
1 基于免疫进化算法优化卷积神经网络的强对流大风

2 分级识别方法及其应用研究^{*}

3 罗玲 张智察 赵军平 陈列 黄旋旋 王丽颖 李文娟 罗然 彭霞云

4 黄娟

5 浙江省气象台, 杭州 100081

6
7 提要: 强对流大风(以下简称强风)发生频次随风速的增大而急剧减少(样本严重不平衡)现象是导致现有
8 各类算法难以分级识别强风的主要原因。为了解决该问题, 将不可微分命中率(POD)作为卷积神经网络
9 (CNN)的损失函数, 偏差(Bias)为其约束条件, 然后利用多目标优化的免疫进化算法(MOIEA)优化 CNN
10 的所有模型参数, 提出了一种针对 $17.2, 20.8, 24.5 \text{ m} \cdot \text{s}^{-1}$ 以上强风的分级识别算法(Severe convective
11 Wind Identification Network, SCWINet)。SCWINet 利用 2022—2024 年浙江省雷达垂直液态水含量、三维
12 雷达反射率、闪电定位仪、分钟级地面自动观测站资料, 实现了时间分辨率为 6 min, 空间分辨率为 0.01°
13 的强风分级识别, 并与两种损失函数进行对比, 分别为加权均方误差可微分损失函数和平衡均方误差可微
14 分损失函数, 模型结构均一致。然后基于邻域法(扫描半径为 5 km)的 TS 评分、Bias、POD、虚警率和强
15 风平面分布特征探讨了 SCWINet 的适用性。主要结果如下:SCWINet 能有效分级识别出系统性和分散性强
16 对流系统对应的 $17.2, 20.8, 24.5 \text{ m s}^{-1}$ 以上强风, 其中对系统性强对流触发的强风分级识别效果要优于分
17 散性强对流。此外, 分级识别效果总体随强风风速的增大而降低, 空报和漏报的增大是造成上述现象的主
18 要原因。加权均方误差和平衡均方误差损失函数则没有任何识别能力, 其识别强风均小于 $17.2 \text{ m} \cdot \text{s}^{-1}$ 。不
19 过, 本文所使用的数据在特征及数据量等并不全面, 未来通过增加雷达径向速度、差分传播相移率、差分
20 反射率因子、卫星等特征和数据量, 可进一步增强其识别准确性, 并可推广至更强风速。

21 关键词: 临近预报, 强对流大风, 分级识别, 深度学习, 损失函数, 雷达

22 中图分类号: TP183, P456

23 DOI: 10.7519/j.issn.1000-0526.2025.061101

24
25 浙江省气象局科技计划项目(2023ZDZL01)、浙江省自然科学基金联合基金资助项目(LZJMY25D050004、
26 LZJMY23D050005、LZJMY23D050001)、浙江省科技厅“尖兵领雁”项目(2022C03150)、浙江省气象局
27 科技计划项目(2024ZDZL02)、宁波市公益性项目(2025S111)和中国气象局复盘总结专项项目
28 (FPZJ2024-051)共同资助

29
30 2024-08-24 收稿 2026-01-22 收修订稿

31 第一作者: 罗玲, 主要从事天气预报机理研究. E-mail: 76847787@163.com

32

33 An Identification Method of Different Levels of Severe Convective
34 Winds with Convolutional Neural Networks Optimized by Immune
35 Evolutionary Algorithm and Its Application

36 LUO Ling ZHANG Zhicha ZHAO Junping CHEN Lie HUANG Xuanxuan WANG
37 Liying LI Wenjuan LUO Ran PENG Xiayun HUANG Juan
38 Zhejiang Meteorological Observatory, Hangzhou 310017
39

40 **Abstract:** The serious imbalance in sample distribution, characterized by a sharp drop in the
41 frequency of severe convective winds with increasing wind speeds, is identified as the
42 predominant factor hindering the accurate intensity-based classification of severe convective
43 winds by various existing algorithms. To address this problem, in this study the non-differentiable
44 Probability of Detection (POD) is proposed to be the loss function for a Convolutional Neural
45 Network (CNN) and Bias to be its constraint condition. Subsequently, the Multi-objective
46 Optimization Immune Evolution Algorithm (MOIEA) is employed to optimize all the model
47 parameters of the CNN. This contributes to the development of a novel identification algorithm,
48 which is named Severe Convective Wind Identification Network (SCWINet), for identifying
49 severe convective winds at the speeds of $17.2 \text{ m}\cdot\text{s}^{-1}$, $20.8 \text{ m}\cdot\text{s}^{-1}$, $24.5 \text{ m}\cdot\text{s}^{-1}$ and above. SCWINet
50 leverages the radar vertical liquid water content, three-dimensional radar reflectivity, lightning
51 location data and minutely surface automatic observation station data in Zhejiang Province during
52 2022-2024, achieving different levels of severe convective wind identification with temporal
53 resolution of 6 min and spatial resolution of 0.01° . Then, the performance of SCWINet is
54 compared to the two approaches, i.e., Weighted Mean Squared Error (WMSE) and Balanced Mean
55 Squared Error (BMSE), which use the same CNN structure but have differentiable loss functions.
56 The applicability of SCWINet is then assessed based on the Threat Score (TS), Bias, POD, False
57 Alarm Ratio (FAR) that uses the neighborhood method (with a scanning radius of 5 km), and the
58 planar distribution characteristics of severe convective winds. The main results are as follows:
59 SCWINet can effectively identify severe convective winds of $17.2 \text{ m}\cdot\text{s}^{-1}$, $20.8 \text{ m}\cdot\text{s}^{-1}$, $24.5 \text{ m}\cdot\text{s}^{-1}$
60 and above corresponding to systematic and scattered severe convective systems, with better
61 performance observed in identifying severe convective winds triggered by systematic convection
62 than those triggered by scattered convection. However, the identification effectiveness of SCWINet
63 generally decreases as wind speed increases, with increased false alarms and missed detections
64 being the primary causes of this phenomenon. By contrast, the commonly used WMSE and BMSE
65 approaches fail to identify severe convective winds, and all severe convective winds they identify
66 are below $17.2 \text{ m}\cdot\text{s}^{-1}$. Nevertheless, the data used in this study are somewhat limited in terms of
67 the feature completeness and volume. Future enhancements in identification accuracy of severe
68 convective winds could be achieved by incorporating additional features and data, such as radar
69 radial velocity, Specific Differential Phase (K_{DP}), Differential Reflectivity (Z_{DR}), and satellite data.
70 This could be also applied to identify even higher wind speeds.

71 **Key words:** nowcasting, severe convective wind, identification of winds at different scales, deep
72 learning, loss function, radar

74 引言

75 强对流大风(以下简称强风)指瞬时风力达到或超过 $17.2 \text{ m}\cdot\text{s}^{-1}$ 的地面大风并伴有雷暴时的大
76 风天气, 其中 17.2 、 20.8 、 $24.5 \text{ m}\cdot\text{s}^{-1}$ 以上的强风分别对应于 8、9、10 级以上, 由于其极强的
77 突发性和致灾性, 现已严重威胁国民生命财产安全与社会经济发展(郑永光等, 2016a; 2016b;
78 樊李苗和俞小鼎, 2020)。然而, 目前全球业务数值预报模式、中尺度数值模式对强风的预报能
79 力仍然有限(杨新林等, 2017; 高帆等, 2023), 因此, 临近预报预警成为业务部门应对强对流
80 大风的主要手段。虽然全国观测网的自动化及其时空精细化程度不断增加, 临近预警技术不
81 断完善, 但仍很难满足强风的预报需求(郑永光等, 2018)。因此, 发展针对强风的预报预警技
82 术具有重大现实意义(彭霞云等, 2022)。

83 现有强风的识别技术主要基于气象领域专家总结的典型雷达特征展开, 其主要可分为以模
84 糊逻辑(李国翠等, 2013)、支持向量机(杨璐等, 2018)等传统识别算法和以全连接神经网络、
85 卷积神经网络、循环卷积神经网络等的深度神经网络算法(周康辉等, 2017; 李海峰, 2018),
86 上述方法在识别强风中取得了一定的成效, 但它们目前仅能区分是否发生强对流大风。迄今为止,
87 针对强风的分级识别, 尤其是针对 17.2 、 20.8 、 $24.5 \text{ m}\cdot\text{s}^{-1}$ 及以上强风的识别研究与业务
88 应用极为少见。造成该问题的主要原因在于:第一, 传统客观识别方法本身性能有限, 很难捕获
89 引发强风的复杂非线性机制, 其识别效果往往较差(方翀等, 2014; 周康辉等, 2021; 杨绚等,
90 2022; 王婷婷等, 2023)。第二, 强风存在严重, 乃至极端的样本不平衡问题, 如 $24.5 \text{ m}\cdot\text{s}^{-1}$ 以
91 上大风相对较为少见, 这也严重制约了各类客观算法的适用性。

92 为解决上述强对流大风分级客观识别中所存在的问题, 进而为强对流大风预报预警能力提
93 供科学支撑。本文提出了一种针对 17.2 、 20.8 、 $24.5 \text{ m}\cdot\text{s}^{-1}$ 以上强风的分级识别算法(Severe
94 Convective Wind Identification Network, SCWINet)。该算法采用不可微分的命中率(POD)作为
95 卷积神经网络(CNN)的损失函数, 以偏差(Bias)为其约束条件, 通过多目标优化的免疫进化算
96 法(MOIEA), 优化了 CNN 的所有模型参数。据此, 使用了 2022—2024 年浙江省多源观测数据。
97 为验证算法性能, 将 SCWINet 与采用相同 CNN 结构的两种方案进行了对比:加权均方误差
98 (WMSE)可微分损失函数和平衡均方误差(BMSE)可微分损失函数方案。基于邻域法(扫描半径
99 为 5 km), 通过 TS 评分、Bias、POD、虚警率(FAR)等指标和强风平面分布特征, 探讨了
100 SCWINet 的适用性。

101 1 资料与方法

102 1.1 资料

103 本研究选用了 2022—2024 年浙江省雷达垂直液态水含量、三维雷达反射率、闪电定位仪和
104 分钟级地面自动观测站资料等多源观测数据。其中, 浙江省三维雷达反射率通过 8 部 S 波段双
105 偏振雷达组网得到, 其时间分辨率为 6 min, 空间分辨率为 0.01° , S 波段双偏振雷达编号及其

106 地理位置信息见表 1 所示。在组网拼图前，采用了基于深度学习的雷达质控方法，该质控方法
107 基于 U-Net 模型架构，人工选取了 2019 年 7—8 月共计 5000 例单帧质控前雷达反射率，故模型
108 的输入为单帧雷达反射率，其输出的对应真值标签为人工标记的非降水回波。将该数据集按顺
109 序划分为 4000 例训练集和 1000 例测试集。在训练阶段，初始学习率为 0.001，模型共迭代 100
110 次，训练期间对学习率采用等间隔衰减策略以确保模型收敛至最优状态。最终，该质控方法对
111 1000 例测试集中非降水回波的识别精度达到 80%。

112 表 1 三维雷达组网拼图所用 8 部 S 波段双偏振雷达信息

113 Table 1 Information of eight S-band dual-polarization radars used in 3D radar network mosaics

雷达编号	纬度	经度
Z9570	29.0852	118.7025
Z9571	30.2732	120.3375
Z9572	30.8380	120.2052
Z9573	30.7392	120.7611
Z9574	30.0697	121.5093
Z9577	27.8956	120.7456
Z9578	28.5445	119.9274
Z9579	29.2188	119.6450

114
115 由于实际业务中观测资料可能存在 6~12 min 延迟，因此本文采用过去两个相邻时刻(6、12
116 min 或 12、18 min)的资料来训练强风分级识别模型。其中，真实极大风资料为分钟级地面自动
117 观测站取逐 6 min 时段内的极大风，并用闪电定位仪对极大风数据进行质量控制(详见表 2)。

118 数据处理包含两个主要步骤:空间插值和特征提取。首先，将自动站站点资料根据最邻近方
119 法插值到格点上，若同一个格点存在多个站点风速，便取最大的风速值。然后，对数据进行质
120 量控制(表 2)。诸多研究表明，基于雷达三维资料可提取出与强对流大风发生所密切相关的垂
121 直和水平空间特征(杨璐等，2018；沈杭峰等，2019；刘娜等，2021；周康辉等，2021)。为此，
122 参照李海峰(2018)的研究方案，从三维雷达组网资料中提取了上述空间特征作为分级识别强风
123 的因变量(表 3)。

124 质量控制后，用于模型训练的样本总数为 11625。每个样本包含输入特征和标签风速，其
125 中输入特征的数据维度为 $10 \times 5 \times 5$ ，代表 10 种特征在 5×5 的格点区域的分布，标签风速为 5×5
126 区域中心点处的自动站风速。训练样本总数中 $17.2 \text{ m} \cdot \text{s}^{-1}$ 以上各风速阈值区间内样本数分布如
127 图 1。从图 1 可见，强风样本频数随风速等级的增大而迅速降低， $28.5 \text{ m} \cdot \text{s}^{-1}$ 以上极端强对流大
128 风样本占比仅为 0.59%。测试数据来自 2024 年 3—4 月的 6 d 强对流过程，共计 119 个时次(间
129 隔为 6 min)，每个时次覆盖 716×814 的网格区域，空间分辨率为 0.01° 。

130


131 表 2 强对流大风样本筛选方法

132 Table 2 Filtering methods for severe convective wind samples

筛选方法描述	说明
剔除冷空气、台风、低空急流等非强对流大风	非强对流大风的加入会干扰模型的训练，这里通过人工筛选的方法，避开出

的样本	现非强对流大风的天数
剔除相邻时刻强对流大风重复率 $\geq 90\%$ 的样本	过高的资料重复会造成强对流过程的样本不平衡，干扰模型训练
剔除沿海地区样本	沿海地区大风易受温压场、下垫面等因素影响，出现非强对流大风，该筛选通过图像标记软件 labelme 完成，即根据人工主观认知，首先基于行政边界数据，在 714×761 的网格区域内按照 $0.05^\circ \times 0.05^\circ$ 标记出属于浙江省的区域(图 1 中白色区域)。然后通过人工主观选择出沿海封闭区作为非强对流大风的滤除区(图 1 中红线区域)，即该区域的大风被滤除，其他区域不滤除
剔除无闪电观测站点周围的 $2^\circ \times 2^\circ$ 区域内样本	避免混入杂波、非强对流大风
剔除 5×5 网格区域内 50 dBz 以上雷达组合反射率因子个数 ≤ 2 的样本	避免混入杂波、非强对流大风

133



134

135

136

注:白色区域为浙江省区域。

137

图 1 基于 Shap 的浙江省行政边界和 Labelme 标注非强对流大风滤除区域(红线区域)

138

Fig. 1 Shap-based Zhejiang Province boundary and Labelme-annotated non-severe convective wind exclusion zones (red polygons)

139

140

表 3 用于分级识别强对流大风的因变量

141

Table 3 The dependent variables used for identifying severe convective winds of different scales

特征类型	因变量名称	单位	特征数量
水平特征	相邻时刻的雷达组合反射率因子强度	dBz	2
	相邻时刻的雷达组合反射率因子在 x 和 y 方向上的水平梯度	dBz	2
	相邻时刻的最强反射率因子高度	km	2
垂直特征	最强反射率因子高度下降速度	km min ⁻¹	1
	相邻时刻的垂直液态水含量	kg m ⁻²	2
	垂直液态水含量变化速度	kg m ⁻² min ⁻¹	1

142




图 2 不同风速等级强风的频率分布

Fig. 2 Frequency distribution of severe convective winds at different wind speed levels

1.2 基于“面对点”识别方案的数据集构建

现有针对强风识别的数据集构建方案主要有三种(表 4):“点对点”“面对点”“面对面”。由于强风的发生与对流系统的小微尺度时空特征密切相关(杨璐等, 2018; 沈杭峰等, 2019; 刘娜等, 2021; 周康辉等, 2021)。因无法提取空间特征, 首先不采用“点对点”方案; 其次, 本研究因仅有站点观测的强风资料, 而缺少格点化的强风资料, 因此未采用基于格点化资料的“面对面”方案, 而是主要参考李海峰(2018)的研究, 选择“面对点”方案, 以 5×5 的格点区域来分级识别中心点的强风风速。

表 4 不同数据构建方案的对比

Table 4 Comparison of different data construction schemes

识别方案	方案描述	优点	缺点
点对点	将大风风速与其他自变量最近邻插值至格点或站点, 仅采用风速格点处的自变量来识别强风	①计算量少 ②识别算法相对简单	①无法学习变量之间的空间信息 ②输入变量特征图像大小与识别效果关系较大。需依赖多次试验确定最优图像大小
面对点	将大风风速与其他自变量最近邻插值到格点, 用方形区域内 $N \times N$ 个格点的自变量来识别中心点强风	①能学习变量之间的空间信息 ②输入和标签真值均为真实场景下所采集数据	②业务部署阶段, 需将目标识别区大小划分成多个子区域, 过大的子区域会导致计算量较大 ③训练阶段计算量最大 ④网络结构最复杂, 模型参数最多
面对面	大风风速真实值和其他自变量均为格点化数据, 用多种格点化的区域自变量资料来识别一个区域内每个格点的强风	①能提取出变量之间更复杂的时空关系	③对数据集质量要求最大

157 **1.3 检验方法**

158 根据中国气象局智能预报技术方法竞赛检验方案，采用“面对点”检验方法，即以实况站
159 点为中心点，扫描半径为 5 km。检验评估指标采用 TS 评分、POD、FAR、Bias 来评估针对强
160 风的识别效果，上述指标能有效检验存在样本严重不平衡问题的强风分级识别能力。其计算方
161 法流程为：首先定义一组风速把最终的预测结果分解成多个二分类问题（大于阈值的点设为正例，
162 反之设为负例），然后根据二分类混淆矩阵计算评分。假设检验的强风阈值为 $K(\text{m}\cdot\text{s}^{-1})$ ，TP 表
163 示观测不小于 K 且预测也不小于 K 的次数，FN 表示观测不小于 K 而预测小于 K 的次数，FP 表
164 示观测小于 K 而预测不小于 K 的次数，TN 表示观测小于 K 且预测小于 K 的次数。本试验使用的 K 分别为 17.2、20.8、24.5 $\text{m}\cdot\text{s}^{-1}$ ：

166
$$\text{TS} = \frac{\text{TP}}{\text{TP} + \text{FN} + \text{FP}} \quad (1)$$

167
$$\text{POD} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$


168
$$\text{FAR} = \frac{\text{FP}}{\text{TP} + \text{FP}} \quad (3)$$

169
$$\text{BIAS} = \frac{\text{TP} + \text{FP}}{\text{TP} + \text{FN}} \quad (4)$$

170 **1.4 SCWINet**

171 每一层的卷积核在提取输入特征的空间特征时，均会导致特征空间尺度的缩小，而用于分
172 级识别强风的因变量空间大小仅为 5×5，因此无法构建过深的卷积层。故本文以图 3 的 CNN 框
173 架用于分级识别强风，其参数量仅为 8529，低于强风的训练样本量（11625），以此尽可能保证
174 模型的计算效率与泛化性。根据表 2，CNN 的输入特征数为 10，输入特征的空间区域大小为
175 5×5，此后经过两次卷积与 ReLU 激活函数（Krizhevsky et al, 2017），将特征的通道数（C）分别扩
176 展为 32 和 16，特征空间尺度则分别缩小为 3×3 和 1×1（H×W），然后经过 2 个维度（Dim）为 16 的
177 全连接层与 ReLU 激活函数，最后输出强风风速。

178



179

180 图 3 用于强风识别的 CNN 结构

181 Fig. 3 The framework of CNN for severe convective wind identification

182 SCWINet 将不可微分的 POD 和 Bias 分别作为损失函数和约束条件。其中，以 POD 作
183 为损失函数，代表模型在训练过程中的目标为仅提升 POD，这虽能解决样本不平衡导致的强风
184 风识别问题，但很可能导致过大的空报，即 Bias 很大。为了约束空报问题，设置了 Bias 约束
185 条件，使得 POD 和 Bias 相互制约。然而，POD 和 Bias 不可微分，因此无法基于梯度下降法来
186 更新 CNN 的所有参数。为了解决该问题，利用 MOIEA 代替梯度下降法来优化 CNN 的所有参
187 数。

188 IEA 训练 SCWINet 的具体实现流程如下。

189

$$F(x) = 1 - \frac{1}{k} \times \sum_{j=1}^k (\text{POD}_{K_j}) \quad (5)$$

190

$$\max(\text{BIAS}_{K_j}) \leq 1 \quad (6)$$

191

$$K_k = \begin{cases} 17.2, k=1 \\ 20.8, k=2 \\ 24.5, k=3 \end{cases} \quad (7)$$

192 式中： $F(x)$ 为 SCWINet 的损失函数； x 是待优化的参数，其对应为 SCWINet 的所有参数。当
193 $F(x)$ 达到最小时且满足式(6)的 Bias 约束条件时，SCWINet 识别的 $17.2, 20.8, 24.5 \text{ m}\cdot\text{s}^{-1}$ 以上
194 强风 POD 均值最高，此时其参数即为最优参数。MOIEA 的原理详见(倪长健等，2003；钟琦等，
195 2024)，本文不再赘述。在本文测试阶段和业务化应用部署时，对表 1 质控后格点仍存在雷达组
196 合反射率因子在 50 dBZ 以上且过去 6 min 仍出现 $17.2 \text{ m}\cdot\text{s}^{-1}$ 以上强风，但 SCWINet 未识别的，
197 将该强风也作为当前识别强风。

198 1.5 基于加权均方误差(WMSE) 损失函数的对比模型

199 常用的深度学习方法多采用可微的损失函数，基于梯度下降法来更新模型参数。为了解决
200 该条件下分级识别强风的样本严重不平衡问题，对比模型基于相同神经网络框架(图 3)，其损
201 失函数则采用了 WMSE 损失函数(Hu et al, 2017; Zhang et al, 2017; Fang et al, 2020)。

202 WMSE 相比于常规的均方误差(MSE) 损失函数而言，其在计算损失时考虑了目标值的大小。
203 通过根据目标值的大小动态调整损失函数中各个样本的权重，使得大目标值和小目标值对损失
204 的贡献相对平衡。因此，WMSE 被广泛地运用于解决样本不平衡问题，以提高模型在处理不同
205 范围目标值时的性能表现。

206

$$\text{WMSE} = \frac{1}{N} \sum_{i=1}^N w(O_{i,j})(P_{i,j} - O_{i,j})^2 \quad (8)$$

207

$$w(O_{i,j}) = \frac{N}{N_j} \quad (9)$$

式中: N 为总样本数, $O_{i,j}$ 为第 i 个观测强风样本的风速, 其对应为 j 的风速等级; $P_{i,j}$ 为第 i 个识别大风风速, 其对应为 j 的风速等级; $w(O_{i,j})$ 为对应风速等级时的权重系数; N 为样本总数; N_j 为 j 风速等级时的样本总数, 其详见图 1 所示。

1.6 基于平衡均方误差(BMSE)损失函数的对比模型

研究表明 (Ren et al, 2022), 当训练数据不平衡时, MSE 会被标签分布所影响而倾向于预测常见的标签。为了解决回归问题中所存在的样本不平衡问题, 基于极大似然估计法, 得到可自适应不平衡数据分布回归问题的 BMSE 损失函数 (Ren et al, 2022), 如下所示:

$$L = -\log \frac{\exp(-(O - P)^2 / (2\sigma^2))}{\sum_{k=1}^B \exp(-(O_{B,k} - P_{B,k})^2 / (2\sigma^2))} \quad (10)$$

式中: O 为所有样本的风速值; P 为所有样本对应的模型识别值; $O_{B,k}$ 为每一次训练过程中所使用到的 O 的子集, B 为此时子集中的样本数; σ 为该损失函数的可学习性参数, 基于梯度下降法, σ 与模型参数一起参与模型训练而得到更新优化。

2 检验结果

2.1 综合检验

WMSE 和 BMSE 目前虽被广泛应用于缓解样本不平衡问题, 但在本文训练和测试环节均发现, WMSE 和 BMSE 的最强识别风速均小于 $17.2 \text{ m}\cdot\text{s}^{-1}$, 表明这两种损失函数所训练的模型均无法识别出强风, 识别结果明显偏低。故接下来仅分析 SCWINet 在测试集中的识别效果。

在 5 km 邻域检验半径的条件下(表 5)可见, SCWINet 识别效果较好。不过, SCWINet 分级识别效果随强风风速的增大而逐渐降低, 空报率的增大和命中率的降低是主要原因。为进一步评估 SCWINet 的适用性, 结合了综合评分和强风平面分布对 2024 年 3 月 25 日 14:12—17:12(北京时, 下同)的 17.2 、 20.8 、 $24.5 \text{ m}\cdot\text{s}^{-1}$ 以上强风过程进行检验。

表 5 SCWINet 的测试集检验结果

Table 5 Test results of SCWINet in test set

评估指标	强风风速(等级)		
	$\geq 17.2 \text{ m}\cdot\text{s}^{-1}$ (8 级)	$\geq 20.8 \text{ m}\cdot\text{s}^{-1}$ (9 级)	$\geq 24.5 \text{ m}\cdot\text{s}^{-1}$ (10 级)
TS	0.123	0.075	0.044
POD	0.415	0.379	0.361
FAR	0.852	0.915	0.952
Bias	2.793	4.437	7.526

2.2 2024年3月25日14:12—17:12强风过程个例检验

受高空槽、低涡切变、西南暖湿气流和冷空气共同影响, 2024 年 3 月 25 日 14:12—17:12, 浙江出现大范围强对流过程, 并伴有 8~13 级分散性与系统性强风。从图 4 和图 5a₁~5d₁ 可见, 此次强风过程主要自西北向东南方向移动, 最初为局地分散性强对流系统所引发的分散性强风 (14:12—15:12)。此后随着系统发展, 逐渐演化为线状对流所引发的系统性大范围强风 (15:12—

236 17:12)。另外，在绍兴东部等地仍伴有分散性对流引发的强风(图 5b₁)。在非强组合反射率区
237 的高山站点则还有混合性大风(图 5 a₁)。


238 从图 4 可见，SCWINet 能有效识别出强风的发生区域，但范围上有所空报。具体而言，在
239 14:12，衢州、杭州西部等地有分散性对流(图 4a)，其中衢州出现 8~10 级、杭州西部出现 8
240 级强风(图 5a₁)。15:12 分散性对流进一步发展，强度和范围明显增大(图 4b)，衢州东部出现
241 8~11 级，杭州西北部出现 8~12 级强风，杭州南部出现 8 级强风(图 5b₁)。16:12 浙江西部出现
242 线状对流，绍兴等地出现分散性对流(图 4c)，在线状对流区域出现 8~11 级强风，主要位于
243 丽水、金华等地(图 5c₁)。17:12 西南-东北向线状对流(图 4d)所在的丽水、金华、宁波等地观
244 测到大范围 8~12 级强风(图 5d₁)。对于上述实况出现强风区域，SCWINet 均识别出 8~10 级以
245 上强风，识别区域和强度与实况总体一致。

246 在此次过程中，SCWINet 也表现出了一定的提前识别预警能力，其能提前识别出绍兴地区
247 分散性对流所触发的强风，提前时效总体可达 20 min 以上，主要表现为 16:12 实况无强风(图
248 5c₁)，但 SCWINet 识别出 8~9 级强风，个别为 10 级(图 5c₂)，此时可能会被认为空报。然而，
249 该系统在东移过程中强度维持稳定，在 16:32 观测到 8~9 级强风，然后在 16:42—17:06 观测到
250 10 级以上强风(图略)，可见，16:12 可考虑为提前预警。不过，SCWINet 易漏报线状对流的前
251 方强风区，这主要原因在于，根据“面对点”的建模方案，SCWINet 仅能识别强对流系统区域
252 内的强风，而线状对流前方的漏报强风区很可能是由阵风锋、下垫面狭管效应所致(沈杭锋等，
253 2019)，该类强风预警可能更需要通过强风临近外推或“面对面”的识别策略予以解决。

254 图 6 是 14:12—17:12 期间逐 6 min 的各评分时间序列，对应共 40 个时次，可见 SCWINet 对
255 各级强风具有较好的识别能力，但随着强风风速的增大，其识别效果与稳定性逐渐降低。此外，
256 强对流类型的不同也是影响 SCWINet 识别效果的重要因素，即在分散性对流为主的时段
257 (14:12—15:12, 0~10 时间序列)，TS 评分(图 6a)相对更低，Bias(图 6b)、POD(图 6c)和
258 FAR(图 6d)相对更大。而此后各评分表现则总体相反，说明 SCWINet 更适用于线状对流等系
259 统性对流所触发的强风，而对分散性对流所触发的强风相对更易空报。

260 此外，从 SCWINet 的识别图中也可见，识别强风还可达到 10 级以上，但考虑到 11 级以上
261 强风样本相对极少，对数据质量控制要求更为严格，因此针对 11 级以上强风的分级识别研究仍
262 有待进一步深入，本文并未对其展开分析研究。但只要具备更多的 11 级以上强风样本，对式(7)
263 加入 28.5、32.7 m·s⁻¹ 的风速阈值，也可完成针对 11 级以上极端强风的分级识别。

264



265

266

267

268

269

270


图 4 2024 年 3 月 25 日雷达组合反射率因子平面分布

(a) 14:12, (b) 15:12, ; (c) 16:12, (d) 17:12


Fig. 4 Plane distributions of radar composite reflectivity at (a) 14:12 BT, (b) 15:12 BT, (c) 16:12 BT and (d)

17:12 BT 25 March 2024


271




272



273



274



275

276

277

图 5 观测强风、SCWINet 识别强风的平面分布

(a₁-d₁) 观测, (a₂-d₂): SCWINet.


Fig. 5 (a₁-d₁) Plane observations of observed severe convective winds and (a₂-d₂) SCWINet-identified severe convective winds

图 6 SCWINet 对 8-10 级以上强风的识别评分时间序列

(a) TS 评分, (b) POD, (c) FAR, (d) Bias

Fig. 6 Time series of the identification scores of SCWINet for severe convective winds above scales 8-10

(a)TS, (b) POD, (c) FAR, (d) Bias

3 结论与讨论

利用 2022—2024 年浙江省雷达垂直液态水含量、三维雷达反射率、闪电定位仪、分钟级地面自动观测站资料，将不可微分 POD 作为 CNN 的损失函数，Bias 为其约束条件，然后利用 MOIEA 优化 CNN 的所有模型参数，据此提出了一种针对 $17.2, 20.8, 24.5 \text{ m}\cdot\text{s}^{-1}$ 以上强风的分级识别算法(Severe Convective Wind Identification Network, SCWINet)，其识别时间分辨率为 6 min，空间分辨率为 1 km。将 SCWINet 与采用相同 CNN 结构的 WMSE 可微分损失函数，BMSE 可微分损失函数方案进行对比，最后基于邻域法(扫描半径为 5 km)的 TS 评分、Bias、POD、FAR 和图像分布特征探讨了 SCWINet 的适用性：

(1) SCWINet 能有效识别出系统性和分散性对流系统所触发的 $17.2, 20.8, 24.5 \text{ m}\cdot\text{s}^{-1}$ 以上强风，其中对系统性对流所触发的强风分级识别效果要优于分散性对流。分级识别效果

296 总体随强风风速的增大而降低，空报的增大是造成上述现象的主要原因。相比之下，WMSE 和
297 BMSE 识别结果均小于 $17.2 \text{m} \cdot \text{s}^{-1}$ ，表明这两种可微分损失函数在强风分级识别中的应用难度相
298 对较大。

299 (2) 强风数据集的构建仍存在一定的不准确，例如剔除非强对流大风样本，一定程度上也
300 剔除了有利于消空的信息。虽然本文强对流大风样本已存在严重乃至极端的不平衡问题，但该
301 占比在实际中仍是明显偏高的。当强风样本占比极低，存在严重的类别不平衡的时候，在业务
302 应用中漏报可能造成严重损失，可以容忍一定程度的空报。传统的加权损失函数(如 WMSE)通过
303 调整样本权重来平衡各类别的贡献，但权重的选择往往依赖经验。平衡损失函数(如 BMSE)
304 试图在类别层面实现平衡，但可能忽视了业务需求中对漏报和空报的非对称要求。相比之下，
305 POD 和 Bias 组合直接针对业务关心的指标进行优化，通过 POD 优化保证对强风事件的较高
306 POD，同时通过 Bias 约束维持预测的空间分布合理性。更强的大风往往与更复杂的天气系统相
307 关。强对流系统在发展到产生极端大风时，常常伴随多尺度天气系统的相互作用，如中尺度对
308 流系统与局地地形、边界层结构的耦合等。本文所选用的雷达特征可能不足以完整刻画这些复
309 杂的物理过程。特别是在系统快速发展阶段，现有特征可能无法充分捕捉到导致风速快速增强
310 的关键因素，因此，针对强风客观识别及外推算法的研究中，未来应引入更多观测数据，例如
311 速度场、差分传播相移率 (K_{DP})、差分反射率因子 (Z_{DR}) 以及卫星观测资料等，以丰富模型输入
312 特。另外需要特别注意的是，受制于自动站观测网在山区，乃至城区密集程度不够，以及下垫
313 面环境因素阻挡等原因，实际可触发致灾性强风的对流系统可能观测不到强风出现，但算法可
314 能会做出提前识别，这也可能会被认定为空报。因此，对于此种现象如何对强风数据做出科学
315 判识标记，构造更准确的数据集，进而强化算法学习能力。

316 (3) 本文探索了一种有效缓解样本不平衡问题的优化策略，以提升强风分级识别的准确性。
317 在气象领域，尤其是强风分级识别任务中，样本不平衡问题常常导致模型难以准确捕捉少数类
318 别的特征，进而影响预测的整体性能。尽管 BMSE 与 WMSE 等损失函数试图通过赋予少数类
319 别更高权重来缓解这一问题，但在本文是无效的。此外，气象专家凭借多年的实践积累，能够
320 在复杂的天气模式识别中发挥关键作用。因此，在气象领域应用人工智能技术时，将气象专家
321 的主观预报经验与数学物理机制相结合是有效的优化策略，可以为人工智能模型提供更为精准
322 的指导和约束，从而提升模型在处理样本不平衡问题时的鲁棒性和准确性。

323 参考文献

324 樊李苗, 俞小鼎, 2020. 杭州地区夏季午后雷暴大风环境条件分析[J]. 气象, 46(12): 1621-1632. Fan L M, Yu X
325 D, 2020. Analysis on the environment conditions of afternoon thunderstorm in Hangzhou[J]. Meteor Mon,
326 46(12): 1621-1632 (in Chinese).

- 327 方翀, 郑永光, 林隐静, 等, 2014. 导致区域性雷暴大风天气的云型分类及统计特征分析[J]. 气象, 40(8): 905-
328 915. Fang C, Zheng Y G, Lin Y J, et al, 2014. Classification and characteristics of cloud patterns triggering
329 regional thunderstorm high winds[J]. Meteor Mon, 40(8): 905-915 (in Chinese).
330 高帆, 俞小鼎, 王秀明, 2023. 山东较大范围致灾雷暴大风的多普勒天气雷达特征[J]. 气象, 49(7): 790-804.
331 Gao F, Yu X D, Wang X M, 2023. Doppler radar characteristics of wide-range damaging thunderstorm gales
332 in Shandong Province[J]. Meteor Mon, 49(7): 790-804 (in Chinese).
333 李国翠, 刘黎平, 张秉祥, 等, 2013. 基于雷达三维组网数据的对流性地面大风自动识别[J]. 气象学报, 71(6):
334 1160-1171. Li G C, Liu L M, Zhang B X, et al, 2013. Automatic identification of ground thunderstorm gale
335 based on the radar mosaic 3D data[J]. Acta Meteor Sin, 71(6): 1160-1171 (in Chinese).
336 李海峰, 2018. 基于雷达回波的雷暴大风识别算法研究[D]. 哈尔滨: 哈尔滨工业大学. Li H F, 2018. Research
337 on identification algorithm of thunderstorm gale based on radar echo[D]. Harbin: Harbin Institute of
338 Technology (in Chinese).
339 刘娜, 熊安元, 张强, 等, 2021. 强对流天气人工智能应用训练基础数据集构建[J]. 应用气象学报, 32(5): 530-
340 541. Liu N, Xiong A Y, Zhang Q, et al, 2021. Development of basic dataset of severe convective weather for
341 artificial intelligence training[J]. J Appl Meteor Sci, 32(5): 530-541 (in Chinese).
342 倪长健, 丁晶, 李祚泳, 2003. 免疫进化算法[J]. 西南交通大学学报, 16(1): 87-91. Ni C J, Ding J, Li Z Y, 2003.
343 Immune evolutionary algorithm[J]. J Southwest Jiaotong Univ, 16(1): 87-91 (in Chinese).
344 彭霞云, 章丽娜, 刘汉华, 等, 2022. 冷涡底部对流引起的杭州湾极端大风形成机制分析[J]. 气象, 48(6): 719-
345 728. Peng X Y, Zhang L N, Liu H H, et al, 2022. Formation mechanism of extreme winds in Hangzhou Bay
346 caused by convection at the bottom of cold vortex[J]. Meteor Mon, 48(6): 719-728 (in Chinese).
347 沈杭锋, 方桃妮, 蓝俊倩, 等, 2019. 一次强飑线过程极端大风的中尺度分析[J]. 气象学报, 77(5): 806-822. Shen
348 H F, Fang T N, Lan J Q, et al, 2019. Mesoscale analysis of the extremely damaging gale in a severe squall
349 line[J]. Acta Meteor Sin, 77(5): 806-822 (in Chinese).
350 王婷婷, 朱文剑, 姚凯, 等, 2023. 2021 年吉林中部一次极端雷暴大风的中尺度成因分析[J]. 气象, 49(10):
351 1215-1226. Wang T T, Zhu W J, Yao K, et al, 2023. Mesoscale analysis of an extreme thunderstorm gale in
352 central Jilin Province in 2021[J]. Meteor Mon, 49(10): 1215-1226 (in Chinese).
353 杨璐, 陈明轩, 孟金平, 等, 2018. 北京地区雷暴大风不同生命期内的雷达统计特征及预警提前量分析[J]. 气象,
354 44(6): 802-813. Yang L, Chen M X, Meng J P, et al, 2018. Radar statistical characteristics and warning lead
355 analysis of thunderstorm gales in different life periods in Beijing[J]. Meteor Mon, 44(6): 802-813 (in
356 Chinese).
357 杨绚, 代刊, 朱跃建, 2022. 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, 80(5): 649-
358 667. Yang X, Dai K, Zhu Y J, 2022. Progress and challenges of deep learning techniques in intelligent grid
359 weather forecasting[J]. Acta Meteor Sin, 80(5): 649-667 (in Chinese).
360 杨新林, 孙建华, 鲁蓉, 等, 2017. 华南雷暴大风天气的环境条件分布特征[J]. 气象, 43(7): 769-780. Yang X L,
361 Sun J H, Lu R, et al, 2017. Environmental characteristics of severe convective wind over South China[J].
362 Meteor Mon, 43(7): 769-780 (in Chinese).
363 郑永光, 田付友, 孟智勇, 等, 2016a. "东方之星"客轮翻沉事件周边区域风灾现场调查与多尺度特征分析[J].
364 气象, 42(1): 1-13. Zheng Y G, Tian F Y, Meng Z Y, et al, 2016a. Survey and multi scale characteristics of
365 wind damage caused by convective storms in the surrounding area of the capsizing accident of cruise ship
366 "Dongfangzhixing"[J]. Meteor Mon, 42(1): 1-13 (in Chinese).

- 367 郑永光, 田付友, 周康辉, 等, 2018. 雷暴大风与龙卷的预报预警和灾害现场调查[J]. 气象科技进展, 8(2): 55-61.
- 368 Zheng Y G, Tian F Y, Zhou K H, et al, 2018. Forecasting techniques and damage survey of convectively
369 driven high winds and tornadoes[J]. Adv Meteor Sci Technol, 8(2): 55-61 (in Chinese).
- 370 郑永光, 朱文剑, 姚聃, 等, 2016b. 风速等级标准与 2016 年 6 月 23 日阜宁龙卷强度估计[J]. 气象, 42(11):
371 1289-1303. Zheng Y G, Zhu W J, Yao D, et al, 2016b. Wind speed scales and rating of the intensity of the 23
372 June 2016 tornado in Funing County, Jiangsu Province[J]. Meteor Mon, 42(11): 1289-1303 (in Chinese).
- 373 钟琦, 张智察, 姚秀萍, 等, 2024. 应用物理结合的人工智能方法提升“21·7”河南极端强降水预报[J]. 中国科学:
374 地球科学, 54(5): 1680-1701. Zhong Q, Zhang Z C, Yao X P, et al, 2024. Improved forecasting via physics-
375 guided machine learning as exemplified using “21·7” extreme rainfall event in Henan[J]. Science China Earth
376 Sciences, 67(5): 1652-1674 (in Chinese).
- 377 周康辉, 郑永光, 韩雷, 等, 2021. 机器学习在强对流监测预报中的应用进展[J]. 气象, 47(3): 274-289. Zhou K H,
378 Zheng Y G, Han L, et al, 2021. Advances in application of machine learning to severe convective weather
379 monitoring and forecasting[J]. Meteor Mon, 47(3): 274-289 (in Chinese).
- 380 周康辉, 郑永光, 王婷波, 等, 2017. 基于模糊逻辑的雷暴大风和非雷暴大风区分方法[J]. 气象, 43(7): 781-791.
381 Zhou K H, Zheng Y G, Wang T B, et al, 2017. Fuzzy logic algorithm of thunderstorm gale identification
382 using multisource data[J]. Meteor Mon, 43(7): 781-791 (in Chinese).
- 383 Fang Y, Hu Y H, Shao M F, et al, 2020. Performance analysis of a backlight dimming method using weighted
384 mean-square-error based on joint edge-saliency characteristics[J]. Displays, 61: 101927.
- 385 Hu S D, Jin L, Wang H L, et al, 2017. Objective video quality assessment based on perceptually weighted mean
386 squared error[J]. IEEE Trans Circuits Syst Video Technol, 27(9): 1844-1855.
- 387 Krizhevsky A, Sutskever I, Hinton G E, 2017. ImageNet classification with deep convolutional neural networks[J].
388 Communications of the ACM, 60(6): 84-90.
- 389 Ren J W, Zhang M Y, Yu C J, et al, 2022. Balanced MSE for imbalanced visual regression[C]//2022 IEEE/CVF
390 Conference on Computer Vision and Pattern Recognition. New Orleans, LA, USA: IEEE: 7916-7925.
- 391 Zhang S, Zheng W X, Zhang J S, et al, 2017. A family of robust m-shaped error weighted least mean square
392 algorithms: performance analysis and echo cancellation application[J]. IEEE Access, 5: 14716-14727.