

引用格式: 郜庆林, 简单. 基于卷积神经网络算法的金华地区高山气象观测站逐时气温预报订正[J]. 山地学报, 2024, 42(2): 278-286.

GAO Qinglin, JIAN Dan. Hourly temperature forecast revision based on convolutional neural network algorithm on observations at alpine meteorological station in Jinhua area of China [J]. Mountain Research, 2024, 42(2): 278-286.

基于卷积神经网络算法的金华地区高山气象观测站逐时气温预报订正

郜庆林¹, 简单²

(1. 金华市气象局, 浙江 金华 321000; 2. 兰溪市气象局, 浙江 兰溪 321100)

摘要: 受地貌和气候条件影响, 智能网格气温预报产品的预报结果, 在复杂地形山区易出现误差。通过人工订正关键点降低误差, 存在较大主观性, 预报精度有限, 难以满足精细化气象服务需求。神经网络算法能够大幅提升预报精度, 然而这种方法在气温逐时波动小的平原地区应用较多, 在气温波动大的山区鲜有应用。本文以浙江金华山区为研究区域, 基于浙江省智能网格温度预报产品以及同时段高山气象观测站逐时气温观测数据, 采用卷积神经网络算法, 实现关键点气温逐时预报订正。研究表明: (1) 小时尺度上, 订正后各站点的气温均方根误差均显著减小, 由订正前 3℃~7℃ 减小至订正后 2℃~3℃, 订正后的预测结果更加准确, 订正效果符合预期。(2) 月尺度上, 相较智能网格原始气温预报数据, 该模型预报结果准确率也明显提升, 订正后月平均气温准确率提高了 33.18%~46.86%, 其中准确率 6 月最高。(3) 相较人工订正的方式, 该模型对山地气温预报的订正能力更稳定, 模型的两项关键指标(平均绝对误差和 2℃ 预报准确率)均接近或超过同时段浙江省天气预报质量检验平台气温业务指标。该研究结果满足金华地区高山气象观测站对于气温预报产品的业务可用性需求, 可为精细化山区气象服务提供数据支撑。

关键词: 卷积神经网络; 高山气象观测站; 精细气温; 订正预报; 智能网格; 金华

中图分类号: P423

文献标志码: A

随着综合气象探测能力的提升和气象数据的丰富, 智能网格预报产品日益成熟, 市县基层气象部门对智能网格产品二次加工, 可以为当地提供丰富的气象服务。在地形复杂山区, 地面气象站空间布局与观测数据的精度^[1]直接影响智能网格预报产品质量, 决定基层气象服务的终端品质。当前, 气象服务的数据质量仍不能满足部分地形复杂山区精细化气象服务需求。

在地形复杂山区, 由于建设条件限制和后期维护要求, 固定气象站点多选址在地势平坦的河谷城镇附近, 在地形险峻的峡谷地带则站点稀少、分布不均^[2], 导致在气候复杂多变^[3-4]的区域, 气象数据质量水平

参差不齐, 智能网格预报产品的预报结果有严重的误差, 需要气象预报员对常规要素预报进行质量校订。

智能网格预报产品的质量校订仍存在技术短板。在实际气象业务中, 气象预报员通常根据经验, 手工检校关键站点数据以提升预报质量, 但这种方式受限于人力成本与个人业务素质, 预报精度有限, 一般无法做到小时预报。因此, 亟需研发客观预报技术来优化传统的主观预报订正方案以满足实际业务需求。数值天气预报模型基于动态回归分析, 保留原模式预报的空间信息来校正要素预报在格点中的误差^[5], 可改善预报质量, 但是订正站点仅限于

收稿日期(Received date): 2023-11-09; 改回日期(Accepted date): 2024-04-10

基金项目(Foundation item): 金华市科学技术局计划项目(2022-4-082)。[Jinhua Science and Technology Bureau Project(2022-4-082)]

作者简介(Biography): 郜庆林(1977-), 男, 浙江金华人, 本科, 高级工程师, 主要研究方向: 气象信息技术、大气探测、气象算法。[GAO Qinglin(1977-), male, born in Jinhua, Zhejiang province, B.S., senior engineer, research on meteorological information technology, atmospheric detection and meteorological algorithm] E-mail: 26250447@qq.com

县级站和乡镇站,高山站点效果未知。智能网格分析系统在预报场添加要素协同订正,直接调取订正结果,发现山区的预报准确率高于平原地区^[6],这表示其在山区的客观订正能力具备优势,而针对山区气温开展客观预报订正研究分析较少^[7]。

地形复杂山区气象模式预报气温订正方案,不仅应确保稳定性和可靠性,还应具备智能化属性^[8]。精细化天气预报引入人工智能技术^[9],例如深度学习算法^[10-11],可解决复杂的气象预报模式识别难题^[12]。研究表明,基于机器学习后处理模型对气温预报进行多种模式集合预报订正,其订正效果明显优于单个天气预报模式,但对于山区订正效果要差一些^[13];通过神经网络模型对地面气温进行订正预报,可以显著地减小预报误差^[14];使用 CNN-BiLSTM-Attention 融合神经网络方法进行时空特征提取,可提取大气温度的局部特征^[15],能够获得更多重要信息的特征。卷积神经网络(Convolutional Neural Network, CNN)在气象预报领域已经得到广泛应用^[16-20],其模型的建立较为自由,且无须人为过度深入理解数据内在成因,更适用于气温预报订正研究。

浙江金华地处丘陵盆地,区内峰岭交错,垂直气候差异大,自然生态环境以及旅游资源优越。目前浙江省智能网格预报产品对于金华山区的气温预报结果存在严重误差,精细化气象服务水平难以满足当地旅游经济^[21]与农业发展需求。本文以改善金华地形复杂区域逐小时气温预报为目标,基于智能网格气温预报产品和高山气象观测站观测数据,采用卷积神经网络算法,建立针对预报气温误差等级的分类订正预测模型,并使用气象站实况资料进行结果检验与评估,研究结果可为金华市、县级气象台站开展制作山区各类气象服务产品提供参考及数据支撑。

1 研究资料

1.1 数据

实况资料选择 2022 年 3 月至 2023 年 2 月金华地区 492 个区域自动气象站(包含国家站和骨干站)的逐时气温观测数据。预报资料为浙江省智能网格预报产品中提取的 2022 年 3 月至 2023 年 2 月 08:00 和 20:00 起报的温度场逐时预报产品,预报时效为 36 h。对研究数据进行筛查质控,并剔除缺

测记录。站点预报数据采用邻近距离最短优先法确定,用于检验分析本文气温订正后的效果。

1.2 站点

由于省内对高山站尚无明确定义,基于站点分布情况和数据的完整程度考虑,本文以浙江中部地区最高峰牛头山(海拔 1560 m)的中点为研究起点,定义海拔高度 800 m 以上的区域气象站为高山气象站,作为研究对象进行分析,后文用高山站代指。样本数据的好坏对建模效果有着直接影响,选取训练样本时优先考虑数据的稳定性和可靠性,在训练样本的选取上遵循少而精的原则。本文选用的站点情况如图 1 所示,各站点标注了相应的海拔高度。需要说明的是,在建模训练初期发现,除高山站外,其余站点使用该算法进行订正后的效果稍差。

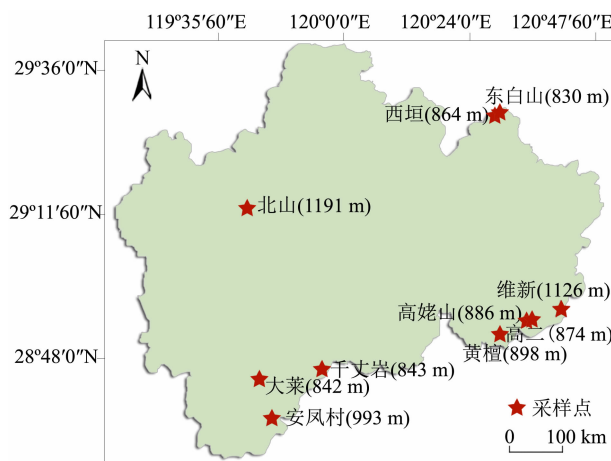


图 1 金华高山气象观测站分布图

Fig. 1 Distribution of alpine meteorological observation stations in Jinhua of China

图 2 为随机选择的四个预报时次(分布在不同季节),智能网格气温预报产品与实况资料(中国气象局实况融合分析网格产品)误差情况。通过等值面中颜色的深浅变化可以粗浅判断智能网格产品在金华地区的气温预报能力,颜色越深,表示模式误差越大。对照图 1 高山站的分布情况,可见山区误差变化波动大,是智能网格气温预报的短板,故本文选择高山站开展气温订正是具有代表性的。

2 模型和方法

2.1 卷积神经网络

卷积神经网络由输入层、卷积层、池化层、全连

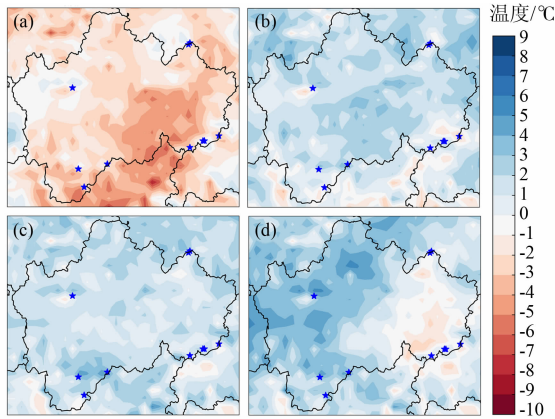


图2 智能网格气温预报模式随机四个时段系统误差分布情况:
(a)2022年7月10日;(b)2022年4月20日;
(c)2023年1月1日;(d)2022年10月1日

Fig.2 System error of intelligent grid temperature prediction model for four random time periods: (a) July 10, 2022;
(b) April 20, 2022; (c) January 1, 2023; (d) October 1, 2022

接层和输出层组成,在结构上具有局部连接、权重共享、时间域或空间域的下采样等特性^[22]。通过卷积层中的卷积核对输入数据进行加权求和,并提取特征信息,然后池化层压缩卷积层中提取到的数据特征,最后全连接层进行样本标记并输出最终结果。将卷积运算看作一个维度小于输入数据的二维权重数组,并以固定的步长在输入数据上滑动,同时截取数据子集,总体是一个相乘再求和的过程^[17]。卷积核计算公式为:

$$T = f(W \otimes C + b) \quad (1)$$

式中, T 为特征矩阵; W 为权重矩阵; \otimes 为卷积运算; b 为偏移向量^[18]。

进行卷积运算后,提取的特征经过非线性激活函数(本文采用 ReLU 函数)映射到非线性空间,再传递到池化层。采用最大值池化法,将卷积层中捕

捉获得的重要特征在池化层再次聚集,并选择出最关键重要的特征,使得特征表达简单化。全连接层作为最后一层,负责对卷积层、池化层得到的高级别特征进行最终整合并接入输出层,从而输出预测(分类)对象结果。

2.2 模型设计

2.2.1 训练样本情况

经过筛选、清洗后,本文使用的建模数据集为2022年3月至2023年2月智能网格预报产品中逐时气温预报数据和相应的高山站观测数据,共计样本23 425个。其中80%的数据样本作为训练集,20%的数据样本作为验证集。

2.2.2 CNN 模型输入构建

CNN 模型输入数据是天擎平台的全国格点预报服务产品(定时拼接),数据编码 NAFP_NWFD_SMERGE,要素场选择 TMP,其包含了预报对象(高山站)的气温预报数据以及二维温度场信息。

2.2.3 数据预处理

为了使原始数据有更好的表现形式,需要对训练数据进行预处理,这是机器学习任务中一个必不可少的步骤。本文将温度场转换为图片格式,并经 torchvision 模块中 transforms 算法预处理,将图片转换为 32×32 二维数据矩阵。

本文标签数据采用实况数据和预报数据差值的分级模型,共分为十级。

2.2.4 确定 CNN 模型结构

本文的 CNN 模型针对分类,依次设定两层卷积层、池化层以及具有十个输出节点的全连接层。两层卷积层中卷积核的个数分别设定为20个和320个,卷积核大小为 10×10 ,池化核大小为 2×2 ,CNN 模型流程图如图3所示。




图3 CNN 模型流程图

Fig.3 Flow chart of CNN model

2.2.5 训练网络

采用 PyTorch 机器学习库进行训练, 损失函数为交叉熵损失函数, 梯度下降选择随机梯度下降法。由图 4 可知, 模型训练次数在 40 次前收敛速度较快, 准确度亦能达到 75%。




图 4 CNN 模型训练误差性能曲线

Fig. 4 Training error performance curve of CNN model

2.3 模型评价指标

为了检验本文提出的基于卷积神经网络气温订正预报方法的预报性能, 使用的模型评价指标包括均方根误差 (RMSE)、平均绝对误差 (MAE)、结果误差相对订正率 I 和预报准确率 F 。计算公式分别为:

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

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (3)$$

$$I = \frac{RMSE_K - RMSE_{CNN}}{RMSE_K} \quad (4)$$

$$F = \frac{m}{M} \times 100\% \quad (5)$$

式中, N 为预测个数; \hat{y}_i 为预测值; y_i 为真实值; \bar{y}_i 为真实值的平均值; $RMSE_K$ 为邻近距离最短优先法的均方根误差; $RMSE_{CNN}$ 为 CNN 模型训练均方根误差; F 为预报相较实况值误差在 2°C 内的百分率; m 为使用的样本中误差在 2°C 内的统计量; M 为总的样本量。其中, $RMSE$ 数值越小, 说明模型的预测值与真实值之间误差越小, 模型质量越好; MAE 数值越小, 说明模型的预测效果越好。

3 结果与分析

3.1 总体订正能力分析

由图 5 可知, 用 CNN 模型订正前, 高山站与智能网格对应点的气温均方根误差为 $3^\circ\text{C} \sim 7^\circ\text{C}$; 订正后, 均方根误差普遍减小至 $2^\circ\text{C} \sim 3^\circ\text{C}$ 。订正后各站点的均方根误差均显著减小, 可见经该模型订正后预测结果更加准确。均方根误差从订正前 $3.4^\circ\text{C} \sim 6.7^\circ\text{C}$ 降至订正后的 $2.1^\circ\text{C} \sim 2.7^\circ\text{C}$, 订正后较订正前稳定性得到增强。其中北山站的均方根误差从 6.7°C 降至 2.3°C , 预报准确率订正后较订正前提升 60.59%, 是订正效果最佳的站点; 高二站的均方根误差从 3.4°C 降至 2.7°C , 预报准确率订正后较订正前仅提升 12.91%, 订正效果一般, 主要是因为高二站较其他站的智能网格原始气温预报情况准确率更高, 导致提升该站的订正准确率难度加大。

通过 CNN 模型订正, 除高二站外, 各站点订正




图 5 CNN 模型订正结果

Fig. 5 Correction results by CNN model

后的预报准确率都达到了 55% 以上,最好的为大莱站 68.22%,说明该模型有着良好的正向订正能力,订正效果符合预期。经统计,除高二站外,结果误差相对订正率随着海拔高度的增加,呈现出明显上升的趋势(表 1、表 2)。进一步分析发现,结果误差相对订正率与海拔高度呈正相关,计算得出相关系数为 71.92%,其中订正后改善效果最好的为北山站(结果误差相对订正率 66.37%,海拔 1191 m)。这说明误差的变化并非随着海拔高度的变化线性增长,海拔仅是造成误差的一个原因。

表 1 各站点结果误差相对订正率
Tab.1 Relative correction rate of result error at observation stations

站点名	海拔/m	结果误差相对订正率/%
东白山	830	39.44
大莱	842	47.99
千丈岩	843	45.93
西垣	864	48.92
高二	874	19.70
高姥山	886	41.95
黄檀	898	43.03
安凤村	993	48.82
维新	1126	52.73
北山	1191	66.37

3.2 不同月份订正能力分析

由表 3 可知,金华地区高山站在智能网格预报产品中,订正前逐时气温预报准确率均值为

表 2 不同海拔高度站点的结果误差相对订正率

Tab.2 Relative correction rate of result error at observation stations in different altitudes

海拔范围/m	结果误差相对订正率/%	站点个数/个	站点比例/%
[800,900]	40.99	7	70
(900,1000]	48.82	1	10
>1000	59.55	2	20

23.01%,订正后准确率提高到 61.87%。订正前各月逐时气温预报准确率较低,订正后准确率较订正前提高了 33.18%~46.86%,其中 6 月订正后预报准确率最高,7 月订正后结果误差相对订正率最高,改善效果最好。订正前各月平均绝对误差与实况相比,从 3.5℃~4.5℃降至 1.8℃~2.0℃,且订正后各月平均绝对误差波动不大。均方根误差订正前各月误差值为 4.1℃~5.0℃,订正后均方根误差控制为 2.3℃~2.5℃,误差值减小,这表示订正后具备更高的稳定性。

3.3 CNN 模型订正结果与人工订正业务对比

为了更好地检验 CNN 模型对逐时气温的订正情况,将浙江省天气预报质量检验平台中 2023 年 4 月金华地区关键点预报 1 h 气温检验情况与同时期高山站作对比。由表 4 可以看出,市台 GFE 产品(人工订正业务)预报准确率为 55.73%~89.58%,平均绝对误差为 1.3℃~2.0℃,各地之间变化波动较大;而 CNN 模型预报准确率为 52.16%~64.36%,平均绝对误差为 1.8℃~2.2℃,各站点间波动变化不大,显示出较为稳定的性能。通过计

表 3 金华地区高山站智能网格产品逐时气温预报检验订正(2023 年 3—8 月)

Tab.3 Correction of hourly temperature forecast of intelligent grid products at alpine observation stations in Jinhua area from March to August in 2023

月份	预报准确率/%		平均绝对误差/℃		均方根误差/℃		结果误差相对订正率/%
	订正前	订正后	订正前	订正后	订正前	订正后	
3 月	24.83	59.37	4.0	2.0	4.7	2.5	45.59
4 月	25.68	59.50	3.8	2.0	4.7	2.5	43.61
5 月	26.23	63.80	3.7	1.8	4.7	2.5	46.56
6 月	28.52	64.09	3.5	1.8	4.1	2.3	43.25
7 月	16.43	61.26	4.5	1.9	5.0	2.4	52.10
8 月	16.35	63.21	4.4	1.8	4.8	2.4	51.38
平均	23.01	61.87	4.0	1.9	4.7	2.4	47.08

算预报准确率这一指标的平均相对订正率,得出市台 GFE 产品平均订正率为 +8.76%,订正能力有限,而在高山站跃升至 +131.70%,具有更强的订正能力。至于平均绝对误差,CNN 模型由订正前的 3.8℃降低为 2.0℃,也有着不错的订正表现。由此可见,相较于人工订正业务,本文的 CNN 模型对于高山站订正能力稳定,无论是平均绝对误差还是预报准确率指标,均表现出接近或超过人工关键点订正业务的检验指标。

4 讨论

山区地形复杂,山谷、山脚、山顶的气象要素受海拔、地形、朝向等多种因素影响,若直接使用智能网格预报产品,不进行本地化订正释用,会阻碍气象服务向高品质、多样化发展。研究人员会根据预报质量诊断结果优化智能网格产品算法,这致使产品的预报性能发生改变,原先针对模式的订正方案将不再适用。CNN 算法模型可以在现有的训练基础上对新的数据集进行训练,无需从头开始就能快速更新模型参数,在较短的时间内将站点预报订正结果融入最新的智能网格预报产品,显著提高产品加

工支撑能力,实现服务产品生成的并行化和高时效性。

本文选取浙江金华地区高山站为研究对象,利用 CNN 算法建立气温分级订正模型,对预报气温存在显著偏差的山区进行订正,得出高山站未来 36 h 逐小时气温,并对智能网格预报的改进能力以及相对于人工站点订正改进情况进行评估。该订正方案,在站点选择上,并不是针对研究区域内资料更为连续和稳定的城镇气象站,而是地形复杂、海拔较高的高山站;在方法技术上,CNN 模型网络结构简单,回报效果良好,可替代人工订正;在业务化方面,其预报精度达到了 1 h,满足输出各类气温相关服务产品制作需求,订正效果已基本达到业务可用性。

该研究成果对于山区进行农业气候资源开发利用、农业气象灾害监测预警、优质气象景观旅游资源研究以及预报技术研发等具有重要的现实意义,也为后续开展山区复杂地形区域气温格点产品订正奠定了基础。此外,CNN 模型仍有较大提升空间,后续可以尝试从区域划分、地理位置等因素着手,整合多个站点提供的信息,从季节、天气类型等不同角度进行分类评估,以及结合深度学习的感知能力和强化学习的决策能力,如采用深度强化学习方法等来

表 4 金华市县与高山气象观测站气温检验对比情况(2023 年 4 月)

Tab. 4 Comparison of temperature inspection between Jinhua county and alpine meteorological observation stations in April 2023

城市	金华市县关键点				站点	高山气象观测站(平均样本量 >2000)			
	预报准确率/%		平均绝对误差/℃			预报准确率/%		平均绝对误差/℃	
	市台 GFE	智能网格	市台 GFE	智能网格		CNN	智能网格	CNN	智能网格
东阳	89.58(48)	63.16(57)	1.3(48)	2.0(57)	西垟	60.58	28.73	1.9	3.4
金华	79.17(48)	73.68(57)	1.4(48)	1.8(57)	北山	60.70	6.19	1.9	6.0
兰溪	63.02(192)	64.04(228)	1.9(192)	2.0(228)	大莱	63.70	32.27	1.8	3.2
磐安	55.73(192)	59.65(228)	2.0(192)	2.2(228)	高二	55.23	43.27	2.1	2.8
浦江	59.72(144)	53.22(171)	2.0(144)	2.8(171)	黄檀	52.16	21.27	2.2	4.0
武义	62.50(96)	63.16(114)	1.8(96)	2.0(114)	维新	56.85	14.66	2.1	4.8
义乌	75.00(96)	66.67(114)	1.4(96)	1.8(114)	高姥山	60.58	34.01	2.0	3.5
永康	54.86(144)	52.63(171)	2.0(144)	2.4(171)	东白山	58.71	23.98	2.0	3.7
					安凤村	64.36	26.62	1.9	3.5
					千丈岩	62.14	25.78	1.8	3.5
平均	67.45	62.03	1.7	2.1		59.50	25.68	2.0	3.8

注:括号内数字为参与统计的样本量。

优化模型,进一步提升其订正效果和预测准确性。

5 结论

(1) CNN 模型订正前,高山站与智能网格对应点的气温均方根误差为 $3\text{ }^{\circ}\text{C} \sim 7\text{ }^{\circ}\text{C}$,订正后均方根误差减小至 $2\text{ }^{\circ}\text{C} \sim 3\text{ }^{\circ}\text{C}$,订正后各站点的均方根误差均显著减小,经该模型订正后预测结果更加准确。通过模型订正,除高二站外,各站点的预报准确率均达到 55% 以上,以大莱站最佳,为 68.22%,说明该模型具有良好的正向订正能力,订正效果符合预期。随着海拔高度的增加,结果误差相对订正率呈明显上升趋势,然而这只是海拔与误差关系的规律之一,后续可寻求新的方法分析误差变化与海拔高度之间的具体关系。

(2) 2023 年 3—8 月运行检验期间,相较智能网格原始预报数据指标,订正后该模型的各项指标每月均提升明显。订正前各月逐时气温预报准确率较低,订正后准确率较订正前提高了 33.18% ~ 46.86%,其中 6 月订正后预报准确率最高,7 月订正效果最好。各月平均绝对误差订正前、后与实况相比波动较小,均方根误差订正前与订正后相比误差值减小,订正后的稳定性更高。

(3) 市台 GFE 产品(人工订正业务)各地区波动变化大,而 CNN 模型订正后各站点波动较小,说明本文提出的 CNN 模型在针对高山站订正方面的稳定性显著优于人工订正。通过对同时段浙江省天气预报质量检验平台关键点人工订正气温检验数据进行对比,发现该模型的平均绝对误差、 $2\text{ }^{\circ}\text{C}$ 预报准确率两项指标,均接近或超过人工关键点订正业务的检验指标,已初步具备业务应用的可行性和实用性。

参考文献(References)

- [1] 易桂花,张廷斌,何奕莹,等. 四种气温空间插值方法适用性分析[J]. 成都理工大学学报(自然科学版), 2020, **47**(1): 115 - 128. [YI Guihua, ZHANG Tingbin, HE Yixuan, et al. Applicability analysis of four spatial interpolation methods for air temperature [J]. Journal of Chengdu University of Technology (Science and Technology Edition), 2020, **47**(1): 115 - 128] DOI: 10.3969/j.issn.1671-9727.2020.01.11
- [2] 王莹,苏永秀,李政. 广西西部山区日最低气温短序列订正方法[J]. 山地学报, 2012, **30**(2): 186 - 194. [WANG Ying, SU

- Yongxiu, LI Zheng. Adjusting methods for daily minimum temperature series in high altitude mountainous areas of western Guangxi [J]. Mountain Research, 2012, **30**(2): 186 - 194] DOI: 10.16089/j.cnki.1008-2786.2012.02.013
- [3] 王晶,赵龙,吴辉,等. 西南地区城市化进程加剧局地气象条件的空间差异[J]. 山地学报, 2022, **40**(1): 120 - 135. [WANG Jing, ZHAO Long, WU Hui, et al. Urbanization magnifies spatial variations of local meteorological conditions in southwest China [J]. Mountain Research, 2022, **40**(1): 120 - 135] DOI: 10.16089/j.cnki.1008-2786.000660
- [4] 李叶,张艳红,陈子琦,等. 中高纬度山区气温空间化的方法比较研究——以大兴安岭北麓为例[J]. 山地学报, 2021, **39**(2): 174 - 182. [LI Ye, ZHANG Yanhong, CHEN Ziqi, et al. Comparative study on spatialization methods of air temperature in middle and high latitude mountainous areas: A case study of northern foot of the Daxing'anling Mountains [J]. Mountain Research, 2021, **39**(2): 174 - 182] DOI: 10.16089/j.cnki.1008-2786.000585
- [5] 潘留杰,薛春芳,王建鹏,等. 一个简单的格点温度预报订正方法[J]. 气象, 2017, **43**(12): 1584 - 1593. [PAN Liujie, XUE Chunfang, WANG Jianpeng, et al. A simple grid temperature forecast correction method [J]. Meteorological Monthly, 2017, **43**(12): 1584 - 1593] DOI: 10.7519/j.issn.1000-0526.2017.12.015
- [6] 戴翼,何娜,付宗钰,等. 北京智能网格温度客观预报方法(BJTM)及预报效果检验[J]. 干旱气象, 2019, **37**(2): 339 - 344 + 350. [DAI Yi, HE Na, FU Zongyu, et al. Beijing intelligent grid temperature objective prediction method (BJTM) and verification of forecast result [J]. Journal of Arid Meteorology, 2019, **37**(2): 339 - 344 + 350] DOI: 10.11755/j.issn.1006-7639(2019)-02-0339
- [7] 赵婷婷,高凌峰,黄荟羽,等. 辽阳地区智能网格产品气温预报检验订正[J]. 现代农业科技, 2023(2): 159 - 163. [ZHAO Tingting, GAO Lingfeng, HUANG Huiyu, et al. Test correction of intelligent grid product temperature forecast in Liaoyang area [J]. Modern Agricultural Science and Technology, 2023(2): 159 - 163] DOI: 10.3969/j.issn.1007-5739.2023.02.037
- [8] 张成军,纪晓玲,马金仁,等. 多种数值预报及其释用产品在宁夏天气预报业务中的检验评估[J]. 干旱气象, 2017, **35**(1): 148 - 156. [ZHANG Chengjun, JI Xiaoling, MA Jinren, et al. Verification of numerical forecast and its application products in weather forecast in Ningxia [J]. Journal of Arid Meteorology, 2017, **35**(1): 148 - 156] DOI: 10.11755/j.issn.1006-7639(2017)-01-0148
- [9] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, **25**(2): 1 - 9. DOI: 10.1145/3065386
- [10] 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.

- [YANG Xuan, DAI Kan, ZHU Yuejian. Progress and challenges of deep learning techniques in intelligent grid weather forecasting [J]. *Acta Meteorologica Sinica*, 2022, **80**(5): 649–667] DOI: 10.11676/qxb2022.051
- [11] 夏景明, 戴如晨, 谈玲. 一种基于 MSF-Net 网络模型的短时降水预测方法; 202310715521.4 [P]. 2023-07-18. [XIA Jingming, DAI Ruchen, TAN Ling. A short-term precipitation prediction method based on MSF-Net network model; 202310715521.4 [P]. 2023-07-18]
- [12] 陈先昌. 基于卷积神经网络的深度学习算法与应用研究[D]. 杭州: 浙江工商大学, 2014: 1–22. [CHEN Xianchang. Research on algorithm and application of deep learning based on convolutional neural network [D]. Hangzhou: Zhejiang Technology and Business University, 2014: 1–22]
- [13] 门晓磊, 焦瑞莉, 王鼎, 等. 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, 2019, **24**(1): 116–124. [MEN Xiaolei, JIAO Ruili, WANG Ding, et al. A temperature correction method for multi-model ensemble forecast in north China based on machine learning [J]. *Climatic and Environmental Research*, 2019, **24**(1): 116–124] DOI: 10.3878/j.issn.1006–9585.2018.18049
- [14] 陈鹤, 蔡荣辉, 陈静静, 等. 基于深度学习方法的温度预报订正应用与评估[J]. 气象, 2022, **48**(11): 1373–1383. [CHEN He, CAI Ronghui, CHEN Jingjing, et al. Application and evaluation of temperature forecast based on deep learning method [J]. *Meteorological Monthly*, 2022, **48**(11): 1373–1383] DOI: 10.7519/j.issn.1000–0526.2002.070101
- [15] 王怡, 普运伟. 基于 CNN-BiLSTM-Attention 融合神经网络的大气温度预测[J]. 中国水运, 2023, **23**(1): 25–27. [WANG Yi, PU Yunwei. Prediction of atmospheric temperature based on CNN-BiLSTM-Attention fusion neural network [J]. *China Water Transport*, 2023, **23**(1): 25–27]
- [16] 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. [JI Yandong. Atmospheric temperature prediction based on improved LSTM model [J]. *Journal of Tonghua Normal University*, 2020, **41**(8): 82–86] DOI: 10.13877/j.cnki.cn22–1284.2020.08.015
- [17] 王彦卷. 基于 CNN-LSTM 和气象要素关联的气温时空预测[D]. 银川: 宁夏大学, 2022: 1–60. [WANG Yanjuan. Spatiotemporal temperature prediction based on CNN-LSTM and meteorological elements correlation [D]. Yinchuan: Ningxia University, 2022: 1–60]
- [18] 雷蕾, 徐邦琪, 高庆九, 等. 基于卷积神经网络的长江流域夏季日最高温度延伸期预报方法研究[J]. 大气科学学报, 2022, **45**(6): 835–849. [LEI Lei, XU Bangqi, GAO Qingjiu, et al. Extended-range forecasting method of summer daily maximum temperature in the Yangtze river basin based on convolutional neural network [J]. *Transactions of Atmospheric Sciences*, 2022, **45**(6): 835–849] DOI: 10.13878/j.cnki.dqkxxb.20211101001
- [19] 施恩, 李骞, 顾大权, 等. 基于局部特征的卷积神经网络模型[J]. 计算机工程, 2018, **44**(2): 282–286. [SHI En, LI Qian, GU Daquan, et al. Convolutional neural network model based on local features [J]. *Computer Engineering*, 2018, **44**(2): 282–286] DOI: 10.3969/j.issn.1000–3428.2018.02.048
- [20] 马司周. 基于深度学习的多序列气温预测研究[D]. 兰州: 兰州理工大学, 2022: 34–51. [MA Sizhou. Research on multi-series temperature prediction based on deep learning [D]. Lanzhou: Lanzhou University of Technology, 2022: 34–51] DOI: 10.27206/d.cnki.gsgsu.2022.000500
- [21] 崔海霞, 刘娜. 甘肃省旅游景点温度预报质量检验评估[J]. 甘肃科技, 2021, **37**(5): 83–85+101. [CUI Haixia, LIU Na. Quality inspection and evaluation of temperature forecast for tourist attractions in Gansu [J]. *Gansu Science and Technology*, 2021, **37**(5): 83–85+101]
- [22] 王飞飞. 基于改进卷积神经网络算法的研究与应用[D]. 南京: 南京邮电大学, 2016: 10–14. [WANG Feifei. Research and applications based the improved convolutional neural network [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2016: 10–14]

Hourly Temperature Forecast Revision Based on Convolutional Neural Network Algorithm on Observations at Alpine Meteorological Stations in Jinhua Area of China

GAO Qinglin¹, JIAN Dan²

(1. Jinhua Meteorological Bureau, Jinhua 321000, Zhejiang, China; 2. Lanxi Meteorological Bureau, Lanxi 321100, Zhejiang, China)

Abstract: Smart grid temperature forecast products are subjected to geomorphology and climatic conditions, and the temperature forecast results are prone to errors in mountainous areas with complex terrain. Reducing the errors by manually revising observations at some key points of an alpine meteorological observatory network had a large

subjectivity and limited forecast accuracy, making it difficult to meet the demand for refined meteorological services.

Neural network algorithms offer an objective computational approach to greatly improving forecast accuracy by learning from historical temperature data to regulate current data; however, this method was more commonly applied in plains with small hourly temperature fluctuations, and seldom used in mountainous areas where temperature fluctuations are large.

In this paper, the Jinhua mountainous area of Zhejiang province, China was taken as research target. The intelligent grid temperature forecast product of Zhejiang province were calibrated with simultaneous hourly temperature observations collected at alpine meteorological observation stations by convolutional neural network (CNN) algorithm for proper revisions on hourly temperature prediction at key points/stations.

(1) On an hourly scale, the root mean square error of temperatures at each station significantly decreased after the CNN revision, from 3 °C – 7 °C before the revision to 2 °C – 3 °C after the revision, satisfying expectation of accuracy.

(2) On a monthly scale, temperature prediction accuracy improved notably as compared with product by the intelligent grid. After the revision, the accuracy of the monthly average temperature increased by 33.18% to 46.86%, with the highest accuracy in June.

(3) The CNN model was more stable in revising mountain temperature forecasts than the manual revision method. It justified that two key indicators (average absolute error and 2 °C forecast accuracy) were close to or exceeded the concurrent acceptance check standards of Zhejiang Provincial Weather Forecast Quality Inspection Platform.

This study improves the operational availability of temperature forecast products in alpine meteorological observatory in Jinhua area, which can provide data support for refined mountain weather services in mountainous areas.

Key words: convolutional neural network; alpine meteorological observatory; fine temperature; forecast revision; intelligent grid; Jinhua

(责任编辑 钟雨倩)