, 相对而言更好应用[3] [6] [7] [8]。

2 m 温度是气象预报中最重要的气象要素之一, 提高其预报的准确性对人们的日常生活、农业生产

等有着重要的意义,在天气预报业务中是一项重要的工作[5] [7]。马清等人使用滞后平均降低误差尺度的自适应误差订正法对不同地区区域集合预报模式预报的 2 m 处温度数据进行订正,能有效改善短期预报的效果[9]。对于 EC-MWF 的 2 m 处温度预报数据,李佰平和智协飞采用了一元线性回归、多元线性回归、单时效消除偏差和多时效消除偏差平均的方法对其进行了订正,薛堪彬等人则采用了动态滑动双权重平均订正法、空间误差逐步订正法结合的综合订正方法对其进行订正,王丹等人使用递减平均法和一元线性回归法对陕西地区预报结果进行了订正,这几种方法均能有效改善预报误差,提高预报的质量[7] [10] [11]。秦俊灵等人使用平均误差作为系统误差对沧州地区 EC 细网格 2 m 处温度预报进行订正,有效提高了预报准确率[12]。王婧等人使用平均法、双权重平均法、滑动平均法和滑动双权重平均法对 GRAPES\_RAFS 的 2 m 处温度预报进行了订正,有效缩小了模式预报误差[5]。

随着计算机技术和人工智能的发展,能够体现非线性关系的机器学习方法也被越来越多的应用到模式预报数据的订正中。王焕毅等人应用 BP 神经网络建立了误差模型,使用该模型对数值模式气温预报数据进行了订正,订正之后数值模式预报结果的平均绝对误差由 2.40℃降低到 1.40℃,显著地提高了预报精度[13]。但 BP 神经网络训练耗时较长,在训练神经网络前需要将输入数据处理为一维数据。在将输入数据调整为一维时会对数据结构产生一定影响。而经验正交分解的方法可以将数据分离为空间特征向量和时间系数,分离出的每个模态的时间系数为一维变量。将经验正交分解与 BP 神经网络相结合可以在不改变数据结构的前提下使用 BP 神经网络进行训练。

本文通过使用经验正交分解和 BP 神经网络相结合的方式对 GRAPES\_Meso (Global/Regional Assimilation and Prediction System)模式的 2 m 处温度预报进行订正,降低其预报误差,提高其预报的准确率。并且使用 BP 神经网络的方法对 GRAPES\_Meso 系统的 2 m 处温度预报进行订正,比较两种方法的优劣。

## 2. 资料与方法

### 2.1. 依据资料

本文所采用的模式温度预报资料为 GRAPES\_Meso 数值模式预报系统 4.0 版本 0 时(世界时,下同)和 12 时两个起报时的 6 小时 2 m 处温度预报数据,其水平分辨率为,覆盖范围是东亚地区(北纬 15°~65°,东经 70°~145°) [14]。温度实际资料以再分析资料代替,这里采用的是欧洲中心的再分析数据,使用双线性插值方法将其插值到对应网格上。

### 2.2. 研究方法

这里首先利用多年的欧洲中心温度再分析数据与 GRAPES\_Meso 数值模式温度预报数据相减得到 2 m 处历史温度预报误差,进而将这一历史温度预报误差进行经验正交函数分解 EOF 得到温度预报误差各模态的空间特征向量和时间系数,然后选取几个主要模态的时间系数,使用 BP 神经网络的方法对其进行训练学习,得到体现时间系数变化规律的网络模型。最后,利用该网络模型计算后续拟需订正时间段的各主要模态时间系数,并将计算得到的模态时间系数和前面 EOF 分解得到的模态空间特征向量进行数据重构,则可以得到温度预报误差订正值。

#### 2.2.1. 经验正交函数分解

经验正交函数分解 EOF 是由 Pearson 提出,由 Lorenz 将其引入到气象问题分析中,常用于分析变量场的时间和空间分布特征。该方法可以将变量场的时间特征和空间分布特征分离,使变量场的主要信息由几个典型特征向量集中表现。该方法的基本原理是:

将由  $m$  个空间点  $n$  次观测构成的变量看成是  $p$  个空间特征向量和对应的时间权重系数的线性组合:

$$X_{m \times n} = V_{m \times p} T_{p \times n}$$

$T$  是时间系数,  $V$  是空间特征向量。这个过程可以将变量场的几个主要信息集中的由几个典型的特征向量表现出来[15] [16] [17]。

### 2.2.2. BP 神经网络

BP 神经网络是一种多层的误差逆向传播神经网络, 是应用最广泛的一种人工神经网络。BP 神经网络可以分成三部分, 分别是输入层、隐含层和输出层, 隐含层中可以包含若干层, 每层包含若干神经元。一般, 三层 BP 神经网络经过学习训练后就可以逼近任何精度变量和函数, 即逼近输入与输出之间的任何映射关系。数据由输入层的神经元进入神经网络, 经隐含层的神经元处理后, 通过输出层的神经元输出结果。如果输出的结果没有达到预期, 则将误差信息反向传播, 在这个过程中调节各神经元之间的权值, 直到输出的结果达到理想的状态[18] [19] [20]。

## 3. 试验结果分析

### 3.1. EOF 与 BP 神经网络相结合的方式对 GRAPES\_Meso 的订正结果分析

这里以欧洲中心的再分析数据作为实际数据, 以 2015~2017 年、2016~2017 年和 2017 年分别作为订正期, 将订正期内 GRAPES\_Meso 数值预报系统每天 0 时和 12 时两个起报时的 2 m 处温度 6 h 预报数据的预报误差整合为一个序列(序列一)、每天 0 时起报的 2 m 处温度 6 h 预报数据的预报误差单独作为一个序列(序列二)、每天 12 时起报的 2 m 处温度 6 h 预报数据的预报误差单独作为一个序列(序列三), 对每个序列数据进行 EOF 分解得到各模态的空间特征向量和时间系数, 其各个模态的方差贡献率和前四个模态的累积方差贡献率如表 1 所示。由表 1 可知, 在 2015~2017 年, 三个序列的前四个模态的累积方差贡献率均分别达到 51.15%、59.89%和 48.81%; 在 2016~2017 年, 三个序列的前四个模态的累积方差贡献率均分别达到 55.15%、64.25%和 52.27%; 在 2017 年, 三个序列的前四个模态的累积方差贡献率均分别达到 57.26%、66.88%和 52.63%。因此, 选取前四个模态的时间系数, 使用 BP 神经网络的方法对其进行训练, 得到体现时间系数变化规律的模型。之后, 使用该模型计算 2018 年 1 月份到 6 月份各个序列前四个模态中每个模态的时间系数。使用 BP 神经网络计算所得 2018 年 1 月份到 6 月份各个序列前四个模态中每个模态的时间系数和前四个模态的空间特征向量进行数据重构, 则可以得到一个新的数据序列, 该数据既为 2018 年 1 月份到 6 月份预报误差估计值。使用该预报误差估计值对 GRAPES\_Meso 数值预报系统 2018 年 1 月份到 6 月份预报数据进行订正, 得到订正后的预报数据, 进而计算出订正后的预报误差。

**Table 1.** The variance contribution rate of the first four modes of each sequence


**表 1.** 各序列前四个模态的方差贡献率

		第一模态方差贡献率(%)	第二模态方差贡献率(%)	第三模态方差贡献率(%)	第四模态方差贡献率(%)	累积方差贡献率(%)
序列一	2015~2017	27.04	13.60	6.64	3.87	51.15
	2016~2017	28.17	15.13	7.53	4.32	55.15
	2017	29.98	15.01	7.72	4.55	57.26
序列二	2015~2017	42.49	9.31	5.43	2.66	59.89
	2016~2017	44.84	10.39	6.34	2.68	64.25
	2017	48.49	9.82	6.49	2.08	66.88
序列三	2015~2017	29.99	10.95	5.14	2.73	48.81
	2016~2017	32.41	11.01	5.85	3.00	52.27
	2017	33.78	8.94	6.46	3.45	52.63

### 3.1.1. 基于 0 时和 12 时两个起报时的订正结果分析

基于 GRAPES\_Meso 数值预报系统每天 0 时和 12 时两个起报时的 2 m 处温度 6 h 预报数据的预报误差整合成的一个序列, 即序列一以 2015~2017 年为订正期计算所得的订正后预报误差的绝对值( $d_1$ )、以 2016~2017 年为订正期计算所得的订正后预报误差的绝对值( $d_3$ )、以 2017 年为订正期计算所得的订正后预报误差的绝对值( $d_4$ )和实际预报误差的绝对值( $d_2$ )以及  $d_1-d_2$ 、 $d_3-d_2$ 、 $d_4-d_2$  的空间平均随时次的变化如图 1 所示。

由图可知, 以 2015~2017 年为订正期, 在 160 时次即前 80 天, 订正后预报误差的绝对值总体在实际预报误差的绝对值之下, 订正后预报误差的绝对值与实际预报误差绝对值之差总体小于 0, 订正后预报误差绝对值总体要比实际预报误差绝对值小。在 160 时次即前 80 天之后, 订正后预报误差的绝对值逐渐在实际预报误差的绝对值之上, 订正后预报误差的绝对值与实际预报误差绝对值之差总体开始大于 0, 订正后预报误差的绝对值开始大于实际预报误差绝对值。这表明在前 80 天即 2018 年 3 月份下旬之前, EOF 分析与 BP 神经网络相结合的订正方法能有效减少预报误差, 提高预报的准确度。以 2016~2017 年为订正期, 在 140 时次即前 70 天, 订正后预报误差的绝对值总体在实际预报误差的绝对值之下, 订正后预报误差的绝对值与实际预报误差绝对值之差总体小于 0, 订正后预报误差绝对值总体要比实际预报误差绝对值小。在 140 时次即前 70 天之后, 订正后预报误差的绝对值逐渐在实际预报误差的绝对值之上, 订正后预报误差的绝对值与实际预报误差绝对值之差总体开始大于 0, 订正后预报误差的绝对值开始大于实际预报误差绝对值。这表明在前 70 天即 2018 年 3 月份中旬之前, EOF 分析与 BP 神经网络相结合的订正方法能有效减少预报误差, 提高预报的准确度。以 2017 年为订正期, 在 100 时次即前 50 天, 订正后预报误差的绝对值总体在实际预报误差的绝对值之下, 订正后预报误差的绝对值与实际预报误差绝对值之差总体小于 0, 订正后预报误差绝对值总体要比实际预报误差绝对值小。在 100 时次即前 50 天之后, 订正后预报误差的绝对值逐渐在实际预报误差的绝对值之上, 订正后预报误差的绝对值与实际预报误差绝对值之差总体开始大于 0, 订正后预报误差的绝对值开始大于实际预报误差绝对值。这表明在前 50 天即 2018 年 2 月份下旬之前, EOF 分析与 BP 神经网络相结合的订正方法能有效减少预报误差, 提高预报的准确度。



**Figure 1.** The absolute value of the corrected forecast error ( $d_1$ ,  $d_3$ ,  $d_4$ ) and the absolute value of the actual forecast error ( $d_2$ ) and the spatial average of  $d_1-d_2$ ,  $d_3-d_2$ ,  $d_4-d_2$  changes over time use the sequence one  
**图 1.** 使用序列一订正后预报误差的绝对值( $d_1$ 、 $d_3$ 、 $d_4$ )和实际预报误差的绝对值( $d_2$ )以及  $d_1-d_2$ 、 $d_3-d_2$ 、 $d_4-d_2$  的空间平均随时次的变化



实际预报误差绝对值与订正后预报误差绝对值之差即预报误差绝对值减少量的时间平均如表 2 所示, 以 2015~2017 年为订正期, 1 月份平均减少 0.33℃、2 月份平均减少 0.40℃、3 月份平均减少 0.15℃、4 月份平均增加 0.23℃、5 月份平均增加 0.73℃、6 月份平均增加 1.09℃、1 月份至 6 月份平均增加 0.20℃。这表示, EOF 与 BP 神经网络相结合的方法在 1 月份、2 月份和 3 月份能有效减少预报误差的绝对值, 提高预报准确率。以 2016~2017 年为订正期, 1 月份平均减少 0.38℃、2 月份平均减少 0.24℃、3 月份平均增加 0.14℃、4 月份平均增加 0.46℃、5 月份平均增加 0.65℃、6 月份平均增加 0.59℃、1 月份至 6 月份平均增加 0.21℃。这表示, EOF 与 BP 神经网络相结合的方法在 1 月份和 2 月份能有效减少预报误差的绝对值, 提高预报准确率。以 2017 年为订正期, 1 月份平均减少 0.34℃、2 月份平基本不变、3 月份平均增加 0.72℃、4 月份平均增加 1.39℃、5 月份平均增加 1.66℃、6 月份平均增加 1.62℃、1 月份至 6 月份平均增加 0.85℃。这表示, EOF 与 BP 神经网络相结合的方法在 1 月份能有效减少预报误差的绝对值, 提高预报准确率。

**Table 2.** Time-averaged amount of decrease in absolute value of forecast error after correction use the sequence one  
**表 2.** 使用序列一订正后预报误差绝对值减少量的时间平均值

		1 月	2 月	3 月	4 月	5 月	6 月	1~6 月
预报误差绝对值减少量 (℃)	2015~2017	0.33	0.40	0.15	-0.23	-0.73	-1.09	-0.20
	2016~2017	0.38	0.24	-0.14	-0.46	-0.65	-0.59	-0.21
	2017	0.34	0.00	-0.72	-1.39	-1.66	-1.62	-0.85


### 3.1.2. 基于 0 时起报的订正结果分析

基于 GRAPES\_Meso 数值预报系统每天 0 时起报的 2 m 处温度 6 h 预报数据的预报误差单独组成的一个序列, 即序列二以 2015~2017 年为订正期计算所得的订正后预报误差的绝对值( $d_1$ )、以 2016~2017 年为订正期计算所得的订正后预报误差的绝对值( $d_3$ )、以 2017 年为订正期计算所得的订正后预报误差的绝对值( $d_4$ )和实际预报误差的绝对值( $d_2$ )以及  $d_1-d_2$ 、 $d_3-d_2$ 、 $d_4-d_2$  的空间平均随时次的变化如图 2 所示。

由图可知, 以 2015~2017 年为订正期, 在 90 时次即前 90 天, 订正后预报误差的绝对值总体在实际预报误差的绝对值之下, 订正后预报误差的绝对值与实际预报误差绝对值之差总体小于 0, 订正后预报误差绝对值总体要比实际预报误差绝对值小。在 90 时次即前 90 天之后, 订正后预报误差的绝对值逐渐在实际预报误差的绝对值之上, 订正后预报误差的绝对值与实际预报误差绝对值之差总体开始大于 0, 订正后预报误差的绝对值开始大于实际预报误差绝对值。这表明在前 90 天即 2018 年 4 月份月上旬之前, EOF 分析与 BP 神经网络相结合的订正方法能有效减少预报误差, 提高预报的准确度。以 2016~2017 年为订正期和以 2017 年为订正期, 在 60 时次左右即前 60 天, 订正后预报误差的绝对值总体在实际预报误差的绝对值之下, 订正后预报误差的绝对值与实际预报误差绝对值之差总体小于 0, 订正后预报误差绝对值总体要比实际预报误差绝对值小。在 60 时次即前 60 天之后, 订正后预报误差的绝对值逐渐在实际预报误差的绝对值之上, 订正后预报误差的绝对值与实际预报误差绝对值之差总体开始大于 0, 订正后预报误差的绝对值开始大于实际预报误差绝对值。这表明在前 60 天即 2018 年 3 月份月上旬之前, EOF 分析与 BP 神经网络相结合的订正方法能有效减少预报误差, 提高预报的准确度。

实际预报误差绝对值与订正后预报误差绝对值之差即预报误差绝对值减少量的时间平均如表 3 所示, 以 2015~2017 年为订正期, 1 月份平均减少 0.56℃、2 月份平均减少 0.61℃、3 月份平均减少 0.06℃、4 月份平均增加 0.53℃、5 月份平均增加 1.35℃、6 月份平均增加 2.00℃、1 月份至 6 月份平均增加 0.45℃。这表示, EOF 与 BP 神经网络相结合的方法在 1 月份、2 月份和 3 月份能有效减少预报误差的绝对值, 提

高预报准确率。以 2016~2017 年为订正期, 1 月份平均减少 0.54℃、2 月份平均减少 0.21℃、3 月份平均增加 0.69℃、4 月份平均增加 1.61℃、5 月份平均增加 2.62℃、6 月份平均增加 3.46℃、1 月份至 6 月份平均增加 1.28℃。这表示, EOF 与 BP 神经网络相结合的方法在 1 月份和 2 月份能有效减少预报误差的绝对值, 提高预报准确率。以 2017 年为订正期, 1 月份平均减少 0.38℃、2 月份平均减少 0.04℃、3 月份平均增加 0.70℃、4 月份平均增加 1.10℃、5 月份平均增加 1.64℃、6 月份平均增加 1.92℃、1 月份至 6 月份平均增加 0.83℃。这表示, EOF 与 BP 神经网络相结合的方法在 1 月份和 2 月份能有效减少预报误差的绝对值, 提高预报准确率。虽然以 2016~2017 年为订正期和以 2017 年为订正期均能在 2018 年 1 月份和 2 月份提高预报准确率, 但前者的订正效果要略好于后者。



**Figure 2.** The absolute value of the corrected forecast error ( $d_1, d_3, d_4$ ) and the absolute value of the actual forecast error ( $d_2$ ) and the spatial average of  $d_1-d_2, d_3-d_2, d_4-d_2$  changes over time use the sequence two

**图 2.** 使用序列二订正后预报误差的绝对值( $d_1, d_3, d_4$ )和实际预报误差的绝对值( $d_2$ )以及  $d_1-d_2, d_3-d_2, d_4-d_2$  的空间平均随时次的变化

**Table 3.** Time-averaged amount of decrease in absolute value of forecast error after correction use the sequence two  
**表 3.** 使用序列二订正后预报误差绝对值减少量的时间平均值

		1 月	2 月	3 月	4 月	5 月	6 月	1~6 月
预报误差绝对值减少量 (°C)	2015~2017	0.56	0.61	0.06	-0.53	-1.35	-2.00	-0.45
	2016~2017	0.54	0.21	-0.69	-1.61	-2.62	-3.46	-1.28
	2017	0.38	0.04	-0.70	-1.10	-1.64	-1.92	-0.83


### 3.1.3. 基于 12 时起报的订正结果分析

基于 GRAPES\_Meso 数值预报系统每天 0 时起报的 2 m 处温度 6 h 预报数据的预报误差单独组成的一个序列, 即序列三以 2015~2017 年为订正期计算所得的订正后预报误差的绝对值( $d_1$ )、以 2016~2017 年为订正期计算所得的订正后预报误差的绝对值( $d_3$ )、以 2017 年为订正期计算所得的订正后预报误差的绝对值( $d_4$ )和实际预报误差的绝对值( $d_2$ )以及  $d_1-d_2, d_3-d_2, d_4-d_2$  的空间平均随时次的变化如图 3 所示。

由图可知, 以 2015~2017 年为订正期、以 2016~2017 年为订正期和以 2017 年为订正期, 在 60 时次左右即前 60 天, 订正后预报误差的绝对值总体在实际预报误差的绝对值之下, 订正后预报误差的绝对值

与实际预报误差绝对值之差总体小于 0，订正后预报误差绝对值总体要比实际预报误差绝对值小。在 60 时次即前 60 天之后，订正后预报误差的绝对值逐渐在实际预报误差的绝对值之上，订正后预报误差的绝对值与实际预报误差绝对值之差总体开始大于 0，订正后预报误差的绝对值开始大于实际预报误差绝对值。这表明在前 60 天即 2018 年 3 月份上旬之前，EOF 分析与 BP 神经网络相结合的订正方法能有效减少预报误差，提高预报的准确度。

实际预报误差绝对值与订正后预报误差绝对值之差即预报误差绝对值减少量的时间平均如表 4 所示，以 2015~2017 年为订正期，1 月份平均减少 0.56℃、2 月份平均减少 0.33℃、3 月份平均增加 0.23℃、4 月份平均增加 0.75℃、5 月份平均增加 0.94℃、6 月份平均增加 1.06℃、1 月份至 6 月份平均增加 0.35℃。以 2016~2017 年为订正期，1 月份平均减少 0.56℃、2 月份平均减少 0.25℃、3 月份平均增加 0.36℃、4 月份平均增加 0.88℃、5 月份平均增加 0.97℃、6 月份平均增加 0.68℃、1 月份至 6 月份平均增加 0.35℃。以 2017 年为订正期，1 月份平均减少 0.50℃、2 月份平均减少 0.13℃、3 月份平均增加 0.65℃、4 月份平均增加 1.37℃、5 月份平均增加 1.80℃、6 月份平均增加 1.84℃、1 月份至 6 月份平均增加 0.85℃。这表示，在三个订正期，EOF 与 BP 神经网络相结合的方法在 1 月份和 2 月份能有效减少预报误差的绝对值，提高预报准确率。而且以 2015-2017 年为订正期订正效果最好，其次是以 2016~2017 年为订正期订正效果较好，以 2017 年为订正期订正效果最差。



**Figure 3.** The absolute value of the corrected forecast error ( $d_1$ ,  $d_3$ ,  $d_4$ ) and the absolute value of the actual forecast error ( $d_2$ ) and the spatial average of  $d_1-d_2$ ,  $d_3-d_2$ ,  $d_4-d_2$  changes over time use the sequence three

**图 3.** 使用序列三订正后预报误差的绝对值( $d_1$ 、 $d_3$ 、 $d_4$ )和实际预报误差的绝对值( $d_2$ )以及  $d_1-d_2$ 、 $d_3-d_2$ 、 $d_4-d_2$  的空间平均随时次的变化

**Table 4.** Time-averaged amount of decrease in absolute value of forecast error after correction use the sequence three

**表 4.** 使用序列三订正后预报误差绝对值减少量的时间平均值

		1 月	2 月	3 月	4 月	5 月	6 月	1~6 月
预报误差绝对值减少量 (℃)	2015~2017	0.56	0.33	-0.23	-0.75	-0.94	-1.06	-0.35
	2016~2017	0.56	0.25	-0.36	-0.88	-0.97	-0.68	-0.35
	2017	0.50	0.13	-0.65	-1.37	-1.80	-1.84	-0.85



由上述结果可看出,使用 EOF 与 BP 神经网络相结合的方式对 GRAPES\_Meso 数值预报结果进行订正具有很强的时效性,前几个月的订正效果较好,能有效减少预报误差,随着时间的推移订正效果越来越差。并且该方法的订正效果与订正期有关,订正期越长,使用的订正数据越多,订正效果越好。0 时和 12 时起报的数据单独组成的序列在 1 月份订正效果远好于共同组成的序列。

### 3.2. 与 BP 神经网络订正方法的效果比较


由于 GRAPES\_Meso 数值预报系统空间覆盖范围较大,以欧洲中心的再分析数据作为实际数据为输出,以 GRAPES\_Meso 数值模式全部区域 2 m 处温度预报数据为输入,利用 BP 神经网络建立模式温度预报误差订正方法所需要的运算量太大,对计算机的要求过高,实际操作比较困难。在本文中选取山东半岛地区 GRAPES\_Meso 数值模式 2 m 处温度预报数据为输入数据,使用 BP 神经网络建立误差订正模型,对山东半岛地区的 2 m 温度预报进行订正。由 3.1 可知,以 2015~2017 年为订正期的订正结果更好,因此选取 3.1 中该订正期山东半岛地区的 EOF 和 BP 神经网络相结合的方法的预报误差订正结果,将两者进行比较。

#### 3.2.1. 基于 0 时和 12 时两个起报时的方法对比

将山东半岛地区 2015~2017 年 GRAPES\_Meso 数值预报系统每天 0 时和 12 时两个起报时的 2 m 处温度 6 h 预报数据作为输入数据,对应时间点的实际数据作为输出数据进行网络训练,得到能够表示两者之间关系的网络模型。使用该网络模型对 2018 年 1 月份到 6 月份每天 0 时和 12 时两个起报时的 2 m 处温度 6 h 预报数据进行订正,得到订正之后的预报数据,进而计算出订正后的预报误差。

使用 BP 神经网络订正后预报误差的绝对值( $d_1$ )、使用 EOF 和 BP 神经网络相结合的方法订正后预报误差的绝对值( $d_2$ )和实际预报误差的绝对值( $d_3$ )以及  $d_1-d_3$ 、 $d_2-d_3$  的空间平均随时次的变化如图 4 所示。由图可知,在 100 时次即前 50 天,使用 EOF 与 BP 相结合的方法订正后预报误差的绝对值总体在其它两个值之下,使用该方法订正后预报误差的绝对值与实际预报误差绝对值之差总体小于 0,使用该方法订正后预报误差绝对值总体要比实际预报误差绝对值小。在 100 时次即前 50 天之后,使用 EOF 与 BP 相结合的方法订正后预报误差的绝对值逐渐在其它两个值之上,使用该方法订正后预报误差的绝对值与实际预报误差绝对值之差总体开始大于 0,使用该方法订正后预报误差的绝对值开始大于实际预报误差绝对值。而使用 BP 神经网络订正方法订正后预报误差的绝对值在 100 时次即 50 天之前在其它两个值之上,使用该方法订正后预报误差的绝对值与实际预报误差绝对值之差总体大于 0,使用该方法订正后预报误差的绝对值大于实际预报误差绝对值。而在 100 时次即 50 天之后,使用该方法订正后预报误差的绝对值在其它两个值之下,其与实际误差绝对值之差总体小于 0,使用该方法订正后预报误差绝对值总体要比实际预报误差绝对值小。这表明在前 50 天即 2018 年 2 月份下旬之前,EOF 分析与 BP 神经网络相结合的订正方法能有效减少预报误差,提高预报的准确度;而在 2018 年 2 月份下旬之后,BP 神经网络订正方法能有效减少预报误差,提高预报的准确度。

实际预报误差绝对值与订正后预报误差绝对值之差即预报误差绝对值减少量的时间平均如表 5 所示,使用 EOF 分析与 BP 神经网络相结合的订正方法在 1 月份平均减少  $0.09^{\circ}\text{C}$ 、2 月份平均减少  $0.12^{\circ}\text{C}$ 、3 月份平均增加  $0.23^{\circ}\text{C}$ 、4 月份平均增加  $0.37^{\circ}\text{C}$ 、5 月份平均增加  $0.57^{\circ}\text{C}$ 、6 月份平均增加  $0.70^{\circ}\text{C}$ 、1 月份至 6 月份平均增加  $0.28^{\circ}\text{C}$ 。使用 BP 神经网络订正方法在 1 月份平均增加  $0.15^{\circ}\text{C}$ 、2 月份平均减少  $0.05^{\circ}\text{C}$ 、3 月份平均增加  $0.01^{\circ}\text{C}$ 、4 月份平均减少  $0.04^{\circ}\text{C}$ 、5 月份平均减少  $0.11^{\circ}\text{C}$ 、6 月份平均减少  $0.11^{\circ}\text{C}$ 、1 月份至 6 月份平均减少  $0.02^{\circ}\text{C}$ 。这表示,EOF 与 BP 神经网络相结合的方法在 1 月份和 2 月份能更加有效的减少预报误差的绝对值,提高预报准确率。但总体而言,BP 神经网络订正方法效果更好。



**Figure 4.** The absolute value of the corrected forecast error ( $d_1$ ,  $d_2$ ) and the absolute value of the actual forecast error ( $d_3$ ) and the spatial average of  $d_1-d_3$ ,  $d_2-d_3$  changes over time use two methods according to the sequence one

**图 4.** 分别使用两种方法根据序列一修正后预报误差的绝对值( $d_1$ 、 $d_2$ )和实际预报误差的绝对值( $d_3$ )以及  $d_1-d_3$ 、 $d_2-d_3$  的空间平均随时次的变化

**Table 5.** Time-averaged amount of decrease in absolute value of forecast error after correction use two methods according to the sequence one

**表 5.** 分别使用两种方法根据序列一修正后预报误差绝对值减少量的时间平均值

预报误差绝对值减少量(°C)	1月	2月	3月	4月	5月	6月	1~6月
EOF + BP	0.09	0.12	-0.23	-0.37	-0.57	-0.70	-0.28
BP	-0.15	0.05	-0.01	0.04	0.11	0.11	0.02


### 3.2.2. 基于 0 时起报的方法对比

将山东半岛地区 2015~2017 年 GRAPES\_Meso 数值预报系统每天 0 时起报的 2 m 处温度 6 h 预报数据作为输入数据, 对应时间点的实际数据作为输出数据进行网络训练, 得到能够表示两者之间关系的网络模型。使用该网络模型对 2018 年 1 月份到 6 月份每天 0 时起报的 2 m 处温度 6 h 预报数据进行订正, 得到订正之后的预报数据, 进而计算出订正后的预报误差。

使用 BP 神经网络订正后预报误差的绝对值( $d_1$ )、使用 EOF 和 BP 神经网络相结合的方法订正后预报误差的绝对值( $d_2$ )和实际预报误差的绝对值( $d_3$ )以及  $d_1-d_3$ 、 $d_2-d_3$  的空间平均随时次的变化如图 5 所示。由图可知, 使用 EOF 与 BP 相结合的方法订正后预报误差的绝对值总体在实际预报误差绝对值之上, 其差值总体大于 0, 该方法订正后预报误差绝对值大于实际预报误差绝对值。而 BP 神经网络方法订正后预报误差的绝对值总体在实际预报误差绝对值之下其差值总体小于 0, 该方法订正后预报误差绝对值小于实际预报误差绝对值。这表明 BP 神经网络订正方法能有效减少预报误差, 提高预报的准确度, 而 EOF 分析与 BP 神经网络相结合的订正方法则不能。

实际预报误差绝对值与订正后预报误差绝对值之差即预报误差绝对值减少量的时间平均如表 6 所示, 使用 EOF 分析与 BP 神经网络相结合的订正方法在 1 月份平均增加 0.44°C、2 月份平均增加 0.96°C、3 月份平均增加 1.78°C、4 月份平均增加 2.38°C、5 月份平均增加 2.85°C、6 月份平均增加 3.19°C、1 月份至 6 月份平均增加 1.94°C。使用 BP 神经网络订正方法在 1 月份变化不大、2 月份平均减少 0.26°C、3

月份平均减少 0.19℃、4 月份平均减少 0.26℃、5 月份平均减少 0.44℃、6 月份平均减少 0.64℃、1 月份至 6 月份平均减少 0.30℃。这表示，相比于 EOF 与 BP 神经网络相结合的方法，BP 神经网络订正方法效果更好。



**Figure 5.** The absolute value of the corrected forecast error ( $d_1$ ,  $d_2$ ) and the absolute value of the actual forecast error ( $d_3$ ) and the spatial average of  $d_1-d_3$ ,  $d_2-d_3$  changes over time use two methods according to the sequence two

**图 5.** 分别使用两种方法根据序列二订正后预报误差的绝对值( $d_1$ 、 $d_2$ )和实际预报误差的绝对值( $d_3$ )以及  $d_1-d_3$ 、 $d_2-d_3$  的空间平均随时次的变化

**Table 6.** Time-averaged amount of decrease in absolute value of forecast error after correction use two methods according to the sequence two

**表 6.** 分别使用两种方法根据序列二订正后预报误差绝对值减少量的时间平均值

预报误差绝对值减少量(°C)	1 月	2 月	3 月	4 月	5 月	6 月	1~6 月
EOF + BP	-0.44	-0.96	-1.78	-2.38	-2.85	-3.19	-1.94
BP	0.00	0.26	0.19	0.26	0.44	0.64	0.30


### 3.2.3. 基于 12 时起报的方法对比

将山东半岛地区 2015~2017 年 GRAPES\_Meso 数值预报系统每天 12 时起报的 2 m 处温度 6 h 预报数据作为输入数据，对应时间点的实际数据作为输出数据进行网络训练，得到能够表示两者之间关系的网络模型。使用该网络模型对 2018 年 1 月份到 6 月份每天 12 时起报的 2 m 处温度 6 h 预报数据进行订正，得到订正之后的预报数据，进而计算出订正后的预报误差。

使用 BP 神经网络订正后预报误差的绝对值( $d_1$ )、使用 EOF 和 BP 神经网络相结合的方法订正后预报误差的绝对值( $d_2$ )和实际预报误差的绝对值( $d_3$ )以及  $d_1-d_3$ 、 $d_2-d_3$  的空间平均随时次的变化如图 6 所示。由图可知，在 40 时次即前 40 天，使用 EOF 与 BP 相结合的方法订正后预报误差的绝对值总体在其它两个值之下，使用该方法订正后预报误差的绝对值与实际误差绝对值之差总体小于 0，使用该方法订正后预报误差绝对值总体要比实际预报误差绝对值小。在 40 时次即前 40 天之后，使用 EOF 与 BP 相结合的方法订正后预报误差的绝对值逐渐在其它两个值之上，使用该方法订正后预报误差的绝对值与实际预报误差绝对值之差总体开始大于 0，使用该方法订正后预报误差的绝对值开始大于实际预报误差绝对值。而

使用 BP 神经网络订正方法订正后预报误差的绝对值除部分时次外, 总体而言在实际预报误差绝对值之下, 其差值之差总体小于 0, 使用该方法订正后预报误差的绝对值总体小于实际预报误差绝对值。这表明在前 40 天即 2018 年 2 月份中旬之前, EOF 分析与 BP 神经网络相结合的订正方法能更加有效减少预报误差, 提高预报的准确度; 而在 2018 年 1~6 月份, 总体而言, BP 神经网络订正方法能有效减少预报误差, 提高预报的准确度。

实际预报误差绝对值与订正后预报误差绝对值之差即预报误差绝对值减少量的时间平均如表 7 所示, 使用 EOF 分析与 BP 神经网络相结合的订正方法在 1 月份平均减少 0.58℃、2 月份平均增加 0.29℃、3 月份平均增加 1.46℃、4 月份平均增加 2.05℃、5 月份平均增加 2.26℃、6 月份平均增加 2.57℃、1 月份至 6 月份平均增加 1.35℃。使用 BP 神经网络订正方法在 1 月份平均减少 0.16℃、2 月份平均减少 0.14℃、3 月份平均减少 0.05℃、4 月份平均增加 0.28℃、5 月份平均减少 0.01℃、6 月份平均减少 0.07℃、1 月份至 6 月份平均减少 0.03℃。这表示, EOF 与 BP 神经网络相结合的方法在 1 月份能更加有效的减少预报误差的绝对值, 提高预报准确率。但总体而言, BP 神经网络订正方法效果更好。



**Figure 6.** The absolute value of the corrected forecast error ( $d_1$ ,  $d_2$ ) and the absolute value of the actual forecast error ( $d_2$ ) and the spatial average of  $d_1-d_3$ ,  $d_2-d_3$  changes over time use two methods according to the sequence three

**图 6.** 分别使用两种方法根据序列三订正后预报误差的绝对值( $d_1$ 、 $d_3$ 、 $d_4$ )和实际预报误差的绝对值( $d_2$ )以及  $d_1-d_2$ 、 $d_3-d_2$ 、 $d_4-d_2$  的空间平均随时次的变化

**Table 7.** Time-averaged amount of decrease in absolute value of forecast error after correction use two methods according to the sequence three

**表 7.** 分别使用两种方法根据序列三正后预报误差绝对值减少量的时间平均值

预报误差绝对值减少量(℃)	1 月	2 月	3 月	4 月	5 月	6 月	1~6 月
EOF + BP	0.58	-0.29	-1.46	-2.05	-2.26	-2.57	-1.35
BP	0.16	0.14	0.05	-0.28	0.01	0.07	0.03

通过以上对比可以看出, 在山东地区, EOF 和 BP 神经网络相结合的订正方法不适用于基于每日 0 时起报的预报数据。而对于基于每日 0 时和 12 时两个起报时的预报数据和基于每日 12 时起报的预报数据而言, EOF 和 BP 神经网络相结合的方法具有较强的时效性, 在前 1、2 个月左右可以更好的减少预报

误差,提高预报准确率,BP神经网络在前1、2个月左右的预报效果没有前者好,但在整个训练期,均能起到较好的订正效果。

#### 4. 结论

对于本文提出的EOF与BP神经网络相结合的数值模式温度预报误差订正方法,通过试验分析可初步得到以下几点结论:

1) EOF与BP神经网络相结合的订正方法时效性强,在前几个月能有效降低GRAPES\_Meso数值预报结果的误差,提高预报准确率,但随着时间的推移订正效果越来越差。

2) GRAPES\_Meso数值预报系统0时、12时序列前1个月份的订正效果比0时和12时整合为一个序列的效果要好得多,建议按不同起报时构建序列进行订正。

3) 所利用历史温度预报误差的时间序列越长,其后续可适于订正的时间也越长。

4) EOF与BP神经网络相结合的方法对基于每日0时和12时两个起报时的预报数据和基于每日12时起报的预报数据而言在1月份的订正效果要明显的优于BP神经网络方法,而BP神经网络订正方法后续月份的订正效果要好于前者。

在本文中,EOF与BP神经网络相结合的订正方法和BP神经网络的订正方法的比较局限在山东半岛地区,具有较大的区域限制。还需要进一步探究在其他地区,这两种方法的优劣。

#### 致 谢

感谢国家气象信息中心与欧洲中心的数据支持。

#### 基金项目

本文得到国家重点研发计划项目(2018YFC1506606)和中国气象科学研究院基本科研业务费重点项目(2019Z003)资助。

#### 参考文献

- [1] 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.
- [2] 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.
- [3] 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.
- [4] Lorenz, E.N. (1982) Atmospheric Predictability Experiments with a Large Numerical Model. *Tellus*, **34**, 505-513. <https://doi.org/10.3402/tellusa.v34i6.10836>
- [5] 王婧,徐枝芳,范广洲,刘佩廷,李泽椿. GRAPES\_RAFS系统2m温度偏差订正方法研究[J]. 气象, 2015, 41(6): 719-726.
- [6] 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.
- [7] 薛谔彬,陈娴,张瑛,郑婧,马晓华,张雅斌,潘留杰. ECMWF高分辨率模式2m温度预报误差订正方法研究[J]. 气象, 2019, 45(6): 831-842.
- [8] 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.
- [9] 马清,龚建东,李莉,等. 超级集合预报的误差订正与集成研究[J]. 气象, 2008, 34(3): 42-48.
- [10] 李佰平,智协飞. ECMWF模式地面气温预报的四种误差订正方法的比较研究[J]. 气象, 2012, 38(8): 897-902.
- [11] 王丹,王建鹏,白庆梅,高红燕. 递减平均法与一元线性回归法对ECMWF温度预报订正能力对比[J]. 气象, 2019, 45(9): 1310-1321.
- [12] 秦俊灵,沈瑞珊,秦玉萍. EC细网格2m温度对沧州市的预报能力检验及订正[J]. 气象研究与应用, 2019, 40(4): 12-17.



- 
- [13] 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.
- [14] 黄丽萍, 陈德辉, 邓莲堂, 徐枝芳, 于翡, 江源, 周非非. GRAPES\_Meso V4.0 主要技术改进和预报效果检验[J]. 应用气象学报, 2017, 28(1): 25-37.
- [15] 吴洪宝, 吴蕾. 气候变率诊断和预测方法[M]. 北京: 气象出版社, 2005.
- [16] 魏凤英. 现代气候统计诊断与预测技术[M]. 北京: 气象出版社, 2007.
- [17] 张祥志, 陈文泰, 黄樱, 秦艳红, 秦玮, 杨雪, 陆维青. 江苏省 2013-2016 年臭氧时空分布特征[J]. 中国环境监测, 2017, 33(4): 50-59.
- [18] 何恩业, 李海, 任湘湘, 蔡怡, 杨静. BP 神经网络在渤海湾叶绿素预测中的应用[J]. 海洋预报, 2008(2): 1-10.
- [19] 潘微, 邢建勇, 万莉颖. 一种基于 BP 神经网络方法的 HY-2A 散射计反演风场偏差订正方案[J]. 海洋预报, 2018, 35(2): 8-18.
- [20] 雷彦森, 蔡晓军, 王文, 李江峰, 李倩文. 遗传算法优化的 BP 神经网络在地面温度多模式集成预报的应用研究[J]. 气象科学, 2018, 38(6): 806-814.