

doi:10.11676/qxxb2025.20240233

STDA-Net: 基于时空特征融合和双重注意力交互网络的热带气旋强度估计*

郑小妹¹ 方巍^{1,2,3,4} 付海燕¹ 万仕全⁵ 丁从慧⁶

ZHENG Xiaomei¹ FANG Wei^{1,2,3,4} FU Haiyan¹ WAN Shiquan⁵ DING Conghui⁶

1.南京信息工程大学计算机学院, 南京, 210044

2.中国气象局流域强降水重点开放实验室/暴雨监测预警湖北省重点实验室 中国气象局武汉暴雨研究所, 武汉, 430205

3.中国气象科学研究院灾害天气国家重点实验室, 北京, 100081

4.南京信息工程大学江苏省大气环境与装备技术协同创新中心, 南京, 210044

5.扬州市气象局, 扬州, 225012

6.安徽省气象台, 合肥, 230031

1. School of Computer Science, Nanjing University of Information Science and Technology, Nanjing 210044, China

2. China Meteorological Administration Basin Heavy Rainfall Key Laboratory/Hubei Key Laboratory for Heavy Rain Monitoring and Warning Research, Institute of Heavy Rain, China Meteorological Administration, Wuhan 430205, China

3. State Key Laboratory of Disaster Weather, Chinese Academy of Meteorological Sciences, Beijing 100081, China

4. Jiangsu Collaborative Innovation Center of Atmospheric Environment and Equipment Technology (CICAET), Nanjing University of Information Science and Technology, Nanjing 210044, China

5. Yangzhou Meteorological Bureau, Yangzhou 225012, China

6. Anhui Meteorological Observatory, Hefei 230031, China

2024-12-30 收稿, 2025-04-11 改回

郑小妹, 方巍, 付海燕, 万仕全, 丁从慧. 2025. STDA-Net: 基于时空特征融合和双重注意力交互网络的热带气旋强度估计. 气象学报, X (X):

Zheng Xiaomei, Fang Wei, Fu Haiyan, Wan Shiquan, Ding Conghui. 2025. STDA-Net: Tropical Cyclone Intensity Estimation Based on Spatiotemporal Feature Fusion and Dual Attention Interaction Network. *Acta Meteorologica Sinica*, X (X):

Abstract Tropical cyclone intensity estimation is of great practical significance for disaster prevention and mitigation. However, the existing methods still have some limitations in estimation accuracy, spatiotemporal information utilisation and channel feature extraction capability. In order to solve the above problems, a novel tropical cyclone intensity estimation model, STDA-Net, based on spatiotemporal feature fusion and dual attention interactive networks, is proposed, with the Northwest Pacific Ocean

*资助课题:国家自然科学基金面上项目(No.42475149、No.42375056)、中国气象局流域强降水重点开放实验室开放研究基金(No.2023BHR-Y14)、灾害天气国家重点实验室开放课题(2024LASW-B19)。

作者简介:郑小妹, 主要从事热带气旋强度估计与预报研究。E-mail:2081647565@qq.com

通信作者:方巍, 主要从事气象领域中的人工智能方法研究。E-mail: fangwei@nuist.edu.cn

serving as the study area. The model consists of three core modules: The spatial feature extraction module is used to capture the spatial characteristics of tropical cyclones; the temporal feature extraction module aims at extracting the temporal characteristics of its changing process; and the spatial-channel interaction module enhances the extraction of vital information by interacting spatial and channel attention. The experimental findings reveal that STDA-Net outperforms the other deep learning methods compared in estimating the intensity of tropical cyclones in the Northwest Pacific Ocean, achieving RMSE and MAE of 9.42 knots and 7.22 knots, respectively, and exhibiting robust estimation performance for multiple tropical cyclone events from 2019 to 2021. It is shown that STDA-Net performs well in estimating the intensity of tropical cyclones in the Northwest Pacific, confirming its accuracy and superiority.

Key words Tropical cyclone, Intensity estimation, Spatiotemporal feature fusion, Dual attention interaction, Channel features

摘要 **[目的]**热带气旋强度估计对于防灾减灾具有重要的现实意义，然而现有方法在估计精度、时空信息利用率及通道特征提取能力方面仍存在一定的局限。**[资料和方法]**为解决上述问题，以西北太平洋为研究海域，提出了一种新颖的基于时空特征融合和双重注意力交互网络的热带气旋强度估计模型—STDA-Net。该模型由三个核心模块构成：空间特征提取模块用于捕捉热带气旋的空间特性；时间特征提取模块旨在提取其变化过程中的时间特征；空间-通道交互模块则通过交互空间和通道注意力来增强对关键信息的提取。**[结果]**实验结果表明，STDA-Net 在估计西北太平洋热带气旋强度方面的表现均优于对比的其他深度学习方法，达到了 9.42 knots 的 RMSE 值和 7.22 knots 的 MAE 值，并在 2019—2021 年多个热带气旋事件中表现出较强的估计性能。**[结论]**从而表明 STDA-Net 在估计西北太平洋热带气旋强度任务中性能良好，证实了其准确性和优越性。

关键词 热带气旋，强度估计，时空特征融合，双重注意力交互，通道特征

中图分类号 P458.1+24

1 引言

[研究的意义]热带气旋是世界上危害性最强的天气灾害之一（Zhong, et al, 2020），多产生于夏秋季节的热带海域中，而临近我国的西北太平洋是世界上热带气旋活动最频繁的海域之一，每年夏秋季节，即热带气旋的高发季节，中国的沿海地区常受西北太平洋热带气旋登陆影响严重。当热带气旋的强度不断增强，其登陆时常引发洪涝、暴雨、风暴潮等次生灾害，对人们的生命和财产安全造成威胁，并在一定程度上严重影响了社会的经济发展。2019 年，第 9 号台风“利奇马”以其强大的登陆强度和广泛的影响范围，造成了约 50.19 亿元人民币的直接经济损失（顾小丽, et al, 2022）。在 2023 年，5 号台风“杜苏芮”的登陆给华北地区带来大范围的强降水（冯亮, 2023；向纯怡, et al, 2024），并引发了较为严重的灾情。热带气旋的强度按照热带气旋中心最大持续风速情况，依据中国气象局规定的热带气旋等级划分标准，具体可分为如表 1 所示的六类等级，不同等级的热带气旋卫星云图示例如图 1 所示。随着热带气旋强度的逐渐增强，其造成的危害程度亦随之加剧，对社会的影响范围亦愈发广泛。当前的业务系统及研究方法对于热带气旋的强度预报仍存在误差较大且进步缓慢的问题，而定强不准是其中的重要原因之一，提高热带气旋强度确定的准确率可为强度预报业务提供可靠的技术支持。因此，精准估计热带气旋强度大小，及时准确地确定热带气旋强度情况，从而掌握热带气旋强度的动态变化，对于气象预警的发布以及防灾减灾工作的有效实施具有举足轻重的意义。

[前人研究进展] 由于热带气旋通常生成于开阔的洋面上，陆上观测设备难以获取其生长过程中的完整信息。随着遥感技术的发展，气象卫星探测到的高分辨率卫星图像为热带气旋强度的研究提供了可靠的分析资料，卫星云图资料可获取到热带气旋发生、发展、成熟、消亡过程中的多种特征，业务人员可从包含红外、水汽、可见光等通道的卫星云图中估计出热带气旋的强度（Song, et al, 2024; 杨梦琪, et al, 2024）。为了准确地估计出热带气旋的强度，相关领域的研究人员已经进行了大量的研究试验，并提出了多种可行方法，Dvorak（Dvorak, 1975; Lee, et al, 2021; Olander, et al, 2021）方法是目前应用最广泛的强度估计方法之一。Dvorak 方法通过主观识别彩色增强红外图像中的中心和带状云特征（周冠博, et al, 2022），基于热带气旋强度与识别到的卫星云图特征之间的统计关系对热带气旋强度进行估计。Dvorak 方法认为，强度相近的热带气旋通常具有相似的云特征，由于该方法通过人为识别云图特征，因而对业务人员的专业知识依赖程度较高，在估计结果上存在较大的主观性。为了降低 Dvorak 方法的主观性，一些基于 Dvorak 方法衍生出的强度估计技术也被相继提出。ADT（Advanced Dvorak Technique）（Olander, et al, 2019; Ahmed, et al, 2021）引入了线性回归的计算方式，结合机器学习和图像处理技术，自动提取和分析云图特征，减少了人工操作带来的随机性，但同时也受到卫星云图质量和分析算法准确性的限制，无法实现对云图特征的深层提取，从而导致强度估计准确性受限。为了更进一步地挖掘卫星云图中热带气旋的形状和结构等特征，Piñeros 等（2011）提出了 DAT（Deviation Angle Variance Technique）（Tian, et al, 2023）方法，通过分析热带气旋卫星云图的对称结构对其进行强度估计。以 Dvorak 方法为代表的基于统计分析的热带气旋强度估计方法很大程度上依赖于人工对云图特征的提取，受制于业务人员的经验和专业水平，并且难以捕捉到卫星云图的深层特征，为估计结果准确性和可靠性带来了挑战。

表 1 中国气象局热带气旋等级划分详情

Table 1 Details of tropical cyclone classification by China Meteorological Administration

等级	英文缩写	底层中心附近最大风力 (m/s)	所属等级
热带低压	TD	10.8—17.1	6—7 级
热带风暴	TS	17.2—24.4	8—9 级
强热带风暴	STS	24.5—32.6	10—11 级
台风	TY	32.7—41.4	12—13 级
强台风	STY	41.5—50.9	14—15 级
超强台风	SuperTY	≥51.0	≥16 级

随着研究的推进，深度学习凭借着自身高效的特征提取和数据处理能力逐渐被尝试应用于气象研究中，为热带气旋强度估计提供了新的研究思路。在基于深度学习的热带气旋强度估计方法中，卷积神经网络（Convolutional Neural Networks, CNN）凭借自身强大的特征提取能力，被广泛应用于提取热带气旋卫星云图空间特征。Pradhan 等（2017）提出了一种基于 CNN 的热带气旋强度估计模型，利用卷积层自动提取云图空间特征，显著提高了强度估计准确率，展示了深度学习在热带气旋强度估计中的潜力。Chen 等（2019）同样基于 CNN 提出了一种热带气旋强度估计模型，利用红外和被动微波数据，显著提高了估计精度。Zhang 等（2021）提出了一种基于红外卫星图像和深度卷积神经网络的热带气旋强度估计方法，通过使用不同的红外通道和最佳轨迹数据，模型在不同强

度类别的估计任务上均表现出色。Wang 等（2021）同样基于深度卷积神经网络设计了一组强度估计模型，用于从静止卫星图像中估计西北太平洋地区热带气旋的强度，通过比较不同红外通道的组合，发现多通道数据输入能显著提高估计精度。对热带气旋时间信息的挖掘及通道特征的充分提取对于提升估计精度至关重要，在挖掘热带气旋时间相关性方面，Zhang 等（2024）提出了基于时空交互注意力模型的热带气旋强度估计方法，通过时空交互模块提取时间和空间特征，显著提升了热带气旋强度估计的精度，然而其在处理输入数据通道上缺乏对通道信息的有效挖掘。对于通道特征的提取而言，Ma 等（2024）和 Tan 等（2022）关注了数据的通道信息，分别在估计模型中设计了通道注意力机制，有效提高了模型的性能，但其缺乏对热带气旋时间信息的利用，估计结果准确性仍有提升的空间。




图 1 不同等级热带气旋卫星云图示例图（子图(a)、(b)、(c)、(d)、(e)和(f)分别是等级为 TD、TS、STS、TY、STY 和 SuperTY 的热带气旋卫星云图的示例）

Fig. 1 Examples satellite images of tropical cyclones of different categories (Subfigure (a), (b), (c), (d), (e) and (f) are examples satellite imagery for tropical cyclones of intensities TD, TS, STS, TY, STY and SuperTY, respectively)

[本研究切入点]目前，深度学习在热带气旋强度估计领域已取得了显著进展，但现有的大部分深度学习方法依赖于 CNN 网络对热带气旋强度进行估计。基于 CNN 的估计方法虽然能够有效地提取到热带气旋的空间特征，却忽略了热带气旋随时间变化过程中的特征信息，对其时间特征的挖掘程度仍然不足，从而导致模型训练过程中时间信息的缺失。此外，由于热带气旋云图数据通常包含多个通道，要精准估计热带气旋的强度，需要分析不同通道间特征信息与强度变化之间的相关性，目前的方法模型对通道特征的提取尚不充分，在一定程度上限制了估计结果的准确性。

[拟解决的关键问题]针对现有热带气旋强度估计方法中存在的对时间特征和通道特征挖掘不充分的问题，本文提出了一种新颖的热带气旋强度估计方法，即 STDA-Net（Spatiotemporal feature fusion and Dual Attention interaction Network）。STDA-Net 以多帧热带气旋卫星云图作为输入，主要包含空间特征提取模块（Spatial Feature Extraction, SFE）、时间特征提取模块（Spatial Feature Extraction, TFE）和空间-通道交互模块（Spatial-Channel Interaction, SCI）三个模块。SFE 利用全局空间特征提取块和 ResNet 提取输入图像序列最后一帧图像，即模型当前所要估计的气旋对象的空间特征；TFE 分别对输入图像序列的时间信息进行全局特征提取和细粒度特征提取，通过时间注

注意力机制捕捉当前估计气旋在随时间变化过程中的时间演变规律；最后将提取到的时空特征进行融合，通过 SCI 模块中所设计的时间注意力机制与通道注意力机制的交互，实现时空融合特征在空间和通道维度上的深度提取与融合。为验证所提出模型的性能，本文以西北太平洋热带气旋为强度估计对象，基于 IBTrACS 和 GridSat-B1 资料构造数据集，探讨了 STDA-Net 在热带气旋强度估计任务中的可行性和准确性。

2 研究方法

STDA-Net 模型主要由空间特征提取模块（SFE）、时间特征提取模块（TFE）和空间-通道交互模块（SCI）三个核心部分构成。这三个模块的有机结合使得 STDA-Net 能够从多个维度对热带气旋图像特征进行全面且深入的挖掘，从而在强度估计任务中展现出卓越的性能。

2.1 STDA-Net 结构

STDA-Net 的模型结构如图 2 所示。空间特征提取模块 SFE 提取当前帧热带气旋的静态空间特征，时间特征提取模块 TFE 结合目标气旋前 T-1 帧的卫星云图，捕捉目标气旋在 T 帧内随时间变化的演变规律，对提取的时间特征与空间特征进行融合，并将融合后的时空特征作为空间-通道交互模块 SCI 的输入。SCI 模块通过空间注意力和通道注意力对时空融合特征的空间和通道信息进行深层提取和交互，从而实现在空间、时间和通道维度上对目标气旋特征信息的有效提取和深度融合交互。最后通过展平层和线性层输出热带气旋的估计强度。




图 2 STDA-Net 模型结构

Fig. 2 Structure of the STDA-Net

2.2 空间特征提取模块（SFE）

为了从当前卫星云图中估计出目标热带气旋的强度，本文通过空间特征提取模块 SFE 对当前图像中的热带气旋进行空间特征提取，SFE 模块结构图如图 3 所示。SFE 通过全局空间特征提取块（Global Spatial Feature Extraction, GSFE）提取目标热带气旋的全局空间特征。对于输入图像 $X \in \mathbb{R}^{C \times H \times W}$ ，本文将其处理为包含红外和水汽两个通道，高、宽分别为 256，即尺寸为 $2 \times 256 \times 256$ 的热带气旋卫星云图数据。GSFE 采用 7×7 的卷积获得较大感受野，能够捕捉到图像中的全局特征，

并通过批归一化以帮助模型稳定训练，采用 ReLU 激活函数处理非线性关系，最后通过最大池化操作减少特征数量，此过程如公式 1 所示。

$$GSFE(x_i) = \text{MaxPool}(\text{ReLU}(\text{BatchNorm}(\text{Conv2d}(x_i)))) \quad (1)$$

式中， $GSFE(\cdot)$ 为全局空间特征提取函数， x_i 表示第*i*个热带气旋卫星云图， Conv2d 表示 2D 卷积操作， BatchNorm 代表批归一化， ReLU 表示激活函数， MaxPool 代表最大池化操作。




图 3 空间特征提取模块结构图

Fig. 3 Structure of the spatial feature extraction module

在得到目标气旋的全局空间特征后，为进一步从更为精细的角度捕捉热带气旋的局部空间特征，本文利用 3×3 的卷积操作，通过较小的卷积核从更精细的局部图像区域中提取出有价值的局部空间特征，并通过 Sigmoid 函数对其进行非线性映射，将特征值映射到 $(0,1)$ 区间，以增强特征的表达能力，再与全局特征进行逐元素的乘积，以融合全局空间特征与经过 Sigmoid 处理后的局部空间特征。为更全面且细致地描述热带气旋的空间特性，本文利用 ResNet18 残差网络深度提取融合后的空间特征信息。ResNet 网络凭借自身的残差结构，能够有效解决深度神经网络训练过程中的梯度消失和梯度爆炸问题，从而更好地学习和保留热带气旋的深度特征信息。经过上述步骤，SFE 模块能够从热带气旋云图中有效捕捉到气旋的全局空间特征和精细尺度的局部特征，并实现深度特征融合，SFE 模块实现过程如公式 2 所示，最终输出空间特征的尺寸为 $512 \times 8 \times 8$ 。

$$f_{spatial} = \text{ResNet}(GSFE(x_i) \otimes \text{Sigmoid}(\text{Conv2d}(GSFE(x_i)))) \quad (2)$$

式中， $f_{spatial}$ 代表当前卫星云图中目标热带气旋的空间特征， ResNet 表示残差网络， $GSFE(x_i)$ 代表提取到的第*i*个热带气旋卫星云图的全局空间特征， $\otimes$ 表示逐元素相乘， Sigmoid 为激活函数。

2.3 时间特征提取模块 (TFE)

在热带气旋的形成与演变过程中，其前期强度的时序变化趋势对于精确评估当前气旋强度而言，具有不可忽视的重要参考价值。鉴于此，本文不仅聚焦于热带气旋空间特性的捕捉，更深入地探索了其强度在时间维度上的动态变化规律。时间特征提取模块 TFE 结合了当前气旋 T 帧内的卫星云

图数据，分析其强度在时间维度上的变化趋势，进而提升对当前气旋强度估计的准确性，TFE 模块结构图如图 4 所示。




图 4 时间特征提取模块结构图

Fig. 4 Structure of the temporal feature extraction module

TFE 模块以图像序列 $Z \in R^{B \times T \times C \times H \times W}$ 作为输入，其中 B 为批次大小，输入图像序列的帧数为 T ，图像通道数为 C ，高和宽分别为 H 和 W 。该模块包含全局时间特征提取块（Global Temporal Feature Extraction, GTFE）、时间注意力单元和细粒度时间特征提取块（Fine Temporal Feature Extraction, FTFE）三部分。为了更准确地捕捉到图像时间上的依赖关系，TFE 模块将输入序列重塑为 $B \times (T \times C) \times H \times W$ ，依次通过 GTFE 块中 7×7 的较大卷积核、批归一化、ReLU 激活函数和最大池化，来获取图像序列中的全局时间特征，提取热带气旋的长周期演变规律，其过程可由公式 3 表示。

$$GTFE(z_i) = \text{MaxPool}(\text{ReLU}(\text{BatchNorm}(\text{Conv2d}(z_i)))) \quad (3)$$

式中， $GTFE(\cdot)$ 为全局时间特征提取函数， z_i 表示第 i 个热带气旋卫星云图序列。

时间注意力单元以 GTFE 块输出的全局时间特征为输入，通过分解帧内静态注意力和帧间动态注意力（Tan, et al, 2023），有效捕捉全局特征中的时间关键信息，其结构图如图 5 所示。时间注意力单元在帧内静态注意力中使用具有较小卷积核的深度卷积（Depthwise Convolution, DW Conv）、深度扩张卷积（Depthwise Convolution with Dilations, DW-D Conv）和 1×1 的卷积来模拟大核卷积，从而获取大感受野，捕捉帧内长距离依赖关系，此过程如公式 4 所示，其中， SA 表示静态注意力， $\text{Conv}_{1 \times 1}$ 、 $DW-D \text{ Conv}$ 和 $DW \text{ Conv}$ 分别表示 1×1 的卷积、深度扩张卷积和深度卷积， H 表示输入的隐藏特征。而帧间动态注意力则使用通道间注意力的方式来学习不同帧之间的通

道权重，从而捕捉帧间的时间变化趋势，如公式 5 所示，其中， DA 代表动态注意力， $AvgPool$ 表示平均池化， FC 为全连接层。将得到的 SA 的结果与 DA 的结果相乘，并与输入特征 H 进行哈达玛乘积运算，得到输出特征 H' ，如公式 6 所示。通过将时间注意力进行分解，能够同时关注帧内静态信息和帧间动态变化，从而更精准地捕捉图像序列中不同时间步的重要性，使模型能够更好地捕捉时间依赖关系。

$$SA = Conv_{1 \times 1}(DW - D Conv(DW Conv(H))) \quad (4)$$

$$DA = FC(AvgPool(H)) \quad (5)$$

$$H' = (SA \otimes DA) \odot H \quad (6)$$




图 5 时间注意力模块结构

Fig. 5 Structure of the temporal attention module

为进一步加强热带气旋图像序列时间特征的提取，FTFE 块对经过时间注意力单元输出的尺寸为 $B \times T \times C' \times H' \times W'$ 的特征数据重塑为 $B \times (T \times C') \times H' \times W'$ ，采用 3×3 的较小卷积核，从更细粒度的层面多次捕捉图像序列的时间依赖关系，最终得到尺寸为 $512 \times 8 \times 8$ 的时间特征。TFE 模块实现过程如公式 7 所示。

$$f_{temporal} = FTFE(TA(GTFE(z_i))) \quad (7)$$

式中， $f_{temporal}$ 代表热带气旋卫星云图序列中的时间特征， $FTFE(\cdot)$ 为细粒度时间特征提取函数， $TA(\cdot)$ 为时间注意力单元， $GTFE(z_i)$ 代表提取到的第 i 个热带气旋卫星云图序列的全局时间特征。

热带气旋的空间特征和时间特征对于热带气旋强度估计任务而言都至关重要，因此，在获取到当前气旋的空间特征，以及其演变过程中的时间特征之后，对空间特征 $f_{spatial}$ 和时间特征 $f_{temporal}$ 进行逐元素相加，再依次通过 3×3 的卷积和 ReLU 激活函数对时空特征进行充分融合，通过公式 8 所示的方式得到融合后的热带气旋时空特征 f_{ST} ，输出特征尺寸为 $128 \times 8 \times 8$ 。

$$f_{ST} = ReLU(Conv2d(f_{spatial} + f_{temporal})) \quad (8)$$

2.4 空间-通道交互模块 (SCI)

热带气旋卫星云图中通常包含多个不同的通道，其中所蕴含的信息对于全面准确地分析热带气旋的特征具有重要意义。以往的强度估计方法中往往忽略了通道信息的重要性，鉴于此，本文通过空间-通道交互模块 SCI 来增强对热带气旋时空特征中的通道信息的关注度，SCI 模块结构图如图 6 所示。鉴于热带气旋的空间特征对提升模型性能及强度估计准确性具有显著影响，为进一步深入挖掘融合时空特征中的潜在信息，SCI 模块通过空间注意力深度提取融合特征中的空间信息，并与通道注意力单元捕获到的通道信息进行交互，以实现在空间、时间和通道三个维度上的深度信息融合，

从而为热带气旋的强度估计提供了全面且详尽的特征信息支持。

SCI 模块将融合后的热带气旋时空特征 f_{ST} 先通过空间注意力单元,在该注意力单元中,采用 3×3 的小卷积和 ReLU 激活函数对输入的时空融合特征进行重复卷积和非线性处理,深入挖掘时空特征中的空间信息。本文引入了 SENet (Squeeze-and-Excitation Networks) 通道注意力网络 (Hu, et al, 2018) 作为该模块中的通道注意力单元,以有效提取出数据中的通道信息。该网络分为压缩 (Squeeze) 和激励 (Excitation) 两部分,为了捕捉通道间的依赖关系,SENet 首先通过全局平均池化将输入特征图在空间维度上进行了压缩操作,扩大了感受野,使得网络能够利用捕捉到的全局信息来理解通道间的关系。同时,激励部分通过全连接层来预测特征图中每个通道的重要性,得到每个通道的权重值,使网络能够根据输入自适应地突出或抑制不同通道的信息。并将经过压缩后的特征图与对应的通道权重进行逐通道相乘,重新计算原始特征在通道维度上的表示,从而使该网络能够通过自适应地学习不同通道间的权重,显式建模通道间的相互依赖关系来增强网络的表征能力。SENet 能够从空间注意力单元输出的深度特征中提取出关键的通道信息,提高对原始数据通道信息的利用率。




图 6 空间-通道交互模块结构图

Fig. 6 Structure of the spatial-channel interaction module

然而此类先采用空间注意力后通过通道注意力的方式不可避免的会丢失部分空间信息。为解决该问题,SCI 模块引入了另一分支来对空间信息进行补充。该分支采用先通过 SENet 网络提取时空特征 f_{ST} 中的通道信息,再通过空间注意力单元对带有通道信息的融合特征进行深度空间信息挖掘。最终,将两个分支的特征输出进行逐元素相加,得到包含了热带气旋空间、时间和通道的多维度深层特征,将其展平并经过线性层,输出最终的热带气旋强度估计结果。SCI 模块实现过程如公式 9 所示。

$$f_{fusion} = SENet(SA(f_{ST})) + SA(SENNet(f_{ST})) \quad (9)$$

式中, f_{fusion} 代表最终得到的包含空间、时间和通道的深层特征,SENet代表通道注意力网络,SA表示空间注意力。

通过空间特征提取模块（SFE）、时间特征提取模块（TFE）和空间-通道交互模块（SCI）的深度协同，构建了 STDA-Net 模型的多维度特征融合体系。SFE 模块采用全局-局部双路径特征提取策略，通过 7×7 大卷积核捕获气旋云系的宏观结构特征，同时利用 3×3 小卷积核聚焦气旋结构的细粒度空间特征，最后通过 ResNet18 网络实现深度特征融合，进而促使模型能够同时把握热带气旋的全局形态特征与局部关键结构。TFE 模块与 SFE 模块形成时空特征互补的纵向关联，采用 7×7 卷积核提取热带气旋的长周期演变规律，再通过分解式时间注意力机制实现时序依赖的精准建模，有效捕捉全局特征中的时间关键信息，最后从精细尺度层面获取序列的时间依赖关系，有效捕捉热带气旋不同发展阶段的特征差异性。通过对时空特征图的逐元素相加、卷积与 ReLU 非线性变换实现对热带气旋空间特征与时间特征的深度交互与融合，既保留了两者的独立性特征，又建立了空间结构与时间演变的耦合关系。

融合后的时空特征中包含的丰富通道信息对于准确分析热带气旋强度特征具有不可忽视的重要参考价值。鉴于热带气旋的空间特征对提升模型性能及强度估计准确性具有显著影响，为进一步深入挖掘融合时空特征中的潜在信息，SCI 模块创造性地构建了空间-通道双向注意力交互机制。该模块采用双分支并行架构实现了融合特征在空间与通道维度的双向信息交互，突破了传统注意力机制的单向性局限，促使模型能够动态调整不同区域、不同通道的特征权重。STDA-Net 模型通过融合 SFE 模块与 TFE 模块并行分析获取的当前帧的静态空间特征与历史气旋序列的动态时间演变规律，经由 SCI 模块实现多维度特征优化，从而实现热带气旋空间、时间与通道特征的多维度层次化融合，有效提高对气旋强度的估计准确性。

3 实验分析

本文采用 GridSat-B1 数据集的热带气旋卫星云图作为输入，并利用 IBTrACS 数据集为其添加风速标签。考虑到早期热带气旋图像数据质量受到观测技术的限制，为了精准揭示十余年间热带气旋强度的变化规律，在确保样本数量满足科学分析需求的前提下，本文选取 2010—2021 年西北太平洋海域的热带气旋数据作为研究对象并进行了充分的实验研究，以验证 STDA-Net 在强度估计任务中的优越性能及模型设计的有效性。

3.1 GridSat-B1 数据集

本文选用 Gridded Satellite-B1 (GridSat-B1)([Xu, et al, 2023](#))公开卫星图像数据集作为 STDA-Net 网络所使用的热带气旋卫星云图。GridSat-B1 是由美国国家海洋和大气管理局 (National Oceanic and Atmospheric Administration, NOAA) ([Wheeler, et al, 2021](#)) 提供的高质量气候数据记录。数据来源于从 1980 年至今的，每 3 小时记录一次的国际卫星云气候学项目 (International Satellite Cloud Climatology Project, ISCCP) B1 数据 ([Tang, et al, 2022](#))，并且每个季度更新一次，并将其投射到全球 0.07° 纬度的等角网格上。GridSat-B1 云图数据包含红外、水汽和可见光三个通道数据，空间覆盖范围为 70°N 至 70°S 。

3.2 IBTrACS 数据集

本文采用国际气候管理最佳轨迹档案数据 (International Best Track Archive for Climate

Stewardship, IBTrACS) (Knapp, et al, 2010; Xie, et al, 2022) 对热带气旋卫星云图数据添加风速标签。IBTrACS 数据集是一个全球性的热带气旋轨迹数据库, 由美国国家海洋和大气管理局和其他国际气象机构共同维护和更新。该数据库整合了来自多个国家和地区的热带气旋观测数据, 包含了热带气旋轨迹、强度信息、分类信息以及气象参数等数据, 是热带气旋领域的重要研究资料, 已被广泛应用于气象学、气候科学和灾害管理等领域。

3.3 数据预处理

本文筛选出区域范围为 $0^{\circ}\text{N}-50^{\circ}\text{N}$, $100^{\circ}\text{E}-170^{\circ}\text{E}$ 的西北太平洋海域的热带气旋数据, 对数据集划分为训练集、验证集和测试集。采用 2010—2018 年的热带气旋数据作为训练集, 取其中 20% 作为验证集, 并利用 2019—2021 年的数据作为测试集, 数据集划分情况如表 2 所示。

表 2 数据集划分详情

Table 2 Details of dataset division

数据集类别	范围	云图数量
训练集	2010—2018	12951
验证集	训练集的 20%	2591
测试集	2019—2021	4554

对于包含红外、水汽和可见光通道的热带气旋卫星云图数据, 由于可见光通道的数据常常难以获取, 故而本文保留图像的红外和水汽通道作为模型的输入通道数据。根据 IBTrACS 中西北太平洋海域热带气旋中心的经纬度坐标将热带气旋的卫星云图裁剪为 256×256 的图像, 并添加风速标签, 按照气旋强度大小, 依据中国气象局规定的热带气旋等级划分标准对其进行强度等级分类。通过对图像数据进行分析, 筛选出其中异常的卫星云图, 为避免该类异常值对模型训练过程产生影响, 本文剔除了异常的云图数据, 以保证训练过程的可靠性。本文构建了 T 帧分辨率均为 256×256 的热带气旋卫星云图作为云图序列, 每一帧的时间间隔为 3 小时, 即结合了当前气旋 T 帧内的历史气旋图像为强度估计结果提供支持。

3.4 实验详情

3.4.1 实验环境

本文基于 Pytorch 深度学习框架构建模型, 并在配备了 Intel® Xeon® Silver 4310 CPU® 2.10Ghz 处理器、RTX 4080 GPU 和 128GB RAM 的 Ubuntu 20.04 LTS 操作系统上进行实验。在模型训练过程中, 设置初始学习率 (Learning Rate) 为 0.001, 批量大小 (Batch size) 为 32, 训练周期 (Epoch) 为 100, 采用 L1 损失函数来评估模型训练损失, 并利用 Adam 优化器对模型进行优化。

3.4.2 评价指标

为了评估模型的性能, 本文采用平均绝对误差 (Mean Absolute Error, MAE) 和均方根误差 (Root Mean Square Error, RMSE) 作为评价指标, 计算表达式分别如公式 10 和公式 11 所示。

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (11)$$

式中, N 表示热带气旋卫星云图样本总数, y_i 和 $\hat{y}_i$ 分别代表真实强度值和估计强度值。平均绝对误差值和均方根误差值越小, 则模型表现越好。

3.5 实验结果比较

为了全面评估 STDA-Net 模型对西北太平洋热带气旋强度估计的综合表现, 本文对其在 2019 年、2020 年和 2021 年中的 MAE 值和 RMSE 值做出总结, 并选取了 DeepCNN(Pradhan, et al, 2017)、CNN-TC (Chen, et al, 2019)、TCIE (Zhang, et al, 2021) 和 DeepMicroNet (Wimmers, et al, 2019) 四个强度估计模型进行对比分析, 对比结果如表 3 所示。

表 3 不同模型在强度估计任务中的评价结果 (节)

Table 3 Evaluation results of different models in the intensity estimation task (knot)

模型	2019		2020		2021		平均	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
DeepCNN	12.41	18.44	12.93	18.68	12.88	18.65	12.72	18.58
CNN-TC	11.63	15.92	12.94	17.65	11.88	16.92	12.08	16.76
TCIE	10.89	14.75	11.40	15.17	11.08	15.54	11.10	15.15
DeepMicroNet	8.78	12.01	9.36	12.58	9.55	13.09	9.20	12.55
STDA-Net	7.40	9.54	7.45	9.60	6.85	9.15	7.23	9.42

从表 3 中可以看出, 相较于所比较的深度学习方法, STDA-Net 模型在对西北太平洋热带气旋强度估计任务中获得了最优表现, 并相较于 DeepCNN 分别降低了 43.16 % 的 MAE 值和 49.30 % 的 RMSE 值。早期的热带气旋强度估计方法如 DeepCNN 和 CNN-TC 多依赖于 CNN 网络中卷积层提取的特征, 然而该类方法在处理梯度下降问题和提取非线性特征时存在的不足会导致估计结果的准确性受限。相比之下, TCIE 和 DeepMicroNet 达到的效果较为可观, 然而 TCIE 模型中只使用了红外通道的单通道数据作为输入, 缺失了对图像中不同通道信息的利用, STDA-Net 增加了对通道信息的关注, 与 TCIE 相比, 分别降低了 34.86 % 的 MAE 值和 37.82 % 的 RMSE 值。DeepMicroNet 使用较小卷积核对多通道数据进行多次卷积, 提取特征更加充分, 相较于上述的对比模型表现较好。然而该模型中忽略了热带气旋变化过程中的时间特征, 与 STDA-Net 相比在强度估计性能方面仍有待提升。STDA-Net 凭借着 TFE 模块和 SCI 模块, 实现了对时间特征和通道特征的有效提取, 并与热带气旋的空间特征进行深度融合, 为强度估计任务提供了充分的特征信息, 有效提高了估计结果的准确性和模型性能。

3.6 消融实验

与现有方法相比, STDA-Net 通过 TFE 模块和 SCI 模块, 除去关注热带气旋的空间特征, 还加强了对时间特征和通道特征的充分提取, 有效提高了估计结果的准确性。为了验证 TFE 模块和 SCI 模块对提升模型性能的有效性, 本文对其进行了消融实验, 采用 MAE 和 RMSE 作为评价指标, 实验结果如表 4 所示。消融模型具体如下:

- w/SFE & SCI: 从 STDA-Net 中移除 TFE 模块, 保留 SFE 模块和 SCI 模块;
- w/SFE & TFE: 从 STDA-Net 中移除 SCI 模块, 保留 SFE 模块和 TFE 模块;
- w/SFE: 从 STDA-Net 中同时移除 TFE 模块和 SCI 模块, 只保留 SFE 模块。

从表 4 中可分析得出, 在针对热带气旋强度进行估计时, 无论是移除了 TFE 模块后的 w/SFE & SCI 模型还是移除了 SCI 模块后的 w/SFE & TFE, 其性能表现均逊色于原 STDA-Net 模型, 其中 w/SFE & SCI 模型性能下滑幅度更为显著。基于此可分析得出, 热带气旋图像中的时间和通道信息对于强度的估计具有不可忽视的关键作用, 并且热带气旋在演变过程中的时间变化规律对于强度估计而言具有更为突出的研究价值。在消融模型中, w/SFE 模型由于摒弃了对时间信息的考量, 同时也忽视了对通道特征与强度之间相关性的挖掘, 致使其模型表现效果最差。该实验结果有力地证实了时间规律、通道信息与强度间存在紧密的内在联系, 以及 TFE 模块和 SCI 模块在提升模型性能方面的有效性与重要性。

表 4 消融实验结果详情 (节)

Table 4 Details of the ablation study (knot)

模型	2019		2020		2021		平均	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
STDA-Net	7.40	9.54	7.45	9.60	6.85	9.15	7.23	9.42
w/SFE & SCI	8.48	11.36	8.34	11.01	8.32	11.57	8.38	11.31
w/SFE & TFE	7.42	9.72	7.62	9.87	7.37	9.70	7.47	9.75
w/SFE	8.52	11.51	8.63	11.45	8.51	11.74	8.55	11.58

4 模型分析

为进一步验证 STDA-Net 在热带气旋强度估计任务中的表现, 本文对估计结果进行了误差分析, 并对其在不同强度类别的热带气旋上的强度估计结果进行了评价分析。为了更加直观地研究 STDA-Net 对热带气旋强度在时间上的演变规律的捕捉能力, 本文对 2019—2021 年间的热带气旋事件的强度估计结果进行了可视化分析与探讨。为更好应对强度变化过程中出现的快速增强情况, 实现对气旋强度的精准估计, 本文选取了不同帧数的历史气旋图像序列进行研究分析, 并在具体的热带气旋个例上进行了可视化呈现与分析。

4.1 误差分析

本文进一步对 STDA-Net 进行误差分析, 为了全面评估不同模型在西北太平洋热带气旋强度估计方面的性能, 本文采用散点图对多个模型的估计结果进行可视化分析。图 7 分别展示了 STDA-Net、CNN-TC、DeepMicroNet 和 TCIE 四个模型在该任务中的表现。

在图 7 中的四个子图中, 横轴表示热带气旋强度的实际值, 纵轴表示各个模型所估计的热带气旋强度值, 不同颜色的散点分别代表不同模型对各个热带气旋样本强度估计的结果, 图中的直线表示对散点进行线性拟合得到的结果。同时, 子图中标注的线性拟合相关系数 R 值, 反映了估计值与实际值之间线性关系的紧密程度, 其取值范围在 0 到 1 之间, 越接近 1 则表示线性关系越强, 即模型的估计准确性越高, 基于此可分析出不同模型在强度估计任务中的误差表现。

从图中可以看出, CNN-TC 和 TCIE 的散点分布较为离散, 相关系数较低, 表明该模型在对西北太平洋热带气旋进行强度估计时产生的误差较大, 准确性较低。相比之下, DeepMicroNet 结果表现略优于 CNN-TC 和 TCIE, 但尽管其散点也较为靠近线性拟合直线, 相较于 STDA-Net, 其离散程度仍然略高。表明该模型在热带气旋强度估计上具有较好的性能, 但在结果误差方面仍存在一


定的改进空间。优于上述模型的表现，STDA-Net 达到了 0.951 的 R 值，热带气旋散点分布较为密集，进而表明其估计值与实际值之间具有较强的线性关系，拟合程度较好，整体误差较小，模型能够较为准确地对西北太平洋热带气旋强度进行估计，性能表现最优。在现实场景中，强热带气旋的数量通常少于弱热带气旋。这就导致热带气旋强度估计的数据集中，强弱气旋数量存在不平衡的情况。这种不平衡使得模型在对热带气旋强度进行估计时，往往对弱气旋的估计结果较好，而对强气旋的估计准确性欠佳。

表 5 数据集中各类别热带气旋卫星云图数量

Table 5 Number of satellite cloud images of tropical cyclones in each category in the dataset

强度类别	测试集中的云图数量
TD	6717
TS	3901
STS	2134
TY	1691
STY	1194
SuperTY	1868

表 5 中给出了不同强度类别的热带气旋图像样本在数据集中所占的数量。由表中数据可知，强热带气旋的样本数量相对于热带低压和热带风暴此类弱气旋而言明显偏少，存在着强弱气旋样本数量不均衡的问题。在基于该数据集训练模型的过程中，所采用的 Adam 优化算法依赖批量样本计算梯度，进而更新参数。由于弱气旋样本数量占据主导地位，在每一个训练批次中，弱气旋样本出现的频率远高于强气旋样本，从而导致模型在参数更新时，更多地依据弱气旋样本的梯度信息进行调整，使得模型参数逐渐向拟合弱气旋特征的方向倾斜，进而导致模型在对强气旋进行估计时相较于弱气旋而言产生的误差较大。反映在图像上的呈现结果为，随着热带气旋强度的增加，散点的离散程度也呈增强趋势，散点分布由低强度区间的相对集中态向高强度区间的显著弥散态过渡。






图 7 不同模型误差分析散点图（子图(a)、(b)、(c)和(d)分别是 STDA-Net、CNN-TC、DeepMicroNet 和 TCIE 模型的散点图）

Fig. 7 Scatterplots of error analysis of different models (Subfigure (a), (b), (c) and (d) are scatterplots for STDA-Net, CNN-TC, DeepMicroNet and TCIE, respectively)

4.2 对各类热带气旋强度估计的结果分析

本文按照热带气旋的不同强度类别,对不同模型在每个类别上的强度估计结果进行了评价与分析,采用 MAE 和 RMSE 作为评价指标,结果如图 8 所示。在图 8(a)中,横轴表示热带气旋的强度类别,纵轴代表 MAE 值,通过不同颜色的折线图展现了不同模型在各类热带气旋强度估计中的平均绝对误差情况。图 8(b)中,横轴表示热带气旋的强度类别,纵轴代表 RMSE 值,呈现出了不同模型在各类热带气旋强度估计中的均方根误差情况。

从图中可以看出,DeepCNN、CNN-TC 和 TCIE 在热带气旋强度估计过程中都表现出了较大的误差波动,在低强度热带气旋中表现尚可,但随着气旋强度增加,误差明显上升,进而说明了其模型的稳定性较差。DeepMicroNet 的误差较平缓,但与 STDA-Net 相比并没有表现出显著的低误差优势,模型性能仍然有待改进。与上述基于 CNN 的模型相比,STDA-Net 几乎在对所有强度类别的热带气旋进行估计上都达到了最低的 MAE 值和 RMSE 值,并且对于强热带气旋仍然能保持相对较低的误差水平,展现了其在各类热带气旋的强度估计中的优异表现,强度估计准确性较高。




图 8 不同模型对各类热带气旋强度估计的评价（子图(a)和(b)分别是 MAE 和 RMSE 指标评价情况）

Fig. 8 Evaluation of different models for intensity estimation of various types of tropical cyclones (Subfigure (a) and (b) represent evaluations based on MAE and RMSE metrics, respectively)

不同强度类别的热带气旋通常具有不同的强度特性,为进一步对不同强度类别的热带气旋定强问题进行分析,本文对 STDA-Net 在各个类别上的估计结果进行了箱线图评价与分析,结果如图 9

所示。在图 9 中，横轴代表热带气旋的不同等级类别，纵轴代表 MAE 值，指数越高表明模型估计值与实际值的偏差越大，即估计准确性越低。图中箱体的上下边缘分别表示数据的上四分位数和下四分位数，箱体部分包含了整体数据中间 50 % 的数据，若箱体较短，则意味着数据较为集中，反之则较为分散，从而直观体现出数据的分散程度。箱体内部的中位数线以及箱体的上下须线分别反映了数据的集中趋势与波动范围，空心圆圈代表异常点。

由图中可以得出，强度等级较弱的热带低压和热带风暴的箱体较短，反映出该两类气旋强度估计误差较为集中，估计结果稳定性较高。随着强度等级的增强，箱体长度整体呈增长趋势，进而表明了随着气旋强度的增强，其估计误差的离散程度也随之增大。此外，随着热带气旋强度增强，箱体的上下须长度也有所增加，表明其估计值的波动范围更大。结合数据集中各个类别的热带气旋样本数量进行分析，由于弱气旋样本占比大，模型训练过程中更多依据弱气旋样本的梯度信息进行参数更新，从而使得模型对弱气旋特征的学习更充分，在估计弱气旋强度时表现较好。而强气旋样本数量少，模型难以充分学习其复杂特征，导致估计误差较大。此外，由于热带气旋在强度较低时，气旋结构相对简单，加之在模型处理样本图像的过程中，大量弱气旋样本参与其中，使得模型能够较好地学习到其更为全面的数据特征。随着气旋强度的增强，气旋整体结构愈加复杂，强度波动大，并且受到强对流等复杂环境场变化的影响，模型难以充分捕捉到气旋复杂特征的完整分布与变化规律，导致对其估计结果的准确性相对较低。




图 9 基于 STDA-Net 的各类热带气旋强度估计结果箱线图

Fig. 9 Box plot of the intensity estimation of various types of tropical cyclones based on STDA-Net

4.3 2019-2021 年热带气旋事件强度估计分析

为了更直观地展现 STDA-Net 对西北太平洋热带气旋强度估计的结果，本文选取 2019 年至 2021 年间所发生的热带气旋事件，对其估计结果进行了可视化分析，估计结果曲线与实际强度曲线对应情况如图 10 所示。从图 10 中可以清晰地看出，STDA-Net 对不同具体的热带气旋进行强度估计时，其估计结果与热带气旋真实强度值随时间变化的趋势基本保持一致，进而表明该模型能够较为有效地捕捉到热带气旋强度在时间上的演变规律，较好地拟合热带气旋强度随时间的演变过程。同时，实验结果表明，该模型对此三年发生的热带气旋事件进行强度估计时能够达到较低的 MAE 值和 RMSE 值，从量化的角度进一步证明了 STDA-Net 在热带气旋强度估计方面产生的误差值较小，具

有较高的准确性。




图 10 STDA-Net 在 2019—2021 年热带气旋事件中的强度估计分析（子图(a)、(b)和(c)分别是对 2019 年、2020 年和 2021 年发生的热带气旋事件的强度估计结果可视化）

Fig. 10 Intensity estimation analysis of STDA-Net for tropical cyclone events from 2019—2021 (Subfigure (a), (b) and (c) are visualizations of intensity estimation results for tropical cyclone events that occurred in 2019,2020 and 2021, respectively)

4.4 针对快速增强引起结果偏差的修正策略分析

当热带气旋的强度发生快速增强时，深度学习模型通常难以捕捉其在短时内的骤然变化，从而导致在强度峰值处出现较大的估计偏差。为缓解快速增强对估计结果造成的影响，提高估计结果的整体准确性，本文深入分析了模型输入图像帧数对强度估计的影响，分别采取了 3 帧、6 帧、9 帧和 12 帧的图像输入，分析其对强度估计结果的影响程度，实验结果如表 6 所示。

由表 6 可知，当输入帧数为 9 时，模型对于热带气旋强度估计的效果最佳，相比于 3 帧、6 帧

和 12 帧输入时的 MAE 值分别降低了 14.23 %、3.21 %和 3.98 %。此时，STDA-Net 利用前 24 小时的历史气旋图像对当前气旋强度进行估计。通过对表中数据的进一步分析可发现，当增加图像序列帧数时，模型能够结合长序列历史气旋云图，捕捉到热带气旋生长阶段强度的时间演变规律，有助于模型学习到更多包含强度快速增强阶段的特征，有效提升模型估计的准确率。此外，实验数据表明，输入图像序列帧数并非是越长越好，当帧数增加到 12 帧时模型性能开始呈下降趋势。帧数过长时模型的计算负担会增大并且会引入一些冗余信息，从而降低模型性能。

表 6 STDA-Net 对不同帧数输入图像的 MAE 和 RMSE（节）

Table 6 MAE and RMSE of STDA-Net for different frames of input images (knot)

帧数	2019		2020		2021		平均	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
3	8.24	11.15	8.69	11.32	8.45	11.75	8.43	11.41
6	7.42	9.81	7.77	10.04	7.22	9.76	7.47	9.87
9	7.40	9.54	7.45	9.60	6.85	9.15	7.23	9.42
12	7.52	9.77	7.93	10.15	7.16	9.44	7.53	9.79

为了更加直观地展示调整输入图像帧数如何有效缓解快速增强对结果误差的影响，本文选取了 2019 年的“BUALOI”，2020 年的“MEKKHALA”和 2021 年的“SURIGAE”三个不同的热带气旋事件，对其在不同输入帧数下的估计结果进行了可视化分析，结果如图 11 所示。实验结果表明，当输入 9 帧时，STDA-Net 在所有选定的热带气旋事件中均表现出色，取得了较低的 MAE 和 RMSE 值，并且能较好地拟合热带气旋的强度变化过程。此外，由图 11 可以看出，当热带气旋的强度在短时间内快速增强时，与其余时刻相比，估计结果的误差较大，表明该类情形易对模型性能带来负面影响。通过对图像帧数的调整，模型能够较好地与真实值曲线相拟合，进而证实了模型能够有效捕捉到强度的增强趋势，显著降低因此产生的结果误差，从而提升模型的整体性能。

热带气旋强度的快速增强是造成强度估计及预报误差增大的关键因素之一，本文通过分析图像序列帧数有效降低了其对估计结果带来的影响。在未来的工作中亟需探索如何综合使用高分辨率雷达观测数据、数值天气预报数据等多源观测与分析预报资料，从多维度捕捉热带气旋发生过程中的垂直风切变、海表温度、对流层中低层相对湿度等环境特征并加以分析，以期实现对热带气旋快速增强的应变能力，缓解深度学习模型在热带气旋快速增强阶段的反应滞后问题。




图 11 STDA-Net 在不同输入帧数下对具体热带气旋事件的强度估计分析（子图(a)、(b)和(c)分别是对“BUALOI”、“MEKKHALA”和“SURIGAE”的强度估计结果可视化）

Fig. 11 Intensity estimation analysis of STDA-Net with different input frames for specific tropical cyclone events (Subfigure (a), (b) and (c) are visualizations of intensity estimation results for "BUALOI", "MEKKHALA" and "SURIGAE", respectively)

5 结论和讨论

针对现有基于深度学习的热带气旋强度估计方法中存在的估计结果准确率受限、时空及通道信息挖掘不充分的问题，本文提出了一种用于西北太平洋热带气旋强度估计的 STDA-Net 模型，引入了时间注意力单元、空间注意力单元和通道注意力单元以提高模型的泛化能力和估计准确率，并与其他深度学习模型的估计结果进行对比。主要结论如下：

(1) 热带气旋由于本身结构的复杂性，其在变化过程中的空间、时间和通道特征对其强度变化关联密切。本文从多维度的方向切入，结合了 SFE、TFE 和 SCI 三个模块构建了 STDA-Net 模型，分别从空间、时间和通道三个维度上提取和融合热带气旋图像特征，提高了强度估计的准确性。基于 2010—2021 年西北太平洋热带气旋数据集上开展的实验结果表明，STDA-Net 在西北太平洋热带

气旋强度估计任务中具有较高的准确性和可行性,估计结果均优于所比较的其他深度学习方法,并相较于 DeepCNN 和 TCIE 分别降低了 43.16 %和 34.86 %的 MAE 值。

(2) 消融实验表明,STDA-Net 模型的 TFE 和 SCI 模块均会影响模型的估计能力,对提升模型性能至关重要,其中 TFE 的作用更为显著,证实了本文所设计的 TFE 模块能够有效提取云图序列的时间特征,通过时空特征融合为当前估计气旋提供其随时间变化过程中的有效时间信息;同时,SCI 模块能够挖掘出通道信息与强度间的内在联系,实现对时空信息和通道信息的深度融合和关联,验证了该模块设计的有效性。说明了充分提取热带气旋在变化过程中的时间信息和通道特征对提升其强度估计准确性的重要性。

(3) 通过对误差分析散点图、强度类别估计结果、STDA-Net 模型在具体热带气旋事件上的估计结果的可视化,以及针对快速增强引起的结果偏差的修正与分析,展现出了 STDA-Net 在强度估计任务中的高拟合性,能够精准地捕捉到热带气旋强度随时间演变的规律,并且通过对图像帧数进行分析和调整,有效缓解了气旋快速增强阶段带来的结果偏差及反应滞后问题。

(4) 尽管 STDA-Net 在热带气旋强度估计上展现出了优秀的性能,但在对强气旋进行估计时,受快速增强和样本不均衡问题的影响,目前的深度学习模型仍存在改进空间。在后续的研究工作中,有必要深入探究热带气旋强度快速增强的机制与原理,并借助生成对抗网络等方法对强热带气旋的图像进行数据增强,提高生成图像的质量,从而更好地解决由快速增强和样本强度不均衡所造成的结果误差问题。

参考文献

- 冯亮. 2023. 一次由台风“杜苏芮”外围影响造成的雷暴天气分析. 自然科学, 11(5): 818-829. Feng L. 2023. Analysis of thunderstorm weather caused by the peripheral influence of typhoon “Dusu Rei”. Open Journal of Natural Science, 11(5): 818-829 (in Chinese)
- 顾小丽, 钱燕珍, 周伟军等. 2022. 台风“利奇马”灾害风险及气象服务效益评估. 热带气象学报, 38(1): 35-42. Gu X L, Qian Y Z, Zhou W J, et al. 2022. Study on disaster risk of typhoon Lekima and benefit of corresponding meteorological service. J Trop Meteor, 38(1): 35-42 (in Chinese)
- 向纯怡, 董林, 刘达等. 2024. 2023 年台风杜苏芮登陆后残涡维持的热力和动力机制研究. 气象, 50(11): 1289-1305. Xiang C Y, Dong L, Liu D, et al. 2024. Thermodynamic and dynamic mechanism of maintenance of typhoon Doksuri remnant vortex after its landfall in 2023. Meteor Mon, 50(11): 1289-1305 (in Chinese)
- 杨梦琪, 陈国民, 张喜平等. 2024. 2022 年西北太平洋和南海台风预报精度评定. 气象, 50(5): 630-641. Yang M Q, Chen G M, Zhang X P, et al. 2024. Verification on typhoon forecasts over the Western North Pacific and the South China Sea in 2022. Meteor Mon, 50(5): 630-641 (in Chinese)
- 周冠博, 钱奇峰, 吕心艳等. 2022. 人工智能在台风监测和预报中的探索与展望. 气象研究与应用, 43(02): 1-8. Zhou G B, Qian Q F, Lv X Y, et al. 2022. Application and expectation of artificial intelligence in typhoon monitoring and forecasting. J Meteor Res Appl, 43(02): 1-8 (in Chinese)
- Ahmed R, Mohapatra M, Giri R K, et al. 2021. An evaluation of the Advanced Dvorak Technique (9.0) for the tropical cyclones over the North Indian Ocean. Tropical Cyclone Research and Review, 10(4):

201-208

- Chen B F, Chen B, Lin H T, et al. 2019. Estimating tropical cyclone intensity by satellite imagery utilizing convolutional neural networks. *Wea Forecasting*, 34(2): 447-465
- Dvorak V F. 1975. Tropical cyclone intensity analysis and forecasting from satellite imagery. *Mon Wea Rev*, 103(5): 420-430
- Hu J, Shen L, Sun G. 2018. Squeeze-and-excitation networks//*Proceedings of the 2018 IEEE Conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 7132-7141
- Knapp K R, Kruk M C, Levinson D H, et al. 2010. The international best track archive for climate stewardship (IBTrACS) unifying tropical cyclone data. *Bull Amer Meteor Soc*, 91(3): 363-376
- Lee Y J, Hall D, Liu Q, et al. 2021. Interpretable tropical cyclone intensity estimation using Dvorak-inspired machine learning techniques. *Engineering applications of artificial intelligence*, 101: 104233
- Ma Z, Yan Y, Lin J, et al. 2024. A multi-scale and multi-layer feature extraction network with dual attention for tropical cyclone intensity estimation. *IEEE Trans Geosci Remote Sens*, 62: 1-15
- Olander T L, Velden C S. 2019. The advanced Dvorak technique (ADT) for estimating tropical cyclone intensity: Update and new capabilities. *Wea Forecasting*, 34(4): 905-922
- Olander T, Wimmers A, Velden C, et al. 2021. Investigation of machine learning using satellite-based advanced Dvorak technique analysis parameters to estimate tropical cyclone intensity. *Wea Forecasting*, 36(6): 2161-2186
- Piñeros M F, Ritchie E A, Tyo J S. 2011. Estimating tropical cyclone intensity from infrared image data. *Wea Forecasting*, 26(5): 690-698
- Pradhan R, Aygun R S, Maskey M, et al. 2017. Tropical cyclone intensity estimation using a deep convolutional neural network. *IEEE Transactions on Image Processing*, 27(2): 692-702
- Song T, Yang K, Li X, et al. 2024. Probabilistic estimation of tropical cyclone intensity based on multi-source satellite remote sensing images. *Remote Sensing*, 16(4): 606
- Tang W, Qin J, Yang K, et al. 2022. Mapping long-term and high-resolution global gridded photosynthetically active radiation using the ISCCP H-series cloud product and reanalysis data. *Earth System Science Data*, 14(4): 2007-2019
- Tan C, Gao Z, Wu L, et al. 2023. Temporal attention unit: Towards efficient spatiotemporal predictive learning//*Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver: IEEE, 18770-18782
- Tan J, Yang Q, Hu J, et al. 2022. Tropical cyclone intensity estimation using Himawari-8 satellite cloud products and deep learning. *Remote Sensing*, 14(4): 812
- Tian W, Lai L, Niu X, et al. 2023. Estimation of tropical cyclone intensity using multi-platform remote sensing and deep learning with environmental field information. *Remote Sensing*, 15(8): 2085
- Wang C, Zheng G, Li X, et al. 2021. Tropical cyclone intensity estimation from geostationary satellite imagery using deep convolutional neural networks. *IEEE Trans Geosci Remote Sens*, 60: 1-16
- Wheeler K I, Dietze M C. 2021. Improving the monitoring of deciduous broadleaf phenology using the

571 Geostationary Operational Environmental Satellite (GOES) 16 and 17. Biogeosciences, 18(6):
572 1971-1985

573 Wimmers A, Velden C, Cossuth J H. 2019. Using deep learning to estimate tropical cyclone intensity
574 from satellite passive microwave imagery. Mon Wea Rev, 147(6): 2261-2282

575 Xie Y, Tian M, Qin Z K. 2022. Tropical cyclone intensity estimation using satellite microwave brightness
576 temperatures and a multi-view feature fusion network//IGARSS 2022-2022 IEEE International
577 Geoscience and Remote Sensing Symposium. Kuala Lumpur: IEEE, 7843-7846

578 Xu G, Li Y, Ma C, et al. 2023. TFG-Net: Tropical cyclone intensity estimation from a fine-grained
579 perspective with the graph convolution neural network. Engineering Applications of Artificial
580 Intelligence, 118: 105673

581 Zhang C J, Wang X J, Ma L M, et al. 2021. Tropical cyclone intensity classification and estimation using
582 infrared satellite images with deep learning. IEEE Journal of Selected Topics in Applied Earth
583 Observations and Remote Sensing, 14: 2070-2086

584 Zhang R, Liu Y, Yue L, et al. 2024. Estimating tropical cyclone intensity using a STIA model from
585 Himawari-8 satellite images in the Western North Pacific basin. IEEE Trans Geosci Remote Sens, 62:
586 1-13

587 Zhong W, Yuan M, Ye H, et al. 2020. Multi-factor intensity estimation for tropical cyclones in the
588 Western North Pacific based on the deviation angle variance technique. Journal of Meteorological
589 Research, 34(5): 1038-1051