暴雨灾害
Torrential Rain and Disasters
中国科技核心期刊
中国科技论文统计源期刊

基于FCN算法的甘肃省强对流逐小时预报技术研究

黄武斌 伏晶 马莉 张君霞 郭润霞

Research on hourly forecast technology of severe convection in Gansu Province based on FCN algorithm

HUANG Wubin，FU Jing，MA Li，ZHANG Junxia，GUO Runxia

在线阅读 View online: https://doi.org/10.12406/byzh.2024-217

您可能感兴趣的其他文章 Articles you may be interested in

山东省一次罕见强对流天气的环境场及雷达特征分析

Analysis of radar echo features and environmental backgrounds of a rare severe convective weather in Shandong province

暴雨灾害. 2020, 39(5): 477-486 https://doi.org/10.3969/j.issn.1004-9045.2020.05.006

基于逻辑回归法的浙江省低涡型暴雨落区预报研究

The potential falling area forecast for rainstorm induced by vortex in Zhejiang Province based on logistic regression algorithm

暴雨灾害. 2024, 43(1): 32-44 https://doi.org/10.12406/byzh.2023-009

河南一次伴有龙卷的多阶段强对流天气形成机制分析

Formation mechanism of a multi-stage severe convective weather event accompanied by local tornado in Henan

暴雨灾害. 2024, 43(3): 299-312 https://doi.org/10.12406/byzh.2023-217

鄂西南一次早春强对流过程的多源资料分析

Analysis of an early spring convective weather event in southwest of Hubei province based on multi-source data

暴雨灾害. 2022, 41(2): 174-183 https://doi.org/10.3969/j.issn.1004-9045.2022.02.008

阿克苏地区一次强对流天气过程的地闪活动特征分析

Activity characteristics of the cloud-to-ground lightning in a severe convective weather event in Arksu of Xinjiang

暴雨灾害. 2022, 41(6): 640-650 https://doi.org/10.12406/byzh.2022-013

重庆不同天气系统短历时设计暴雨雨型比较研究

Comparative study on short-duration designed storm patterns of different weather systems in Chongqing

暴雨灾害. 2020, 39(1): 96-101 https://doi.org/10.3969/j.issn.1004-9045.2020.01.011

关注微信公众号，获得更多资讯信息

黄武斌,伏晶,马莉,等.2026.基于 FCN 算法的甘肃省强对流逐小时预报技术研究[J].暴雨灾害,45(2):287−296. HUANG Wubin, FU Jing, MA Li, et al. 2026. Research on hourly forecast technology of severe convection in Gansu Province based on FCN algorithm [J]. Torrential Rain and Disasters,45(2):287−296 (in Chinese). doi:10.12406/byzh.2024−217

基于 FCN 算法的甘肃省强对流逐小时预报技术研究

黄武斌[1, 2], 伏晶[2], 马莉[2], 张君霞[2], 郭润霞[2]

(1. 甘肃省敦煌市气象局, 酒泉 735000; 2. 兰州中心气象台, 兰州 730020)

摘　要: 传统预报方法难以有效捕捉强对流天气快速演变的特征, 全卷积神经网络 (Fully Convolutional Network, FCN) 算法因其有独特的局部感知特性优势, 能够有效提取中小尺度天气系统的时空演变特征。通过构建基于 FCN 的预报模型, 可以突破传统方法的局限性。本文将 2017—2021 年地面观测的强对流天气实况、ECMWF 数值模式资料作为训练集, 2022 年上述数据作为测试集, 采用 FCN 算法, 构建甘肃省冰雹、雷暴大风和短时强降水 (以下简称为短强) 三类强对流和非强对流天气 0—12 h 内逐小时天气预报模型, 并将模型在 2023 年实际业务中应用验证。结果表明: (1) 在 2022 年的训练集中, 模型表现良好, 强对流天气和和非强对流天气的整体误判率 (FNR) 仅为 16.6%。三类强对流天气的平均临界成功指数 (CSI) 为 25.8%, 平均命中率 (POD) 保持在 65.2% 以上, 且其对短强的预报效果最好。(2) 在 2023 年实际业务应用的验证集中, 模型对三类强对流天气的平均 CSI 为 24.3%, 平均 POD 为 62.6%, 平均空报比率 (FAR) 为 71.2%。2017—2023 年全部数据集中, 短强的 CSI 最高, 达到 45.5%, 雷暴大风和短强的 POD 均超过了 70%, 冰雹和雷暴大风的 FAR 相似, 均高于 77%, 短强的平均 FAR 最低。(3) 由模型的逐小时预报看, 冰雹在第 4 h、8 h 和 10 h 表现最好, 雷暴大风在第 6 h 表现最好, 短强在第 2 h、4 h 的预报效果最好。本研究构建的 FCN 模型在强对流天气预报方面表现较为理想, 在加快未来气象业务自动化进程中具有较好的应用前景。

关键词: 强对流天气; FCN 算法; 逐小时预报; 甘肃

中图法分类号: P456　　**文献标志码**: A　　**DOI:** 10.12406/byzh.2024−217

Research on hourly forecast technology of severe convection in Gansu Province based on FCN algorithm

HUANG Wubin[1, 2], FU Jing[2], MA Li[2], ZHANG Junxia[2], GUO Runxia[2]

(1. *Meteorological Bureau of Dunhuang City*, *Gansu Provincey*, *Jiuquan* 735000; 2. *Lanzhou Central Meteorological Observatory*, *Lanzhou* 730020)

Abstract: Traditional forecasting methods are difficult to effectively capture severe convective weather rapidly evolving characteristics, and there is still a problem of insufficient forecasting accuracy in meteorological operations. Fully convolutional neural networks, due to their unique local perception characteristics, can effectively extract the spatiotemporal evolution features of small and medium-sized weather systems. Therefore, it is urgent to construct a prediction model based on fully convolutional neural networks to overcome the limitations of traditional methods. This article uses ground observations of severe convective weather from 2017 to 2021 and ECMWF (the European Center of Medium range weather forecasts) numerical model data as the training set, and 2022 as the test set. The FCN (Fully Convolutional Network) algorithm was adopted to construct three types of severe convective weather forecast models for hail, convective gust, and short-term heavy rainfall within 0-12 hours in Gansu Province. The model was applied in forecast business operations in 2023. The results are as follows. (1) In the training set of 2022, the model performed well, with an overall false positive rate(FNR) of only 16.6% for severe convective weather and non-severe convective weather. The average critical success index (CSI) for three types of severe convective weather is 25.8%, and the average hit rate (POD) remains above 65.2%, with short and strong weather forecasts showing the

收稿日期: 2024−12−09; **定稿日期**: 2025−01−13

资助项目: 甘肃省自然科学基金项目 (25JRRA322, 24JRRA1178, 23JRRA1572); “飞天风云”青年拔尖人才项目 (2425rczx); 甘肃省青年科技基金项目 (23JRRA1330, 23JRRA1332); 甘肃省气象局气象科研重点项目 (Zd20284-B-2); 甘肃省重点人才项目 (2025RCXM037); 中国气象局青年创新团队项目 (CMA2024QN04); 甘肃省气象局创新团队项目 (GSQXCXTD-2024-01)

第一作者: 黄武斌, 主要从事客观天气预报技术研究。E-mail: hwb0707@sina.com

通信作者: 伏晶, 主要从事灾害天气预报技术研究。E-mail: Fujing_1228@163.com

© Editorial Office of *Torrential Rain and Disasters*. OA under CC BY−NC−ND 4.0

best results. (2) In the validation set of forecast business operations in 2023, the average CSI of the three types of severe convective weather is 24.3%, the average POD is 62.6%, and the average false alarm ratio (FAR) is 71.2%. On all datasets from 2017 to 2023, the CSI of short-term heavy rainfall was the highest, reaching 45.5%, while the POD for thunderstorm and strong winds exceeded 70%. The FAR results for hail and thunderstorm winds were similar, both exceeding 77%, while the average FAR for short and strong winds was the lowest. (3) From the hourly forecast of the model, hail performs best in the 4th, 8th, and 10th hours, thunderstorm winds perform best in the 6th hours, and short-term intensity forecasts perform best in the 2nd and 4th hours. Therefore, the FCN model constructed in this study performs well in strong convective weather forecasting, providing application prospects for future meteorological business automation.

Key words: severe convective weather; FCN algorithm; hourly forecast; Gansu Province

引　言

强对流天气是由深厚湿对流引发的一种破坏力极强的灾害性天气现象 (Doswell, 2014), 主要包括闪电、直径 5 mm 及以上的冰雹、任何级别的龙卷、17 m·s^{-1} 及以上的雷暴大风、20 mm·h^{-1} 及以上的短时强降水 (以下简称为短强) (刘新伟等, 2021a), 具有历时短、天气剧烈、破坏性强等特点, 极易对全球大多数地区构成严重的生命与财产威胁 (Zhou et al., 2019)。然而, 强对流天气系统通常具有突发性和中小尺度特征, 其演变速度快, 且与周边环境存在复杂的相互作用。这使得传统气象预报方法在准确性和时效性方面面临严峻挑战 (刘新伟等, 2021b)。

强对流天气的监测和预报工作通常集中在临近预报 (0—2 h) 和短时预报 (2—12 h) 时效 (孙继松等, 2014; 俞小鼎等, 2020; 黄天文等, 2024), 其中临近预报主要依赖于经验预报和基于雷达回波、卫星云图的外推 (郭瀚阳等, 2019; 俞小鼎和郑永光, 2020); 短时预报方法主要包括流型辨识法 (McNulty, 1995) 和配料法 (蔡志颖等, 2024)。目前, 随着数值天气预报模式分辨率的提高, 对预报员的信息提取能力提出了较高要求, 预报员需要从大量气象数据中提取动力、水汽、能量、地形等影响强对流天气形成的条件 (周康辉等, 2021a)。然而, 短时预报方法存在一定的局限性, 比如不同地区气候特征的差异使得采用统一的预报阈值难以适应不同区域强对流天气的准确预报 (吕晓娜等, 2020; 谭丹等, 2022; 王国安等, 2023)。并且随着气象观测网和数值天气预报的快速发展, 信息量的急剧增加也使得单纯依赖人工预报变得越来越困难, 亟需更高效的自动化预报方法。

近年来, 机器学习特别是深度学习技术在气象预报中的应用取得了显著进展, 尤其是在强对流天气的监测与预报领域 (张华龙等, 2021; 朱岩等, 2021; 黄静等, 2024; 杨栎楠等, 2025; 庄潇然等, 2025)。例如, 陈锦鹏等 (2021) 基于卷积神经网络 (Convolutional Neural Network, CNN) 订正的逐小时降水预报, 相比于频率匹配法, 预报准确性显著提高; 周康辉等 (2021b) 提出的深度学习融合数值预报 (LightningNet Numerical Weather Prediction, LightningNet-NWP) 算法用于闪电落区的短期预报, 结果优于仅使用多源观测数据和数值模式预报数据的单一方法。此外, Zhang 等 (2023) 提出的深度学习模型, 通过结合物理演化规律和条件学习方法, 提升了 0—3 h 极端降水事件的预报能力。可见, 深度学习在自动特征提取、图像分类及数据分析方面展现出一定优势 (Yann et al., 2015; Maryam et al., 2015), 使其在气象数据中的应用具有巨大潜力。

语义分割技术作为深度学习技术的重要方法之一, 已被广泛应用于气象领域 (Romero et al., 2016)。诸如全卷积神经网络 (Fully Convolutional Network, FCN) (Long et al., 2015)、金字塔场景解析网络 (Pyramid Scene Parsing Network, PSPNet) (Yu et al., 2021) 以及语义图像分割 (Semantic Image Segmentation, SegNet) (Vijay et al., 2017) 等, 均能有效地从多源观测数据中提取特征, 提升强对流天气分类预报准确性 (Zhang et al., 2019)。Zhou 等 (2020) 使用深度语义分割模型, 结合卫星、雷达和闪电探测器的多源数据, 实现了对强对流天气的高效分类和预报, 尤其在 0–1 h 的闪电预报中效果较好; 张亚萍等 (2024) 基于显著目标检测算法构建了 30 min 内强降水落区临近预报模型, 对强降水落区的预报较为可靠; Scarino 等 (2023) 利用深度神经网络 (Deep Neural Network, DNN) 算法基于卫星等资料建立的实时冰雹尺寸分类预报模型, 其预报准确率较高。尽管语义分割技术在强对流天气监测和临近预报中表现优异, 但在 0—12 h 逐小时分类预报中的应用研究相对较少。如何结合语义分割技术与多源观测数据及高分辨率数值天气预报数据, 尤其在强对流样本稀缺且类别不平衡的甘肃地区, 实现更高精度的预报, 仍是一个亟待解决的问题。

借鉴随机森林算法在冰雹天气识别 (刘新伟等, 2021a) 及 LightGBM (Light Gradient Boosting Machine) 算法在强对流天气分类 (刘新伟等, 2021b) 中的研究经验, 本文将研究范围进一步扩展, 通过引入更先进

的 FCN 算法, 探索其在强对流天气预报中的应用潜力。FCN 的主要优势在于将 CNN 应用于像素级语义分割任务, 并通过卷积化、上采样以及并联跳跃连接等技术, 实现对任意大小输入图像的处理。这不仅提升了训练速度和分类准确率, 还显著扩展了模型的适用范围。为此基于 FCN 算法, 构建了甘肃省冰雹、雷暴大风和短强等三类强对流 0—12 h 内逐小时天气预报模型, 以期能够高效提取强对流天气的预报信息, 提升分类预报精度, 为推进气象业务预报自动化和提高预报准确性提供新的思路和参考。

1 资料和方法

1.1 资料来源

本文使用的资料包括: (1) 2017—2023 年欧洲中期天气预报中心 (European Centre for Medium-Range Weather Forecasts, ECMWF) 数值预报产品, 根据黄玉霞等 (2017) 的研究结果, 选取了与甘肃省冰雹、短强、雷暴大风天气相关性较高的变量, 如对流有效位能 (CAPE) 和 700 hPa、500 hPa、200 hPa 高度层的涡度 (PVORT)、温度 (TMP)、位势高度 (HGT)、散度 (DIV)、水平风场 (UV), 及 700 hPa、500 hPa 的比湿 (Q) 等。此外, 为了能够让模型学习到更多信息, 还加入了 700 hPa、500 hPa 的垂直风 (W) 和饱和水汽比湿 (SPFH), 整层大气可降水量 (PW), 2 m 露点温度 (DPT-2M) 等共计 24 个自变量。(2) 实况资料来源于甘肃省信息保障中心 2017—2023 年的国家和区域气象观测站逐 1 h 风速、降水、冰雹等资料。

1.2 FCN 算法介绍

语义分割是将场景图像分割为若干个有意义的图像区域, 并对每一个像素点进行分类 (张鑫, 2022) 的技术。Long 等 (2015) 提出了 FCN 算法, 这是首个能够实现任意大小输入图像的像素级语义分割任务的模型, 本文 FCN 模型结构如图 1。下面对 FCN 算法的主要组成部分进行简要介绍。

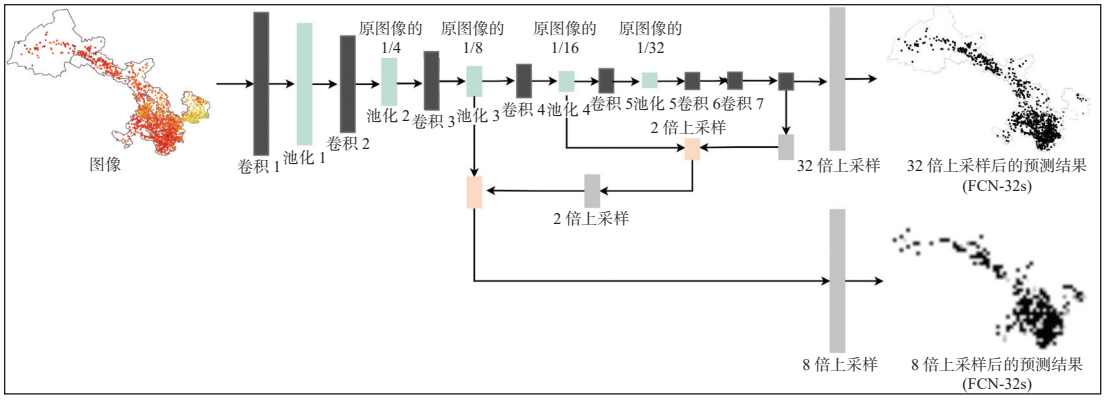


图 1 本文 FCN 模型结构示意图

Fig. 1 Schematic diagram of the FCN model structure used in this paper

(1) 卷积化。CNN 通常在最后使用全连接层进行分类, 而 FCN 将这个全连接层替换为卷积层, 以便进行像素级的直接分割。通过经过 5 次卷积和池化操作, 图像的尺寸逐渐缩小 2、4、8、16、32 倍, 从中提取出主要信息, 可以粗略地判断每个区域属于什么类别。

(2) 上采样。在网络的过程中, 由于多次下采样操作, 导致特征层的大小减小。为获得与原始图像大小相匹配的预测层, 需要对最后一层进行 32 倍的上采样操作, 这使得预测结果的分辨率与原始图像相同, 这类似于反卷积操作。

(3) 多重跳转结构。利用多层信息进行分类预测, 通过相互连接不同层次的信息, 可以在提取主要信息的同时保留其他层次的信息, 有助于提高模型性能。

1.3 建模因子选取

由于 ECMWF 数值预报产品时间分辨率为 3 h, 地面层 (CAPE、DPT-2M) 和整层的 PW 产品水平分辨率为 0.125°×0.125°, 200 hPa、500 hPa、700 hPa 气压层水平分辨率为 0.25°×0.25°。为和智能网格预报业务的时空分辨率保持一致, 因此对 ECMWF 中的 24 个自变量采用非递减三次样条插值 (刘娜等, 2023) 和双线性插值方法将时间和空间进行降尺度, 使得自变量时间分辨率为 1 h, 空间分辨率为 0.05°×0.05°。

图像在进入模型前需要标准化或归一化处理, ECMWF 的自变量包含各种不同的量纲, 所以同样需要类似的数据预处理 (陈锦鹏等, 2021)。该自变量 (x) 与图像不同之处在于自变量存在明确的上、下限, 而且其数值的空间分布及相对高低对模型输出都至关重要。为保留数值的空间及区间信息, 采用归一化处理, 归一化后的自变量 (x') 计算公式如下

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{1}$$

其中 max、min 分别为该自变量的最大值和最小值。

1.4 模型构建

模型的构建通常包括五个关键步骤: 数据收集、数据处理、模型训练、交叉验证和模型评估 (图 2)。第一步是数据收集和分类 (步骤 1), 它为模型提供了足够的信息用于训练和预测, 主要包括冰雹、雷暴大风、短强等强对流天气的实况数据 (因变量) 和强对流发生期间的 ECMWF 数值模式输出产品 (自变量)。第二步是数据处理 (步骤 2), 旨在筛选和清洗数据, 去除特征不全或包含异常值的样本, 以提高数据质量。此外, 样本数据需进行归一化, 以统一不同特征的尺度, 从而有助于模型的稳定训练。模型训练 (步骤 3) 使用经过处理的数据集来建立并训练 FCN 模型。训练过程通常包括多个迭代周期, 模型通过不断调整权重和参数, 逐步拟合数据。在交叉验证 (步骤 4) 中, 模型训练样本和交叉验证样本占比分别为 80% 和 20%, 模型首先在训练样本上进行学习, 再在交叉验证样本上进行评估。这有助于验证模型是否过拟合或欠拟合, 并为超参数调整提供依据。最后, 在模型优化完成后, 使用常见的模型评估方法, 在交叉验证样本集和测试集上评估模型准确性和泛化能力 (步骤 5)。

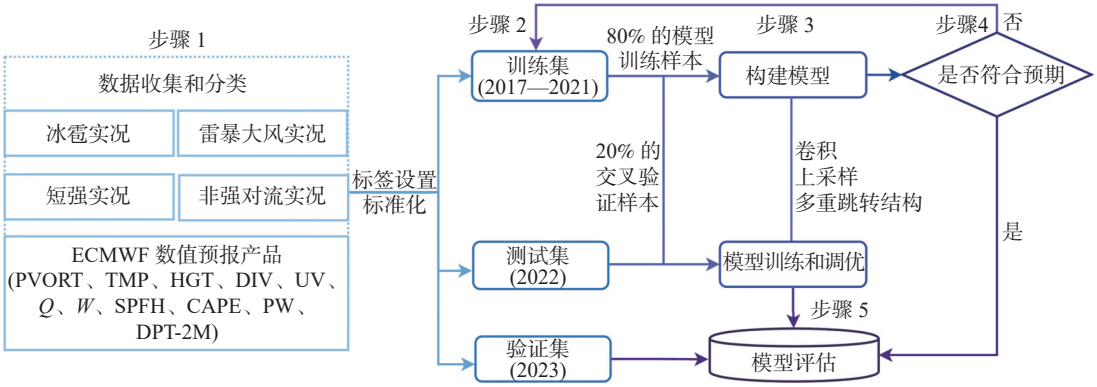


图 2 基于 FCN 模型的强对流算法流程图

Fig. 2 Flow chart of severe convection algorithm based FCN model

1.5 建模因变量及样本

收集整理了甘肃省范围内 2017—2023 年短强、冰雹、雷暴大风三类强对流天气实况资料。其中, 短强为小时雨量超过 20 mm, 冰雹指直径≥5 mm 的冰雹, 雷暴大风采用目前中国气象局业务规定判识标准: 当地面观测站点小时累计闪电次数≥1 且该时次小时阵风风速≥17 $m \cdot s^{-1}$, 判定为雷暴大风。

根据地面观测到的强对流天气站点经纬度及发生时段信息, 提取该时段前 3 h 和后 3 h 时段内的模式产品数据作为强对流天气样本, 其中该时段内的数据为强对流天气样本, 时段前、后 3 h 为非强对流天气样本。例如 18:00—22:00 (北京时, 下同) 某地观测到有短强, 那么样本提取时间为 15:00—次日 01:00, 其中 18:00—22:00 时段的样本为强对流天气样本, 15:00—18:00、22:00—01:00 时段的样本为非强对流天气样本。如果同一时段观测到两种或者三种强对流天气, 则分别计入各自的样本。此外, 甘肃省强对流天气较少, 为更好的识别强对流天气和非强对流天气, 还采集了没有发生强对流天气的样本, 其样本与有强对流天气时的样本比例接近 10:1。

通过以上方式共建立 2017—2023 年 26 747 个强对流天气和 269 746 个非强对流天气样本数据集。由于 FCN 模型需要较大的训练集来建模, 本文将 2017—2021 年的 186 095 个样本作为模型的训练集。在交叉验证中, 训练样本和交叉验证样本比例为 8:2。将 2022 年样本作为模型的测试集, 共有 4 093 个强对流天气样本和 51 024 个非强对流天气样本。2023 年的样本用于业务应用中的验证集, 共有 3 667 个强对流天气样本和 51 614 个非强对流天气样本。为便于机器学习模型的识别, 对冰雹、雷暴大风、短强和非强对流这四种类型设置了标签。标签分类如下: 非强对流为 1, 冰雹为 2, 雷暴大风为 3, 短强为 4。样本集的分布情况及标签分类如表 1 所示。

1.6 检验指标

本研究所使用的检验指标与刘新伟等 (2021b) 保持一致, 主要为误判率 FNR (记为 R_{FN})、命中率 POD (记为 P_{OD})、临界成功指数 CSI (记为 I_{CS}) 和空报比率 FAR (记为 R_{FA}) 等, 便于判别强对流天气的识别和预报效果, 计算公式如下

$$R_{FN} = \frac{F_N}{P} \times 100\% \tag{2}$$

$$P_{OD} = \frac{T_P}{P} \times 100\% \tag{3}$$

$$I_{CS} = \frac{T_P}{T_P + F_P + F_N} \times 100\% \tag{4}$$

$$R_{FA}=\frac{F_P}{T_P+F_P}\times 100\% \tag{5}$$

其中, F_N 为某类天气实际有但预报无的样本数量, P 为某类天气实际样本数量, T_P 为某类天气实际有且预报有的样本数量, F_P 为某类天气实际无但预报有的样本数量。

表 1 FCN 模型的训练集 (2017—2021 年)、测试集 (2022 年) 及验证集 (2023 年) 样本集中各类型强对流天气和非强对流天气的样本个数及标签值

Table 1 Sample numbers and label values of each type of severe convective weather and non severe convective weather in the training set (2017-2021), testing set (2022) and validation set (2023) of the FCN model

数据集	非强对流 (1)	强对流类型		
		冰雹 (2)	雷暴大风 (3)	短强 (4)
训练样本集	167 108	1 125	11 972	5 890
测试样本集	51 024	168	2 258	1 667
验证样本集	51 614	167	2 331	1 169

注: 括号中的数字为标签值

本文采用的强对流天气识别判定标准与当前预报业务保持一致, 即通过地面观测到的强对流天气发生时段内的所有时次模型预报结果与实际观测进行点对点对比验证。具体而言, 判别的时间范围与地面观测实况发生的时段一致, 空间范围为以观测点为中心, 半径 40 km 的区域, 如图 3 所示, 若某时次地面观测到雷暴大风, 则以雷暴大风发生点为中心, 40 km 半径内所有 FCN 模型网格预报结果都需进行验证 (图 3a)。如果模型预报为雷暴大风并与观测一致, 则视为 T_P。如果观测有雷暴大风, 模型预报为其他类型的强对流天气或非强对流天气, 则视为 F_N。如果模型预报为雷暴大风但观测没有, 则视为 F_P。

基于以上建模步骤和检验方法, 建立了基于 FCN 算法的甘肃省 0—12 h 内逐小时强对流天气分类预报模型, 模型输出结果为空间分辨率 5 km、时间分辨率 1 h 的雷暴大风、冰雹、短强和非强对流四种天气类型的确定性预报结果, 即每个格点的值只是四种天气类型中的一种。

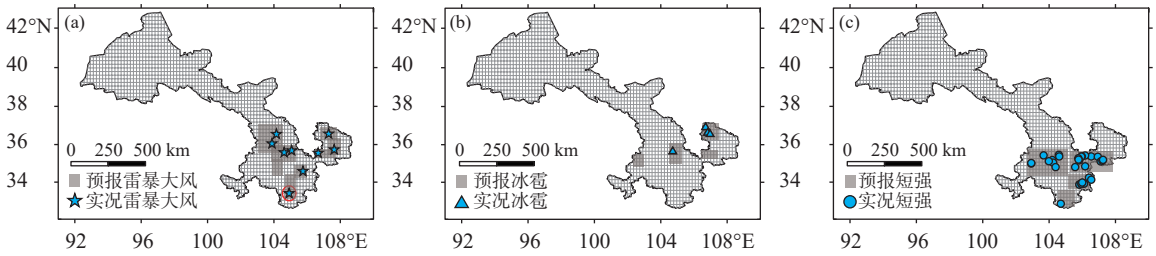


图 3 甘肃省 2023 年 7 月 30 日雷暴大风 (a)、冰雹 (b)、短强 (c) 强对流天气实况和模型预报结果 (网格为模型输出的 5 km 空间分辨率, 红色圆圈为 40 km 的半径范围)

Fig. 3 Schematic diagram of (a) thunderstorm gale, (b) hail, (c) short term heavy precipitation observation and model prediction results on 30 July 2023 in Gansu Province (The Grid is 5 km spatial resolution of the output of model prediction results. Red circle is the radius range of 40 km)

2 应用效果评估

2.1 训练集效果评估

使用 2017—2021 年的强对流训练集对 FCN 模型进行训练, 并进行交叉验证, 评估结果如下表 2 所示。针对冰雹、雷暴大风和短强三种强对流天气情况, 对 FNR 进行了详细分析。短强最低为 21.8%, 主要表现为将短强错误预报为雷暴大风。冰雹天气最高, 达到 33.3%, 这主要是由于冰雹被错误预报为雷暴大风。雷暴大风为 24.9%, 主要是将其错误预报为短强或非强对流天气。非强对流天气 FNR 相对较低, 为 15.7%。若将所有类型的错误预报次数总和除以总训练集样本数, FCN 模型对于强对流天气的整体 FNR 仅为 16.6%。综合考虑 FNR 指标, FCN 模型在强对流天气的分类任务中表现出了较高的准确性, 能够较为有效地区分不同类型的强对流天气。

图 4 为 FCN 模型在训练集中的评分结果。为了评估模型在冰雹、雷暴大风和短强三种强对流天气情况中的表现, 使用了 CSI、POD 和 FAR 指标。在各项评估指标中, 短强表现最佳, CSI 和 POD 分别达到了 51.9% 和 78.2%。相比之下, 冰雹和雷暴大风

表 2 FCN 模型训练集中天气分类预报数量及误判率 (FNR)

Table 2 Number and misjudgment rate of weather classification forecasts in the FCN model training set

天气类型	模型预报数量/个				FNR/%
	冰雹	雷暴大风	短强	非强对流	
冰雹	150	46	16	13	33.3
雷暴大风	36	1 798	320	241	24.9
短强	22	194	921	41	21.8
非强对流	366	4 619	262	28 174	15.7

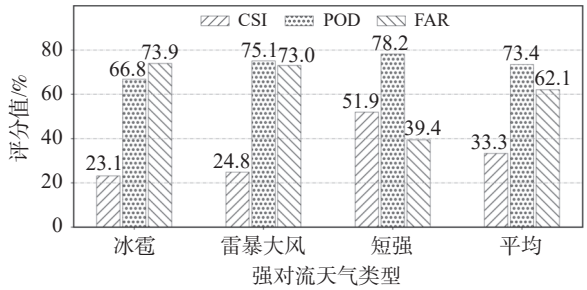


图 4 FCN 模型在甘肃省 2017—2021 年训练集中分类预报结果评分

Fig. 4 FCN model classification forecast result score in the training set from 2017 to 2021 in Gansu Province

的 CSI 值相似，且明显低于短强。雷暴大风的 POD 值仅略低于短强，但明显高于冰雹，达到了 75.1%。此外，短强的 FAR 值最低，为 39.4%，这表明其虚警率较低。冰雹和雷暴大风的 FAR 值差异不大，均高于短强。

综合来看，模型的平均 CSI 为 33.3%，平均 POD 为 73.4%，平均 FAR 为 62.1%。这些结果表明，在经过充分训练后，FCN 模型在强对流天气的分类任务中能够达到令人满意的性能，具有较好的预测能力，因此可视为一种理想的模型。

2.2 测试集效果评估

将在训练集上构建的 FCN 模型应用于 2022 年测试集后，经过评估得到的结果如表 3 和图 5 所示。该测试集包含了 55 117 个样本，模型表现如下 (表 3)：

表 3 FCN 模型测试集中天气分类预报数量及误判率 (FNR)

Table 3 Number and misjudgment rate of weather classification forecasts in the FCN model testing set

天气类型	模型预报数量/个				FNR/%
	冰雹	雷暴大风	短强	非强对流	
冰雹	87	44	18	19	48.2
雷暴大风	67	1 603	128	460	29.0
短强	44	281	1 214	128	27.2
非强对流	281	6 117	980	43 646	14.5

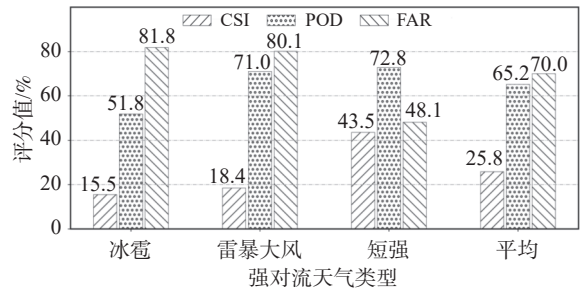


图 5 FCN 模型在甘肃 2022 年测试集中分类预报结果评分

Fig. 5 Rating of FCN model classification forecast results in the 2022 test set in Gansu Province

冰雹、雷暴大风和短强三种强对流天气的 FNR 分别为 48.2%、29.0% 和 27.2%。相比之下，非强对流天气的 FNR 最低，为 14.5%。在测试集中，错误预报情况与训练集结果相似：冰雹天气主要错误预报为雷暴大风，短强天气则主要错误预报为雷暴大风和非强对流天气。

尽管测试集的表现略低于训练集，但模型在测试集中 (图 5) 的平均 CSI 仍达到了 25.8%，平均 POD 为 65.2%，平均 FAR 为 70.0%。与训练期集的结果一致，短强的 CSI 和 POD 表现最佳，且 FAR 最低。雷暴大风和冰雹的 CSI 和 FAR 评分相似，且明显低于短强。雷暴大风的 POD 接近短强，而冰雹的 POD 最低，为 51.8%。这些结果表明，尽管在测试集中的性能有所下降，但 FCN 模型仍能够在强对流天气分类中展现出一定的准确性和稳定性。

2.3 验证集效果评估

将构建的 FCN 模型投入实际业务后，在 2023 年对 55 281 个独立样本进行了业务化应用评估，评估结果如表 4 和图 6 所示。冰雹、雷暴大风和短强三种强对流天气的 FNR 分别为 46.7%、34.0% 和 31.5%。与此相比，非强对流天气的 FNR 最低，仅为 13.3% (表 4)。在验证集中，错误预报情况与训练集和测试集的结果相似：冰雹天气仍然主要预报为雷暴大风，短强天气则主要预报为雷暴大风和非强对流天气。尽管验证集中的表现略低于训练集和测试集，但差距并不显著。

表 4 FCN 模型验证集中天气分类预报数量及误判率 (FNR)

Table 4 FCN model validation of centralized weather classification forecast quantity and misjudgment rate

天气类型	模型预报数量/个				FNR/%
	冰雹	雷暴大风	短强	非强对流	
冰雹	89	58	12	8	46.7
雷暴大风	58	1 539	340	394	34.0
短强	23	222	801	123	31.5
非强对流	388	6 053	421	44 752	13.3

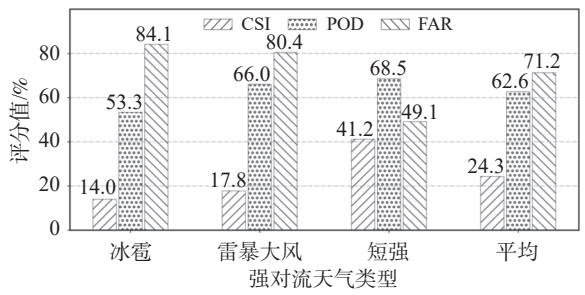


图 6 FCN 模型在甘肃 2023 年验证集中分类预报结果评分

Fig. 6 FCN model validation set classification forecast result score in 2023

此外, 在验证集中 (图 6) 模型的平均 CSI 为 24.3%, 平均 POD 保持在 62.6%, 平均 FAR 为 71.2%。这些结果与之前的评估一致, 短强的 CSI 和 POD 表现最佳, 而雷暴大风和冰雹的 CSI 和 FAR 评分相似, 明显低于短强。此外, 雷暴大风的 POD 接近短强, 且较冰雹高 12.7%, 这与训练集和测试集的结果一致。这些结果表明, 尽管模型在业务运行中的表现略有下降, 但其依然能够在强对流天气分类中展现出一定的准确性和稳定性, 从而支持了在实际业务中的应用。

2.4 全部数据集综合效果评估

在 2017—2023 年的全部数据集综合评价来看 (图 7), FCN 模型中冰雹的平均 CSI 为 17.6%, 雷暴大风为 20.3%, 而短强则达到了最高的 45.5%。在平均 POD 方面, 冰雹的最低为 57.3%, 而雷暴大风和短强均超过了 70%。至于平均 FAR, 冰雹和雷暴大风的结果相似, 都高于 77%, 而短强的平均 FAR 最低, 为 45.5%。

这些结果与基于 CNN 模型的强对流天气预测模型 (Zhou et al., 2019) 进行比较, 表明 FCN 模型在

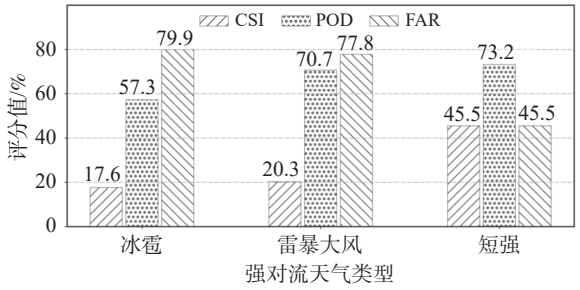


图 7 FCN 模型在甘肃 2017—2023 年全样本中的分类预报结果评分

Fig. 7 Classification forecast results score of FCN model in the entire sample from 2017 to 2023 in Gansu Province

冰雹、雷暴大风和短强的 CSI 和 POD 评分方面表现更为优秀, 同时在 FAR 方面也显示出较好的性能。总体而言, 基于 FCN 模型的强对流天气分类表现出令人满意的准确性, 表明该模型在自动化强对流天气识别和预警方面具有广泛的应用前景。

2.5 逐小时效果评估

为了进一步分析 FCN 模型的分类预报效果, 对逐小时结果进行评估。为了更加直观的展示每个时次三类强对流天气在不同检验指标下的差异性, 对检验结果做距平 (图 8) 处理, 具体为各强对流天气在各时次、各指标在不同样本集下的评分值减去全样本该指标的评分值 (图 7 中的值), 例如第 1 h 交叉验证集的冰雹 CSI 距平 (7.1%) 为交叉验证集冰雹 CSI 评分 (24.7%) 与全样本冰雹 CSI 评分平均 (17.6%) 的差值。

由图 8 的 CSI 可见, 冰雹在训练集中除第 2 h、11 h 外, 其余时次都是明显高于平均成绩 4.0% 以上, 最好的为第 8 h, 距平达 10.0% 以上。测试集中除第 4 h 高于平均成绩外, 大部分时次均偏低, 尤其是第 1 h、6 h 和 11 h 偏低 4.0% 以上。在验证集中第 3 h 表现最好, 为 0.5%; 第 2 h 最差, 达-8.0% 以上, 另外, 在第 1 h、5 h、7 h、12 h 等 4 个时次也均偏低 4.0% 以上。雷暴大风在训练集中, 第 11 h 最差, 第 10 h 最好, 另外在第 1 h、2 h、4 h、5 h、6 h、9 h、10 h 等 7 个时次也是明显高于平均成绩 5.0% 以上。测试集中第 6 h 最好, 第 5 h 最差, 与冰雹结果类似, 大部分时均偏低, 且整体偏低水平和冰雹结果相差不大。在验证集中, 第 1 h 和第 2 h 高于平均值, 就时次数而言略好于测试集, 但是整体评分成绩来看, 低于测试集的结果, 尤其在第 6 h 以后成绩下降的较为明

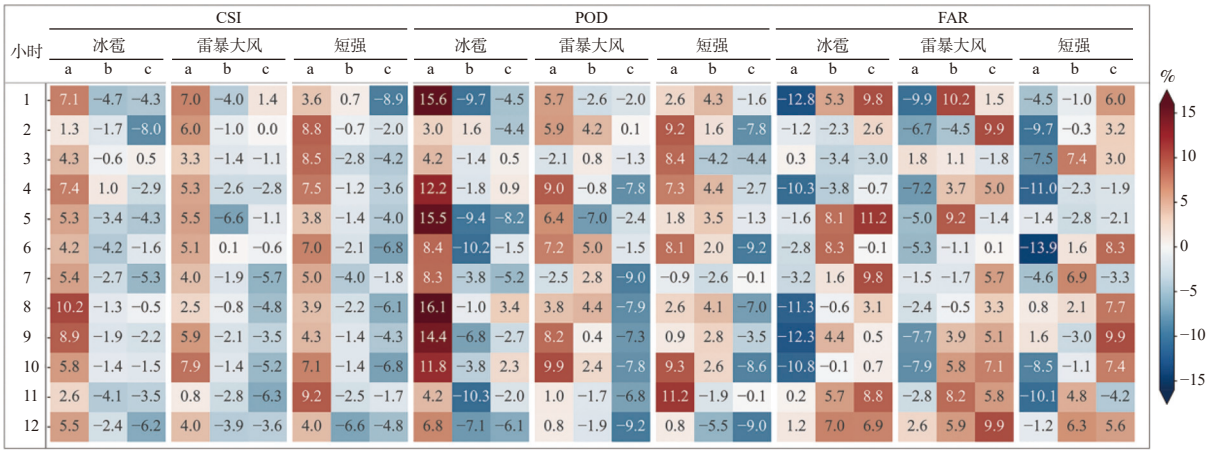


图 8 FCN 模型在甘肃省逐小时分类预报结果评分距平 (a、b、c 依次为 2017—2021 年训练集、2022 年测试集、2023 年验证集评分结果)

Fig. 8 Hourly classification forecast results of the FCN model score anomaly in Gansu Province (The a, b, c are score results of the training set from 2017 to 2021, the test set from 2022, and the validation set from 2023, respectively)

显。短强在训练集中明显高于平均成绩，尤其在第 2 h、3 h、4 h、6 h、7 h、10 h、11 h 等 7 个时次高于平均成绩 5.0% 以上，最好的为第 11 h，最差的第 1 h 也为 3.6%。在测试集除第 1 h 外，其余时次整体偏低，其中第 7 h 和第 12 h 偏低较大，但是整体水平还是略优于冰雹和雷暴大风。在验证集上，所有时次均偏低，尤其在第 1 h、6 h、8 h、10 h 等 4 个时次偏低最多。

从 POD 可见，冰雹在训练集上远高于平均成绩，尤其在第 1 h、4 h、5 h、8 h、9 h、10 h 等 6 个时次高 10.0% 以上。相对训练集结果，测试集上明显偏低，尤其在第 1 h、5 h、6 h、11 h 等 4 个时次偏低 10.0% 左右。验证集上，在第 5 h、7 h 和 12 h 等 3 个时次偏低 5.0% 以上，在第 3 h、4 h、8 h、10 h 等 4 个时次高于平均结果，最高的为第 8 h，达 3.4%。雷暴大风在训练集上与冰雹存在明显不同，在第 3 h 和第 7 h 是低于平均成绩，第 10 h 表现最好，但也没有超过 10.0%。测试集上除了第 1 h、4 h、5 h、11 h、12 h 等 5 个时次为偏低外，其余 7 个时次均偏高，最好的为第 6 h，达 5.0%。验证集上只有第 2 h 与平均值接近外，其余时次偏低，尤其在第 4 h、7—12 h 等 7 个时次偏低较多，最低的为第 12 h 达-9.2%。短强与雷暴大风相似，训练集只有在第 7 h 为-0.9%，其余均偏高，最高为第 11 h。在测试集上只有第 3 h、7 h、11 h、12 h 等 4 个时次偏低外，其余时次均偏高。验证集上全部为偏低，尤其在第 2 h、6 h、8 h、10 h、12 h 等 5 个时次偏低较为明显。

从 FAR 可见，冰雹在训练集上除个别时次为高于平均成绩外，大部分时次低于平均成绩，尤其是第 1 h、4 h、8 h、9 h、10 h 等时次低于平均成绩 10.0% 以上。测试集上第 2 h、3 h、4 h、8 h 和 10 h 等 5 个时次低于平均成绩，其余小时均偏高。验证集上只有第 3 h、4 h 和 6 h 低于平均成绩，其余时次高于平均成绩，尤其是在第 5 h 达到 11.2%。雷暴大风在训练集的第 3 h 和第 12 h 偏高，在测试集的第 1 h、4 h 和 11 h 明显较其他时次偏高，在第 2 h 偏小最多为 −4.5%，在验证集上除了第 3 h、5 h 和 6 h 共 3 个时次外，其余时次均明显偏高，尤其是第 2 h 和第 12 h 最为明显。短强在训练集上除了第 8 h、9 h 和 12 h 外，其余时次低于平均成绩，尤其是第 4 h、6 h 和 11 h 达到−10.0% 以上。测试集上在第 1 h、2 h、4 h、5 h、9 h、10 h 等 6 个时次偏低，其余时次较平均成绩偏高。验证集上在第 4 h、5 h、7 h、11 h 等 4 个时次偏低，其余时次偏高，最高为第 9 h 达到了 9.9%。

对比测试集、验证集结果，冰雹的 POD 和 FAR 在测试集均低于验证集，主要原因是 2023 年冰雹天气过程偏少，但每次过程的冰雹站次较多造成的。雷暴大风和短强的独立验证集的 POD 差于测试集，FAR 高于测试集，主要原因是 2023 年雷暴大风天气过程偏多而每次过程发生的站次少，全省短强天气过程偏少且每次过程出现的短强站次也较常年少造成的。

通过逐小时的训练集、测试集和验证集的 CSI、POD、FAR 检验指标综合来看，FCN 模型在冰雹训练集表现较好，测试集和验证集的表现相对较差，时次上在第 4 h、8 h 和 10 h 等 3 个时次表现最好，其次为第 3 h 和第 9 h，在第 5 h、11 h 和 12 h 最差。雷暴大风在训练集表现较为均衡，在测试集整体偏低，验证集在后期时次表现下降，时次上第 6 h 最好，其次为第 1 h、2 h 和 5 h，在第 11 h 和 12 h 最差。短强在训练集表现优于其他天气类型，在测试集和验证集较训练集偏低，时次在第 2 h 和 4 h 最好，其次为第 3 h、5 h、6 h、10 h、11 h 等 5 个时次，在第 8 h 和 12 h 最差。总体来看，模型在训练集表现较好，但在测试集和验证集上的效果受样本分布和天气过程特点的影响较大，尤其是在 POD 和 FAR 指标上，验证集和测试集的表现波动较大。

通过对逐小时分类预报结果分析，可见尽管 FCN 模式在不同类别的强对流天气和不同的时次中表现出不同的性能，但在准确分类强对流天气事件方面仍然具有相当大的潜力，能够为预报业务提供有价值的参考。

3 结论与讨论

本文利用 2017—2023 年地面观测的强对流天气实况、ECMWF 数值模式资料，基于 FCN 算法，构建了甘肃省冰雹、雷暴大风和短强等三类强对流以及非强对流天气 0—12 h逐小时预报模型，并检验了该模型的性能。得到以下主要结论：

(1) 在 2017—2021 年训练集上，FCN 模型对强对流天气和非强对流天气的整体 FNR 为 16.6%。其中，短强的 FNR 最小，为 21.8%；冰雹最高，为 33.3%，非强对流天气为 15.7%。在评分指标上，FCN 模型对三类强对流天气的平均 CSI 为 33.3%，平均 POD 为 73.4%，平均 FAR 为 62.1%。其中，短强的 POD 和 CSI 表现最佳，且 FAR 最小，而雷暴大风和冰雹的 CSI 和 FAR 评分相似，但雷暴大风的 POD 高于冰雹。在 2022 年测试集上，冰雹、雷暴大风和短强的 FNR 分别为 48.2%、29.0% 和 27.2%，非强对流天气的 FNR 为 14.5%。尽管三类强对流天气在测试集的评分较训练集有所下降，但平均 CSI 为 25.8%，平均

POD 仍保持在 65.2%, 平均 FAR 为 70.0%, 其中短强的预报效果最好。

(2) 将 FCN 模型投入实际业务应用后, 在 2023 年验证集上, 冰雹、雷暴大风和短强的 FNR 分别为 46.7%、34.0% 和 31.5%, 非强对流天气的 FNR 为 13.3%。从评分结果来看, 平均 CSI 为 24.3%, 平均 POD 为 62.6%, 平均 FAR 为 71.2%。其中, 短强的预报效果最好, 其次为雷暴大风。全部数据集上, 短强的 CSI 最高, 达到 45.5%, 其次为雷暴大风 20.3%, 冰雹为 17.6%。同时, 雷暴大风和短强的 POD 均超过了 70%, 冰雹为 57.3%。另外, 冰雹和雷暴大风的 FAR 结果相似, 都高于 77%, 而短强的平均 FAR 最低, 为 45.5%。

(3) 逐小时检验结果上, CSI、POD、FAR 等指标在不同时次表现不尽相同, 但整体上冰雹在第 4 h、8 h 和 10 h 等 3 个时次表现最好, 雷暴大风在第 6 h 最好, 短强在第 2 h 和 4 h 最好, 第 12 h 上三类强对流天气预报效果最差。因此, FCN 模型对强对流天气的分类预报较为准确, 能够支撑强对流天气预报业务。

本文基于 ECMWF 数值模式资料构建的 FCN 模型, 能迅速、准确的预报强对流天气, 提升预报水平, 实现 0—12 h 的三类强对流天气自动化分类预报, 突破单一类型判识预报的局限。该模型不仅充分利用观测样本, 提高数据应用价值, 还拓展人工智能在气象业务应用, 推动自动化、智能化发展且验证其可行性, 应用前景广阔。但本文不足之处是尚未对造成不同强对流天气的环流形势进行分类, 限制了模型泛化与预报准确性提升。未来将融合雷达回波外推产品和卫星数据提高 0—2 h预报准确性。同时, 对不同强对流天气的环流形势进行分类研究, 以增强模型泛化能力, 也是后期改进算法的工作重点之一。

参考文献 (References):

蔡志颖,郑艳,张程明等.2024.基于逻辑回归法的浙江省低涡型暴雨落区预报研究[J].暴雨灾害,43(1):32−44. Cai Z Y, Zheng Y, Zhang C M, et al. 2024. The potential falling area forecast for rainstorm induced by vortex in Zhejiang Province based on logistic regression algorithm [J]. Torrential Rain and Disasters,43(1):32−44 doi:10.12406/byzh.2023−009

陈锦鹏,冯业荣,蒙伟光,等.2021.基于卷积神经网络的逐时降水预报订正方法研究[J].气象,47(1):60−70. Chen J P, Feng Y R, Meng W G, et al. 2021. Acorrection method of hourly precipitation forecast based on convolutional neural network [J]. Meteorological Monthly,47(1):60−70 (in Chinese). doi:10.7519/j.issn.10000526.2021.01.006

郭瀚阳,陈明轩,韩雷,等.2019.基于深度学习的强对流高分辨率临近预报试验[J].气象学报,77(4):715−727. Guo H Y, Chen M X, Han L, et al. 2019. High resolution nowcasting experiment of severe convections based on deep learning [J]. Acta Meteorologica Sinica,77(4):715−727 doi:10.1167 6/qxxb2019.036

黄静,佘勇,樊予江.2024.深度学习方法预测阿克苏地区冰雹云雷达回波个例分析[J].沙漠与绿洲气象,18(2):107−113. Huang J, She Y, Fan Y J. 2024. Case analysis of deep learning methods for predicting radar echoes of hail cloudsin Aksu region [J]. Desert and Oasis Meteorology,18(2):107−113 (in Chinese). doi:10.12057/j.issn.1002−0799.2024.02.014

黄天文,焦飞,伍志方.2024.一种基于迁移学习和长短期记忆神经网络的降水预报方法[J].暴雨灾害,43(1):45−53. Huang T W, Jiao F, Wu Z F. 2024. A precipitation forecast method based on transfer learning and Long Short Term Memory [J]. Torrential Rain and Disasters,43(1):45−53 (in Chinese). doi:10.12406/byzh.2023−118

黄玉霞,王宝鉴,王勇,等.2017.甘肃省强对流天气中尺度分析业务技术规范[M].北京:气象出版社:20-47 Huang Y X, Wang B J, Wang Y, et al. 2017. Mesoscale Analysis Operational Technical Specifications for Severe Convective Weather in Gansu Province [M]. Beijing:China Meteorological Press:20-47 (in Chinese)

刘娜,王勇,段伯隆,等.2023.基于 LPSC 算法的逐小时格点气温客观预报及检验评估[J].大气科学学报,46(6):928−939. Liu N, Wang Y, Duan B L, et al. 2023. The objective forecast of hourly gird temperature based on LPSC algorithm and its' evaluation [J]. Transactions of Atmospheric Sciences,46(6):928−939 (in Chinese). doi:10.13878/j.cnki.dqkxxb.20220806001

刘新伟,蒋盈沙,黄武斌,等.2021a.基于雷达产品和随机森林算法的冰雹天气分类识别及预报[J].高原气象,40(4):898−908. Liu X W, Jiang Y S, Huang W B, et al. 2021a. Classified identification and nowcast of hail weather eased on radar products and random forest algorithm [J]. Plateau Meteorology,40(4):898−908 (in Chinese). doi:10.7522/j.issn.1000−0534.2020.00063

刘新伟,黄武斌,蒋盈沙,等.2021b.基于 LightGBM 算法的强对流天气分类识别研究[J].高原气象,40(4):909−918. Liu X W, Huang W B, Jiang Y S, et al. 2021b. Study of the classified identification of the strong convective weathers based on the LightGBM algorithm [J]. Plateau Meteorology,40(4):909−918 (in Chinese). doi:10.7522/j.issn.1000−0534.2020.00075

吕晓娜,牛淑贞,张一平,等.2020.基于概率与权重的雷暴大风潜势客观预报方法研究[J].暴雨灾害,39(1):20−29. Lü X N, Niu S Z, Zhang Y P, et al. 2020. Research on objective forecast method of thunderstorm potential based on probability and weight [J]. Torrential Rain and Disasters,39(1):20−29 (in Chinese). doi:10.3969/j.issn.1004−9045.2020.01.003

孙继松,戴建华,何立富,等.2014.强对流天气预报的基本原理与技术方法: 中国强对流天气预报手册[M].北京:气象出版社:282. Sun J S, Dai J H, He L F, et al. 2014. Fundamental Principles and Technical Methods for Severe Convective Weather Forecasting: Manual for Severe Convective Weather Forecasting in China [M]. Beijing:China Meteorological Press:282 (in Chinese)

谭丹,黄玉霞,沙宏娥.2022.甘肃省强对流天气特征分析[J].自然灾害学报,31(2):222−232. Tan D, Huang Y X, Sha H E. 2022. Characteristic analysis of severe convective weather in Gansu Province [J]. Journal of Natural Disasters,31(2):222−232 (in Chinese). doi:10.13577/j.jnd.2022.0224

王国安,乔春贵,张一平,等.2023.冷涡背景下河南风雹强对流天气统计特征[J].气象与环境科学,46(4):27−37. Wang G A, Qiao C G, Zhang Y P, et al. 2023. Statistical characteristics of thunderstorm gale and hail severe convection in Henan under the background of cold vortex [J]. Meteorological and Environmental Sciences,46(4):27−37 (in Chinese). doi:10.16765/j.cnki.1673−7148.2023.04.004

杨栎楠,徐海,伍一,等.2025 基于集成学习的天府机场强对流潜势预报模型[J].高原山地气象研究,45(S2):78-82. Yang L N, Xu H, Wu Y,et al. 2025. Severe convection potential prediction for Tianfu International Airport based on ensemble learning [J]. Plateau and Mountain Meteorology Research,45(S2):78-82(in Chinese). doi:10.3969/j.issn.1674−2184.2025.Z2.015

俞小鼎,王秀明,李万莉,等.2020.雷暴与强对流临近预报[M].北京:气象出版社:416 Yu X D, Wang X M, Li W L, et al. 2020. Thunderstorm and Severe Convective Nowcasting [M]. Beijing:China Meteorological Press:416 (in Chinese)

俞小鼎,郑永光.2020.中国当代强对流天气研究与业务进展[J].气象学报,78(3):391−418. Yu X D, Zheng Y G. 2020. Advances in severe convective weather research and operational service in China [J]. Acta Meteorologica Sinica,78(3):391−418 (in Chinese). doi:10.11676/qxxb2020.035

张华龙,伍志方,肖柳斯,等.2021.基于因子分析的广东省短时强降水预报模型及其业务试验[J].气象学报,79(1):15−30. Zhang H L, Wu Z F, Xiao L S, et al. 2021. A probabilistic forecast model of short-time heavy rainfall in Guangdong Province based on factor analysis and its operational experiments [J]. Acta Meteorologica Sinica,79(1):15−30 (in Chinese). doi:10.11676/qxxb2020.076

张鑫,姚庆安,赵健,等.2022.全卷积神经网络图像语义分割方法综述[J].计算机工程与应用,58(8):45−57. Zhang X, Yao Q A, Zhao J, et al. 2022. Image semantic segmentation based on Fully convolutional neural network [J]. Computer Engineering and applications,58(8):45−57 (in Chinese). doi:10.3778/j.issn.1002−8331.2109−0091

张亚萍,刘伯骏,庞玥,等.2024.基于深度学习网络显著目标检测算法的强降水落区临近预报技术[J].气象学报,83(2):334−349. Zhang Y P, Liu B J, Pang Y, et al. 2024. A technique for nowcasting heavy rainfall locations using salient object detection algorithm based on deep learning network [J]. Acta Meteorologica Sinica,83(2):334−349 doi:10.11676/qxxb2025.20240061

周康辉,郑永光,韩雷,等.2021a.机器学习在强对流监测预报中的应用进展[J].气象,47(3):2274−289. Zhou K H, Zheng Y G, Han L, et al. 2021a. Advances in application of machine learning to severe convective weather monitoring and forecasting [J]. Meteorological Monthly,47(3):2274−289 (in Chinese). doi:10.7519/j.issn.100 0−0526.2021.03.002

周康辉,郑永光,王婷波.2021b.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):1−14. Zhou K H, Zheng Y G, Wang T B. 2021b. Very short-range lightning forecasting with NWP and observation data: A deep learning approach [J]. Acta Meteorologica Sinica,79(1):1−14 (in Chinese). doi:10.11676/qxxb2021.002

朱岩,翟丹华,吴志鹏,等.2021.基于 Xgboost 算法的短时强降水预报方法[J].气象科技,49(3):406−418. Zhu Y, Zhai D H, Wu Z P, et al. 2021. A methodof short-duration heavy rain forecast based on Xgboost algorithm [J]. Meteorological Science And Technology,49(3):406−418 (in Chinese). doi:10.19517/j.1671−6345.20200216

庄潇然,刘梅,蔡凝昊,等.2025.基于深度学习的降水临近预报方法及其在 2023 年江苏汛期的应用评估[J].暴雨灾害,44(1):1−8. Zhuang X R, Liu M, Cai N H, et al. 2025. Evaluation of deep learning-based precipitation nowcasting methods during the 2023 flood season in Jiangsu Province [J]. Torrential Rain and Disasters,44(1):1−8 (in Chinese). doi:10.12406/byzh.2023−206

Doswell C A. 2015. Severe convective storms in the European societal context [J]. Atmospheric Research,158:210−215. doi:10.1016/j.atmosres.2014.08.007

Long J, Shelhamer E, Darrell T. 2015. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern analysis and Machine Intelligence,39(4):3431−3440. doi:10.1109/CVPR.2015.7298965

Maryam M N, Flavio V, Taghi M K, et al. 2015. deep learning applications and challenges in big data analytics [J]. Journal of Big Data,2(1):21−21. doi:10.1186/s40537−014−0007−7

Mcnulty R P. 1995. Severe and convective weather: a central region forecasting challenge [J]. Weather and Forecasting,10(2):187−202. doi:10.1175/1520−0434(1995)010<0187:SACWAC>2.0.CO;2

Romero A, Gatta C, Camps-Vall G. 2016. Unsupervised deep feature extraction for remote sensing image classification [J]. IEEE Transactions on Geoscience and Remote Sensing,54(3):1349−1362. doi:10.1109/tgrs.2015.2478379

Scarino B, Itterly K, Bedka K, et al. 2023. Deriving severe hail likelihood from satellite observations and model reanalysis parameters using a deep neural network [J]. Artificial Intelligence for the Earth Systems,2(1):e0042. doi:10.1175/AIES−D−22−0042.1

Vijay B, Kendall A, Cipolla R. 2017. Segnet: A deep convolutional encoder-decoder architecture for image segmentation [J]. IEEE Transactions on Pattern analysis and Machine Intelligence,39(12):22481−2495. doi:10.1109/tpami.2016.2644615

Yann L C, Bengio Y S, Hinton G. 2015. deep learning [J]. Nature,521(7553):436−444. doi:10.1038/nature14539

Yu W B, Li Y, Yang H T, et al. 2021. The centerline extraction algorithm of weld line structured light stripe based on pyramid scene parsing networ [J]. IEEE Access,9:105144−105152. doi:10.1109/ACCESS.2021.3098833

Zhang X D, Wang T, Chen G Z, et al. 2019. convective clouds extraction from Himawari–8 satellite images based on double-stream fully convolutional networks [J]. IEEE Geoscience and Remote Sensing Letters,17(4):553−557. doi:10.1109/LGRS.2019.2926402

Zhang Y C, Long M S, Chen K Y, et al 2023. Skilful nowcasting of extreme precipitation with nowcastNet [J]. Nature,619(7970):526-532. doi:10.1038/S41586−023−06184−4

Zhou K H, Zheng Y G, Dong W S, et al. 2020. A deep learning network for cloud-to-ground lightning nowcasting with multisource data [J]. Journal of Atmospheric and Oceanic Technology,37(5):927−942. doi:10.1175/JTECH−D−19−0146.1

Zhou K H, Zheng Y G, Li B, et al. 2019. Forecasting different types of convective weather: a deep learning approach [J]. Journal of Meteorological Research,33(5):797−809. doi:10.1007/s13351−019−8162−6

(责任编辑 唐国瑛)