

基于改进长短期记忆网络的湖南网格气温 预报模型*

卢姝^{1,2} 陈鹤^{1,2} 陈静静^{1,2} 赵琳娜³ 郭田韵⁴

1 湖南省气象台, 长沙 410118

2 湖南省气象防灾减灾重点实验室, 长沙 410018

3 中国气象科学研究院, 北京 100081

4 湖南省气象服务中心, 长沙 410118

摘要: 基于欧洲中期天气预报中心高分辨率模式预报产品以及中国气象局陆面数据同化系统逐1 h气温实况, 构建一种改进的长短期记忆网络 ED-LSTM-FCNN 模型, 模型中加入嵌入层模块处理高维空间、时间特征, 并通过全连接神经网络融合不同类型特征实现气温的回归预测, 生成 0.05°×0.05° 格点逐 1 h 气温预报产品。针对湖南省 2022 年预报检验表明: 该模型能显著降低数值模式的预报误差, 提高预报稳定性, 1~24 h 预报时效均方根误差比模式预报与中央气象台指导预报分别降低了 25.4%~37.7% 和 15.8%~40.0%; 模型明显改善了数值模式在空间上(尤其是复杂地形)的预报效果, 大部分地区均方根误差介于 1.2~1.6 °C; 该模型在不同季节 2 °C 误差以内的预报准确率达 85.0% 以上, 明显高于模式预报与中央气象台指导预报, 在平稳性极端高温天气中的优势更加明显, 可有效应用于智能网格预报业务中。

关键词: 网格预报, 长短期记忆网络, 气温预报, 深度学习

中图分类号: P456 中图分类号: A 10.7519/j.issn.1000-0526.2024.022003

Gridded Temperature Forecast Model in Hunan Based on Improved Long Short-Term Memory Networks

LU Shu^{1,2} CHEN He^{1,2} CHEN Jingjing^{1,2} ZHAO Linna³ GUO Tianyun⁴

1 Hunan Meteorological Observatory, Changsha 410118

2 Hunan Key Laboratory of Meteorological Disaster Prevention and Reduction, Changsha 410118

3 Chinese Academy of Meteorological Sciences, Beijing 100081

4 Hunan Meteorological Service Center, Changsha 410118

Abstract: Based on forecast products of the European Center for Medium-Range Weather Forecasts - Integrated Forecasting System (ECMWF-IFS) and hourly temperature observation data from the China Meteorological Administration Land Data Assimilation System (CLDAS),

* 湖南省气象局创新发展专项(青年专项)(CXFZ2024-QNZX23)、国家自然科学基金(U2342219)、中国气象科学研究院基本科研业务费专项(2023Z022、2023Z013)和中国气象科学研究院科技发展基金(2023KJ022、2024KJ008)共同资助

第一作者: 卢姝, 主要从事人工智能气象应用与研究. E-mail: lushu0818@163.com

通讯作者: 陈鹤, 主要从事天气预报与研究. E-mail: chenhe@msn.cn

31 an enhanced model named ED-LSTM-FCNN is constructed, incorporating an embedding layer
32 module to handle high-dimensional spatial and temporal features. A fully connected neural
33 network was utilized to integrate various features types and achieve regression prediction of
34 temperature, generating gridded hourly temperature forecast products with a resolution of
35 $0.05^{\circ} \times 0.05^{\circ}$. Verification for the 2022 forecast in Hunan Province revealed that the model
36 exhibits a notable capacity to mitigate forecast errors inherent in the numerical model, thereby
37 enhancing the overall forecast stability. The root mean square errors (RMSE) for forecast lead
38 times ranging from 1 to 24 hours exhibit a reduction of 25.4% to 37.7% when compared to
39 ECMWF-IFS and a decrease of 15.8% to 40.0% in comparison to the SCMOC. The model
40 significantly enhances the forecast performance of ECMWF-IFS in spatial prediction,
41 particularly in regions characterized by intricate terrain features. The RMSEs across most areas
42 vary within the range of 1.2 °C to 1.6 °C. The forecast accuracy of the model, with an error
43 margin of ± 2 °C, surpasses 85.0% across various seasons, demonstrating a significant
44 improvement compared to both ECMWF-IFS and SCMOC. The forecasting performance is
45 notably superior, particularly in stable extreme high-temperature weather conditions, when
46 compared to alternative products. In conclusion, this method proved to be effective for
47 high-resolution temperature grid forecasting operations.

48 **Key words:** gridded forecast, long short-term memory network, temperature forecast, deep
49 learning

51 引言

52 气温是水文学、气象学、地球系统科学领域中最关键的地表变量之一，与气候变化、自然
53 灾害以及人类健康密切相关，当前政府以及公众对于精细化网格气温预报需求日益提升，
54 要求获取具备空间无缝性和时间连续性的天气预报产品(刘新伟等，2020)。现代天气预报主
55 要建立在数值预报模型基础之上，然而大气、海洋以及其耦合系统运动常呈现非线性不稳定
56 特征，数值模式还不能很好刻画这种运动规律，存在模式误差(孙健等，2021)，直接输出预
57 报产品的时空分辨率不能满足当前业务需求，需要进一步对模式输出产品进行后处理。常见
58 的模式后处理方法包括模式输出统计(Glahn and Lowry, 1972)、准对称混合滑动训练期方法
59 (吴启树等，2016)、最优集合预报订正方法(郝翠等，2019)以及卡尔曼滤波自适应误差订正
60 方法(王丹等，2019)等，这类传统客观预报技术主要应用于站点建模，大多基于预报因子与

61 预报量之间线性关系建立模型,无法有效处理海量气象数据信息,随着预报时空分辨率的提
62 高和预报时效的延长,预报效果并不理想(陈昱文等, 2020)。

63 机器学习方法也可用于天气预报中(杨璐等, 2021; Han et al, 2021; 张延彪等, 2022a;
64 徐景峰等, 2023; 陈锦鹏等, 2024)。早在 2009 年, Paras et al (2009) 引入了基于特征的
65 神经网络模型来预报最高、最低温度,神经网络特征在不同时间段从时间序列天气参数中提
66 取,利用前馈神经网络和反向传播的方式进行监督学习,展示出神经网络的巨大潜力。
67 近年来,随着气象数据和计算资源的发展,机器学习技术在模式订正中得到广泛应用(Zhao
68 et al, 2023; Wang et al, 2023; 方鸿斌等, 2024)。Cho et al (2020) 应用随机森林、支持向
69 量回归、全连接神经网络(FCNN)和多模型集成策略,建立预报量和预报因子之间的统计
70 关系模型,以校正数值模式在城市地区极端高温的预报偏差,表明机器学习技术对于天气过
71 程的非线性建模有显著优势。Qin et al (2023) 提出了一种网格到多点(G2N)模型输出误
72 差校正方案,通过构建 AlexNet 的网络架构提取空间特征并同时校正多站预测,G2N 使数
73 值模型的 2 m 温度预报均方根误差降低了 19%。

74 在气象预测模型构建中,普通人工神经网络通常假定气象要素之间相互独立,并未考虑
75 要素之间的时序关系(门晓磊等, 2019; 陈鹤等, 2022)。循环神经网络诸如长短期记忆网
76 络(LSTM)等用于处理序列数据,可提取时序特征(Cho et al, 2022)。Hewage et al (2021)
77 基于 LSTM 和时间卷积网络的时序建模方法,预报未来 12 h 的 10 个地面气象要素,预报
78 效果优于 WRF 模式。Zhang et al (2022) 应用长短期记忆-全连接网络(LSTM-FCNN)对
79 国家气象中心 CMA-MESO(原 GRAPES-3km)模式输出的 2 m 温度进行偏差订正,通过融
80 合 LSTM 和 FCNN,将从站点气象要素预报中挖掘的时间序列信息以及站点的海拔、经纬
81 度信息相结合,与模式相比陕西区域的站点气温预报均方根误差降低了 32%。

82 上述研究工作主要以观测站点为预报对象,精细化格点预报的应用研究并不多,张延彪
83 等(2022b)使用睿思高分辨率系统输出的 2 m 温度、2 m 相对湿度、10 mU 风速以及 10 mV
84 风速格点预报数据,建立卷积神经网络模型进行偏差订正,取得一定的改善效果。然而卷积
85 神经网络忽略了数据的时序关系,尤其对于气温这类连续性变量而言,考虑时序关系建模尤
86 为重要,LSTM 可发挥重要作用(Yan et al, 2021; 张桃等, 2023)。基于 LSTM 的建模方
87 式是将所有站点样本进行堆叠,建立统一的预报模型,克服了传统方法中仅针对单一站点建
88 模的局限性,可以推广至格点建模中。但是 LSTM 仅专注数据时序性,未考虑其空间性(Jeong
89 et al, 2021)。为了更好地应用空间信息,赵琳娜等(2022)曾在 FCNN 中融入嵌入层(ED)
90 结构以结合站点和月份信息,核心思想是将站点号、月份特征视作分类变量而非连续变量。
91 嵌入层最初应用于深度学习自然语言处理的词嵌入任务中,主要目的是将高维度的离散输入
92 数据映射到低维度的连续向量空间中,可以用以处理高维分类变量(Dahouda and Joe, 2021)。

93 针对当前我国气象部门智能网格预报发展要求,本研究结合欧洲中期天气预报中心高分
94 辨率模式(ECMWF-IFS)预报产品和中国气象局陆面数据同化系统(CLDAS)气温资料,
95 构建融合 LSTM、FCNN 以及 ED 这几类不同网络结构的混合神经网络预报模型,以提高格
96 点气温预报的时空分辨率。进一步检验评估该模型输出的湖南地区范围内逐小时格点气温预
97 报产品、中央气象台智能网格指导预报(SCMOC)以及逐 3 h 的 ECMWF-IFS 预报产品,
98 验证该方法在业务上的实际应用效果,以期对精细化气温预报研究提供参考。

99

100 1 数据及预处理

101 1.1 资料

102 本文采用的预报数据为 ECMWF-IFS 高分辨率预报产品，起报时间分别为 08 时（北京
 103 时，下同）和 20 时，预报时效 15~36 h，时间分辨率 3 h，地面、高空变量预报场水平分辨率
 104 分别为 0.125°×0.125° 和 0.25°×0.25°。在实际业务运行中，ECMWF-IFS 预报产品接收时间
 105 相比实际起报时间延迟约 7 h，因此对 ECMWF-IFS 后处理时需采用预报时效 12 h 之后的预报
 106 产品。观测数据为 CLDAS 逐 1 h 气温产品，水平分辨率为 0.05°×0.05°，参与对比检验的
 107 格点包括湖南省界线以内所有格点，空间范围大致为(24.50° ~30.25° N, 108.65° ~114.40° E)。
 108 预报与观测数据总时长为 2017 年 10 月至 2022 年 12 月，划分 2017 年 10 月至 2021 年
 109 9 月为训练集，2021 年 10 月至 2021 年 12 月为验证集，2022 年为测试集。

110 1.2 数据预处理

111 为获取未来 24 h 逐 1 h 气温预报，基于 ECMWF-IFS 不同起报时次，不同预报时效(15~36
 112 h，逐 3 h) 单独建模，共建立 16 个模型。分别构建输入模型的数据集，其中特征数据集为
 113 单个预报时效的 ECMWF-IFS 数据，目标数据集为该预报时效对应预报时间及前 2 h 的观测
 114 数据，采用最近邻插值方法将 ECMWF-IFS 数据上采样至观测数据格点。为保证模型在训练
 115 过程尽可能收敛，在数据预处理中进行数据缩放操作，公式如下：

$$116 \quad x^* = \frac{x - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

117 式中： X_{\min} 和 X_{\max} 分别为样本数据的最小值和最大值。

118 为提高建模效率，增强模型泛化能力，采用相关分析法从 ECMWF-IFS 所有预报因子中
 119 筛选出相关变量，选择与气温实况相关系数大于 0.3，且概率小于 0.05 的预报因子 (Zhang et
 120 al, 2020)。通过计算不同预报时效 ECMWF-IFS 预报因子与气温实况的相关性发现，在不
 121 同预报时效中相关系数均超过 0.8 的因子包括 2 m 温度、地表温度、2 m 露点温度、850/1000
 122 hPa 温度和 1000 hPa 比湿等。可见低空至近地面温度相关预报因子对气温预报影响较大，此
 123 外，中、低层的比湿、风场也对气温有一定贡献。除模式预报因子外，融合多源数据可以帮助
 124 建模 (周康辉等, 2021)。赵琳娜等 (2022) 指出在预报数据中融合历史观测数据 (时间
 125 滞后观测变量) 作为模型输入能增加神经网络学习的信息量，提高气温预报准确率。本文增
 126 加三种类型的辅助变量 (时间滞后观测变量、月份和格点号)，为模型提供临近气温观测信
 127 息以及时间、空间信息。当基于预报时效 15~30 h (逐 3 h) ECMWF-IFS 数据建模时，时间
 128 滞后观测变量包括滞后 1 d、滞后 2 d 气温观测。当基于预报时效 33 h、36 h 的模式预报建
 129 模时，考虑实际业务运行时，模式到报时间较晚，时间滞后观测变量只包含滞后 2 d 气温观
 130 测。表 1 给出最终输入各模型的共同特征。

131 表 1 输入模型的共同特征

132 Table 1 Common features of input all models

ECMWF-IFS 预报因子		辅助变量
地面变量	高空变量	
2 m 温度、2 m 露点温度、10 m 经向风、对流有效位能、预报反照率、地表温度、大气柱总水量、大气柱水汽总量	500 hPa 位势高度、500/700/850/1000 hPa 温度、1000 hPa 经向风、500/700/850/1000 hPa 比湿	时间滞后观测变量、月份、格点号

133

134 2 模型构建

135 2.1 算法建模

136 考虑到气象数据的时间关联性以及气温序列变化所具有的趋势性、周期性和连续性等特点，引入 LSTM 以学习 ECMWF-IFS 预报因子以及时间滞后观测变量（时序特征）在给定

137 时序上的演变规律。其中，LSTM 属于循环神经网络中的一种，被广泛应用至时序预测问题。

138 与 FCNN 不同，LSTM 有着重复的神经网络模块形成链式结构，可捕捉信息间的长距离依赖关系，同时引入特殊的门控机制，从而解决了普通循环神经网络存在的梯度爆炸和梯度弥散问题，其内部结构如图 1 所示，前一个时间步的隐藏状态 h_{t-1} 和当前时间步的输入 x_t 在通过各个门之前首先合并处理，遗忘门控制忘记信息量，输入门有助于识别需要添加到细胞状态 c_t 的重要元素，信息经历 LSTM 循环单元后最终更新细胞状态 c_t 和隐藏状态 h_t 。LSTM 的详细运算过程见参考文献（Hochreiter and Schmidhuber, 1997）。

141 142 143 144

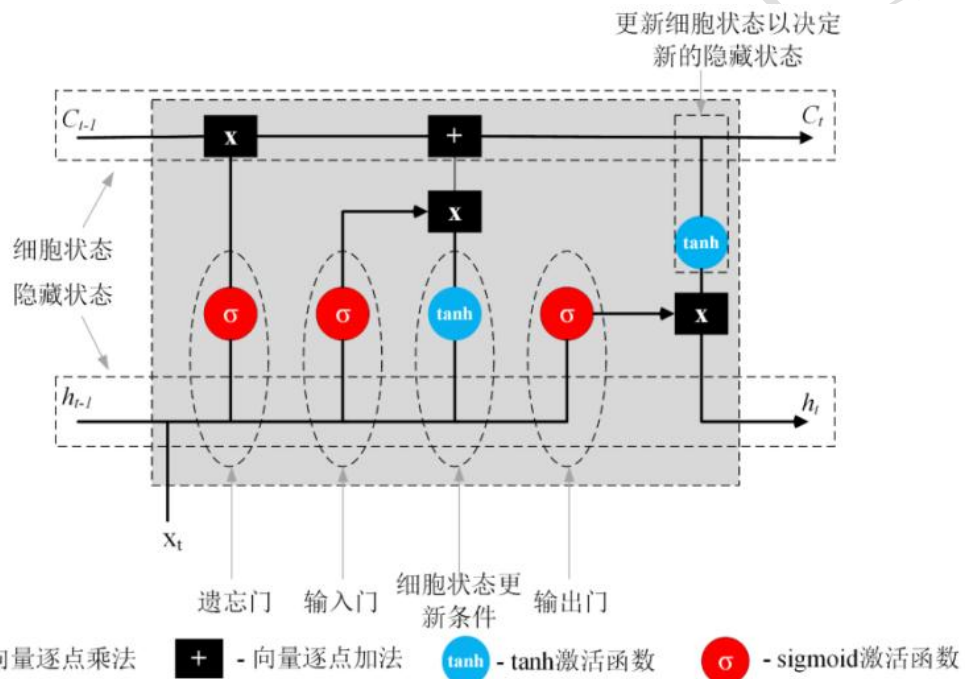


图 1 长短期记忆神经网络结构

Fig.1 Long short-term memory networks neuron structure

145

146

147

148

149 为满足 LSTM 输入，应用滑动时间窗口构建时序数据集。滑动时间窗口时序长度过长

150 会导致内存消耗增加等问题，另外，为更好地帮助模型捕捉数据中周尺度趋势及变化，进一

151 步提升平稳天气气温预报能力，本文选取时间窗口长度为 7d。在不同格点上，应用滑动时

152 间窗口沿着时间维度进行逐日滑动。对于时序特征，形成长度为 7d 的时序数据，对于目标，

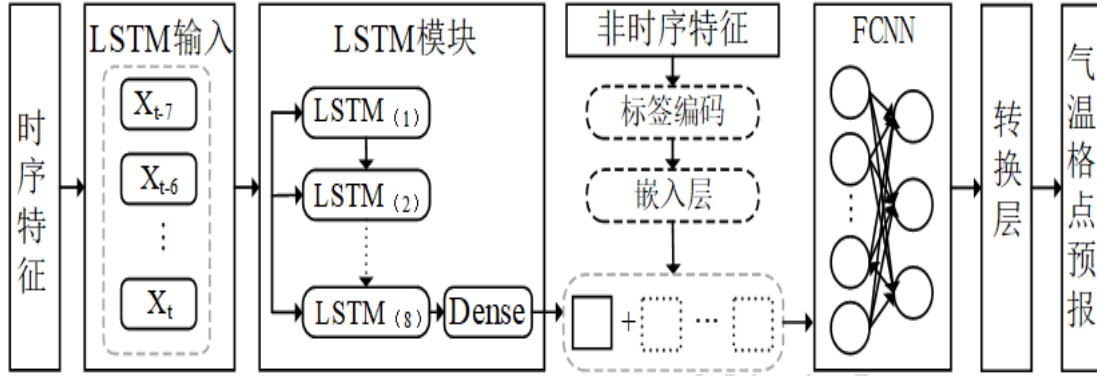
153 仅取滑动时间窗口的最后 1d，以构造多步长到单步长的时序预测任务。拼接不同格点的样

154 本，以进一步增加样本量，保证深度学习模型训练数据量。

155 然而，有些非时序特征（格点号和月份）对于模型可能有重要影响，将此类特征连同时

156 序特征共同输入 LSTM 实际上没有意义，并且降低模型训练速率。ED 模块可以帮助处理此

157 类高维分类变量,使模型能从大量样本中识别不同月份、不同格点的样本。赵琳娜等(2022)
 158 在构建全国站点的日最高气温预报模型时发现,加入嵌入层的 FCNN(简称 ED-FCNN 模型)
 159 相比普通的 FCNN 能取得更优的预报性能,验证了嵌入层的可用性。因此本文基于 ED-FCNN
 160 架构,进一步引入了 LSTM 模块,构造多输入混合神经网络 ED-LSTM-FCNN 模型(图 2),
 161 以接收不同类型数据。时序特征输入 LSTM 模块进行特征提取,非时序特征输入 ED 层进行
 162 数据分类、降维处理,由 FCNN 接收 LSTM 与 ED 模块的输出,对提取的高阶特征进行解
 163 码,最后由转换层将拼接数据重组为格点数据输出。



164
 165 图 2 ED-LSTM-FCNN 模型结构
 166 Fig.2 ED-LSTM-FCNN model structure
 167

168 2.2 试验设置

169 本文模型超参数设置见表 2。为帮助模型在训练中更好地拟合数据,增强模型泛化能力,
 170 采用早停法进行训练,当模型在验证集上连续 3 个时期损失值不降反增时,停止训练,并保
 171 存在训练过程中验证集上表现最优的模型。

172 表 2 模型训练超参数设置

173 Table 2 Hyperparameter settings in model training

超参数	设置
学习率	0.001
优化器算法	自适应动量随机优化算法
训练时期数	10
正则化方法	早停法
批量数	64
损失函数	平均绝对误差
嵌入层嵌入向量维度	8

174 为评估模型在测试集上的表现效果,采用的检验方法包括均方根误差 RMSE、平均偏差
 175 ME 与气温预报准确率 F_2 :

177
$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (obs_i - pre_i)^2} \quad (2)$$

178

$$ME = \frac{1}{N} \sum_{i=1}^N (pre_i - obs_i) \quad (3)$$

179

$$F_2 = \frac{n_2}{n} \times 100\% \quad (4)$$

180

式中： obs_i 和 pre_i 分别代表第 i 个样本的观测值与预报值， n_2 为气温预报值与观测值绝对误差不超过 $2\text{ }^\circ\text{C}$ 的样本量， n 为总样本量。

182

183 3 结果分析

184 3.1 分时效预报效果检验


185

为验证 LSTM 模块的有效性，基于 ED-LSTM-FCNN 模型进行消融试验，去除模型中 LSTM 模块，直接将时序特征与经过嵌入层处理后的非时序特征拼接后输入 FCNN（简称 ED-FCNN）。省级预报业务中常用 SCMOC 作为参考预报源，因此本文中分别对比 ED-LSTM-FCNN、ED-FCNN、ECMWF-IFS 和 SCMOC 预报效果。图中结果统一使用实际业务起报时间（数值模式起报时间+12 h、预报时效-12 h）。当 ECMWF-IFS 预报产品的起报时次为 08（20）时，预报时效为 12~36 h，对应 SCMOC 和深度学习模型产品的起报时次为 20（08）时，预报时效为 0~24 h。

192

图 3 为不同起报时次、不同预报时效的深度学习模型、ECMWF-IFS 和 SCMOC 的 RMSE 对比。从逐 3 h 预报来看，ECMWF-IFS 模式 08、20 时（对应实际业务 20、08 时）起报的 RMSE 分别介于 $1.9\sim 2.6\text{ }^\circ\text{C}$ 和 $1.8\sim 2.4\text{ }^\circ\text{C}$ ，在不同起报时次的预报误差日变化特征相似，午后预报误差较大，凌晨较小。模式不同起报时次对高、低温时段的预报效果各有优劣，08 时起报（截取预报时段为当日 20 时至次日 20 时）与 20 时相比，低温时段更接近于起报时次，因此对于低温时段的预报误差要更小（图 3a）；当起报时次为 20 时（截取预报时段为次日 08 时至第三日 08 时），对于白天的高温预报效果更优（图 3b）。综合两个起报时次的检验结果，ED-LSTM-FCNN、ED-FCNN 模型有效降低了 ECMWF-IFS 的 RMSE，降幅分别达 $25.4\%\sim 37.7\%$ 和 $20.2\%\sim 29.6\%$ ，误差日变化趋势与模式相似，说明深度学习模型的预报效果与模式产品相关性较大。对比逐 1 h 深度学习模型与 SCMOC 产品预报效果，ED-LSTM-FCNN、ED-FCNN 模型的 RMSE 分别介于 $1.2\sim 2.0\text{ }^\circ\text{C}$ 、 $1.3\sim 2.1\text{ }^\circ\text{C}$ ，与 SCMOC 相比分别降低了 $15.8\%\sim 40.0\%$ 和 $6.2\%\sim 33.5\%$ 。ED-LSTM-FCNN 模型在不同起报时次、所有预报时效上 RMSE 均最低，20 时、08 时起报的 RMSE 与 ED-FCNN 模型相比分别降低 $3.5\%\sim 19.3\%$ 和 $5.9\%\sim 16.6\%$ ，可见 LSTM 模块的引入对于模型性能提升至关重要，由于不同类型的气象现象具有不同时间尺度特征，LSTM 的记忆单元能够有效学习序列中的长期依赖关系，帮助模型更好地理解气象数据的变化趋势。经过 LSTM 提取的时序特征输送至 FCNN，再由 FCNN 整合该时序特征以及嵌入层输出的非时序特征，融入空间和月份信息，增强模型对复杂数据样本的辨识及拟合能力，进一步提升了 ED-LSTM-FCNN 模型的预测准确性。

210



注：图中标注表示 ECMWF-IFS 在 15~36 h (逐 3 h) 预报时效上的气温预报均方根误差。
图 3 不同预报产品 (a) 20 时、(b) 08 时起报的各预报时效气温预报均方根误差

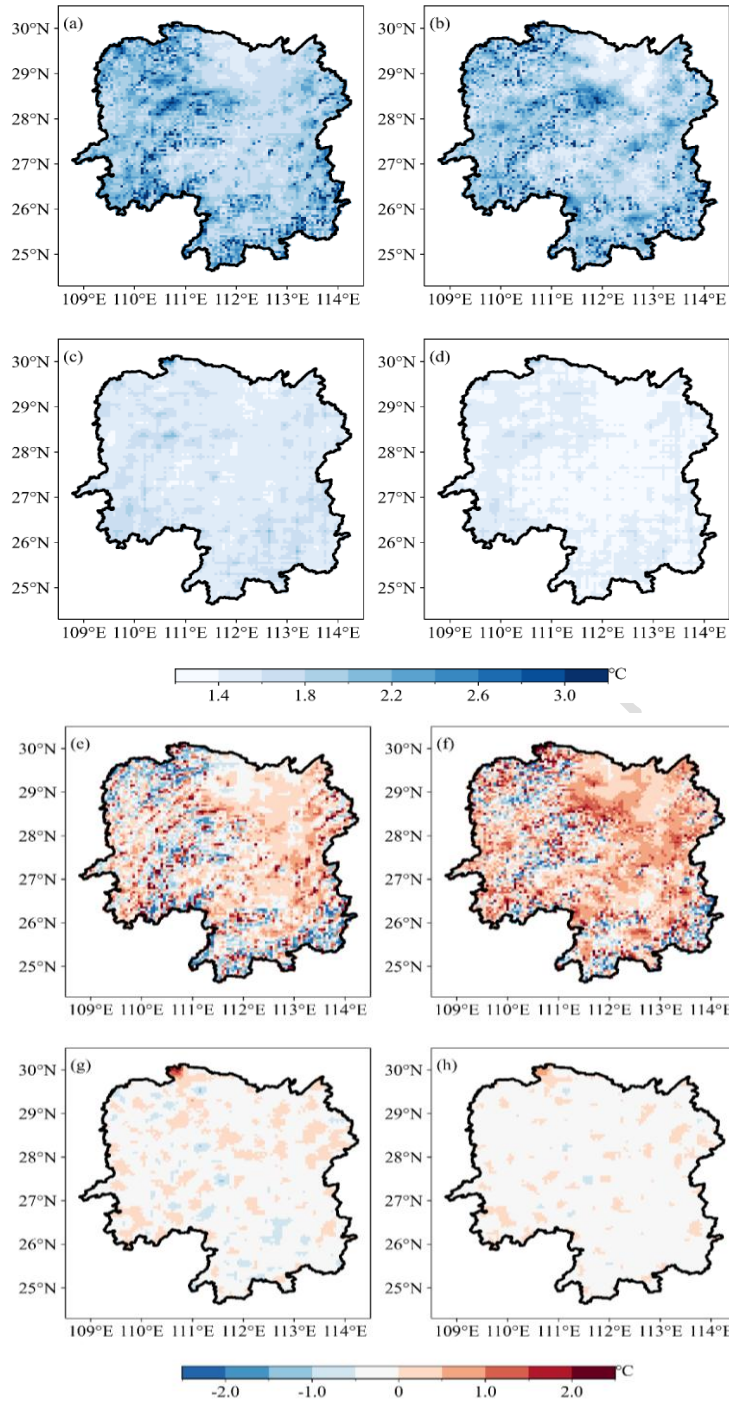
Fig.3 Root mean square error of temperature forecast for each leading times of different products initiated at (a) 20:00 BT, (b) 08:00 BT

3.2 空间和时间应用效果检验

图 4 是湖南地区 ECMWF-IFS 逐 3 h、SCMOC、深度学习模型逐 1 h 气温预报的平均 RMSE (图 4a~4d) 与 ME 空间分布 (图 4e~4h)。ECMWF-IFS 的 RMSE 空间分布特征与湖南地形结构相似, 湖南西北、西南、南部以及东部分别分布有武陵山脉、雪峰山脉、南岭以及罗霄山脉, 该区域 RMSE 达 2.0 °C 以上, 最高值为 6.5 °C, 中部丘陵盆地地势相对低平, RMSE 为 1.6~2.0 °C, 北部洞庭湖平原为 1.4~1.6 °C。SCMOC 的 RMSE 空间分布也呈现明显的地形相关特征, 介于 1.3~6.6 °C, 与 ECMWF-IFS 相比对于北部平原预报效果更好。ED-LSTM-FCNN 和 ED-FCNN 模型有效降低了 ECMWF-IFS 的系统性偏差, 整体预报效果优于 SCMOC, RMSE 分别介于 1.2~2.0 °C 和 1.3~2.7 °C, 显著降低了西部、南部和东部复杂地形区域的预报误差。统计上述模型在不同区间 RMSE 上的格点数占总格点数比例, 以 1.2~1.4 °C 为例, ED-LSTM-FCNN、ED-FCNN、SCMOC 和 ECMWF-IFS 的比例分别约 52.7%、4.0%、2.2% 和 0.0%, 即 ED-LSTM-FCNN 模型超过一半区域 RMSE 低于 1.4 °C, 且主要分布在向北开口的马蹄形盆地区, 而 ED-FCNN 模型仅占比 4.0%, 可见 ED-LSTM-FCNN 模型在空间上应用效果优于 ED-FCNN 模型。

RMSE 可反映整体偏差幅度, 但忽略误差正负向问题, 为了考量不同模型定量预报订正效果, 进一步评估 ME 的空间分布。ECMWF-IFS 和 SCMOC 在中部、北部的丘陵盆地和平原区预报比实况整体偏高, 在山原山地区预报比实况整体偏低, ME 分别介于 -4.3~6.2 °C 和 -4.8~6.4 °C。ED-LSTM-FCNN 和 ED-FCNN 模型明显降低了湖南全域 ME 绝对值, 其中

236 ED-LSTM-FCNN 模型将 ME 绝对值降低至 1.0 °C 以内，绝大部分地区介于 -0.5~0 °C，优于
 237 ED-FCNN 模型。



238

239

240

241

242

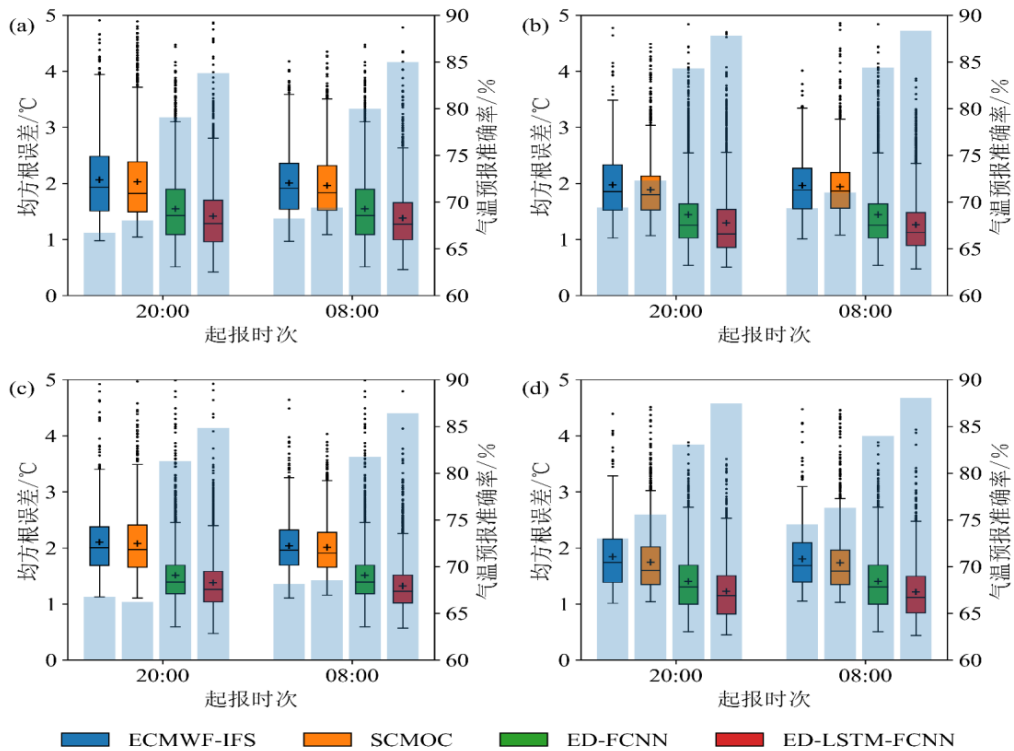
243

244

图 4 2022 年湖南地区不同预报产品气温预报的平均 (a, b, c, d) RMSE 和 (e, f, g, h) ME 空间分布
 Fig.4 Spatial distribution of (a, b, c, d) average root mean square error and (e, f, g, h) mean deviation of
 different products in Hunan Province in 2022

从不同季节逐小时气温预报 RMSE 箱线图以及平均准确率柱状图来看，无论是 20 时还

245 是 08 时起报,深度学习模型 RMSE 分布的均值和中位数明显低于 ECMWF-IFS 与 SCMOC,
 246 在箱体两端出现误差较大的离群点,说明经过模型订正后仍然会出现个别天数预报误差与实
 247 况有较大差距的情况。以 20 时起报为例,ECMWF-IFS、SCMOC、ED-LSTM-FCNN 和
 248 ED-FCNN 模型在冬季预报效果优于其他季节, RMSE 分布的均值和中位数分别为 1.8 °C 和
 249 1.7 °C (ECMWF-IFS)、1.7 °C 和 1.6 °C (SCMOC)、1.2 °C 和 1.2 °C (ED-LSTM-FCNN)、
 250 1.4 °C 和 1.3 °C (ED-FCNN)。在不同季节,ED-LSTM-FCNN 模型 RMSE 分布的均值和中
 251 位数均最低,例如,春季均值相比 ECMWF-IFS、SCMOC 和 ED-FCNN 模型分别下降 33.3 %、
 252 30.0 % 和 12.5 %。同时从气温预报准确率柱状图来看,ED-LSTM-FCNN 模型气温预报准确
 253 率最高,在不同季节均可达到 85.0 % 以上,夏季达到 88.3 %。
 254



255 注:箱线图箱体中横线为中位数,“+”为均值,箱体上端及下端分别为第 75%和 25%分位值,触须的上端和下端分别代表除异
 256 常值外的最大值和最小值,尾端实心点为超出第 75%位数差 3 倍距离的异常值。
 257

258 图 5 不同预报产品在不同起报时次、不同季节气温预报的 RMSE (箱线图) 与平均准确率 (柱状)

259 Fig.5 The temperature root mean square error and average accuracies of different products at different initialized
 260 times and seasons
 261

262 3.3 超阈值气温预报效果评估

263 温度过高或过低导致的高低温事件(如寒潮和高温热浪)更易对公众和农牧业生产等活
 264 动产生重要影响,因此,本文评估了在超阈值样本上不同预报产品的预报效果。超阈值分为
 265 超高温阈值和超低温阈值(邱贵强等, 2023),高低温阈值分别通过实况数据的 90%、10%
 266 分位数确定,分别计算湖南境内各格点的高低温阈值,基于选出的超阈值样本分别计算
 267 RMSE、ME 和 F_2 (表 3)。08 时起报的深度学习模型对于极端高温的预报效果好于 20 时

268 起报，与 3.1 节中结论一致。ED-LSTM-FCNN 模型在不同起报时次对于各格点上相对极端
 269 的气温预报效果最优。针对超高温阈值，08、20 时起报的 ED-LSTM-FCNN 模型 RMSE 分
 270 别为 1.4 °C 和 1.6 °C，相比 ECMWF-IFS(SCMOC)降低了 41.7 % 和 36.0 % (30.0 % 和 27.3 %)，
 271 预报准确率提高了 47.6 % 和 46.6 % (22.5 % 和 28.0 %)；对于超低温阈值预报的 RMSE 分
 272 别为 1.3 °C 和 1.2 °C，相比 ECMWF-IFS(SCMOC)降低了 27.8 % 和 33.3 % (27.8 % 和 33.3 %)，
 273 预报准确率提高了 14.0 % 和 15.1 % (16.1 % 和 18.1 %)，且明显优于 ED-FCNN 模型。从
 274 ME 来看，模型对于超低（高）温阈值样本预报偏高（低）。

275
 276 表 3 不同预报产品对超阈值气温预报的 RMSE、ME 与 F_2

277 Table 3 Root mean square error, average deviation and accuracy of temperature forecast exceeding the threshold
 278 by different products


起报时次	模型	低于超低温阈值样本			高于超高温阈值样本		
		RMSE/°C	ME/°C	F_2 /%	RMSE/°C	ME/°C	F_2 /%
20	ECMWF-IFS	1.8	0.3	78.3	2.5	-1.5	58.0
	SCMOC	1.8	0.8	76.3	2.2	-1.2	66.4
	ED-FCNN	1.3	0.3	87.5	1.7	-0.5	80.6
	ED-LSTM-FCNN	1.2	0.4	90.1	1.6	-0.6	85.0
08	ECMWF-IFS	1.8	0.3	78.3	2.4	-1.5	59.4
	SCMOC	1.8	0.7	76.9	2.0	-0.8	71.6
	ED-FCNN	1.4	0.3	87.4	1.6	-0.5	81.5
	ED-LSTM-FCNN	1.3	0.5	89.3	1.4	-0.6	87.7

279
 280

281 3.4 天气个例评估

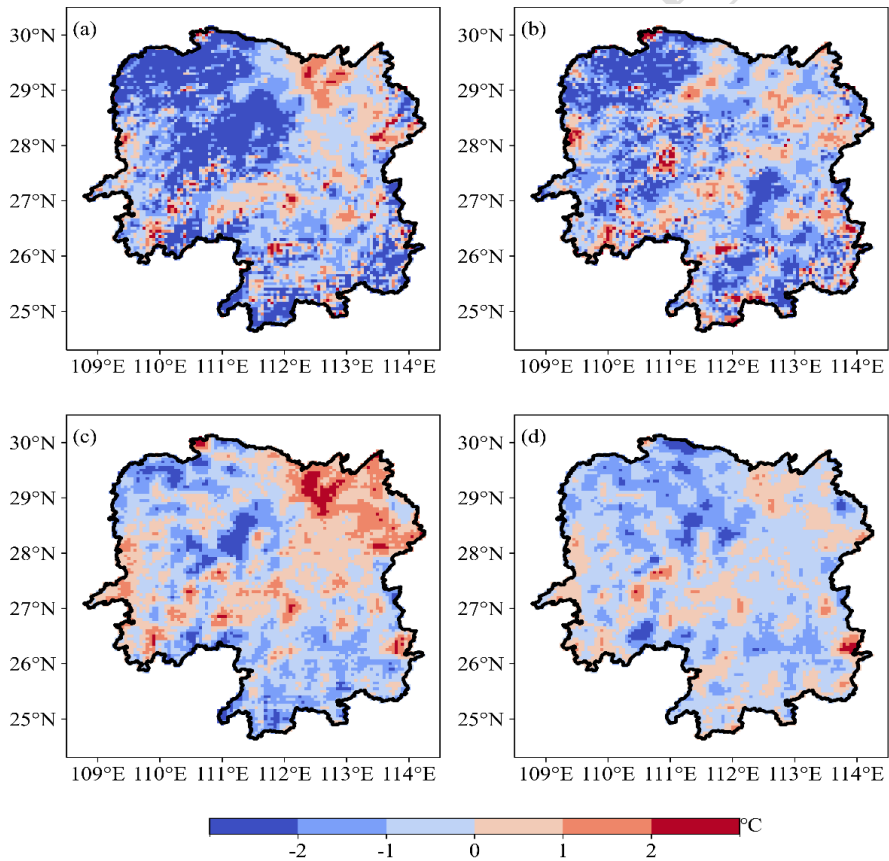
282 为具体评估各模型在极端天气情况下的预报能力，本文选取 2022 年 8 月 17—19 日的极
 283 端高温过程和 2022 年 11 月 27—29 日的强降温过程分别进行评估。

284 从高温个例来看，湖南地区大部分时段受 500 hPa 西太平洋副热带高压控制，维持晴热
 285 少雨天气。模式在夜间对于平均气温预报明显偏高（图 6），大部分区域气温预报值高于观
 286 测值，偏差在 2.0 °C 以上（图略）。在 ED-LSTM-FCNN 模型中，加入了时间滞后观测变量，
 287 对于这种平稳性的天气过程，观测数据能够提供对模式的约束，此外 LSTM 模块擅长捕捉
 288 时序演变特征，进一步修正模式偏差，在夜间预报效果优于其他产品。而对于一天中的高温
 289 时段，模式预报比实况明显偏低，尤其在武陵山和雪峰山等高海拔地区。图 7 为 8 月 19 日
 290 14 时预报值与观测值的偏差空间分布，ED-LSTM-FCNN 模型在绝大部分地区预报比实况略
 291 偏低，RMSE 为 0.9 °C，ED-FCNN 模型则在部分地区（如洞庭湖平原区）预报比实况明显
 292 偏高，RMSE 为 1.1 °C。在模型训练中，训练数据未包含足够的高温天气样本，模型无法充
 293 分学习高温天气的特征，导致极端高温预报略有偏差。从整个高温过程的 RMSE 空间分布
 294 来看（图 8），ECMWF-IFS 在湖南西北部、东部武功山、连云山等山丘地区误差达 2.5 °C
 295 以上，而深度学习模型尤其 ED-LSTM-FCNN 模型在湖南绝大部分区域误差低于 1.5 °C，预
 296 报效果明显优于其他产品。



297
298
299
300
301

图 6 2022 年 8 月 17 日 20 时至 19 日 20 时不同预报产品全省平均气温预报与实况对比
Fig.6 Comparison between the average temperature forecast of different products and the observations in Hunan Province from 20:00 BT 17 August to 20:00 BT 19 August 2022



302
303
304
305
306

图 7 2022 年 8 月 19 日 14 时不同预报产品气温预报值与观测值的偏差空间分布
Fig.7 Spatial distribution of the deviation between temperature forecasts of different products and observations at 14:00 BT 19 August 2022

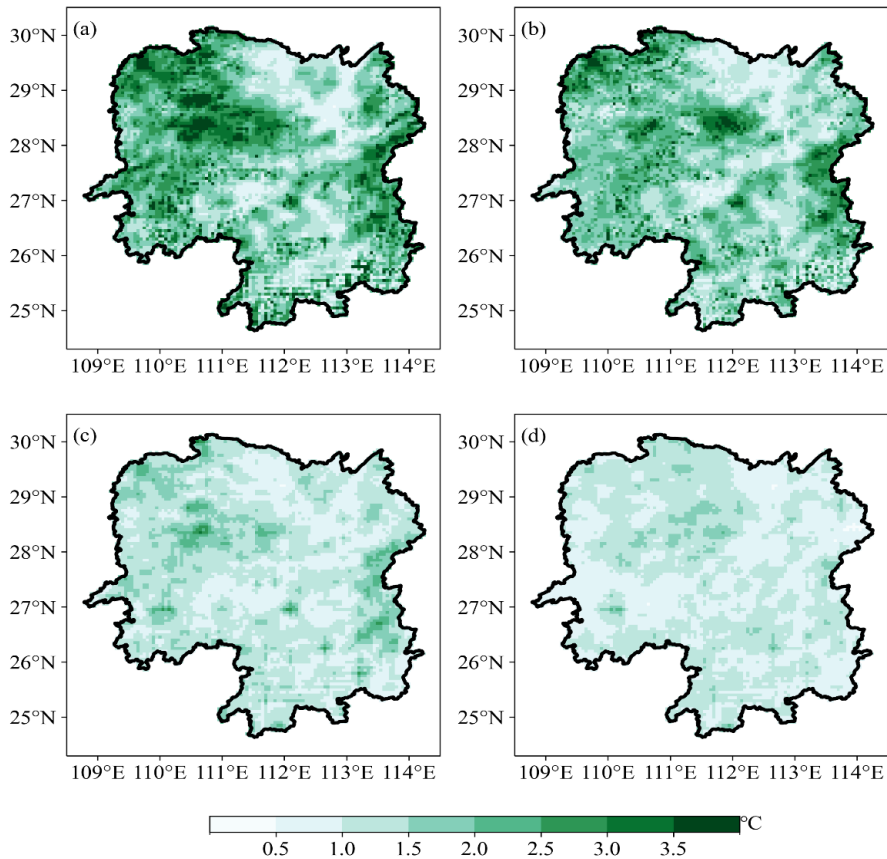


图 8 2022 年 8 月 17—19 日不同预报产品气温预报的 RMSE 空间分布


Fig.8 Spatial distribution of root mean square error in temperature forecasts of different products from 17 to 19

August 2022

307
308
309
310
311
312
313
314
315
316
317
318
319
320
321
322
323
324
325
326
327

2022 年 11 月 27—29 日的过程是一次寒潮降温伴随较强降水天气过程（图 9）。11 月 27 日开始，湖南地区 850 hPa 中低空为较强西南气流，切变线位于湖南北部地区，相对湿度在 90 % 以上，动力和水汽条件充沛，有利于降水发生，同时近地面有冷空气渗透南下。28 日 14 时，切变线开始缓慢南移，925 hPa 高度以下中部以北地区已转成偏北风，风速达 $10 \text{ m} \cdot \text{s}^{-1}$ ，至次日 02 时，850 hPa 切变线已南移至湘南地区，925 hPa 湖南全省转为偏北风，最大风速达 $20 \text{ m} \cdot \text{s}^{-1}$ 以上，在此期间配合较好的水汽、动力条件，全省出现小到中雨。受强冷空气与降水的共同影响，全省平均气温从 28 日 14 时至 29 日 20 时持续下降（图 10），达到寒潮标准，而 SCMOC 和 ED-FCNN 模型预报 29 日上午平均气温为上升趋势。图 11 为 11 月 29 日 11 时预报与观测的偏差空间分布，ED-LSTM-FCNN 模型在湘西、湘南等地预报高于实况，ED-FCNN 模型和 SCMOC 偏高的范围和程度更明显，前一天同时段气温呈增加趋势，模型预报结果可能受到前期气温趋势影响。从整个强降温过程的 RMSE 空间分布来看（图 12），ECMWF-IFS 在湘西南地区（山地为主）误差达 $3.0 \text{ }^{\circ}\text{C}$ 以上，高于其他区域。SCMOC 在雪峰山、南岭等地气温预报误差甚至达到 $4.0 \text{ }^{\circ}\text{C}$ 以上。ED-LSTM-FCNN 和 ED-FCNN 模型对于湘北地区模式预报误差有一定订正效果，其他地区效果不佳。从过程的逐 3 h 偏差空间分布来看（图略），ED-LSTM-FCNN 模型无法显著改善模式预报，RMSE 由 $2.4 \text{ }^{\circ}\text{C}$ 降低至 $2.1 \text{ }^{\circ}\text{C}$ ，但仍然优于 SCMOC，逐 1 h 气温预报的 RMSE 相比 SCMOC 降低

328 了 14.8 %，综上，ED-LSTM-FCNN 模型对于大范围复杂的强降温过程预报能力稍弱，可能
 329 原因在于训练数据集中强降温过程的样本占比较少，影响此类天气形势下的模型预报能力。

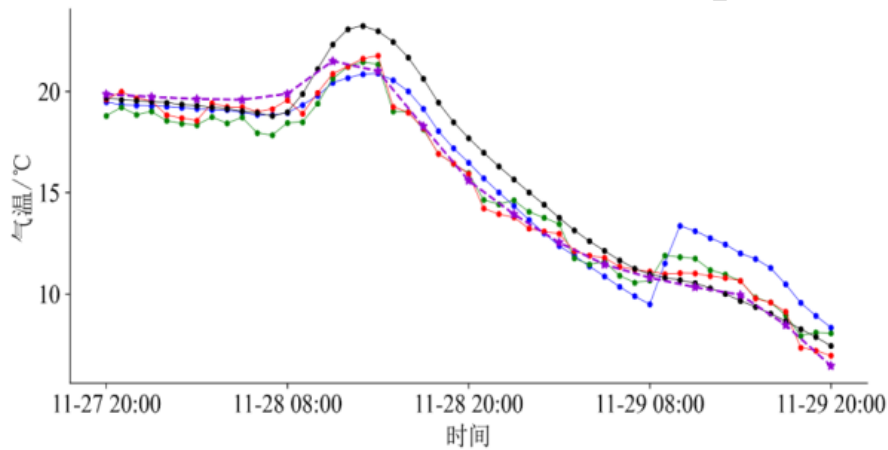


330

331 图9 2022年11月(a)28日14时、(b)29日02时500hPa高度场(等值线,单位:dagpm)、850hPa
 332 风场(蓝色风羽)、相对湿度场(填色)和925hPa风场(黑色风羽)

333 Fig.9 500 hPa height (contour, unit: dagpm), 850 hPa wind (blue barb), 850 hPa relative humidity and
 334 925 hPa wind (black barb) at (a)14:00 BT 28 and (b) 02:00 BT 29 November 2022

335



336

—●— SCMOC —■— ED-FCNN —▲— ED-LSTM-FCNN —◆— OBS —★— ECMWF-IFS

337

图10 2022年11月27日20时至29日20时不同预报产品全省平均气温预报与实况对比

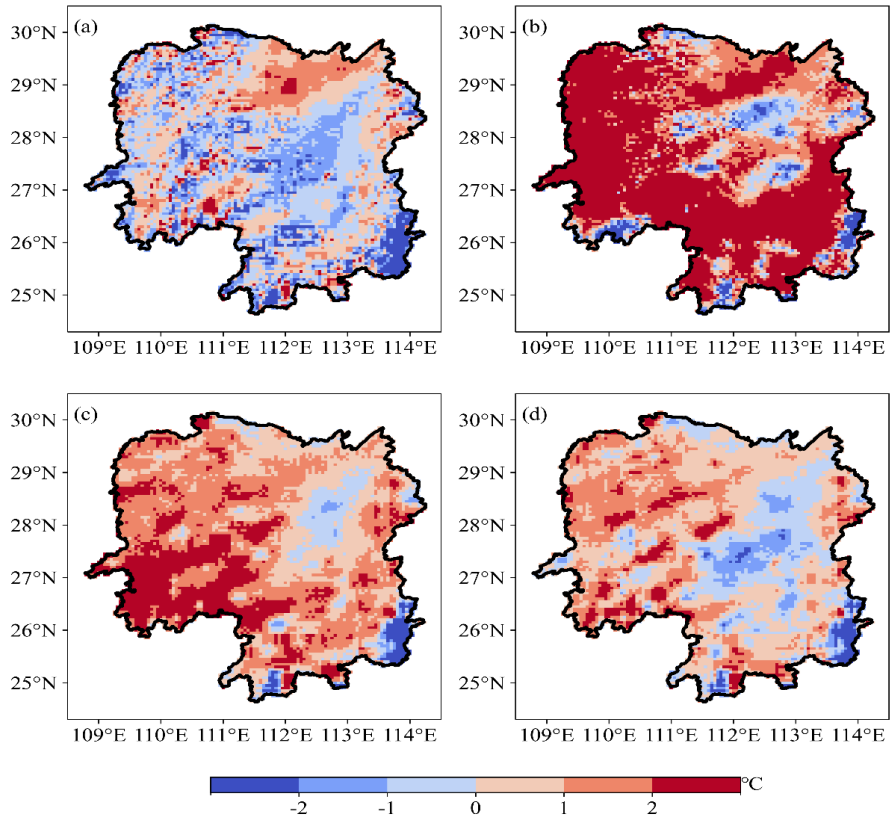
338

Fig.10 Comparison between the average temperature forecast of different products and the observations in Hunan

339

Province from 20:00 BT 27 to 20:00 BT 29 November 2022

340



341
 342
 343
 344
 345

图 11 2022 年 11 月 29 日 11 时不同预报产品气温预报值与观测值偏差的空间分布
 Fig.11 Spatial distribution of the deviation between temperature forecasts of different products and observations
 at 11:00 BT 29 November 2022

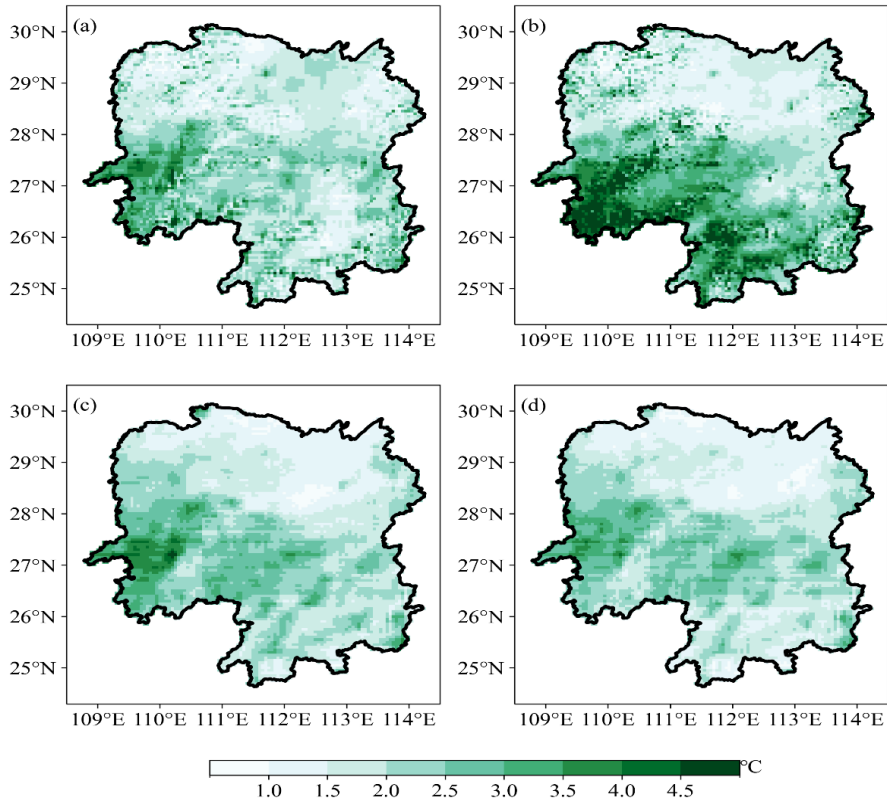


图 12 2022 年 11 月 27—29 日不同预报产品气温预报的 RMSE 空间分布

Fig.12 Spatial distribution of root mean square error in temperature forecasts of different products from 27 to 29

November 2022

346
347
348
349

4 结论

350

351 本文利用 ECMWF-IFS 高分辨率预报产品和中国气象局下发的逐 1 h 气温实况资料建立了
352 了嵌入层-长短期记忆-全连接网络 (ED-LSTM-FCNN)，实现湖南地区逐 1 h 精细化格点气
353 温预报。为验证模型中 LSTM 模块有效性，进行消融实验构建嵌入层-全连接网络
354 (ED-FCNN)。综合检验评估了 ECMWF-IFS、SCMOC、ED-LSTM-FCNN 和 ED-FCNN 模
355 型预报效果，主要结论如下：

356 (1) 深度学习模型对于逐 3 h 气温预报 RMSE 显著低于 ECMWF-IFS，降幅为
357 20.2 %~37.7 %，逐 1 h 气温预报 RMSE 显著低于 SCMOC，降幅为 6.2 %~40.0 %。其中，
358 ED-LSTM-FCNN 模型在不同起报时次、所有预报时效上 RMSE 均最低，与 ED-FCNN 模型
359 相比 RMSE 降低了 3.5 %~19.3 %。

360 (2) 从空间分布来看，深度学习模型均能有效降低 ECMWF-IFS 的系统性偏差，且整
361 体预报效果优于 SCMOC，尤其在湖南西部、南部和东部的复杂地形区域。ED-LSTM-FCNN
362 模型在湖南中部丘陵盆地和北部平原地区 RMSE 达 1.4 °C 以下，格点数占总格点数比例为
363 52.7 %，远高于 ECMWF-IFS (0.0 %)、SCMOC (2.2 %) 和 ED-FCNN 模型 (4.0 %)。从
364 季节尺度上看，ED-LSTM-FCNN 模型在各个季节误差分布的均值与 ECMWF-IFS、SCMOC
365 和 ED-FCNN 模型相比降幅分别为 33.3 %~35.0 %、29.4 %~33.3 % 和 6.7 %~14.3 %。

366 (3) ED-LSTM-FCNN 模型在不同起报时次对于相对极端的气温值预报效果最优，在

367 20 时起报对于超低（高）温阈值预报的 RMSE 与 ECMWF-IFS、SCMOC、ED-FCNN 模型
368 相比分别降低了 30.3 %、33.0 % 和 8.3 %（35.9 %、26.7 % 和 7.6 %）；08 时起报分别降低了
369 29.0 %、31.7 % 和 7.4 %（41.8 %、29.6 % 和 12.7 %）。通过个例分析可知，ED-LSTM-FCNN
370 模型对于相对平稳、具有连续性天气的气温预报效果很好，对于较复杂的强降温过程（转折
371 性天气）预报效果稍有欠缺，可能与数据集中转折性天气样本占比较少有关。

372 （4）ED-LSTM-FCNN 模型相对于 ED-FCNN 模型能够更好地从短期历史气象要素时间
373 序列中提取到深层特征信息，从而改善预测效果，并且模型属于轻量级深度学习模型，具有
374 计算资源需求低、推断速度快、便于迭代和实验等优势。消融实验表明，LSTM 模块加入尤
375 为重要，LSTM 的门控机制允许模型在不同时间尺度上适应数据模式，可以同时捕获短期和
376 长期特征。但 ED-LSTM-FCNN 模型对于转折性天气的气温预报改善效果不明显，后期可以
377 引入注意力机制或者卷积层模块来捕获气象数据中局部时间和空间模式，也可以针对转折性
378 天气样本单独建模，以进一步提升复杂天气形势下的气温预报水平。

379

380 参考文献

- 381 陈鹤, 蔡荣辉, 陈静静, 等, 2022. 基于深度学习方法的气温预报技术应用与评估[J]. 气象, 48(11): 1373-1383. Chen H, Cai
382 R H, Chen J J, et al, 2022. Application and evaluation of temperature forecast based on deep learning method[J]. Meteor Mon,
383 48(11): 1373-1383 (in Chinese).
- 384 陈锦鹏, 黄奕丹, 朱婧, 等, 2024. 集成学习和动态融合算法在福建省短时强降水预报中的应用[J]. 气象, 50(1): 48-58. Chen
385 J P, Huang Y D, Zhu J, et al, 2024. Application of ensemble learning and dynamic fusion for short-time severe rainfall forecasting
386 in Fujian Province[J]. Meteor Mon, 50(1): 48-58 (in Chinese).
- 387 陈昱文, 黄小猛, 李熠, 等, 2020. 基于 ECMWF 产品的站点气温预报集成学习误差订正[J]. 应用气象学报, 31(4): 494-503.
388 Chen Y W, Huang X M, Li Y, et al, 2020. Ensemble learning for bias correction of station temperature forecast based on ECMWF
389 products[J]. J Appl Meteor Sci, 31(4): 494-503 (in Chinese).
- 390 方鸿斌, 王珊珊, 王晓玲, 等, 2024. 基于机器学习的格点气温预报订正方法[J]. 气象, 50(1): 103-114. Fang H B, Wang S S,
391 Wang X L, et al, 2024. Gridded temperature forecast correction method based on machine learning[J]. Meteor Mon, 50(1):
392 103-114 (in Chinese).
- 393 郝翠, 张迎新, 王在文, 等, 2019. 最优集合预报订正方法在客观温度预报中的应用[J]. 气象, 45(8): 1085-1092. Hao C,
394 Zhang Y X, Wang Z W, et al, 2019. Application of analog ensemble rectifying method in objective temperature prediction[J].
395 Meteor Mon, 45(8): 1085-1092 (in Chinese).
- 396 刘新伟, 段伯隆, 黄武斌, 等, 2020. 基于小波分析的客观预报方法在智能网格高低温预报中的应用[J]. 大气科学学报,
397 43(3): 577-584. Liu X W, Duan B L, Huang W B, et al, 2020. Application of objective prediction method based on wavelet
398 analysis in intelligent grid high and low temperature prediction[J]. Trans Atmos Sci, 43(3): 577-584 (in Chinese).
- 399 门晓磊, 焦瑞莉, 王鼎, 等, 2019. 基于机器学习的华北气温多模式集合预报的订正方法[J]. 气候与环境研究, 24(1):
400 116-124. Men X L, Jiao R L, Wang D, et al, 2019. A temperature correction method for multi-model ensemble forecast in North
401 China based on machine learning[J]. Climatic Environ Res, 24(1): 116-124 (in Chinese).
- 402 邱贵强, 时少英, 王洪霞, 等, 2023. 2m 气温集成订正方法及在冬奥延庆赛区的应用[J]. 应用气象学报, 34(4): 400-412. Qiu
403 G Q, Shi S Y, Wang H X, et al, 2023. An integrated correction method for 2 m temperature and its application to Yanqing
404 competition zone of Olympic Winter Games[J]. J Appl Meteor Sci, 34(4): 400-412 (in Chinese).
- 405 孙健, 曹卓, 李恒, 等, 2021. 人工智能技术在数值天气预报中的应用[J]. 应用气象学报, 32(1): 1-11. Sun J, Cao Z, Li H, et al,
406 2021. Application of artificial intelligence technology to numerical weather prediction[J]. J Appl Meteor Sci, 32(1): 1-11 (in
407 Chinese).
- 408 王丹, 王建鹏, 白庆梅, 等, 2019. 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, 45(9):

409 1310-1321. Wang D, Wang J P, Bai Q M, et al, 2019. Comparative correction of air temperature forecast from ECMWF model by
410 the decaying averaging and the simple linear regression methods[J]. Meteor Mon, 45(9): 1310-1321 (in Chinese).
411 吴启树, 韩美, 郭弘, 等, 2016. MOS 温度预报中最优训练期方案[J]. 应用气象学报, 27(4): 426-434. Wu Q S, Han M, Guo H,
412 et al, 2016. The optimal training period scheme of MOS temperature forecast[J]. J Appl Meteor Sci, 27(4): 426-434 (in Chinese).
413 徐景峰, 宋林焯, 陈明轩, 等, 2023. 冬奥会复杂山地百米尺度 10m 风速预报的机器学习订正对比试验[J]. 大气科学, 47(3):
414 805-824. Xu J F, Song L Y, Chen M X, et al, 2023. Comparative machine learning-based correction experiment for a 10 m wind
415 speed forecast at a 100 m resolution in complex mountainous areas of the Winter Olympic Games[J]. Chin J Atmos Sci, 47(3):
416 805-824 (in Chinese).
417 杨璐, 南刚强, 陈明轩, 等, 2021. 基于三种机器学习方法的降水相态高分辨率格点预报模型的构建及对比分析[J]. 气象学
418 报, 79(6): 1022-1034. Yang L, Nan G Q, Chen M X, et al, 2021. The construction and comparison of high resolution precipitation
419 type prediction models based on three machine learning methods[J]. Acta Meteor Sin, 79(6): 1022-1034 (in Chinese).
420 张桃, 林鹏飞, 刘海龙, 等, 2023. 利用长短期记忆网络 LSTM 对赤道太平洋海表面温度短期预报[J]. 大气科学, 48(X): 1-10.
421 Zhang T, Lin P F, Liu H L, et al, 2023. Short-term sea surface temperature forecasts for the equatorial Pacific based on long
422 short-term memory network[J]. Chin J Atmos Sci, 48(2): 1-10 (in Chinese).
423 张延彪, 陈明轩, 韩雷, 等, 2022a. 数值天气预报多要素深度学习融合订正方法[J]. 气象学报, 80(1): 153-167. Zhang Y B,
424 Chen M X, Han L, et al, 2022a. Multi-element deep learning fusion correction method for numerical weather prediction[J]. Acta
425 Meteor Sin, 80(1): 153-167 (in Chinese).
426 张延彪, 宋林焯, 陈明轩, 等, 2022b. 基于卷积神经网络的京津冀地区高分辨率格点预报偏差订正试验[J]. 大气科学学报,
427 45(6): 850-862. Zhang Y B, Song L Y, Chen M X, et al, 2022b. A study of error correction for high-resolution gridded forecast
428 based on a convolutional neural network in the Beijing-Tianjin-Hebei Region[J]. Trans Atmos Sci, 45(6): 850-862 (in Chinese).
429
430 赵琳娜, 卢姝, 齐丹, 等, 2022. 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, 33(3): 257-269. Zhao L N,
431 Lu S, Qi D, et al, 2022. Daily maximum air temperature forecast based on fully connected neural network[J]. J Appl Meteor Sci,
432 33(3): 257-269 (in Chinese).
433 周康辉, 郑永光, 王婷波, 2021. 利用深度学习融合 NWP 和多源观测数据的闪电落区短时预报方法[J]. 气象学报, 79(1):
434 1-14. Zhou K H, Zheng Y G, Wang T B, 2021. Very short-range lightning forecasting with NWP and observation data: a deep
435 learning approach[J]. Acta Meteor Sin, 79(1): 1-14 (in Chinese).
436 Cho D, Yoo C, Im J, et al, 2020. Comparative assessment of various machine learning - based bias correction methods for
437 numerical weather prediction model forecasts of extreme air temperatures in urban areas[J]. Earth Space Sci, 7(4):
438 e2019EA000740.
439 Cho D, Yoo C, Son B, et al, 2022. A novel ensemble learning for post-processing of NWP Model's next-day maximum air
440 temperature forecast in summer using deep learning and statistical approaches[J]. Weather Clim Extrem, 35: 100410.
441 Dahouda M K, Joe I, 2021. A deep-learned embedding technique for categorical features encoding[J]. IEEE Access, 9:
442 114381-114391.
443 Glahn H R, Lowry D A, 1972. The use of model output statistics (MOS) in objective weather forecasting[J]. J Appl Meteor
444 Climatol, 11(8): 1203-1211.
445 Han L, Chen M X, Chen K K, et al, 2021. A deep learning method for bias correction of ECMWF 24-240 h forecasts[J]. Adv
446 Atmos Sci, 38(9): 1444-1459.
447 Hewage P, Trovati M, Pereira E, et al, 2021. Deep learning-based effective fine-grained weather forecasting model[J]. Pattern Anal
448 Appl, 24(1): 343-366.
449 Hochreiter S, Schmidhuber J, 1997. Long short-term memory[J]. Neural Comput, 9(8): 1735-1780.
450 Jeong S, Park I, Kim H S, et al, 2021. Temperature prediction based on bidirectional long short-term memory and convolutional

451 neural network combining observed and numerical forecast data[J]. *Sensors*, 21(3): 941.
452 Paras S M, Kumar A, Chandra M, 2009. A feature based neural network model for weather forecasting[J]. *Int J Comput*
453 *Intelligence*, 4(3): 209-216.
454 Qin Y, Liu Y B, Jiang X Y, et al, 2023. Grid-to-point deep-learning error correction for the surface weather forecasts of a fine-scale
455 numerical weather prediction system[J]. *Atmosphere*, 14(1): 145.
456 Wang F, Tian D, Carroll M, 2023. Customized deep learning for precipitation bias correction and downscaling[J]. *Geosci Model*
457 *Dev*, 16(2): 535-556.
458 Yan R, Liao J Q, Yang J, et al, 2021. Multi-hour and multi-site air quality index forecasting in Beijing using CNN, LSTM,
459 CNN-LSTM, and spatiotemporal clustering[J]. *Expert Syst Appl*, 169: 114513.
460 Zhang C J, Zeng J, Wang H Y, et al, 2020. Correction model for rainfall forecasts using the LSTM with multiple meteorological
461 factors[J]. *Meteor Appl*, 27(1): e1852.
462 Zhang H, Wang Y Q, Chen D D, et al, 2022. Temperature forecasting correction based on operational GRAPES-3km model using
463 machine learning methods[J]. *Atmosphere*, 13(2): 362.
464 Zhao L N, Lu S, Qi D, 2023. Improvement of maximum air temperature forecasts using a stacking ensemble technique[J].
465 *Atmosphere*, 14(3): 600.
466
467
468