

基于深度学习的南海海表温度重构及其时空变化研究

孙志伟^{1,4}, 李云波², 张殿君¹, 孙绍杰³, 陈思宇³

1. 天津大学 海洋科学与技术学院, 天津 300072;

2. 中国人民解放军91001部队, 北京 100161;

3. 中山大学 海洋科学学院, 珠海 519082;

4. 北京吉威数源信息技术有限公司, 北京 100043

摘要: 海表温度 SST (Sea Surface Temperature) 是研究海洋动力学、海洋—大气相互作用和气候变化的重要指标之一。传统的 SST 获取方式虽然精确, 但受限于采样点的数量和覆盖范围, 难以满足大尺度、高分辨率的海洋研究需求。虽然, 卫星遥感数据可覆盖全球海域, 具有更新频率高的特点, 在海洋研究中应用广泛, 但是, 卫星遥感数据在采集过程中, 受到天气条件、卫星扫描轨道范围和卫星传感器运行故障等因素的影响, 导致获得的 SST 数据常常存在缺失, 一定程度上限制了数据的应用。因此, 为对遥感数据进行重构以提高其利用效率, 获得高质量全覆盖的数据集, 本研究通过引入 Inception 模块嵌入深度卷积自编码器 DINCAE (Data-Interpolating Convolutional Auto-Encoder), 提出采用 I-DINCAE 模型用于 FY-3C 卫星南海海表温度产品的数据重构; 同时, 结合研究区多年的实测数据, 运用深度神经网络 DNN (Deep Neural Networks) 模型对新模型重构的温度数据进行校正, 并采用 Quam SST 数据集的 11993 个独立实测数据点的数据集进行检验。结果表明: 重构 SST 与实测 SST 的 RMSE 为 1.27 °C, MAE 为 0.96 °C, R^2 为 0.84; 经过 DNN 模型校正后, RMSE 降至 0.57 °C, MAE 降至 0.43 °C, R^2 提高至 0.92。基于校正后的海表温度数据, 从时间和空间两个维度分析了南海在月度和季度尺度的海表温度时空分布和变化特征。结果表明: 在季节尺度上, 南海的 SST 变化特征明显, 表现为夏季 SST 达到最高值, 冬季 SST 降至最低; 在月尺度上, 南海 SST 的变化呈现出正 (余) 弦波动形式, SST 通常在 6 月达到极大值, 在 1 月达到极小值。本研究不仅为获取高覆盖、高质量的南海区域海表温度数据提供了新的算法, 还揭示了南海区域海表温度的时空变化特征。

关键词: 海表温度, 数据重构, 深度学习, FY-3C, 时空变化

中图分类号: TP751/P2

引用格式: 孙志伟, 李云波, 张殿君, 孙绍杰, 陈思宇. 2025. 基于深度学习的南海海表温度重构及其时空变化研究. 遥感学报, 29(7): 2382-2398

Sun Z W, Li Y B, Zhang D J, Sun S J and Chen S Y. 2025. Sea surface temperature reconstruction based on deep learning and its application on the spatiotemporal analysis of SST variation in the South China Sea. National Remote Sensing Bulletin, 29(7): 2382-2398 [DOI: 10.11834/jrs.20254493]

1 引言

海表温度 SST (Sea Surface Temperature) 是驱动整个海洋循环系统的核心要素之一, 其微小的变化都可能对海洋生态系统的结构与功能产生深远的影响 (徐宾等, 2018; 刘铭坤等, 2023)。SST 的波动不仅直接关系到海洋生物栖息地的迁移和生物多样性的保持, 还间接影响着渔业资源的分布与渔业生产的稳定性。随着海洋温度的升高,

一些海洋生物可能会面临栖息地的丧失, 生物多样性可能遭受严重打击, 这将对渔业资源的可持续利用构成严峻挑战 (何露雪, 2022)。同时, 海表温度的变化与海洋环流模式之间存在着密切的联系。具体而言, SST 能够直接作用于海洋表层与深层水流之间的热量交换过程, 从而影响海洋的热量分布和传输机制, 这种热量交换不仅决定了海洋内部的温度梯度, 而且进一步影响了全球的气候格局。此外, 海表温度的变化还可能加剧一

收稿日期: 2024-11-07; 预印本: 2025-01-15

基金项目: 国家重点研发计划 (编号: 2023YFC3107701); 智慧地球重点实验室基金资助项目 (编号: KF2023YB03-03)

第一作者简介: 孙志伟, 研究方向为遥感智能处理技术与应用。E-mail: 657399121@qq.com

通信作者简介: 张殿君, 研究方向为海洋遥感与人工智能海洋学研究。E-mail: zhangdianjun@tju.edu.cn

些极端气候事件的发生,例如,热带气旋(如台风和飓风)的形成和发展与海表温度密切相关(宋晚郊等,2022)海表温度的升高可能会增加这些极端气候事件的强度和频率,对沿海地区的人类生活和生态系统构成严重威胁。因此,准确获取海表温度信息对于深入理解海洋生态系统的运行机制至关重要,并为应对全球气候变化及保护海洋生态环境提供了科学基础。

基于Argo浮标、海洋调查船、观测站台等现场实测手段获取的海洋温度资料日益丰富。尽管这些海洋现场观测手段在获取海表温度方面展现出了较高的精度,但受限于技术条件和自然环境的约束,这些数据的获取过程往往耗时较长,分布离散且不均匀,难以获得大规模的同步SST数据(Venkat Shesu等,2021)。卫星遥感技术因其广泛的时空覆盖范围被广泛应用于海洋研究,例如对海洋锋、涡流和湍流的监测(Brasnett和Colan,2016;郑晓莉等,2020;黄春铭等,2024)。相较于常规的SST测量方法,卫星获得的SST展现出监测范围广、连续性强的显著优势(Klein等,1999)。通过卫星等遥感平台能够实现对广阔海洋的大范围覆盖,从而获取全球尺度的海洋数据,这种实时监测的方式大大提高了海洋信息监测和预报的及时性和准确性,为海洋生态环境的监测和研究提供了宝贵的数据支持。

目前海表温度产品主要来自于热红外遥感卫星,由于受到云覆盖等因素的影响,获取的海表温度产品存在不同程度的缺失,数据完整性大大降低,而基于数据重构方法可以获取研究区内连续的海温分布。基于卫星遥感的海表温度数据重构方法主要可归纳为两大类:传统方法和基于深度学习的方法。传统的数据重构技术主要采用确定性插值方法(钟宝江等,2016)和地学统计插值方法(何海伦等,2013)来填补缺失的像素数据。当数据缺失较少且均匀分布时,该方法有较好的效果,但在数据严重缺失或分布不均的情况下,结果准确性将受到较大影响,这主要是因为这些方法依赖于缺失像素周围的有效信息进行预测,当周围的信息不足或存在异常时,结果的准确性便会降低。传统数据重构方法通常依赖于空间或时间连续性等统计假设,这些方法具有稳定性高、计算效率高等优点,且在特定应用场景下能展现出可靠的重构精度。然而,在应对

复杂环境和处理遥感数据时,传统方法展现出一些局限性。首先,在复杂多变的环境中,传统方法难以有效适应遥感数据(Meng等,2021)的非线性特征,这限制了其在处理复杂场景时的性能。其次,面对大量的遥感数据时,传统方法通常需要主观调整参数,这不仅耗时,而且难以确保全局最优。

随着人工智能技术的飞速发展,一些基于神经网络的算法被用于恢复间隙数据(Park等,2019),深度学习能够处理变量之间的非线性关系而被广泛用于处理海洋数据中(Bolton和Zanna,2019),其强大的特征学习能力使得深度学习模型能够自动捕获数据中的复杂特征,并据此生成与真实数据高度吻合的结果。

人工神经网络ANN(Artificial Neural Network)使用监督学习方法,通过学习已知数据特征与目标数据之间的关系来预测缺失数据值。Pisoni等(2008)成功地应用人工神经网络重建不完整卫星SST数据,并与插值法的结果进行了比较,然后对地中海SST变化进行验证,证明了该方法的有效性,该方法可以处理NOAA/AVHRR SST数据,模拟严重风暴事件。卷积神经网络CNN(Convolutional Neural Networks)在图像修复领域表现出优于ANN的性能。基于CNN的模型通过逐层学习图像的空间特征,能够预测并填充缺失值,这些方法引入了非线性变换,能够有效地捕捉数据中复杂的空间分布和时间相关性,从而更好地从数据中学习并预测复杂的趋势,特别是在利用上下文信息进行像素级重构时表现出色。使其成为数据重建的新兴解决方案。Ducournau和Fablet开发了一种基于深度学习和复杂卷积神经网络方法的图像超分辨率模型来评估海表温度(Ducournau和Fablet,2016)。自动编码器AE(Auto-Encoder)是一种无监督的学习模型,它可以学习输入数据的低维表示(编码),并从这个低维表示中重建出原始输入(解码)。这种编码—解码过程不仅实现了数据的有效压缩,还保留了数据的核心特征,使其能够广泛应用于海洋数据重建。Goh E等(2023)提出了一种利用掩码自动编码器MAE(Masked Autoencoders)重建云层下高分辨率SST场的方法,该方法可以在随机80%掩码下重建全局SST,将这种方法应用于具有严重云污染的海温数据,可以提高数据集质量,发现云隐藏的细节并扩大高分

分辨率海温图像的使用范围。与传统的基于线性假设的OI方法不同, DINCAE通过一系列卷积运算赋予OI非线性可解释性。DINCAE成功地解决了DINEOF在处理时间和空间域中的非线性关系方面的局限性。通过充分利用神经网络的强大功能, DINCAE可以有效地处理复杂的非线性关系。近年来, DINCAE方法被广泛用于卫星遥感数据缺失数据的重构, 并被证明是SST (Jung等, 2022)、Chl-a (Luo等, 2022)和其他变量数据重构的潜在工具。虽然DINCAE模型在海洋环境要素重构方面取得了一定的成果, 但随着网络的深度增加, 会出现过拟合现象, 因此, 本研究拟在DINCAE模型的基础上增加Inception模块, 构建适用于FY-3C卫星的海表温度产品重构算法模型I-DINCAE模型, 然后利用深度神经网络DNN (Deep Neural Networks) 结合实测数据对重构数据进行校正, 得到高精度的海表温度数据, 并利用实测数据进行验证, 以获得高质量、高覆盖的海表温度产品。最后, 基于校正后的海表温度产品进行月度和季度尺度的时空变化分析, 以期揭示南海的海表温度时空变化规律, 为南海海洋生态环境研究提供参考依据。

2 研究区与数据来源

2.1 研究区域

研究区域位于南海及其邻近海域 (5°N — 20°N , 105°E — 120°E)。南海地处中国大陆南部, 是西太平洋的重要组成部分, 与黄海和东海并列为中国3大边缘海。南海是中国近海区域中面积最大、水深最深的海域。南海的地理范围北起广东省南澳岛与台湾岛南端的鹅銮鼻一线, 南至加里曼丹岛、苏门答腊岛, 西靠中南半岛、马来半岛, 东抵菲律宾, 这一海域不仅通过海峡和水道与太平洋紧密相连, 还通过复杂的海洋通道与印度洋相通, 成为连接东、西两大洋的重要纽带 (Li等, 2023)。南海的地形复杂包括陆架和深海盆地, 其中大部分地区有陆架, 而中央和南部则主要是深海盆地。南海重要的地理位置和复杂的海洋环境, 使其成为研究海洋与大气相互作用的关键区域, 高分辨率和高精度的海表温度数据集对于深入了解该区域海洋在不同时间和空间尺度上的波动至关重要。

2.2 数据来源

2.2.1 海表温度遥感数据

本研究采用国家卫星气象中心所提供的FY-3C VIRR SST数据, 获取了具有全球覆盖范围的L2级每日海表温度产品 (<http://data.nsmc.org.cn/> [2024-11-07]) (Liu等, 2021)。风云三号C星 (FY-3C) 是中国第二代气象卫星, 于2013年9月23日发射升空。它在太阳同步轨道上运行, 轨道高度为836 km, 轨道倾角为 98.75° , 可见光红外扫描辐射计VIRR (Visible and Infra-Red Radiometer) 有10个光谱通道, 扫描宽度为 $\pm 55.4^{\circ}$, 扫描幅宽为2800 km, 星下点分辨率为1.1 km, 等级是10 bit。该卫星主要应用在云、植被、雪、海/陆表温度、火点、气溶胶等的监测。VIRR有一个短波长红外通道 ($3.55\text{--}3.93\text{ }\mu\text{m}$) 和两个长波长红外通道 ($10.3\text{--}11.3\text{ }\mu\text{m}$ 和 $11.5\text{--}12.5\text{ }\mu\text{m}$) 可以用于海表温度的观测, 数据由北京、广州、新疆、佳木斯和基律纳5个地面站接收。利用MCSST算法制作VIRR海温产品, 可用于观测全球海表温, 产品采用 $0.05^{\circ}\times 0.05^{\circ}$ 的等经纬度投影分辨率, 其时间分辨率为1 d, 数据以HDF格式存储 (熊远康, 2023)。产品包括日间和夜间SST产品, 考虑到太阳辐射角的变化会影响海洋中水体的热量吸收与释放, 进而对白天SST产生震荡影响, 而夜间温度相对稳定, 为降低白天太阳辐射对上层海洋温度分析的干扰, 选用夜间SST数据, 即每天当地时间22:15捕获的分辨率为 0.05° 的夜间SST产品 (王素娟等, 2017)。

本研究选取2014年5月4日—2020年2月3日的VIRR SST数据, 在实际数据获取过程中, 发现某些时间存在数据缺失的情况, 最终共计获得2017个数据文件。

2.2.2 实测海表温度数据

实测海表温度数据来源于美国国家海洋和大气管理局 (NOAA) 的SST质量监测系统 (iQuam), 该系统由NOAA的卫星应用与研究中心 (STAR) 运维, 通过网站 (<http://www.star.nesdis.noaa.gov/sod/sst/iquam/index.html> [2024-11-07]) 提供全球范围内的海洋观测数据。iQuam详尽记录了数据的时间、经纬度、测量类型、海表温度、风向和风速等信息, 并将其分为1—5个质量级别 (Liu等, 2021)。为了确保分析的准确性, 本研究选取质量

最高的5级SST数据做为实测数据。

3 研究方法

本研究首先利用改进的数据插值卷积自动编码器(I-DINCAE)方法对缺失的SST数据进行重构,然后利用深度神经网络DNN(Deep Neural Networks)结合实测数据对重构数据进行校正,得到高精度的海表温度数据。

3.1 I-DINCAE模型

DINCAE是由Barth等(2020, 2022)提出的一种先进的深度学习方法。该方法巧妙地融合了自动编码器AE(Autoencoder)与卷积神经网络CNN(Convolutional Neural Network)的各自优势。该方法不仅继承了自动编码器在数据特征提取和降维方面的强大能力,还充分利用了卷积神经网络在图像处理领域的卓越性能,从而实现对数据的有效重构。

在CAE中,编码器主要由卷积层和池化层组成,其功能是滤波和提取不变特征,具体的计算流程包括:首先初始化 k 个卷积核(W)及其偏置(b),然后通过这些卷积核与输入图像(x)进行卷积操作,生成多个特征图 h ,然后特征图经过激活函数激活,表示为

$$h^k = \sigma(W^k \times x + b^k) \quad (1)$$

式中, h^k 代表卷积过程, σ 代表激活函数, W^k 代表卷积核, b^k 代表偏置。

在解码器部分,卷积层执行反卷积和上采样操作,将每个编码后的特征图 h 与对应卷积核的转置进行卷积,结果累加后再加上偏置 c ,并通过激活函数 σ 进行激活,从而重构输入图像,解码过程可以表示为

$$y = \sigma(\sum_k \hat{W}^k \times h^k + c) \quad (2)$$

式中, $\hat{W}$ 表示卷积核的转置。

最小化输入样本与其重构结果之间的损失来训练模型。在使用欧几里得距离作为损失函数时,其基本计算公式如下:

$$L = \frac{1}{2n} \sum_{i=1}^n (x_i - y_i)^2 \quad (3)$$

式中, x_i 表示第 i 个样本的原始值, y_i 表示第 i 个样本的重构值, n 是样本总数, $1/2n$ 是一个常数因子,用于缩放损失函数的值。除以 n 是为了使损失函数不依赖于样本的数量,即规范化损失,除以2是为了在求导时简化计算。

I-DINCAE网络主要在DINCAE网络中引入Inception模块对编码器输出进行多尺度处理,用于从编码器输出中提取多尺度特征。通过在中间层的特征图上使用不同大小的卷积核来丰富模型所学习的特征,这些结果通过 1×1 卷积层进行级联和合并。此外,对不同级别解码器的输出进行重新采样和连接,以形成更全面的特征表示,提高了模型在数据重构中的准确性。

Inception模块能够高效扩展网络的深度和宽度,显著提高网络性能(Masci等, 2011)。该架构的核心在于多尺度卷积与并行结构的创新结合。通过在网络中并行运用不同大小的卷积核和池化层,Inception架构成功捕获了图像中不同尺度的特征信息,进一步丰富了特征表示的层次性,具体来说,该模块融合了3种不同尺度的卷积核,包括 1×1 、 3×3 和 5×5 ,从而能够提取出不同层次的图像特征信息。这种设计使得特征图能够覆盖不同大小的感受野,有效平衡了网络的宽度和深度,进而提升了网络的整体性能。此外,为了降低计算复杂度并调整特征图的尺寸,Inception模型还引入了 1×1 卷积核进行降维,这一策略不仅减少了计算量,还有助于优化特征图的维度,使其更加适应后续的网络处理。

I-DINCAE的结构包括输入层、编码器层、全连接层、解码层和输出层部分。完整的网络结构如图1所示:

(1) 输入层用于接收训练数据集(训练阶段)和测试数据集(重构阶段)。在输入层中,噪声被随机添加到数据中。

(2) 在编码层中,关键特征被提取并且重要信息得以保留。具体而言,卷积层通过使用尺寸为 3×3 的卷积核,负责从输入数据中提取特征。池化层对卷积层提取的特征进行压缩,压缩程度由池化层的类型、大小和步幅决定,池化层大小为 (2×2) ,步长为 (2×2) 。Inception模块用于提取图像中不同尺度的特征信息(彭进业等, 2023),该模块融合了3种不同尺度的卷积核,包括 1×1 、 3×3 和 5×5 ,并引入了 1×1 卷积核进行降维。

(3) 全连接层相当于传统前馈神经网络中的隐藏层。它们的功能是以非线性方式组合所有提取的特征,从而增强模型拟合能力。本研究中包含两个完整的连接层,两个完全连接的层被配置为具有 $N/5$ 和 N 的大小。其中 N 是编码器最后一个池化层中的神经元数量。




图1 I-DINCAE网络结构

Fig. 1 I-DINCAE network structure diagram

(4) 解码层包括卷积层和采用最近邻插值的插值层，通过转置卷积层和插值层实现特征图的上采样。为了恢复编码层及完全连接层中可能丢失的精细尺度信息，池化层的输出被跳过并直接连接到插值层以进行上采样。

(5) 输出层引入残差连接，将解码层每一层的输出添加到网络的输出中。输出大小为 $300 \times 300 \times 2$ ，包括两个参数：

Y_{ij1} : SST按预期误差方差的倒数缩放；

Y_{ij2} : 预期误差方差的倒数的对数。

本研究中有5个编码层和5个解码层，根据预期误差方差的倒数的对数函数计算相应的误差方差 $(\hat{\sigma}_{ij}^2)$ 、重构海表温度值 $(\hat{y}_{ij})$ 计算如下：

$$\hat{\sigma}_{ij}^2 = \frac{1}{\max(\exp(\min(Y_{ij1}, \gamma)), \delta)} \quad (4)$$

$$\hat{y}_{ij} = Y_{ij2} \hat{\sigma}_{ij}^2 \quad (5)$$

式中， $\gamma = 10$ ， $\delta = 0.001/^{\circ}\text{C}^2$ ，这是为了防止分母趋近零值。 i 和 j 代表数据网格中每个单元的位置， $\max$ 和 $\min$ 分别表示取最大值和最小值的函数，与Barth等(2020, 2022)使用的方法相同。

为了实现最佳的重构效果，模型在训练过程中将损失函数作为优化指标。通过反复的迭代训练，模型不断学习并精细调整其内部参数，以逐渐减小损失函数的值，直至达到最小化。损失函数为：

$$J(\hat{y}_{ij}, \hat{\sigma}_{ij}) = \frac{1}{2N} \sum_{ij} \left[\frac{(y_{ij} - \hat{y}_{ij})^2}{\hat{\sigma}_{ij}^2} + \lg(\hat{\sigma}_{ij}^2) + 2\lg(\sqrt{2\pi}) \right] \quad (6)$$

式中， y_{ij} 为原始SST值， $\hat{y}_{ij}$ 为重构SST值， $\hat{\sigma}_{ij}$ 为重构SST的标准差， N 为数据点的总数。公示6中第1项是标准化残差平方，由误差标准差获得。第2项减少误差标准差的方差，以防止高估。第3项表示归一化的常数。因此，确定参数（即权重和偏置）以使估计和观测值之间的似然（即以高斯概率分布的形式）最大化。由于损失函数与异常估计（即期望误差方差）和期望误差估计都有关，因此DINCAE的优点是在重构和误差估计方面提供可靠的性能。

3.2 DNN模型

DNN是一种由多个神经网络层堆叠而成的复杂模型，按照不同层的作用可分为输入层、隐藏层和输出层共3部分。在DNN中，隐藏层尤为关键，充当了输入层与输出层之间的桥梁，负责在数据从输入传递到输出的过程中，逐步提取和转换数据中的特征。隐藏层是DNN的核心部分，决定了模型学习复杂模式的能力。层与层之间采用全连接的方式，即第 i 层的每一个神经元都与第 $i+1$ 层的每一个神经元通过特定的权重进行连接。这种连接方式确保了信息在神经网络中的充分流通，使得模型能够捕捉到数据中的非线性关系。每个隐藏层包含多个神经元（也称为节点），这些神经元通过各自的权重和偏差与上一层的神经元相连。当数据从输入层传递到隐藏层时，每个神经元会将其接收到的输入数据与对应的权重相

乘，并加上一个偏差项，然后通过一个激活函数进行非线性转换，产生该神经元的输出。这个过程在隐藏层的每个神经元中都会重复进行，从而逐步将输入数据转换为更高层次的特征表示。虽然 DNN 的结构较为复杂，但从组成其基础的单个局部模型来看，仍类似于感知机，均由线性关系及相应的激活函数组成，DNN 网络模型结构如图 2 所示：




图2 DNN 网络结构
Fig. 2 DNN network structure

DNN 包含两个过程，分别为前向传播 FP (Forward Propagation) 和反向传播 BP (Backward Propagation)。神经网络的前向传播算法是指将输入数据通过网络的各层，最终得到输出的过程。在深度神经网络中，前向传播是从输入层到输出层的过程，利用上一层的输出计算下一层的输出，每一层都对输入进行加权、激活，并将结果传递给下一层，逐层进行前向计算，直至输出层。前向传播包括输入层到隐藏层的传播和隐藏层到输出层的传播。

3.2.1 数据集选取

FY-3C SST 数据是网格数据，实测数据提供的是离散点数据，二者数据格式存在差异。因此，在建立神经网络模型之前，首先需要对卫星数据与实测数据进行时空匹配。以订正后的重构 SST 为基准，本研究使用 iQuam SST 数据集的经纬度和时间信息在 1.5 h 的时间窗口内与卫星遥感获取的海表温度数据进行匹配（宋晚郊 等，2022；Jung 等，2022），总计 59963 个样本点，全体样本点分布较为均匀地覆盖研究区域。2014 年—2020 年每年的有效数据个数为 10251、17868、8808、8276、9442、4932、386。为了研究模型参数设置对于模型结果的影响，同时考虑到当前设备有限的计算能力，将其按照 4:1 的比例随机分配到训练集和测试集中，训练集的样本容量为 47970 个样点，测试集的样本容量 11993 个样点。

3.2.2 模型结构的选择

在深度神经网络（DNN）模型的训练过程中，对模型结构的选择至关重要。模型结构直接决定了网络能够学习和表示数据特征的能力，以及最终结果的精度。不同的模型结构，如节点个数、步长、隐藏层层数、迭代次数等参数均对模型的性能产生重要影响。为使 DNN 模型发挥最佳效果，本文进行了多次不同参数设置的实验，对于每一参数设置，均进行了多次重复实验。在训练过程中，采用五折交叉验证方法，将训练数据集划分为两个不重叠的子集，每个子集交替作为验证数据集，其余 4 个子集组合作为训练数据集。

（1）隐藏层层数和节点数。如果隐含层节点数目过少，则导致模型数据拟合能力变差，容错性较差，缺乏鲁棒性；如果隐含层节点数目过多，将导致模型结构复杂，从而使模型效率降低甚至发生过拟合现象。为了评估模型层数和节点数在训练过程中的影响，改变模型的层数和节点数，对比模型的误差，可以确定最佳的模型层数和节点数方案，参与实验的模型结构如表 1 所示：

表 1 不同层数和节点数的模型的误差比较
Table1 Comparison of errors in models with different layers and nodes

实验	隐含层层数	节点数	测试集误差/℃	
			RMSE	MAE
1	1	16	0.953	0.744
2	1	32	0.876	0.669
3	1	64	0.772	0.591
4	1	128	0.656	0.499
5	2	16、32	0.664	0.507
6	2	16、64	0.654	0.499
7	2	32、64	0.637	0.490
8	3	16、32、16	0.615	0.468
9	3	16、64、16	0.593	0.451
10	3	16、32、64	0.585	0.443
11	3	32、64、128	0.613	0.464
12	4	16、32、64、128	0.630	0.476
13	4	164、128、256、64	0.626	0.472
14	5	16、32、64、32、16	0.631	0.476
15	5	32、64、128、64、32	0.620	0.466

在模型结构和节点数的试验中，本文测试了从单隐藏层到 5 个隐藏层的模型结构。在每个特定的层数配置下，进一步调整了每一层的节点数量，

以观察其对模型性能的影响。结果表明：当隐含层层数为3层，隐含层节点数分别为16、32、64时，模型精度最高。

(2) 步长。步长就是网络更新一次权重所需要的数据样本的个数，步长的大小会影响模型的优化程度和速度。太小的步长会使梯度来回变化，使网络很难收敛；太大的步长，就会影响网络的训练轮数。因此，研究模型在确定隐藏层层数和节点数的条件下，分别选取16、32、64、128作为步长来训练数据，实验结果表明：当步长大小为64时，结果最好。

(3) 迭代次数。在确定了包含3个隐含层的模型结构以及合适的步长大小后，通过逐步增加训练的迭代次数，探究迭代次数对模型性能的影响。实验结果表明，随着迭代次数的增加，模型在测试数据上的误差不断减小，若继续增加迭代次数，模型的精度仍有可能得到一定程度的提升，但提升速度逐渐放缓，为了保证模型的训练效率，最终将本文模型的迭代次数确定为500次。

根据验证数据精度对模型参数进行调整，最终确定了一个4层结构的DNN模型，其中第1层为输入层，第2层为隐藏层节点个数为16个，第3层为隐藏层节点个数为32个，第4层为隐藏层节点个数为64个，最后一层的输出隐藏层节点个数为1个，Dropout为0.3，激活函数选择为Relu，迭代次数500次，步长64，初始学习率为0.001，优化函数选择为Adam。其各项参数的最优配置如表2所示。

表2 DNN模型参数设置
Table2 DNN model parameter settings

参数	最优值
隐藏层	3
节点数	16、32、64
激活函数	Relu
优化方式	Adam
Dropout	0.3
迭代次数	500
学习率	0.001

4 结果与分析

4.1 海表温度重构结果

为了评估重构方法的准确性，本研究采用交

叉验证方法。交叉验证集包括1951415个有效重叠像素。其中验证数据集并未参与模型的训练或重构过程，确保了评估结果的客观性。为了量化评估重构的效果，本研究选择了决定系数(R^2)、均方根误差(RMSE)和偏差(Bias)这3个关键参数。在对比DINCAE算法与I-DINCAE算法的重构性能时，分析显示DINCAE算法重构的数据与原始数据之间的相关性为0.93，均方根误差为0.41℃。而I-DINCAE算法则显示出更高的性能，其重构数据与原始数据之间的相关性达到了0.96，同时均方根误差降低至0.37℃。为了更直观地展现两种算法重构效果的差异，绘制了重构数据和相应原始数据的散点密度图(图3)。该图通过颜色编码直观地反映了数据的分布和散点频率。图中的每个散点都代表了一对来自原始数据和重构数据的值，而颜色的深浅则代表了该组合出现的频率。通过观察图中的分布，可以看出I-DINCAE算法的重构结果不仅在RMSE上表现出更低的误差，而且在散点图上更接近于1:1的拟合线，这进一步证明了I-DINCAE算法在重构海表温度数据方面具有较高的准确性和可靠性。

为了全面评估利用I-DINCAE方法重构的SST数据的在不同区域的空间重构精度，绘制了图4。可见重构SST与原始SST之间的空间误差分布，为了更精确地量化重构SST与原始SST之间的差异，本研究采用了多个关键误差度量指标来量化重构SST与原始SST之间的差异，包括均方根误差(RMSE)、偏差(Bias)和误差标准偏差(Error standard deviation)，可以更直观地看出空间上重构算法的精度高低。

重构数据与原始数据之间的均方根误差分布如图4(a)所示。可见：误差值的范围从0—0.8℃，近岸和陆地接壤地带的均方根误差大，部分海域区域的重构误差较小。图4(b)为重构数据相对于原始数据的偏差，直观反应模型重构数据相比于原始数据的高低程度。可见：偏差为-0.1—0.25℃，大部分区域偏差较小，但存在一些局部区域(尤其是近岸区域)显示较大的正偏差。图4(c)描述了重构数据的误差标准偏差，用于衡量残差的变异性或散布程度，标准偏差越小重构值与原始值之间的一致性越高。可见：误差标准偏差0—0.6℃，部分近岸区域的重构误差较大，海洋部分的重构误差相对较小。在近岸区域的

I-DINCAE 重构结果的均方根误差、偏差、误差标准差都偏高，在离岸地区的值要低，说明算法在

海洋区域的适用性优于近岸区域。




图3 不同重构方法 SST 和原始 SST 数据的散点密度
Fig. 3 Scatter density of different reconstructed methods SST and original SST




图4 原始 SST 与重构 SST 的空间误差分布
Fig. 4 The spatial error distribution of the original SST and reconstructed SST

为了进一步验证空间重构能力，选择2019年12月20日的数据，比较原始数据和重构数据的空间分布，结果见图5。图5 (a) — (c) 分别为原始SST数据，使用I-DINCAE算法的重构图像及重构数据和相应原始数据的散点图 (c)。由图5 (c) 可见：显重构数据和原始数据之间的 R^2 为 0.96，RMSE 为 0.34 °C，偏差为 0.12 °C，表明二者之间具有良好的一致性。反映原始 SST 图像的分布趋势：冬季，沿海地区的 SST 比附近海域低，这与海水和

陆地的热容差异一致。
为了探究数据有效覆盖率对网络空间重构能力的影响，本研究选取了5个具有不同数据缺失率的 SST 数据进行重构分析。这些数据分别采集于2018年3月4日、2019年4月3日、2018年11月28日、2015年12月25日和2018年4月1日，受云或其他因素影响而呈现不同程度的污染，其缺失率依次为 14.03%、24.20%、32.13%、49.21% 和 62.99%。通过计算每幅影像中有效数据点处原始

SST与重构SST之间的均方根误差（RMSE）、平均绝对误差（MAE）和决定系数（ R^2 ），得到了不同缺失率下的重构SST精度，详见表3。可见，随着数据缺失率的上升，重构误差也随之显著增大，这表明在数据不完整的情况下，重构的准确性受到影响。





图5 空间重构能力验证
Fig. 5 The verification maps of spatial reconstruction capability

表3 不同缺失率下重构SST的精度
Table 3 Accuracy indicators for reconstructing SST under different missing rates

缺失率/%	N(有效点数)	RMSE/°C	MAE/°C	R^2
14.03	63766	0.298	0.192	0.943
24.20	56179	0.325	0.210	0.918
32.13	50216	0.343	0.215	0.901
49.21	37430	0.463	0.298	0.889
62.99	27107	0.518	0.362	0.758

图6分析了不同数据缺失率的原始SST与I-DINCAE算法重构SST的直观对比及散点图。通过

对比原始SST和I-DINCAE图像，详见图6（a）、（b）、（c）、（d）、（e）中I和II，可见：重构SST与原始SST的空间分布趋势一致，I-DINCAE算法补齐了原始数据的空间缺失，说明I-DINCAE算法在数据重构的强大能力。为更直观地评估重构数据的质量，对比原始SST与重构SST之间的散点图，详见图6（a）、（b）、（c）、（d）、（e）中III。可见：即使在较高的缺失率下，I-DINCAE算法重构的数据仍能较好地反映当天的SST分布趋势；然而，随着数据缺失率的上升，重构数据的质量也呈现出一定程度的下降，说明算法精度会受到数据缺失的影响。






图6 不同缺失率下的重构结果
Fig. 6 Reconstruction results under different missing rates

4.2 海表温度重构结果校正

为了验证校正后的 SST 数据的准确性，将测试数据集输入到训练好 DNN 模型中，并计算模型生成的温度值与实测温度值之间的决定系数 (R^2)、均方根误差 (RMSE) 和平均绝对误差 (MAE)，结果见表 4。可见：重构 SST 与实测 SST 的 RMSE 为 1.27 °C，MAE 为 0.96 °C， R^2 为 0.84，与实测数据存在一定差异，而经过 DNN 模型校正后，RMSE 降至 0.57 °C，MAE 降至 0.43 °C， R^2 提升至 0.92。这一结果说明通过 DNN 模型的校正能够有效地减小重构 SST 与实测 SST 之间的误差，显著提高 SST 数据的准确性。

为进一步验证 DNN 模型的有效性，选择代表

不同季节的 4 个不同日期（2019 年 3 月 1 日、6 月 22 日、9 月 24 日和 12 月 20 日）的 SST 数据，以评估原始数据、重构数据和校正数据与实测数据之间的相关性，这 4 天的数据没有用于训练。在这 4 天中共有 42 个实测数据点在空间和时间上与卫星 SST 数据相匹配，这些点相对均匀的分布在研究区域，其空间分布详见表 5。

表 4 校正前后的精度比较
Table4 Comparison of accuracy before and after correction

数据	RMSE/°C	MAE/°C	R^2
重构 SST	1.27	0.96	0.84
校正 SST	0.57	0.43	0.92

表 5 实测数据的空间分布
Table 5 Spatial distribution of validation data

日期	纬度/(°)	经度/(°)	实测数据/°C	日期	纬度/(°)	经度/(°)	实测数据/°C
2019-03-01	16.99	109.83	26.24	2019-06-22	19.40	111.90	31.00
2019-03-01	16.75	109.71	26.29	2019-06-22	8.65	111.92	29.80
2019-03-01	16.74	109.71	26.29	2019-06-22	8.65	111.92	29.70
2019-03-01	16.72	109.71	26.30	2019-06-22	8.02	110.62	29.90
2019-03-01	8.68	106.60	26.40	2019-06-22	11.42	114.33	30.20
2019-03-01	8.65	111.92	26.90	2019-06-22	10.80	111.60	30.00
2019-03-01	7.00	115.20	27.00	2019-06-22	17.30	113.90	31.00
2019-03-01	14.70	115.70	27.00	2019-06-22	8.65	111.92	29.30
2019-03-01	12.09	116.90	27.25	2019-06-22	11.42	114.33	30.30
2019-03-01	12.13	116.94	27.26	2019-09-24	17.00	118.00	28.30
2019-03-01	6.26	107.83	27.27	2019-09-24	8.02	110.62	28.60
2019-03-01	12.09	116.91	27.27	2019-09-24	8.80	109.20	28.70
2019-03-01	8.02	110.62	27.30	2019-09-24	14.70	109.54	29.36
2019-03-01	6.39	107.98	27.34	2019-09-24	14.73	109.53	29.37
2019-03-01	8.00	109.50	27.80	2019-09-24	14.76	109.53	29.37
2019-03-01	11.90	112.30	28.00	2019-09-24	15.34	109.44	29.43
2019-03-01	14.80	112.50	28.00	2019-12-20	17.59	109.51	24.80
2019-03-01	16.00	116.00	28.00	2019-12-20	17.63	109.68	24.90
2019-03-01	16.20	116.10	28.00	2019-12-20	19.39	117.58	25.24
2019-03-01	16.40	116.30	28.00	2019-12-20	13.00	112.80	25.50
2019-06-22	15.80	115.90	30.50	2019-12-20	8.02	110.62	28.40

本研究还分析了原始数据、重构数据、校正数据与实测数据之间的相关性，详见图 7。可见：原始数据和实测数据之间的 R^2 为 0.84，均方根误差为 1.26 °C；与实测数据相比，重构数据的 R^2 为

0.83，均方根误差为 1.21 °C，而调整后的数据与实测数据之间的 R^2 为 0.93，均方根误差为 0.59 °C。这表明校正后的 SST 提高了精度，调整后的 SST 数据与实测数据的一致性最高。




图7 实测SST和卫星SST之间的散点图

Fig. 7 Scatters between the measured SST and satellite SST

4.3 南海海表温度时空变化分析

4.3.1 南海季节平均SST时空变化特征

将南海的3—5月划分为春季, 6—8月划分为夏季, 9—11月划分为秋季, 12月—次年2月划分为冬季, 对南海季节平均SST空间分布特性进行分析, 详见图8 (a)、(b)、(c)、(d)。可见: 南海海表温度呈现显著的季节性变化, 冬季的海温普遍最低、夏季最高、春季与秋季的海温接近, 但秋季的海温略高于春季, 呈现典型的热带海洋季节性温度差异。此外, 在春季, 随着太阳辐射的增强和冬季风的减弱, 大陆沿岸的寒流影响减少, 导致南部海域的温度显著升高, 南海区域的海温沿着沿岸到外海方向呈现升高趋势, 构成了“东南—西北”型的分布模式, 见图8 (a); 进入夏季, 28 °C以上的高温海水几乎覆盖了整个南海, 温度分布较为均匀, 整个南海的海表温度变化较小, 突显出热带海表温度在夏季达到高值的典型特征, 见图8 (b); 秋季随着太阳辐射的逐渐减弱和冬季风开始影响, 南海北部及中南半岛东侧海域的温度逐步下降, 暖水团向东南方向退去, 温度呈现东南至西北向递减, 并表现出明显的季节性温度变化趋势, 见图8 (c); 冬季, 南海的大部分区域海温降至27 °C以下, 标志着该海域达到一年中海表温度的最低点。在空间分布特征上, 南部区域高于北部、东部高于西部, 形成了清晰的温度变化趋势, 自东南向西北方向递减, 反映了东北季风对沿岸寒流强烈影响,

见图8 (d)。整体而言, 南海的海表温度季节性分布呈现出由于太阳辐射和季风循环共同作用下的明显热力学特性, 这种分布不仅体现了热带海洋的季节性温度变化, 也反映了大尺度气候动力过程对区域海温分布的重要影响。

4.3.2 南海月平均SST时空变化特征

为了进一步分析南海SST的演化特征, 对1—12月中国南海月平均SST空间分布状况进行分析, 详见图10中1—12月海表温度空间分布。可见: 南海近海海域整体SST空间分布相似, 由近岸到离岸海域表层温度呈阶梯状分布, 近岸海域海表温度低, 离岸海域海表温度高, 这可能是因为南海地区存在复杂的海洋环流系统, 如南海暖流、黑潮等。这些海洋环流会影响海洋表层的热量分布和传递, 导致近岸海域和离岸海域的温度差异。南海的海温在一年内经历了显著的变化, 首先是春季, 3月随着太阳辐射的增强和冬季风的减弱, 大陆沿岸的寒流影响减弱, 南部海域的温度逐渐升高。4月和5月海温继续上升, 南部海域的海温明显高于北部, 整个南海区域的海温从沿岸向外海方向呈现升高的趋势, 总体上呈现温暖的特征, 见图9 (a)、(b)和(c)。其次是夏季, 南海海温达到全年峰值, 几乎整个南海被28 °C以上的高温海水覆盖, 温度分布均匀, 突显出热带海洋在夏季的典型高温特征。6月、7月、8月的南海海温较高, 高温海水覆盖范围广泛, 海域内部温度变化不大, 见图9 (d)、(e)、(f)。再次是秋季, 南海海域的海温开始逐渐下降。9月随着太阳辐射的减弱和冬季风的开始影响, 南海北部及中南半岛东侧海域的温度逐步下降, 暖水团向东南方向退去, 展现出明显的递减趋势。10月、11月, 秋季海温继续下降, 南海海域的海温分布开始出现明显的季节性变化, 北部海域的温度相对较低, 而南部海域也开始逐渐降温, 见图9 (g)、(h)、(i)。最后是冬季, 到了12月南海海温进一步下降, 受东北季风影响, 南海大部分区域的海温降至27 °C以下, 南部和东部海温相对较高, 形成明显的温度梯度, 并呈现出西南至东北向的等温线分布, 反映了东北季风下沿岸寒流的强烈影响。这一周期性变化不仅体现了南海地区的气候特征, 也对海洋生态系统产生了深远的影响。





图8 南海季节平均 SST
Fig. 8 Seasonal mean SST in the South China Sea






图9 南海区域月平均海表温度
Fig. 9 Monthly mean sea surface temperature map of the South China Sea

5 讨论与结论

首先，本研究提出的I-DINCAE重构方法显著提升了SST重构精度（RMSE=0.37 °C），较传统DINCAE降低9.8%，且在高缺失率（>60%）下仍保持鲁棒性。DNN校正模型显著降低了重构SST与实测数据的误差（RMSE从1.27 °C降至0.57 °C， R^2 从0.84提升至0.92），为南海高精度SST产品提供了可行的技术方案。基于本研究的海表温度重构方法，对南海季节和月度SST进行分析，南海SST呈现显著的季节与月度变化。夏季达全年峰

值、冬季最低；月度变化呈正弦波动，6月为极大值、1月为极小值。空间上表现为东南高、西北低的梯度分布，受太阳辐射与季风环流共同调控，为南海生态环境研究提供了数据参考。

其次，本研究重构算法与传统的DINCAE模型相比，I-DINCAE通过引入Inception模块，有效捕捉了多尺度空间特征，将重构SST与原始数据的相关性从0.93提升至0.96，RMSE从0.41 °C降至0.37 °C。这一结果与Jung等（2022）的研究一致，表明深度学习中多尺度特征融合能显著提升遥感数据的重构精度。然而，与Goh等（2023）提出的掩

码自动编码器 (MAE) 相比, 本模型在云污染严重区域 (缺失率>60%) 的重构误差 (RMSE=0.518 °C) 仍略高于 MAE 在类似场景的表现。这可能源于 MAE 对随机掩码的鲁棒性训练策略, 而 I-DINCAE 更依赖局部上下文信息。未来可结合掩码预训练策略, 进一步提升模型对极端缺失数据的适应性。

再次, 在数据校正方面, DNN 模型将重构 SST 的 RMSE 从 1.27 °C 显著降低至 0.57 °C, 优于 Pisoni 等 (2008) 基于 ANN 的校正结果。这得益于 DNN 对非线性关系的强大拟合能力, 与 Bolton、Zanna 等 (2019) 提出的深度学习在海洋数据建模中的优势一致。值得注意的是, 校正后数据在实测验证中表现出高一致性 ($R^2 = 0.92$), 但在近岸浅海区域仍存在微小偏差 (Bias = 0.12 °C), 这与南海沿岸复杂的水动力过程有关, 传统卫星数据难以完全捕捉其细节。后续研究可引入多源数据 (如盐度、风场) 联合建模, 以增强校正模型的物理一致性。

最后, 该海表温度重构方法在南海区域得到有效验证, 未来可扩展至全球其他海域。同时, 随着南海更多数据的积累, 可以对更长时间序列的海表温度数据进行深入探讨, 以揭示更为全面和长期的变化趋势, 为应对海洋环境变化的挑战和保护提供支撑。

参考文献 (References)

- Barth A, Alvera-Azcárate A, Licer M and Beckers J M. 2020. DIN-CAE 1.0: a convolutional neural network with error estimates to reconstruct sea surface temperature satellite observations. *Geoscientific Model Development*, 13(3): 1609-1622 [DOI: 10.5194/gmd-13-1609-2020]
- Barth A, Alvera-Azcárate A, Troupin C and Beckers J M. 2022. DIN-CAE 2.0: multivariate convolutional neural network with error estimates to reconstruct sea surface temperature satellite and altimetry observations. *Geoscientific Model Development*, 15(5): 2183-2196 [DOI: 10.5194/gmd-15-2183-2022]
- Bolton T and Zanna L. 2019. Applications of deep learning to ocean data inference and subgrid parameterization. *Journal of Advances in Modeling Earth Systems*, 11(1): 376-399 [DOI: 10.1029/2018MS001472]
- Brasnett B and Colan D S. 2016. Assimilating retrievals of sea surface temperature from VIIRS and AMSR2. *Journal of Atmospheric and Oceanic Technology*, 33(2): 361-375 [DOI: 10.1175/JTECH-D-15-0093.1]
- Ducournau A and Fablet R. 2016. Deep learning for ocean remote sensing: an application of convolutional neural networks for super-resolution on satellite-derived SST data//2016 9th IAPR Workshop on Pattern Recognition in Remote Sensing (PRRS). Cancun: IEEE: 1-6 [DOI: 10.1109/PRRS.2016.7867019]
- Goh E, Yepremyan A, Ward I, Ward I, Wang J B and Wilson B. 2023. Reconstruction of sea surface temperature under clouds using masked autoencoders//IGARSS 2023-2023 IEEE International Geoscience and Remote Sensing Symposium. Pasadena: IEEE: 1076-1079 [DOI: 10.1109/IGARSS52108.2023.10282485]
- He H L, Li Y, Wang Y, Song X S and Liu X H. 2013. Reconstruction of chlorophyll a mass concentration in the East China sea using data interpolating empirical orthogonal functions. *Journal of Marine Sciences*, 31(2): 10-15 (何海伦, 李熠, 王渊, 宋迅殊, 刘晓辉. 2013. 利用经验正交函数数据插值法重构东中国海叶绿素 a 质量浓度场. *海洋学研究*, 31(2): 10-15) [DOI: 10.3969/j.issn.1001-909X.2013.02.002]
- He L X. 2022. Research on the Relationship Between Key Environmental Factors and Typical Fishery Resources in the Northwestern South China Sea. Zhanjiang: Guangdong Ocean University (何露雪. 2022. 南海西北海域关键环境要素与典型渔业资源的关系研究. 湛江: 广东海洋大学) [DOI: 10.27788/d.cnki.ggdhy.2022.000152]
- Huang C M, Chen X Y, Wang X and Chen G. 2024. Correlation analysis of the sea surface features under eddy modulation in the global ocean using remote sensing data. *National Remote Sensing Bulletin*, 28(8): 2002-2013 (黄春铭, 陈笑炎, 王璇, 陈戈. 2024. 中尺度涡调制下全球海洋遥感特征相关性分析. *遥感学报*, 28(8): 2002-2013) [DOI: 10.11834/jrs.20231830]
- Jung S, Yoo C and Im J. 2022. High-resolution seamless daily sea surface temperature based on satellite data fusion and machine learning over Kuroshio Extension. *Remote Sensing*, 14(3): 575 [DOI: 10.3390/rs14030575]
- Klein S A, Soden B J and Lau N C. 1999. Remote sea surface temperature variations during ENSO: evidence for a tropical atmospheric bridge. *Journal of Climate*, 12(4): 917-932 [DOI: 10.1175/1520-0442(1999)012<0917:RSSTVD>2.0.CO;2]
- Li J, Sun W F and Zhang J. 2023. Reconstruct infrared sea surface temperature data based on an improved DINCAE method//IGARSS 2023-2023 IEEE International Geoscience and Remote Sensing Symposium. Pasadena: IEEE: 4120-4123 [DOI: 10.1109/IGARSS52108.2023.10281656]
- Liu M K, Guan L, Liu F L and Liu J Q. 2023. Retrieval and validation of sea surface temperature from HY-1D COCTS. *National Remote Sensing Bulletin*, 27(4): 953-964 (刘铭坤, 管磊, 刘凡莉, 刘建强. 2023. HY-1D COCTS 海表温度反演与印证. *遥感学报*, 27(4): 953-964) [DOI: 10.11834/jrs.20221689]
- Liu Y Y, Wang S J, Liu J, Gong Z S and Jia X L. 2021. Evaluation of FY-3/VIRR sea surface temperature data for climate applications. *Journal of Meteorological Research*, 35(6): 952-963 [DOI: 10.1007/s13351-021-1055-5]
- Luo X M, Song J, Guo J R, Fu Y Z, Wang L H and Cai Y. 2022. Reconstruction of chlorophyll-a satellite data in Bohai and Yellow sea based on DINCAE method. *International Journal of Remote Sens-*

- ing, 43(9): 3336-3358 [DOI: 10.1080/01431161.2022.2090872]
- Masci J, Meier U, Cireşan D and Schmidhuber J. 2011. Stacked convolutional auto-encoders for hierarchical feature extraction//21st International Conference on Artificial Neural Networks on Artificial Neural Networks and Machine Learning-ICANN. Espoo: Springer: 52-59 [DOI: 10.1007/978-3-642-21735-7_7]
- Meng L S, Yan C, Zhuang W, Zhang W W, Geng X P and Yan X H. 2021. Reconstructing high-resolution ocean subsurface and interior temperature and salinity anomalies from satellite observations. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 4104114 [DOI: 10.1109/TGRS.2021.3109979]
- Park J, Kim J H, Kim H C, Kim B K, Bae D, Jo Y H, Jo N and Lee S H. 2019. Reconstruction of ocean color data using machine learning techniques in polar regions: focusing on off Cape Hallett, Ross Sea. *Remote Sensing*, 11(11): 1366 [DOI: 10.3390/rs11111366]
- Peng J Y, Yu Z, Qu S Y, Hu Q Y and Wang J. 2023. A survey of image inpainting methods based on deep learning. *Journal of Northwest University (Natural Science Edition)*, 53(6): 943-963 (彭进业, 余喆, 屈书毅, 胡琦瑶, 王珺. 2023. 基于深度学习的图像修复方法研究综述. *西北大学学报(自然科学版)*, 53(6): 943-963) [DOI: 10.16152/j.cnki.xdxbzr.2023-06-006]
- Pisoni E, Pastor F and Volta M. 2008. Artificial neural networks to reconstruct incomplete satellite data: application to the mediterranean sea surface temperature. *Nonlinear Processes in Geophysics*, 15(1): 61-70 [DOI: 10.5194/npg-15-61-2008]
- Song W J, Zhang P, Sun L, Tang S H and Zhou F C. 2022. Reconstruction of sea surface temperature from DINEOF-based FY polar-orbiting meteorological satellite. *Journal of Marine Sciences*, 40(2): 10-18 (宋晚郊, 张鹏, 孙凌, 唐世浩, 周芳成. 2022. 基于DINEOF的风云极轨气象卫星海表温度重构方法研究. *海洋学研究*, 40(2): 10-18) [DOI: 10.3969/j.issn.1001-909X.2022.02.002]
- Venkat Shesu R, Udaya Bhaskar T V S, Pattabhi RamaRao E, Ravichandran M and Venkateswara Rao B. 2021. An improved method for quality control of *in situ* data from Argo floats using α convex hulls. *MethodsX*, 8: 101337 [DOI: 10.1016/j.mex.2021.101337]
- Wang S J, Cui P, Zhang P, Yang Z D, Ran M N, Hu X Q, Lu F and Liu J. 2017. Progress of VIRR sea surface temperature product of FY-3 satellite. *Aerospace Shanghai*, 34(4): 79-84 (王素娟, 崔鹏, 张鹏, 杨忠东, 冉茂农, 胡秀清, 陆风, 刘健. 2017. FY-3 卫星 VIRR 海表温度产品进展. *上海航天*, 34(4): 79-84) [DOI: 10.19328/j.cnki.1006-1630.2017.04.010]
- Xiong Y K. 2023. Deep Learning-Based Reconstruction of Chlorophyll a Data and Its Spatial and Temporal Variation Characteristics. Guilin: Guilin University of Technology (熊远康. 2023. 基于深度学习的叶绿素 a 数据重构及其时空变化特征研究. 桂林: 桂林理工大学) [DOI: 10.27050/d.cnki.gglgc.2023.000951]
- Xu B, Yu J J, Zhang L, Shi C X and Zhou Z J. 2018. Research progress of global sea surface temperature fusion. *Advances in Meteorological Science and Technology*, 8(1): 164-170 (徐宾, 宇婧婧, 张雷, 师春香, 周自江. 2018. 全球海表温度融合研究进展. *气象科技进展*, 8(1): 164-170) [DOI: 10.3969/j.issn.2095-1973.2018.01.022]
- Zheng X L, Dong Q and Fan X. 2020. Characteristics of sea surface temperature and Chlorophyll concentration inside mesoscale eddies in the North Pacific Ocean. *Journal of Remote Sensing*, 24(1): 85-96 (郑晓莉, 董庆, 樊星. 2020. 北太平洋中尺度涡海表温度和叶绿素浓度特征分析. *遥感学报*, 24(1): 85-98) [DOI: 10.11834/jrs.20208215]
- Zhong B J, Lu Z F and Ji J H. 2016. Review on image interpolation techniques. *Journal of Data Acquisition and Processing*, 31(6): 1083-1096 (钟宝江, 陆志芳, 季家欢. 2016. 图像插值技术综述. *数据采集与处理*, 31(6): 1083-1096) [DOI: 10.16337/j.1004-9037.2016.06.002]

Sea surface temperature reconstruction based on deep learning and its application on the spatiotemporal analysis of SST variation in the South China Sea

SUN Zhiwei^{1,4}, LI Yunbo², ZHANG Dianjun¹, SUN Shaojie³, CHEN Siyu³

1. School of Marine Science and Technology, Tianjin University, Tianjin 300072, China;

2. Unit No. 91001 of People Liberation Army, Beijing 100161, China;

3. School of Marine Science, SUN YAT-SEN University, Zhuhai 519082, China;

4. Beijing Geoway Info-Tech Co., Ltd., Beijing 100043, China

Abstract: The Sea Surface Temperature (SST) is an important indicator for studying ocean dynamics, ocean-atmosphere interaction, and climate change, which is closely related to multiple marine environmental factors, such as ocean currents, salinity, and nutrient distribution, collectively affecting the balance and evolution of marine ecosystems. Although the traditional SST acquisition methods are precise, they are limited by the number and coverage of sampling points, making it difficult to meet the requirements of large-scale and high-resolution ocean research. Satellite remote sensing data can cover global waters with high update frequency and is widely used in ocean research. However, during the collection process of satellite remote sensing data, SST data are often missing due to factors such as weather conditions, satellite

scanning orbit range, and satellite sensor operation failures, which limits the use of data to some extent. Therefore, precise reconstruction of missing data in satellite remote sensing SST data to obtain high-quality and fully covered SST datasets is of great significance for ocean research. This study incorporates an Inception module into a deep interpolation convolutional autoencoder (DINCAE) and proposes the improved DINCAE (I-DINCAE) model used for data reconstruction of SST products with the FY-3C satellite in the South China Sea. The I-DINCAE is used to reconstruct the missing SST data in the South China Sea from 2014 to 2020, and the reconstruction accuracy of the DINCAE and I-DINCAE models is compared and analyzed. To further improve the accuracy of SST data, deep neural networks (DNNs) are used to calibrate satellite data in combination with the measured data, thereby optimizing the quality of the SST dataset. Finally, based on the corrected SST data, spatiotemporal variation analysis is conducted to reveal the characteristics of SST changes. At the same time, combined with many years of measured data, DNN model is used to calibrate the reconstructed temperature data of the new model. A dataset of 11,993 independent measured data points is used for testing. Results show that the RMSE, MAE, and R^2 of the reconstructed SST and measured SST are 1.27 °C, 0.96 °C, and 0.84, which decreased to 0.57 °C, 0.43 °C, and 0.92 after the DNN model correction, respectively. Based on the corrected SST data, the spatiotemporal distribution and variation characteristics of SST in the South China Sea at monthly and quarterly scales are analyzed from two dimensions of time and space. Results show that on the seasonal scale, the SST of the South China Sea has obvious variation characteristics. This shows that the SST reaches the highest value in the summer, and the SST decreases to the lowest value in the winter. On the monthly scale, the SST variation in the South China Sea presents a sine (cosine) wave form, with SST usually reaching a maximum value in June and a minimum value in January. This study not only reveals the uniqueness of the marine environment in the South China Sea but also provides an important basis for understanding the marine ecosystem and climate change in the South China Sea.

Key words: sea surface temperature, data reconstruction, deep learning, FY-3C, spatio-temporal variation

Supported by National Key Research and Development Program of China (No. 2023YFC3107701); Key Laboratory of Smart Earth (No. KF2023YB03-03)