

融合物理信息的热带气旋强度估计^①

丁嘉慕, 乐璐辉, 杭仁龙

(南京信息工程大学 计算机学院, 南京 210044)

通信作者: 丁嘉慕, E-mail: djm13806419595@163.com



摘要: 热带气旋强度的精确估计是进行有效强度预测的基础工作, 对于灾害预报至关重要. 当前基于深度学习的热带气旋强度估计技术展现出了优越的性能, 但仍然存在着物理信息融合不足的问题. 因此, 本文基于深度学习框架, 提出一种融合物理信息的热带气旋强度估计模型 (physical factor fusion for tropical cyclone intensity estimation, PF-TCIE), 来估计西北太平洋的热带气旋强度. PF-TCIE 由多通道卫星云图学习分支和物理信息提取分支组成. 多通道卫星云图学习分支用于提取热带气旋云系特征, 物理信息提取分支用于提取物理因子特征, 来约束云系特征的学习. 本文数据选用葵花-8 卫星资料和 ERA-5 再分析资料. 实验证明, 在引入多个通道后, 模型的 RMSE 误差较单通道降低了 3.7%. 同时, 物理信息的引入使模型的误差进一步下降了 8.5%. PF-TCIE 的 RMSE 最终达到了 4.83 m/s, 优于大部分深度学习方法.

关键词: 热带气旋强度估计; 融合物理信息; 深度学习; 葵花-8 卫星图像; ERA-5 再分析资料

引用格式: 丁嘉慕, 乐璐辉, 杭仁龙. 融合物理信息的热带气旋强度估计. 计算机系统应用, 2024, 33(9): 28–37. <http://www.c-s-a.org.cn/1003-3254/9623.html>

Physical Factor Fusion for Tropical Cyclone Intensity Estimation

DING Jia-Mu, YUE Lu-Hui, HANG Ren-Long

(School of Computer, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: Accurate estimation of tropical cyclone intensity is the basis of effective intensity prediction and is crucial for disaster forecasting. Current tropical cyclone intensity estimation technology based on deep learning shows superior performance, but there is still a problem of insufficient physical information fusion. Therefore, based on the deep learning framework, this study proposes a physical factor fusion for tropical cyclone intensity estimation model (PF-TCIE) to estimate the intensity of tropical cyclones in the northwest Pacific. PF-TCIE consists of a multi-channel satellite cloud image learning branch and a physical information extraction branch. The multi-channel satellite cloud image learning branch is used to extract tropical cyclone cloud system features, and the physical information extraction branch is used to extract physical factor features to constrain the learning of cloud system features. The data used in this article include Himawari-8 satellite data and ERA-5 reanalysis data. Experimental results show that after introducing multiple channels, the root mean squared error (RMSE) of the model is reduced by 3.7% compared with a single channel. At the same time, the introduction of physical information further reduces the model error by 8.5%. The RMSE of PF-TCIE finally reaches 4.83 m/s, which is better than most deep learning methods.

Key words: tropical cyclone intensity estimation; physical factor fusion; deep learning; Himawari-8 satellite image; ERA-5 reanalysis data

① 基金项目: 国家自然科学基金 (U21B2049)

收稿时间: 2024-03-20; 修改时间: 2024-04-16; 采用时间: 2024-04-29; csa 在线出版时间: 2024-07-26

CNKI 网络首发时间: 2024-07-29

热带气旋 (tropical cyclone, TC) 是生成于热带或者副热带海洋上的低压涡旋。热带气旋的出现不仅往往伴随着强降水和大风, 同时也可能伴随着洪水, 泥石流, 滑坡等次生灾害。根据国家气象局统计, 每年全世界会发生 80-90 个气旋。其中西北太平洋海域发生的热带气旋数量最多, 约占总气旋数的 1/3^[1]。我国正是位于西北太平洋海域, 每年约有 7 个热带气旋登陆, 所带来的经济损失约为 480 亿元, 人员伤亡约为 70 人, 是世界上受热带气旋影响最严重的国家之一。因此, 研究热带气旋对我国防灾减灾具有重要意义。

热带气旋强度估计是强度预报的基础性工作, 其在气象学和灾害管理领域具有重要意义。准确估计热带气旋的强度可以提高灾害预警和应急响应的效率, 最大限度地降低人员伤亡和财产损失。此外, 研究热带气旋强度有助于理解气候变化对热带气旋活动的影响, 为应对未来气候极端事件提供科学依据。因此, 热带气旋强度估计的研究对于提高社会对热带气旋灾害的应对能力具有重要意义。

热带气旋强度估计是指采用各种气象数据和技术手段来确定热带气旋的强度, 通常以最大持续风速或最低海平面气压来衡量^[2,3]。根据热带气旋强度估计和预测的方法主要分为数值方法、统计方法和深度学习方法。数值方法通过建立数理方程来描述热带气旋的演变规律。统计方法主要依据热带气旋的统计特征来估计其强度。深度学习方法则是基于神经网络从大量数据中提取热带气旋特征, 进而估计其强度。

数值方法虽然物理意义明确, 可解释性强, 但其存在着一些问题: 1) 不同的气旋个例、不同的海域以及不同的时间尺度均会显著影响强度估计性能; 2) 数值方法的性能高度依赖于精确的建模和初始化; 3) 需要耗费大量的时间资源和计算资源。

统计方法则基于气旋的统计特征来估计强度, 代表方法有 Dvorak 系列技术、偏差方差角技术和机器学习技术等。业务上虽然主要使用的是 Dvorak 技术, 但其具有较强的主观性, 准确依赖于专家的经验。而偏差角方差技术和机器学习技术依赖于热带气旋的手工特征, 随着复杂环境的变化, 可能存在着遗漏和不足。

近年来, 基于深度学习方法的热带气旋强度估计展现出了优异的性能。不同于数值方法和统计方法, 深度学习方法具有以下优势: 1) 无需手动从卫星云图中提取特征, 神经网络以数据驱动的方式可以自动地从

大量数据中提取信息并拟合物理规律, 减少了对专家经验的依赖, 因此具有较强的客观性; 2) 时间成本和金钱成本较低; 3) 具有同时处理大批量数据的能力。随着时间的推移, 模型学到的数据将越来越多, 强度估计能力也将越来越强。深度学习方法主要是以一些经典的模型 (如 ResNet^[4], VGGNet^[5], Transformer^[6]等) 为骨干网络, 在其基础上做简单的改进后, 让网络参数从大量的数据中提取热带气旋特征, 进而估计其强度。该类方法的本质是通过纯数据驱动的形式从大批量数据中提取物理规律, 虽然无需构建数学物理方程并且具有一定的客观性, 取得了较好的性能。但是, 热带气旋是一个极其复杂的灾害性系统, 其受到诸多物理因素的影响, 仅从图像信息上获得的特征可能相对片面, 因此本文基于 ERA-5 再分析资料, 引入了多个和热带气旋强度相关的物理因子作为约束, 来辅助模型在卫星云图中的学习。

本文提出了一个融合物理信息的热带气旋强度估计模型 (PF-TCIE)。通过融合物理信息来约束并辅助深度学习模型从卫星云图中获取知识。模型主要有两个分支, 分别是多通道特征提取分支和物理信息提取分支。多通道特征提取分支主要负责提取不同通道组合的卫星云图从而对模型估计热带气旋强度起到一定的促进作用。物理信息提取分支则是从 ERA-5 因子中提取到和热带气旋强度相关的物理信息并注入多通道特征提取分支中来辅助估计热带气旋强度。模型在西北太平洋海域上进行训练并测试, 其性能要显著优于部分传统方法和深度学习方法。

1 相关工作

1.1 数值方法

数值方法基于数学物理方程来描述热带气旋的演变规律。如全球预报系统 (global forecast system, GFS) 由美国国家气象局 (National Weather Service, NWS) 提出, 为热带气旋提供全球范围的预测和模拟, 在气象和灾害管理应用中发挥着至关重要的作用。欧洲中期天气预报中心 (European Centre for Medium Range Weather Forecasts, ECMWF) 可以提供全球中纬度地区的气象预报^[7]。此外, 还有一些专门用于热带气旋研究的事件模型, 例如飓风天气研究和预报 (hurricane weather research and forecasting, HWRF)^[8]、地球物理流体动力学实验室模型 (geophysical fluid dynamics

laboratory, GFDL). 然而, 由于模拟小尺度特征困难、精度受初始值影响较大、不确定性较大、计算资源要求较高, 物理方法在应用于热带气旋时表现出一定的局限性.

1.2 基于统计的方法

基于统计的热带气旋强度估计方法中最具有代表性的就是德沃夏克 (Dvorak) 类的方法^[9-13]. 该方法假设具有相似强度的热带气旋往往会表现出相似的模式. 然而, 这种方法具有主观因素, 因为它需要气象专家从复杂的卫星图像中分析热带气旋的结构信息, 例如眼形和风墙等. 为了缓解这个问题, Velden 等人开发了客观的德沃夏克技术 (objective Dvorak technique, ODT)^[11], 但该方法不适用于热带低气压或弱热带气旋, 需要专家提供热带气旋中心位置. 此外, 为了估计每个热带气旋强度类别并消除人为主观性, 提出了先进的德沃夏克技术 (advanced Dvorak technique, ADT)^[12,13], 这是一种完全自动化的方法. 最新的 ADT 达到了甚至超过了相较于主观 Dvorak 方法的精度.

除了 Dvorak 方法之外, 还有一些其他方法, 例如偏差角方差技术 (DAVT)^[14,15]. 其原理是利用专家的经验根据卫星图像的云结构来估计热带气旋强度. 具体来讲是通过计算红外通道的亮温值的梯度来定量估算热带气旋云结构的对称程度. 通过构建热带气旋强度和结构之间的关系来估计强度. 但其会导致其准确率极大的依赖于热带气旋的中心定位信息. 此外, 当热带气旋结构信息不够明确 (如遭遇了较强的风切变) 时, 将会导致其结果极其不准确. 因此, 有些研究人员采用了美国国家飓风中心 (National Hurricane Center, NHC) 所提供的最佳路径集获取到中心定位信息作为标签, 使得这种偏差角方差技术的均方根误差下降了约 14%^[16,17].

1.3 深度学习方法

上述的一些方法大多需要大量的时间成本, 算力成本亦或是需要气象学家对于卫星云图处理的经验来估计热带气旋的强度. 近些年来, 步入了大数据时代, 人工智能 (artificial intelligence, AI) 随着算力的增强和数据的指数级增长而蓬勃发展, 越来越多的研究人员开始尝试使用数据驱动的深度学习方法来估计热带气旋强度^[18-27]. 一些研究人员根据卷积神经网络来拟合数据并取得了较好的效果^[18,19]. Chen 等人^[20]利用卷积神经网络并结合主动微波降水率和红外通道的亮温数

据, 在世界各大海域上的平均 RMSE 为 5.34 m/s. Zhang 等人^[21]通过将回归问题转化为分类问题并逐类别分析气旋强度, 最后再转为回归问题, 最终在西北太平洋海域上达到了 4.93 m/s 的 RMSE. Zhang 等人^[22]通过使用了双通道 (红外通道和水汽通道) 的数据设计了一个双分支的卷积神经网络来估计热带气旋的强度, 在西北太平洋海域达到了 5.13 m/s 的 RMSE. Xu 等人^[23]使用了 ResNet 作为主干网络, 采用图卷积神经网络来设计风级转换规则生成器作为先验知识, 进而注入神经网络中, 该方法在 GridSat 数据集上达到了 5.72 m/s 的 RMSE. Wang 等人^[24]选择了葵花-8 (Himawari-8) 中的 4 个通道, 并将其与卷积块注意力模块 (convolutional block attention module, CBAM)^[28]方法相结合, 验证了不同通道对卷积神经网络模型的重要性以及注意力机制的有效性, 在西北太平洋海域上测试的 RMSE 达到了可观的效果. Zhang 等人^[25]将密集连接方式应用于热带气旋强度估计中, 构建了 DenseConvMixer 模型. 此外, 他们还提出了一个时空编码器模块 (STE-TC) 来增强热带气旋图像的空间信息与时间信息. Zhuo 等人^[26]将气旋丰满意度这一概念引入到神经网络中, 并利用多任务学习来同时估计热带气旋的强度和尺度, 该方法在 GridSat 数据集上取得了较好的性能. Jiang 等人^[27]提出了一种深度多源注意力网络 (DMANet) 用于多光谱红外图像的动态建模. 模型通过将信息传递增强模块与局部全局模块相结合的方式, 在多个海域上的平均 RMSE 达到了 5.03 m/s.

2 气象数据及其预处理

本文主要针对西北太平洋海域的热带气旋研究, 葵花-8 提供模型的训练和测试数据, ERA-5 提供物理因子, CMA 最佳路径集提供标签集来指导模型训练.

2.1 葵花-8 (Himawari-8) 数据集及预处理

葵花-8 数据集是由日本气象厅收集并处理得到的, 覆盖了整个西北太平洋海域, 包含了中国、日本在内的东亚地区和西太平洋领域. 其具体范围为 90°E-180°E, 0°N-60°N. 时间分辨率为 1 h, 空间分辨率为 0.05°.

葵花-8 数据共包含了 16 个通道, 分别为 3 个可见光通道, 3 个近红外通道和 10 个红外通道. 每一个通道都有其对应的功能, 如检测冰雪 (1.6 μm), 检测土壤植被 (2.3 μm) 等. 本文根据其功能选取了对判断热带气

旋强度最相关的5个通道进行组合研究,所选取的通道分别是:3.9 μm 、6.2 μm 、10.4 μm 、12.3 μm 和13.3 μm 。

为了充分考虑热带气旋的云系特征本文选取以风眼为中心,大小范围为400×400的图片,各通道图像的可视化如图1所示。

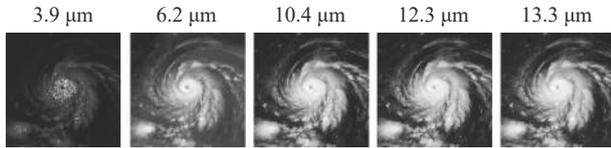


图1 各通道的卫星云图

2.2 ERA-5数据集及预处理

本文使用由欧洲中期天气预报中心(ECMWF)提供的第5代全球大气再分析(ECMWF Reanalysis v5, ERA-5)数据^[29]。该数据基于ECMWF综合预报系统(IFS)CY41R2中的4D-Var数据同化产生,时间范围为1979年至今,包含了多种气象再分析要素。

本文根据文献^[30]中选取了对热带气旋强度具有较强相关性的3个因子,分别是600 hPa的相对湿度(relative humidity, RH),200–850 hPa之间的垂直风切变(vertical wind shear, VWS)和海平面温度(sea surface temperature, SST)。数据类型为浮点类型数据,文件格式为NetCDF,原始空间分辨率为0.25°,时间分辨率为1h。

如图2为3个物理因子的可视化,从左至右分别是:600 hPa高度的相对湿度,200–850 hPa之间的垂直风切变和海平面温度。600 hPa的相对湿度和海平面温度均可以直接从因子集中提取,而200–850 hPa之间的垂直风切变需要通过计算得到。具体计算过程根据式(1)–式(3)所示。其中 $U_{200\text{hPa}}$ 和 $U_{850\text{hPa}}$ 分别表示200 hPa和850 hPa高度的U风(经线方向),而 $V_{200\text{hPa}}$ 和 $V_{850\text{hPa}}$ 分别表示200 hPa和850 hPa高度的V风(纬线方向)。

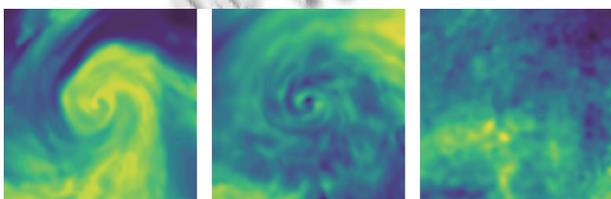


图2 ERA-5物理因子

$$U_{wind} = U_{200\text{hPa}} - U_{850\text{hPa}} \quad (1)$$

$$V_{wind} = V_{200\text{hPa}} - V_{850\text{hPa}} \quad (2)$$

$$VWS = \sqrt{U_{wind}^2 + V_{wind}^2} \quad (3)$$

2.3 CMA最佳路径集

中国气象局(China Meteorological Administration, CMA)的最佳路径集包含了自1949年以来西北太平洋海域上发生的热带气旋的基本信息,包含了发生时间,强度,中心经纬度,近中心最低气压以及最大持续风速等^[31,32]。其时间分辨率为6h,为了匹配葵花数据,本研究对CMA最佳路径集数据进行了逐小时的线性插值。

3 融合物理信息的热带气旋强度估计网络

本文提出了一种融合物理因子的热带气旋强度估计模型(physical factor fusion for tropical cyclone intensity estimation, PF-TCIE)。该模型通过将物理信息和云图特征融合入数据驱动的神经网络来辅助模型估计热带气旋的强度。整个模型分为两部分,如图3所示,分别是多通道物理因子融合模块(MPFM)和深度分类回归模块(CIsR)。考虑到热带气旋是一个复杂的灾害性系统,其形成与演化受多种物理因素的影响,仅依赖从卫星云图提取的热带气旋强度信息可能相对片面。因此,MPFM的独特之处在于它能够同时融合卫星云图和物理信息,充分利用两种来源的信息以提高模型的估计性能。MPFM主要包含两个分支,分别是多通道特征提取分支和物理信息提取分支,用于在提取多通道信息的同时融合强度相关的物理因子信息。此外,热带气旋强度类别之间存在着不平衡问题,弱气旋较多而强气旋较少。因此,CIsR根据这一点首先将回归问题转化为深度分类问题,然后根据统计信息设计了一个风尺度的权重矩阵,针对不同类别分配以不同权重,最终使得模型性能有所提高。

3.1 物理因子融合的多通道特征提取模块(MPFM)

物理因子融合的多通道云图特征提取模块(multi-channel cloud image extraction module for physical factors fusion module, MPFM)由多通道特征提取分支和物理信息提取分支组成。多通道的特征提取分支负责从多个不同波段的云系结构中提取强度信息,而物理信息提取分支则是分别提取垂直风切变,海平面温度和相对湿度的深层特征并将其作为约束以实现辅助模型估计气旋强度的功能。

多通道特征提取模块主要由CBAM^[28]、ResNet34^[4]和一些全连接层构成。CBAM模块的设计目的是从多通道的400×400大小的输入云图中提取浅层通道信息

和空间信息. 具体来说, 先根据通道注意力机制学习不同波长的通道对于强度估计的重要性, 然后利用空间注意力机制从每个通道提取与气旋强度高度相关的特征区域. ResNet34 作为热带气旋强度估计任务中常用的特征提取的骨干网络, 此处将其置于 CBAM 模块后, 其目的是先利用 CBAM 模块从原始的多通道卫星云图中提取到重要的浅层信息, 然后再利用 ResNet34 从浅层特征中进一步提取更深层的强度相关特征. 全连接层的初始阶段由 256 个节点构成, 其包含了模型从多通道卫星云图中提取到的强度相关信息. 通过与物

理信息提取模块提取到的物理特征拼接, 实现了云图特征与物理信息的融合.

物理信息提取模块主要由卷积层、池化层、批归一化层、全连接层和 Sigmoid 函数构成. 由于该分支任务难度相对较低, 且考虑到训练效率, 因此对于该分支的网络设计相对简单. 首先利用卷积神经网络分别从 3 个物理因子中提取到与气旋强度相关的高层特征, 然后将高层特征经过批归一化、激活函数等操作后展平成一维向量, 最后将该一维向量 (即物理信息特征) 通过拼接操作注入云系特征中.

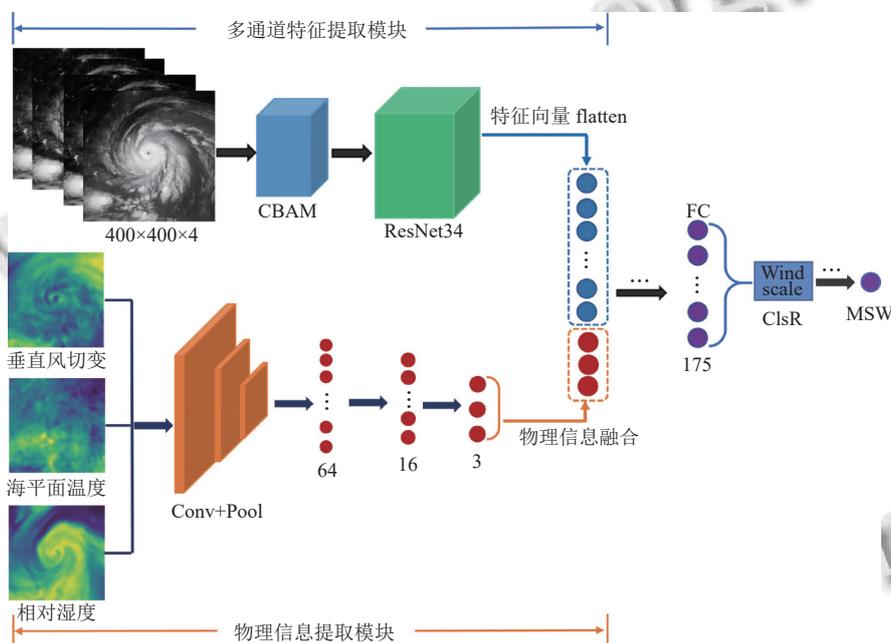


图 3 PF-TCIE 网络模型图

综上, 通过这种模型构造方式, 可以有效地利用物理信息来辅助模型从卫星云图中提取与强度相关的特征, 从而提升模型的强度估计性能.

3.2 深度细分类回归模块 (ClsR)

将特征提取器输出得到的深层特征输入到全连接层, 根据文献[22], 本文将全连接部分的回归问题转化为深度分类回归问题. 热带气旋在强度上存在着类别不均衡的问题^[33], 如表 1 所示, 将热带气旋根据最大持续风速分为 6 类, 分别是热带低压 (TD, 10.8–17.1 m/s), 热带风暴 (TS, 17.2–24.4 m/s), 强热带风暴 (STS, 24.5–32.6 m/s), 台风 (TY, 32.7–41.4 m/s), 强台风 (STY, 41.5–50.9 m/s), 超强台风 (SuperTY, 51 m/s 及以上). 可以发现 TY 和 TS 在西北太平洋海域总占比约 55% (表 1 中

加粗部分), 而 STY 和 SuperTY 则具有较少的占比. 本文将根据这一点设计 wind scale 矩阵来缓解热带气旋类别不平衡问题.

ClsR 的处理流程如图 4 所示, 首先将全连接得到的神经元经过 Softmax 函数将输出变为 0–1 之间的 logit 概率分布, 得到维度为 175 的向量, 该向量表示对于热带气旋强度细分类后得到的每一个类别的概率. 然后将该细分类的输出 logit 进行 Reshape 操作, 将 175×1 的向量扩张, 得到一个矩阵 V_p , 其形状为 $W \times 175$, 再与提前设计好的权重 wind scale 矩阵 V_w 相乘最终得到分配好权重的 $W \times 1$ 的向量, 这一步目的是通过构造好的权重矩阵, 重新为每一个类别分配权重来缓解强度类别不均现象.

表1 西北太平洋不同年份中不同热带气旋强度类别的气旋数量及占比

强度类别	2015年	2016年	2017年	2018年	2019年	2020年	2021年	2022年	总数(占比)
热带低压(TD)	471	897	878	1117	1382	750	837	780	7112(25.3%)
热带风暴(TS)	815	1023	1146	1214	1098	815	1202	896	8209(29.2%)
强热带风暴(STS)	509	450	475	602	732	419	508	417	4112(14.6%)
台风(TY)	681	364	564	529	489	356	232	353	3568(12.7%)
强台风(STY)	647	430	180	494	361	211	263	240	2826(10.1%)
超强台风(SuperTY)	440	306	66	489	295	124	334	186	2240(8.0%)
总数	3563	3470	3309	4445	4357	2675	3376	2872	28067(100%)

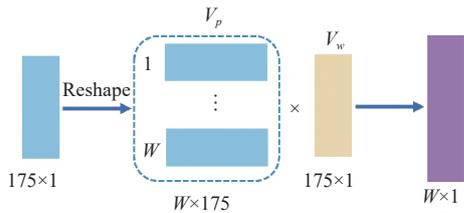


图4 ClsR 中矩阵操作流程

Wind scale 权重矩阵 V_w 如式(4)所示. 本研究中根据气旋强度的分类标准来制定的矩阵. 其中, α 和 β 分别为可调节的超参数, 在此处直接沿用文献[22]分别设置为 0.3 和 0.6. 将其分为类别不均匀的共 175 个强度等级, 其取值范围从 10.8 m/s 到 79.9 m/s.

$$V_w = [10.8, 10.8 + \alpha, 10.8 + 2\alpha, \dots, 17.1, 17.1 + \beta, 17.1 + 2\beta, 17.1 + 3\beta, \dots, 24.4, 24.4 + \alpha, 24.4 + 2\alpha, 24.4 + 3\alpha, \dots, 50.9, 50.9 + \beta, 50.9 + 2\beta, 50.9 + 3\beta, \dots, 79.9]^T \quad (4)$$

综上, 通过 ClsR 中将回归任务首先转为深度分类任务, 并根据统计信息设计的风尺度权重矩阵, 可以一定程度上缓解热带气旋类别不平衡所带来的模型性能下降问题.

3.3 算法流程

在训练阶段, 首先将红外通道 (3.9 μm 、6.2 μm 、10.4 μm 和 12.3 μm) 中的 4 个波段的卫星云图进行拼接 (concat) 操作并送入到多通道特征提取模块中, 然后分别通过 CBAM 中的通道注意力模块和空间注意力模块. 具体来说, 通道注意力模块部分的计算如式(5)所示, 首先将 $400 \times 400 \times 4$ 的特征图输入, 分别经过最大池化和平均值池化后, 通过 MLP 得到各自的特征, 最后经过 Sigmoid 激活函数得到最后的通道注意力的特征. 空间注意力模块部分的计算如式(6)所示, 首先将通道注意力模块所得到的特征 x 送入到该模块中, 然后对该特征分别在通道上进行最大池化和平均池化操作, 再将得到的两种特征进行拼接操作, 将拼接好的特

征输入到卷积层中, 在通道处降维, 最终将降维成 1 维通道的特征送入到激活函数 Sigmoid 中, 最终得到了空间注意力特征.

$$M_c(x) = \sigma(MLP(MaxPool(x)) + MLP(AvgPool(x))) \quad (5)$$

$$M_s(x) = \sigma(Conv^{7 \times 7}([MaxPool(x); AvgPool(x)])) \quad (6)$$

CBAM 模块的目的是让模型首先关注每个输入为 $400 \times 400 \times 4$ 的卫星云图的通道和空间信息, 通过这种算力较小的模型首先提取原图像中的重要信息. 然后再将提取到的浅层特征送入到 ResNet34 中进一步提取其更深层次的语义信息. 最后, 将深层特征经过自适应的平均池化层后展平成一维向量.

在物理信息提取模块中, 首先将 3 个物理因子输入到卷积神经网络中分别提取到与强度相关的信息, 将该类信息通过自适应的平均池化层首先展平为一维向量, 然后将其注入到刚得到的一维向量中, 使得原一维向量既包含卫星云图中的图像结构信息, 又包含与强度相关的物理信息. 最后经过全连接层和 Softmax 函数, 得到了 175 个关于气旋强度深度分类的神经元. 然后将其 Reshape 后乘以提前设定好的权重矩阵 (wind scale matrix), 得到参数权值变化后的一维向量. 最后将分类再转化为回归问题得到最终的热带气旋强度估计值. 该强度值将和标签中的强度值之间计算误差, 这里通过式(7)的损失来优化整体的网络模型参数. 其中, y_i 表示对应气旋的 CMA 最佳路径集中的标签, x_i 表示卫星云图的输入, 而 $f(x_i)$ 表示模型关于输入的拟合结果.

$$loss = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2} \quad (7)$$

4 实验

4.1 实验设置

本文利用葵花-8 数据集, ERA-5 物理因子数据集

作为模型的输入, CMA 最佳路径集作为标签集来指导模型的训练. 训练集为 2015–2020 年, 测试数据集为 2021–2022 年. 本研究是在 NVIDIA GeForce RTX 3090 服务器上进行的, 其 batch size 设置为 32, 模型所使用的为 Adam 优化器和 PyTorch 3.7 框架, 设置的初始学习率为 0.001. 所使用的损失函数为 RMSE 函数, 评价标准为均方根误差 RMSE, 平均绝对误差 MAE 以及估计值与真值之间的偏差 Bias.

4.2 消融实验

本研究中设置了 3 组消融实验, 一组是验证不同通道组合的重要性; 另一组是研究了不同 ERA-5 的因子组合对模型的影响; 最后, 将探究引入 ClsR 模块对模型性能的影响.

不同波段的辐射为云层结构、气旋特征等提供多样化信息, 影响卫星云图在气旋强度估计的准确度. 若从 5 个波段中随机组合进行模型训练, 可产生近百种不同的组合. 为了系统化训练过程, 本文采用了一种逐步递归的训练策略. 初始阶段, 从 5 个波段中选出 1 个起始波段, 然后基于此逐步扩展其他组合. 通过将单波段的卫星云图输入同一模型并进行测试, 如表 2 所示, 单通道下 12.3 μm 波段的 RMSE 最优, 相比于 3.9 μm 提升了 9.5%. 因此将 12.3 μm 作为起点逐步构建模型进行强度估计最合适.

表 2 单一波段下性能对比

葵花-8通道(波长)	模型	RMSE (m/s)
7 (3.9 μm)	M1	6.12
8 (6.2 μm)	M2	5.89
13 (10.4 μm)	M3	5.62
15 (12.3 μm)	M4	5.59
16 (13.3 μm)	M5	5.72

然而, 红外波段虽然对热带气旋的强度估计起到了主要作用, 但水汽波段和短波红外波段对于判断热带气旋的强度也起到至关重要的作用. 如水汽通道和红外通道的亮温差可以指示对流现象的存在^[34], 短波红外通道接收了一部分长波红外和太阳辐射, 增强了热力特征观测. 这些特征都是强度估计的重要线索, 因此对于水汽和短波红外通道的选取组合尤为重要.

表 3 中采用递归方式来测试所选的 5 个通道的组合. 值得注意的是, 如模型 M9 所示, 当 13.3 μm 波段与 12.3 μm 波段结合时, 模型精度没有提升. 因此, 在之后的研究中, 13.3 μm 波段被排除在外. 经过一系列实验验证, 结合 3.9 μm 、6.2 μm 、10.4 μm 和 12.3 μm 这

4 个通道的卫星云图, 可以取得模型性能的最优效果, 相比于单通道 12.3 μm 提升了 3.7%.

表 3 多通道组合性能对比

葵花-8通道	模型	RMSE (m/s)
3.9 μm , 12.3 μm	M6	5.82
6.2 μm , 12.3 μm	M7	5.77
10.4 μm , 12.3 μm	M8	5.52
12.3 μm , 13.3 μm	M9	5.61
3.9 μm , 10.4 μm , 12.3 μm	M10	5.44
6.2 μm , 10.4 μm , 12.3 μm	M11	5.49
3.9 μm 6.2 μm , 10.4 μm , 12.3 μm	M12	5.38

第 2 组消融实验是在选择的模型 M12 的基础上继续添加物理信息, 对比不同的 ERA-5 组合对模型性能的影响. 表 4 展示了对不同物理因子消融后, 测试得到的对应 RMSE. 如 M13、M14、M15 所示, 通过 3 个因子作为辅助信息可以使未添加物理信息的神经网络的性能有所提升. 可以发现添加 SST 对模型性能的提升最大, 相比于不引入任何因子提升了 3.1%, 而只引入 *VWS* 的提升最小. 可以得到结论: 引入 SST 对于模型估计热带气旋强度的辅助效果最显著, 而引入 *VWS* 所带来的收益最小. M16–M18 是在给定的 3 个因子中任选两个并组合得到的模型, 可以发现引入 SST 和 RH_600hPa 这两个因子后的提升最明显, 其相比于仅引入单因子的 M13–M15 模型有大幅提升. 因此继续考虑将 3 个因子全部作为辅助信息来辅助 M12 估计热带气旋强度. M19 为同时引入 3 个因子后的模型, 其 RMSE 达到了 4.96 m/s. 可以发现, 相比于不引入任何因子, 性能提升了 8.5%.

表 4 引入不同 ERA-5 因子的 RMSE

模型	SST	RH_600hPa	<i>VWS</i>	RMSE (m/s)
M13	√	—	—	5.22
M14	—	√	—	5.29
M15	—	—	√	5.36
M16	√	√	—	5.08
M17	—	√	√	5.17
M18	√	—	√	5.03
M19	√	√	√	4.96
M20 (with ClsR)	√	√	√	4.83

最后, 表 4 中的 M20 表示在 M19 的基础上使用 ClsR 模块后的整体性能, 相比于不引入该模块性能提升了 2.7%.

4.3 性能比较

为了验证 PF-TCIE 模型的性能, 将其与不同方法进行了对比, 如表 5 所示.

表5 PF-TCIE模型与其他方法的性能对比

方法	数据	RMSE (m/s)	MAE (m/s)	参考文献
DAVT	红外	—	6-7.7	[14,15]
WIRa-based	红外, 水汽	-9	-6.4	[30]
Deep-CNN	红外	5.8	—	[18]
CNN-TC	红外, 微波	5.34	—	[20]
DeepMicroNet	MINT	5.45	—	[35]
CNN-based hybrid	红外	4.89	3.97	[19]
DMANet	红外	4.96	3.89	[27]
TCIENet	红外, 水汽	5.13	4.03	[22]
PF-TCIE (ours)	红外, 水汽	4.83	3.94	本文

相比于统计方法如偏角方差技术 DAVT, 深度学习方法要远优于此类方法. 此外, 由于 WIRa-based 技术是以最低海平面气压作为强度估计的指标, 因此本研究中根据联合台风预警中心 (Joint Typhoon Warning Center, JTWC) 所提出的风-压转换公式^[36], 将最低海平面气压转为了最大持续风速并进行比较, 其 RMSE 和 MAE 分别约为 9 m/s 和 6.4 m/s. 实验所用的大多为红外通道数据, 其中 DeepMicroNet 方法使用 NRLTC (MINT) 的微波图像来进行学习, 本文则采用红外和水汽通道进行训练和测试. PF-TCIE 相比于不引入物理信息的方法如 Deep-CNN、CNN-TC、DMANet、DeepMicroNet 和 CNN-based hybrid 方法取得了更优的性能. 说明物理信息能够作为约束, 帮助网络学习热带气旋特征, 提高其强度估计性能.

4.4 误差分析

为了更方便地分析不同类别下的误差, 表6展示了不同指标下各强度类别的误差分布. 指标包括模型的 RMSE、MAE、Bias、高估样本量及其占总样本量的比例. 从结果中可以发现, 模型在 TD 和 TS 类别下的估计较为准确, 具有较低的 RMSE 和 MAE.

表6 不同热带气旋强度类别下的误差分布统计

强度类别	样本量	RMSE (m/s)	MAE (m/s)	Bias (m/s)	高估样本量
TD	1617	3.31	2.52	-0.91	737 (45.6%)
TS	2098	3.42	3.56	0.21	1336 (63.7%)
STS	925	5.06	4.23	0.22	472 (51%)
TY	585	5.18	4.86	-0.72	316 (54%)
STY	503	5.87	5.24	-3.15	220 (43.7%)
SuperTY	520	6.27	3.19	-2.17	130 (25%)
总计	6248	4.83	3.94	-0.597	3211 (51.4%)

如图5为模型估计结果和 CMA 的最佳路径集标签之间的对比. 图5中黑线为 $y=x$ 的直线, 散点表示真值与估计值之间的坐标, 散点越接近于直线说明拟合效果越好. 图5中左上角为拟合的直线和相关系数 R

(取值范围为 0-1), 可以发现斜率为 1.06 接近于 1, 且相关系数为 0.91, 证明模型关于强度的拟合程度较好.

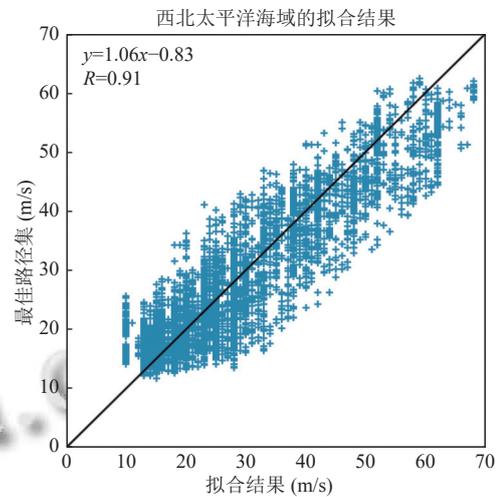


图5 模型估计值与最佳路径集之间的拟合关系

此外, 本研究根据 CMA 强度分类标准, 各个强度类别绝对误差的箱线图分布如图6所示. 绝对误差的计算是将每一个卫星云图的模型输出结果和真值之间做差的绝对值. 从图6中可以看出随着台风强度类别的提高, 绝对误差的中位数 (横线部分) 也随之增加, TD 和 TS 具有较小的中位数和较小的绝对误差分布, 说明模型对于 TD 和 TS 的强度类别的估计能力较好, 而这两个类别的数量约占总气旋类别的 55%. 中位数最大的是 STY 和 SuperTY, 其中 STY 有着最大的绝对误差分布范围, 说明模型对于该气旋类别的强度估计能力较差. 此外, 图6中在箱线图之外的独立的灰色散点表示不同强度类别的台风在绝对误差值上的异常值, 这说明在某些特定的台风类别中, 存在着一些绝对误差值偏离了正常的预期值.

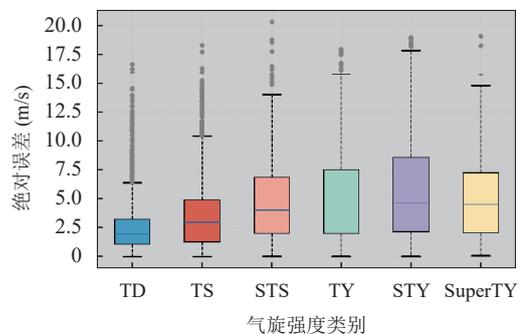


图6 不同强度类别的绝对误差箱线图分布

图7展示了不同气旋强度类别的偏差分布的提琴图. 提琴图同时结合了箱线图和核密度图的特点, 不仅

反映了纵坐标的值的范围,也反映了纵坐标值的分布情况.从图7中可以看出大多数强度值均处于0 m/s附近,STS、TY和STY类别的数据分布偏差范围较广,表明在这些类别中估计的变异性较大.而TD、TS、SuperTY类别的分布较窄,说明模型关于这几个类别的系统偏差更小一些,估计能力相对较好.

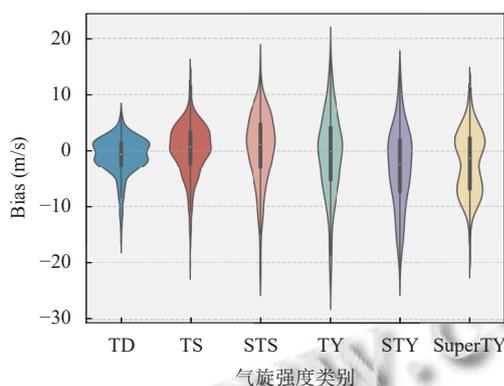


图7 不同强度类别的Bias分布提琴图

5 结论

本文主要针对西北太平洋海域的热带气旋强度估计,通过物理信息和深度学习网络相融合的方式来提升模型对于热带气旋强度估计的能力.最终根据实验得到结论.1)选取3.9 μm 、6.2 μm 、10.4 μm 和12.3 μm 这4个波段可以有效提升模型估计热带气旋的能力,相比于单通道性能提升了约3.7%.2)随着海平面温度,200–850 hPa之间的垂直风切变和600 hPa的相对湿度这3个物理因子的同时引入,模型性能相比于不引入物理因子时有8.5%的提升,说明物理因子的引入可以有效辅助深度学习模型拟合复杂的热带气旋系统.通过一系列实验结果的可视化分析了不同类别的误差分布.实验结果表明该方法可以有效地估计西北太平洋海域的热带气旋强度,误差仅为4.83 m/s.

参考文献

- 1 Woo WC, Wong WK. Operational application of optical flow techniques to radar-based rainfall nowcasting. *Atmosphere*, 2017, 8(3): 48. [doi: 10.3390/atmos8030048]
- 2 Wang Y, Wu CC. Current understanding of tropical cyclone structure and intensity changes—A review. *Meteorology and Atmospheric Physics*, 2004, 87(4): 257–278. [doi: 10.1007/s00703-003-0055-6]
- 3 Zhuge XY, Guan J, Yu F, *et al.* A new satellite-based indicator for estimation of the western North Pacific tropical cyclone current intensity. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(10): 5661–5676. [doi: 10.1109/TGRS.2015.2427035]
- 4 He KM, Zhang XY, Ren SQ, *et al.* Deep residual learning for image recognition. *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016. 770–778.
- 5 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *Proceedings of the 3rd International Conference on Learning Representations*. San Diego: ICLR, 2015.
- 6 Vaswani A, Shazeer N, Parmar N, *et al.* Attention is all you need. *Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach: ACM, 2017. 6000–6010.
- 7 Molinari J, Vollaro D, Robasky F. Use of ECMWF operational analyses for studies of the tropical cyclone environment. *Meteorology and Atmospheric Physics*, 1992, 47(2): 127–144.
- 8 Tallapragada V, Bernardet L, Biswas MK, *et al.* Hurricane weather research and forecasting (HWRF) model: 2013 scientific documentation. Technical Report, Developmental Testbed Center, 2014.
- 9 Dvorak VF. A technique for the analysis and forecasting of tropical cyclone intensities from satellite pictures. NOAA Technical Memorandum NESS, 1973.
- 10 Dvorak VF. Tropical cyclone intensity analysis and forecasting from satellite imagery. *Monthly Weather Review*, 1975, 103(5): 420–430. [doi: 10.1175/1520-0493(1975)103<0420:TCIAAF>2.0.CO;2]
- 11 Velden CS, Olander TL, Zehr RM. Development of an objective scheme to estimate tropical cyclone intensity from digital geostationary satellite infrared imagery. *Weather and Forecasting*, 1998, 13(1): 172–186. [doi: 10.1175/1520-0434(1998)013<0172:DOAOST>2.0.CO;2]
- 12 Olander TL, Velden CS. The advanced Dvorak technique: Continued development of an objective scheme to estimate tropical cyclone intensity using geostationary infrared satellite imagery. *Weather and Forecasting*, 2007, 22(2): 287–298. [doi: 10.1175/WAF975.1]
- 13 Olander TL, Velden CS. The advanced Dvorak technique (ADT) for estimating tropical cyclone intensity: Update and new capabilities. *Weather and Forecasting*, 2019, 34(4): 905–922. [doi: 10.1175/WAF-D-19-0007.1]
- 14 Piñeros MF, Ritchie EA, Tyo JS. Estimating tropical cyclone intensity from infrared image data. *Weather and Forecasting*, 2011, 26(5): 690–698. [doi: 10.1175/WAF-D-10-05062.1]
- 15 Piñeros MF, Ritchie EA, Tyo JS. Objective measures of tropical cyclone structure and intensity change from remotely sensed infrared image data. *IEEE Transactions on*

- Geoscience and Remote sensing, 2008, 46(11): 3574–3580. [doi: [10.1109/TGRS.2008.2000819](https://doi.org/10.1109/TGRS.2008.2000819)]
- 16 Ritchie EA, Valliere-Kelley G, Piñeros MF, *et al.* Tropical cyclone intensity estimation in the North Atlantic basin using an improved deviation angle variance technique. *Weather and Forecasting*, 2012, 27(5): 1264–1277. [doi: [10.1175/WAF-D-11-00156.1](https://doi.org/10.1175/WAF-D-11-00156.1)]
- 17 Ritchie EA, Wood KM, Rodríguez-Herrera OG, *et al.* Satellite-derived tropical cyclone intensity in the North Pacific Ocean using the deviation-angle variance technique. *Weather and Forecasting*, 2014, 29(3): 505–516. [doi: [10.1175/WAF-D-13-00133.1](https://doi.org/10.1175/WAF-D-13-00133.1)]
- 18 Pradhan R, Aygun RS, Maskey M, *et al.* Tropical cyclone intensity estimation using a deep convolutional neural network. *IEEE Transactions on Image Processing*, 2018, 27(2): 692–702. [doi: [10.1109/TIP.2017.2766358](https://doi.org/10.1109/TIP.2017.2766358)]
- 19 Tian W, Huang W, Yi L, *et al.* A CNN-based hybrid model for tropical cyclone intensity estimation in meteorological industry. *IEEE Access*, 2020, 8: 59158–59168. [doi: [10.1109/ACCESS.2020.2982772](https://doi.org/10.1109/ACCESS.2020.2982772)]
- 20 Chen BF, Chen B, Lin HT, *et al.* Estimating tropical cyclone intensity by satellite imagery utilizing convolutional neural networks. *Weather and Forecasting*, 2019, 34(2): 447–465. [doi: [10.1175/WAF-D-18-0136.1](https://doi.org/10.1175/WAF-D-18-0136.1)]
- 21 Zhang CJ, Wang XJ, Ma LM, *et al.* Tropical cyclone intensity classification and estimation using infrared satellite images with deep learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 2070–2086. [doi: [10.1109/JSTARS.2021.3050767](https://doi.org/10.1109/JSTARS.2021.3050767)]
- 22 Zhang R, Liu QS, Hang RL. Tropical cyclone intensity estimation using two-branch convolutional neural network from infrared and water vapor images. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(1): 586–597. [doi: [10.1109/TGRS.2019.2938204](https://doi.org/10.1109/TGRS.2019.2938204)]
- 23 Xu GN, Li Y, Ma C, *et al.* TFG-Net: Tropical cyclone intensity estimation from a fine-grained perspective with the graph convolution neural network. *Engineering Applications of Artificial Intelligence*, 2023, 118: 105673. [doi: [10.1016/j.engappai.2022.105673](https://doi.org/10.1016/j.engappai.2022.105673)]
- 24 Wang C, Zheng G, Li XF, *et al.* Tropical cyclone intensity estimation from geostationary satellite imagery using deep convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 4101416.
- 25 Zhang Z, Yang XY, Wang X, *et al.* A neural network with spatiotemporal encoding module for tropical cyclone intensity estimation from infrared satellite image. *Knowledge-based Systems*, 2022, 258: 110005. [doi: [10.1016/j.knsys.2022.110005](https://doi.org/10.1016/j.knsys.2022.110005)]
- 26 Zhuo JY, Tan ZM. Physics-augmented deep learning to improve tropical cyclone intensity and size estimation from satellite imagery. *Monthly Weather Review*, 2021, 149(7): 2097–2113.
- 27 Jiang WJ, Hu G, Wu TT, *et al.* DMANet_KF: Tropical cyclone intensity estimation based on deep learning and Kalman filter from multispectral infrared images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 4469–4483. [doi: [10.1109/JSTARS.2023.3273232](https://doi.org/10.1109/JSTARS.2023.3273232)]
- 28 Woo S, Park J, Lee JY, *et al.* CBAM: Convolutional block attention module. *Proceedings of the 15th European Conference on Computer Vision (ECCV)*. Munich: Springer, 2018. 3–19.
- 29 Hersbach H, Bell B, Berrisford P, *et al.* The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 2020, 146(730): 1999–2049. [doi: [10.1002/qj.3803](https://doi.org/10.1002/qj.3803)]
- 30 Bhatia K, Baker A, Yang WC, *et al.* A potential explanation for the global increase in tropical cyclone rapid intensification. *Nature Communications*, 2022, 13(1): 6626. [doi: [10.1038/s41467-022-34321-6](https://doi.org/10.1038/s41467-022-34321-6)]
- 31 Ying M, Zhang W, Yu H, *et al.* An overview of the China meteorological administration tropical cyclone database. *Journal of Atmospheric and Oceanic Technology*, 2014, 31(2): 287–301. [doi: [10.1175/JTECH-D-12-00119.1](https://doi.org/10.1175/JTECH-D-12-00119.1)]
- 32 Lu XQ, Yu H, Ying M, *et al.* Western North Pacific tropical cyclone database created by the China Meteorological Administration. *Advances in Atmospheric Sciences*, 2021, 38(4): 690–699. [doi: [10.1007/s00376-020-02111-7](https://doi.org/10.1007/s00376-020-02111-7)]
- 33 Zhou YC, Zhan RF, Wang YQ, *et al.* Characteristics and controlling factors of rapid weakening of tropical cyclones after reaching their intensity peaks over the western North Pacific. *Journal of Geophysical Research: Atmospheres*, 2022, 127(21): e2022JD036697. [doi: [10.1029/2022JD036697](https://doi.org/10.1029/2022JD036697)]
- 34 Olander TL, Velden CS. Tropical cyclone convection and intensity analysis using differenced infrared and water vapor imagery. *Weather and Forecasting*, 2009, 24(6): 1558–1572. [doi: [10.1175/2009WAF2222284.1](https://doi.org/10.1175/2009WAF2222284.1)]
- 35 Wimmers A, Velden C, Cossuth JH. Using deep learning to estimate tropical cyclone intensity from satellite passive microwave imagery. *Monthly Weather Review*, 2019, 147(6): 2261–2282. [doi: [10.1175/MWR-D-18-0391.1](https://doi.org/10.1175/MWR-D-18-0391.1)]
- 36 Atkinson GD, Holliday CR. Tropical cyclone minimum sea level pressure/maximum sustained wind relationship for the western North Pacific. *Monthly Weather Review*, 1977, 105(4): 421–427. [doi: [10.1175/1520-0493\(1977\)105<0421:TCMSLP>2.0.CO;2](https://doi.org/10.1175/1520-0493(1977)105<0421:TCMSLP>2.0.CO;2)]

(校对责编: 张重毅)