

基于 SIT-TransNET 的被动微波海冰厚度反演

韩彦岭, 朱晓俊, 王静, 潘海燕, 张云

(上海海洋大学信息学院, 上海 201306)

摘要: 海冰厚度是全球气候变化研究中的关键参数之一, 其在调节地球气候系统、海洋环流和热量交换中具有重要作用。但是, 由于海冰的物理特性高度变化, 使得海冰厚度的精确反演面临巨大挑战。针对该问题, 提出一种多特征融合和改进 Transformer 的被动微波遥感海冰厚度反演方法 SIT-TransNET。该方法利用 AMSR2 卫星的亮度温度数据, 并结合辅助数据(包括雪表面温度、海面盐度和 1.4 GHz 亮度温度), 探讨这些数据与海冰厚度之间的复杂关联, 分析不同特征的重要性并通过建立不同的特征融合方案, 加强对海冰厚度的有效表征; 通过 SIT-TransNET 模型的自注意力机制和多头注意力机制捕捉不同特征及组合对于海冰厚度反演的贡献, 并动态调整不同特征的权重, 实现海冰厚度的精确反演。实验结果表明, 相比其他方法, SIT-TransNET 方法显著提高了海冰厚度反演精度, 决定系数(R^2)达到了 0.96, 均方根误差(RMSE)为 9 cm, 表明此方法适用于海冰厚度反演, 为实现大范围海冰厚度监测和气候变化研究提供了有效的技术手段。

关键词: 海冰厚度; 被动微波; 特征融合; 自注意力机制; 多头注意力机制

中图分类号: TP391

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0070709

Passive Microwave Sea Ice Thickness Inversion Based on SIT-TransNET

HAN Yanling, ZHU Xiaojun, WANG Jing, PAN Haiyan, ZHANG Yun

(College of Information Technology, Shanghai Ocean University, Shanghai 201306, China)

【Abstract】 Sea ice thickness is a key parameter in global climate change research, and it plays a crucial role in regulating the Earth's climate system, ocean circulation, and heat exchange. However, accurate retrieval of sea ice thickness is significantly challenging because of the highly variable physical properties of sea ice. To address this issue, this paper proposes a passive microwave remote sensing method for sea ice thickness retrieval named SIT-TransNET. This method integrates multi-feature fusion and an improved Transformer, and it utilizes brightness temperature data from the Advanced Microwave Scanning Radiometer 2 (AMSR2) satellite combined with auxiliary data (including snow surface temperature, sea surface salinity, and 1.4 GHz brightness temperature) to explore complex relationships between these data and sea ice thickness. Further, this method analyzes the importance of different features and enhances the effective representation of sea ice thickness by establishing various feature fusion schemes. The self-attention and multi-head attention mechanisms of the SIT-TransNET model enable capturing the contributions and combinations of different features and dynamically adjusting the weights of different features for accurate sea ice thickness retrieval. Compared to the other methods, experimental results demonstrate that the SIT-TransNET method significantly improves the accuracy of sea ice thickness retrieval with a coefficient of determination (R^2) of 0.96 and Root Mean Square Error (RMSE) of 9 cm. This confirms that this method is suitable for sea ice thickness retrieval and provides an effective technical method for large-scale sea ice thickness monitoring and climate change research.

【Key words】 sea ice thickness; passive microwave; feature fusion; self-attention mechanism; multi-head attention mechanism

0 引言

海冰覆盖了地球表面约 7% 的区域, 占全球海洋面积约 12%, 是地球气候系统的重要组成部分, 直接影响全球气候变化、海洋循环以及生态环境的

变化。海冰厚度作为其重要物理属性之一, 不仅影响海冰的空间分布和动态演变, 还对全球气候系统产生深远影响^[1-2]。研究海冰厚度有助于全面了解海冰变化趋势及其对气候系统的影响, 保障人类和生态环境的可持续发展。

基金项目: 国家自然科学基金(42176175, 42271335)。

作者简介: 韩彦岭, 女, 教授、博士, 主研方向为海洋灾害遥感、渔业大数据技术; 朱晓俊, 硕士研究生; 王静(通信作者), 副教授、博士; 潘海燕, 讲师、博士; 张云, 教授、博士。

收稿日期: 2024-12-16

修回日期: 2025-02-16

E-mail: wangjing@shou.edu.cn

钻孔测量、声呐、激光雷达等传统的海冰厚度测量方法虽然在局部区域能够提供高精度数据,但受限于设备、时间和空间因素,难以满足大范围、长时序监测的需求。遥感技术的快速发展为迅速、大面积地获取海冰数据提供了技术手段,基于遥感数据的海冰厚度反演逐渐成为研究热点。近年来,深度学习方法的发展为海冰厚度反演带来了新的机遇,深度学习模型能够学习大量数据间的复杂关系,从而实现更高精度的海冰厚度反演,但是在应用过程中也面临着一定的挑战,如遥感数据会受到大气条件、季节变化等的影响。

本文旨在探讨基于遥感数据和深度学习技术的海冰厚度反演方法,结合多源数据与先进的深度学习算法,提出一种提高海冰厚度反演精度的模型。通过对现有方法的评估与改进,本文希望能够提高海冰厚度反演精度,推动海冰监测技术的发展。

1 相关工作

1.1 传统海冰厚度测量方法

在传统的海冰厚度测量方法中,钻孔测量被认为是最高精度的技术,它通过直接测量海冰厚度来提供高精度数据,但由于其高资源消耗和受限于空间尺度,难以广泛应用于大范围的海冰厚度研究。在钻孔测量之外,仰视声呐(ULS)是一种经典的海冰厚度测量方法,它通过测量冰吃水深度来反演冰层的厚度^[3]。尽管 ULS 技术在过去的研究中发挥了重要作用,但由于受限于时间和空间尺度,其难以进行大规模海冰变化的全面分析^[4]。

在科考船和飞机上,常用激光雷达或声呐设备进行海冰厚度测量^[5]。例如,美国航空航天局(NASA)的冰桥行动就利用先进的激光雷达技术,测量了北极地区海冰的表面高程、干舷及雪深等数据,旨在改进海冰厚度的检索算法^[6]。然而,飞机等设备往往受极端天气的影响,难以长期、大范围地进行海冰厚度测量。

1.2 测高卫星和光学遥感反演海冰厚度

卫星遥感技术显著推动了海冰厚度研究的进展,尤其是在长时间、大范围观测方面。CryoSat-2 卫星搭载的合成孔径干涉雷达测高仪(SIRAL)利用微波脉冲向地面发射并接收反射信号,从而计算海冰的干舷,通过静力平衡方程估算冰厚。然而,这种方法对于厚冰的反演较为精确,但对薄冰的反演精度较差,主要受波浪、积雪等因素影响,导致反射信号不稳定,进而影响海冰厚度的精确计算^[7]。

光学遥感利用光学影像和热红外数据反演海冰

厚度,如文献[8]基于多光谱通道的扫描辐射仪 AVHRR 的热红外数据,利用傅里叶热传导定律计算冰层热通量和总热通量,从而估算冰厚。文献[9]使用 MODIS 数据,从渤海的实际情况出发,对于冰厚指数关系模型中海水反照率与衰减系数参数的设置进行反演算法改进,反演结果的平均绝对误差(MAE)由原来的 7.05 cm 缩小到 2.74 cm,相关系数由 0.434 提高到 0.485。但是,光学遥感易受云层、雾霾、降雪等影响,导致数据不准确。

1.3 微波遥感反演海冰厚度

微波遥感技术在海冰厚度反演中的应用日益广泛。合成孔径雷达(SAR)作为一种主动微波遥感技术,在任何气象条件下都能够有效观测海冰厚度^[10]。文献[11]利用 SAR 后向散射系数与海冰厚度建立经验模型反演海冰厚度。文献[12]研究“CP ratio”参数对介电常数和冰层厚度的敏感性,推导出海冰条件和雷达入射角对厚度反演的影响,海冰厚度反演的均方根误差(RMSE)为 8 cm,相关系数为 0.94。但是,SAR 图像受相干效应影响,导致地物信息不够丰富,从而影响反演的准确性^[13]。

被动微波遥感具有全天候观测和大范围覆盖的特点,海冰的微波辐射信号能反映其物理状况^[14],因此,用亮度温度数据反演海冰厚度的方法迅速发展起来^[15]。传统方法使用 SMOS 卫星提供的 L 波段亮度温度数据,通过半经验算法推导海冰厚度。文献[16]利用微波辐射计 SSM/I 的极化比进行多元回归分析,显示 37 与 85 GHz 的垂直极化比与海冰厚度相关性较高。目前,已有研究通过深度学习方法进行海冰厚度反演,如文献[17]利用微波辐射计 AMSR2 提供的被动微波数据,结合一维卷积神经网络(1DCNN)反演海冰厚度,均方根误差为 18 cm,证明被动微波数据与海冰厚度具有一定相关性。文献[15]使用微波辐射器 FMPL-2 的亮度温度数据和辅助数据,通过卷积神经网络(CNN)对 0.6 m 以内的薄冰和全范围厚度的海冰进行训练,实验结果中平均绝对误差分别为 6.5 和 23 cm。

在特征融合方面,文献[18]提出用光学数据融合纹理特征以及归一化差分植被指数(NDVI),运用随机森林方法实现海冰分类,分类精度可达 84.68%。文献[19]通过 SAR 图像和高分辨率的无云光学数据,通过卷积神经网络获得了较好的海冰分类结果。文献[20]先通过分类得到海冰类型,再将海冰分类作为特征加入海冰厚度反演中,依靠不同海冰类型的特性、遥感信息和其他信息,使用梯度

决策提升树(GBDT)进行实验,以提高反演精度,其均方根误差为 13.7 cm。文献[21]使用随机森林方法,结合入射角、反射率、海冰盐度、海冰温度来反演海冰厚度,反演精度达到了 3.8 cm。

海冰厚度的变化存在较强的时序关联特性,目前,传统机器学习方法以及 CNN 和递归神经网络(RNN)等深度学习方法在处理长时依赖、复杂数据模式时存在一定局限性,难以有效捕捉数据之间的复杂关联,导致反演精度相对较低。Transformer 强大的全局依赖建模能力、灵活的特征交互机制和高效的非局部信息提取能力,以及模型能够通过其独特的自注意力机制和全局信息的交互,来捕捉数据中的长时依赖关系^[22],使得其在处理海冰厚度反演任务时,能够更好地捕捉时序数据中复杂的关联性,提升反演的精度。

为进一步挖掘被动微波数据与海冰厚度的相关性,本文提出了一种基于 Transformer 和多特征融合的海冰厚度反演方法 SIT-TransNET。利用 AMSR2 的 7 个频段亮度温度数据,结合雪表面温度、海面盐度和 1.4 GHz 亮度温度数据,分析不同特征的重要性并进行多特征融合;利用 SIT-TransNET 的多头注意力机制及其捕捉数据长距离依赖关系的特性,实现精确的海冰厚度反演。实验结果表明,相较于传统方法和其他深度学习方法,本文方法获得了较好的海冰厚度反演效果。

2 研究区域与数据来源

2.1 研究区域

本文的实验研究区域为北极的部分区域,具体位置位于西经 140°~西经 180°、北纬 68°~北纬 80°,如图 1 所示(彩色效果见《计算机工程》官网 HTML 版,下同)。




图 1 研究区域

Fig.1 Study area

2.2 AMSR2 亮度温度数据

AMSR2 是日本宇宙航空研究开发机构发射的全球降水测量(GPM)核心卫星上的微波辐射计,主要用于测量地球表面和大气的微波辐射。AMSR2 记录了 7 个频率(6.9、7.3、10.6、18.7、23.8、36.5 和 89 GHz)的水平(H)和垂直(V)极化数据,空间分辨率为 10 km,时间分辨率为 1 天^[23],数据获取地址为 <https://gportal.jaxa.jp/gpr/search>。本文采用 AMSR2 提供的亮度温度数据作为输入变量。

2.3 SMOS 海冰厚度数据

SMOS 卫星由欧洲空间局(ESA)于 2009 年 11 月 2 日发射,主要用于测量全球土壤湿度和海洋表面盐度。SMOS 搭载微波成像综合孔径辐射计 MIRAS,工作频率为 1.4 GHz(L 波段),通过被动微波遥感技术获取地球表面辐射亮度温度。L 波段在海冰中的穿透深度较大,可用于反映冰厚信息。SMOS 海冰厚度数据的空间分辨率为 12.5 km,时间分辨率为 1 天。

SMOS 利用合成孔径微波辐射计 MIRAS 在全偏振情况下测量 L 波段亮度温度数据,但受雷达等的射频干扰(RFI)影响。为此,本文对亮度温度应用一个阈值,若亮度温度超过 300 K,则认为该地点受 RFI 污染。北极地区不可能出现高于 300 K 的亮度温度^[24]。本文从 JRA-55 大气再分析数据中提取海面温度,海面盐度数据来自麻省理工学院环流模型(MITgcm),数据获取地址为 <https://smos-diss.eo.esa.int/oads/access/>。将两者进行插值,使其与海冰厚度空间分辨率一致。

3 方法设计

3.1 被动微波反演海冰厚度原理

被动微波遥感监测海冰厚度的基本原理是利用海冰和海水在不同频率下对微波辐射的反射和吸收特性来推断海冰厚度,这些辐射源自地球热辐射,包括海冰和海水的辐射。海冰和海水在不同的微波频率下具有不同的辐射特性。通常情况下,海冰在低频和高频的微波辐射差别较大,而海水的辐射特性则相对稳定。辐射特性可以用亮度温度来表示,辐射率的计算综合考虑了电磁波在空气-海冰和海冰-海水 2 个界面上的反射和透射,以及在海冰中的传播和相位变化。根据 APINIB 和 PEOKE 提出的计算公式得出辐射率 e :

$$e = \frac{(1-r_i)(1-Ar_w)}{1+Ar_i r_w} + 2\sqrt{Ar_i r_w} \cos(2\beta d) \quad (1)$$

式中: r_i 为空气到海冰的反射系数; r_w 为海冰到海水的反射系数; β 为相位常数; d 为海冰厚度; A 为衰减系数^[25]。

当电磁波从海水通过海冰层辐射时,海冰会吸收和散射部分辐射能量,称为衰减。衰减程度与海冰厚度直接相关,海冰越厚,衰减越显著。超过一定厚度时,海水辐射几乎完全被吸收,透过冰层的辐射能量极微弱,传感器难以检测。此时,传感器主要接收到海冰的辐射信号,海冰厚度的反演可能达到上限。

3.2 海冰厚度反演流程

海冰厚度反演的总体框架包括数据处理、方法应用和精度评估 3 个部分,如图 2 所示。首先,根据第 4.1 节所提方法进行数据预处理;然后,使用多特征融合和改进 Transformer 的被动微波遥感海冰厚度反演方法 SIT-TransNET 进行海冰厚度反演,并与线性回归、支持向量回归、神经网络等方法进行对比分析;最后,使用平均绝对误差、均方根误差和决定系数评价模型精度。




图 2 海冰厚度反演总体框架

Fig.2 Overall framework for sea ice thickness inversion

3.3 SIT-TransNET

Transformer 是一种基于自注意力机制的神经网络模型,与传统的卷积神经网络和递归神经网络不同,Transformer 完全依赖于注意力机制,彻底消除了递归和卷积的需求,其在处理长距离特征依赖和并行计算方面表现出色,能够有效提高海冰厚度反演的精度和效率,因此,本文提出基于改进 Transformer 的海冰厚度反演模型 SIT-TransNET。

Transformer 本质上是一个由编码器(Encoder)和解码器(Decoder)组成的架构。编码组件由多层编码器堆叠而成,解码组件则由相同数量的解码器构成。每个编码器包含 2 个子层,即多头自注意力机制和位置前馈网络。其中,多头自注意力机制的功能为计算输入序列中每个位置对其他位置的注意力权重,以及通过多个头(head)来捕获不同的注意力模式,并将它们的结果拼接起来。位置前馈网络包含 2 个线性变换和 1 个 ReLU 激活函数,独立应用于每个位置,同时提供非线性变换能力。每个编码器具有相同的网络结构,但它们使用不同的权重参数。Transformer 模型中的位置编码是一个关键的组成部分,它通过向输入序列中的每个元素添加相应的位置信息来帮助模型理解和挖掘元素之间的位置关系和内在关联。由于海冰厚度反演中样本特征存在内在位置关联及局部的空间相似特性,Transformer 的自注意力机制和位置前馈网络对于挖掘样本特征和海冰厚度之间的复杂关系尤其有利。

海冰厚度反演属于回归任务,不需要生成序列输出,可以省略解码器部分,直接将输入数据通过编码器映射到输出数据,因此,本文将编码器的最后一层作为输出,同时在原始模型上添加层归一化部分,来减少训练过程中出现的内部协变量偏移以及提高模型的稳定性。针对样本的输入序列 $\mathbf{X}$,首先通过嵌入层 $\mathbf{E} = \text{Embedding}(x)$,转化为嵌入向量 $\mathbf{E}$,同时,为了保留位置信息,加入位置编码 $\mathbf{P}$ 。位置编码的计算如式(2)和式(3)所示:

$$p_{i,2k} = \sin\left(\frac{i}{10000^{\frac{2k}{d}}}\right) \quad (2)$$

$$p_{i,2k+1} = \cos\left(\frac{i}{10000^{\frac{2k}{d}}}\right) \quad (3)$$

式中: i 为位置索引; k 为维度索引; d 为嵌入向量的维度。

然后,将嵌入向量和位置编码的和 $\mathbf{Z}_0 = \mathbf{E} + \mathbf{P}$ 作为编码器的输入。对于输入的 $\mathbf{Z}_0$,通过 $\mathbf{W}_Q$ 、 $\mathbf{W}_K$ 、 $\mathbf{W}_V$ 的权重矩阵进行线性变换得到 Query($\mathbf{Q}$)、Key($\mathbf{K}$)、Value($\mathbf{V}$)。接下来,用式(4)计算出注意力权重:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (4)$$

式中: d_k 为键向量的维度。

多头注意力机制将 h 个独立的注意力头的输出拼接起来,然后将其输出通过层归一化与残差连接,如式(5)和式(6)所示:

$$\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(h_{\text{head},1}, \dots, h_{\text{head},h}) \quad (5)$$

$$\mathbf{Z}' = \text{LayerNorm}(\mathbf{Z} + \text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V})) \quad (6)$$

式中: $h_{\text{head},i}$ 为注意力头; $\mathbf{Z}'$ 为多头注意力层的输出矩阵; $\mathbf{Z}$ 为编码器层的输入矩阵。

前馈神经网络接收到矩阵 $\mathbf{Z}'$, 再经过层归一化和残差连接, 得到编码器层的最终输出 $\mathbf{Z}''$, 如式(7)和式(8)所示:

$$\text{FFN}(x) = \text{ReLU}(x\mathbf{W}_1 + \mathbf{b}_1)\mathbf{W}_2 + \mathbf{b}_2 \quad (7)$$

$$\mathbf{Z}'' = \text{LayerNorm}(\mathbf{Z}' + \text{FFN}(\mathbf{Z}')) \quad (8)$$

式中: $\text{FFN}(x)$ 为位置前馈网络的输出; $\mathbf{W}_1$ 和 $\mathbf{W}_2$ 为前馈网络的权重矩阵; $\mathbf{b}_1$ 和 $\mathbf{b}_2$ 为前馈网络的偏置向量。

最后, 将多个编码器层堆叠起来, 形成完整的编

码器部分。对于回归任务, 编码器最终输出的值经过线性层转换为目标值^[26]。

SIT-TransNET 的结构如图 3 表示。SIT-TransNET 通过去除解码器, 模型可以在进行海冰厚度反演时降低计算复杂度, 适应多维度输入数据和时序关联数据, 更有利于海冰厚度的时空特征提取; 层归一化帮助模型在处理长时序数据时保持梯度稳定, 加速收敛, 提高反演精度。同时, SIT-TransNET 能充分利用多头注意力机制和位置前馈网络挖掘样本特征和海冰厚度之间的复杂关联, 通过模型的自注意力机制捕捉不同特征及特征组合对海冰厚度反演的贡献, 并能够动态调整不同特征的权重, 实现海冰厚度的精确反演。




图3 SIT-TransNET 结构

Fig.3 SIT-TransNET structure

4 实验验证

4.1 实验设置

在实验开始前, 先剔除异常值以提高样本数据质量。根据 AMSR2 高级产品规范, 亮度温度值为 65 535 的为缺失值, 亮度温度值为 65 531~65 534 的为错误值, 需要剔除。同时, 将 AMSR2 亮度温度乘以比例系数 0.01 以保证数值正确性。海冰厚度小于 0.01 m 时可能存在海冰和海水误判情况, 在实验中也将其去除。由于被动微波遥感对厚冰反演的局限性, 将海冰厚度大于 1.6 m 的数据去除, 以提高模型泛化能力。样本中部分海面盐度和雪表面温度为 0 的情况属于异常值, 将其剔除以减少数据噪声, 提高模型性能。

将 AMSR2 提取的 7 个频率中 H 和 V 极化下的亮度温度作为基础特征, SMOS 卫星提供的 1.4 GHz 的亮度温度、雪表面温度和海面盐度作为辅助特征。由于 2 种卫星数据的空间分辨率不同,

需使用双线性插值法, 将 12.5 km 分辨率的海冰厚度和辅助特征插值到 10 km 分辨率, 以匹配 AMSR2 数据。

考虑到亮度温度、雪表面温度和海面盐度的量纲和数量级不同, 需将各类特征值归一化至 $[0, 1]$ 区间, 消除数量级差异对模型训练和反演的影响。归一化计算如式(9)所示:

$$F_1 = \frac{F - F_{\min}}{F_{\max} - F_{\min}} \quad (9)$$

式中: F_1 表示特征归一化后的值; F 表示归一化前的值; $F_{\min}$ 和 $F_{\max}$ 分别表示数据集中该特征的最小值和最大值。最后, 将不同特征与海冰厚度通过经纬度匹配构建数据集。

为了保证训练集的时间跨度和多样性, 本文选取 2021 年 10 月 15 日—2022 年 1 月 1 日间每隔 5 天共 16 天作为训练集。使用 AMSR2 的 7 个波段的 14 个亮度温度特征及 3 个辅助特征作为模型输入, 将 SMOS 提供的海冰厚度进行 10 km 双线性插值后匹

配输入特征,得到数据集。该时间段的海冰厚度分布直方图如图 4 所示。2021 年 10 月 15 日—11 月 1 日期间,薄冰(<0.6 m)占大多数,随后逐渐减少,厚冰增加。11 月 5 日后,随着天气变冷,海冰迅速增长,

1.2~1.4 m 的样本显著增加。11 月 25 日起,冰厚大于 1.2 m 的样本占据主要部分,最大可达 1.6 m。样本分布分析对于处理样本不平衡问题、构建精确反演模型和提高模型泛化能力具有重要参考价值。




图 4 海冰厚度分布直方图

Fig. 4 Histogram of sea ice thickness distribution

训练集和验证集按 7:3 比例划分,训练集 35 万条数据,验证集 15 万条。测试集选取 2022 年 10 月 15 日—2023 年 1 月 1 日间每隔 5 天共 50 万条数据,用于测试模型精度。平均绝对误差 (MAE, E_{MAE})、均方根误差 (RMSE, E_{RMSE}) 表示真实值与反演值之间的误差,值越小表示回归模型的反演误差越小。决定系数 (R^2) 用来判断回归模型拟合效果的优劣,值越接近 1,模型拟合效果越好。各指标计算方法如下:

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

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

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (12)$$

式中: n 代表样本个数; y_i 代表第 i 个样本的真实值; $\hat{y}_i$ 代表第 i 个样本的预测值; $\bar{y}$ 表示真实值的均值。

4.2 不同模型对比实验

为了验证本文模型在海冰厚度反演方面的有效性和先进性,使用同一数据集对比不同回归模型,包括线性回归 (LR)、支持向量回归 (SVR)^[27]、梯度提升决策树 (GBDT)、长短时记忆 (LSTM) 网络^[28]、一维卷积神经网络 (1DCNN)^[29]、CNN-LSTM^[30]、Transformer 和 SIT-TransNET。上述模型的输入均为 14 个基础亮度温度特征。实验结果如表 1 所示。

表 1 不同模型的实验结果对比

Table 1 Comparison of experimental results of different models

模型	MAE/m	RMSE/m	R^2
LR	0.244	0.302	0.605
SVR	0.131	0.191	0.841
GBDT	0.131	0.192	0.843
LSTM	0.169	0.226	0.777
1DCNN	0.119	0.179	0.859
CNN-LSTM	0.112	0.173	0.869
Transformer	0.110	0.177	0.866
SIT-TransNET	0.104	0.132	0.869

分析实验结果可知,海冰厚度反演是一个非线性问题,传统数学模型 LR 难以拟合亮度温度特征与海冰厚度的关系,平均绝对误差为 24.4 cm,均方根误差为 30.2 cm,决定系数为 0.605,效果较差。LSTM、1DCNN、CNN-LSTM 模型能较好地拟合亮度温度特征与海冰厚度的强相关性,证明深度学习模型在反演海冰厚度方面有优势,平均绝对误差分别为 16.9、11.9 和 11.2 cm,均方根误差分别为 22.6、17.9 和 17.3 cm,决定系数分别为 0.777、0.859 和 0.869。SVR 使用高斯径向基函数(RBF)处理非线性问题,平均绝对误差为 13.1 cm,均方根误差为 19.1 cm,决定系数为 0.841,反演效果较好。GBDT 通过构建多个决策树并对它们的预测进行加权,能够有效地捕捉这些复杂的非线性关系,反演的均方根误差为 19.2 cm,决定系数为 0.843。SIT-TransNET 利用位置编码捕捉海冰位置信息,并通过多头注意力机制建立全局依赖关系,以及利用层归一化消除了数据分布在训练过程中可能发生的偏移,充分发挥了模型优势,获得了最佳反演效果,平均绝对误差为 10.4 cm,均方根误差为 13.2 cm,决定系数为 0.869。

4.3 不同特征组合对比实验

为获得更好的反演效果,本文比较了不同特征组合对冰厚的影响。实验中使用原始的 14 个亮度

温度特征(F1 组合)、加入 1.4 GHz 亮度温度特征后的 15 个特征(F2 组合)以及加入辅助特征后的 17 个特征(F3 组合)。通过这些实验,发现海冰厚度的影响因素并提高反演精度,实验结果如表 2 所示。

表 2 特征组合对比实验结果

Table 2 Experimental results of feature combination comparison

特征组合	特征描述	特征数/个
F1	H_i 、 V_i	14
F2	H_i 、 V_i 、1.4 GHz 亮度温度	15
F3	H_i 、 V_i 、雪表面温度、1.4 GHz 亮度温度、海面盐度	17

不同方法下的特征组合实验结果如表 3 所示(F1 组合的结果已列出)。相比 F1 组合,加入低频 1.4 GHz 亮度温度特征的 F2 组合使模型反演精度明显上升,表明低频亮度温度特征具有更强的穿透深度,受大气影响较小,能够表征更厚的海冰。LR 模型表现最差,均方根误差为 21.1 cm,决定系数为 0.805。SVR 模型表现优越,均方根误差为 11.2 cm,决定系数为 0.945,优于 LSTM。1DCNN、CNN-LSTM、Transformer 和 SIT-TransNET 在加入低频信号后,反演精度显著提升。

表 3 不同方法下的特征组合对比实验结果

Table 3 Comparative experimental results of feature combinations under different methods

方法	F1		F2		F3	
	RMSE/m	R^2	RMSE/m	R^2	RMSE/m	R^2
LR	0.302	0.605	0.211	0.805	0.179	0.859
SVR	0.191	0.841	0.112	0.945	0.074	0.975
GBDT	0.192	0.843	0.121	0.937	0.071	0.977
LSTM	0.226	0.777	0.142	0.911	0.088	0.966
1DCNN	0.179	0.859	0.095	0.955	0.083	0.969
CNN-LSTM	0.173	0.869	0.095	0.956	0.024	0.984
Transformer	0.177	0.866	0.091	0.959	0.024	0.983
SIT-TransNET	0.132	0.869	0.087	0.967	0.022	0.987

在特征组合 F3 中,加入海面盐度和雪表面温度后,模型反演精度显著提升。由于积雪的导热系数几乎比海冰低一个数量级,海冰上的薄雪会极大地影响地表和大气之间的热通量^[31],因此,雪表面温度会对海冰厚度及变化产生一定的影响;海面结冰会析出盐分,从而增加周围海水的盐度,而融冰又会冲淡海水从而降低海水的盐度,因此,海面盐度可以反映海冰厚度的变化。SIT-TransNET 模型在 F3 组合中的反演精度最高,均方根误差仅为

2.2 cm,决定系数达到 0.987。结果表明,在相同特征组合下,SIT-TransNET 方法效果最好,在相同方法下,特征组合 F3 最佳。

4.4 消融实验

为进一步验证 SIT-TransNET 模型对于海冰厚度反演的有效性,选取反演结果最好的特征组合 F3 进行消融实验,结果如表 4 所示,以评估不同模块对海冰厚度反演的影响。其中,Model-1 为 Transformer 原始架构,Model-2 为 Model-1 去除解

码器部分的架构,Model-3 为 Model-1 加上层归一化的架构,SIT-TransNET 为第 3.3 节提出的去除解码器且叠加层归一化的架构。

表 4 消融实验结果

Table 4 Ablation experiment results

方法	MAE/m	RMSE/m	R^2
Model-1	0.079	0.107	0.949
Model-2	0.073	0.101	0.954
Model-3	0.071	0.097	0.961
SIT-TransNET	0.069	0.091	0.966

从表 4 可以看出,相对 Model-1,Model-2 模型架构提高了海冰厚度的反演精度,这是因为在海冰厚度反演任务中,模型的目标是反演一个连续的数值,不需要根据上下文信息就能生成目标序列,因此,通过全连接层替换解码层,可以简化模型复杂性,提高计算效率,并避免过拟合,进一步提升了反演精度。Model-3 模型架构的层归一化可以使得模型在训练中保持稳定的参数更新,降低梯度异常的风险,从而有效提高模型的反演精度和鲁棒性。SIT-TransNET 针对海冰厚度反演任务改进了 Transformer,避免了复杂的解码器结构,并且叠加了层归一化,从而使得反演结果最佳。

4.5 泛化实验

为了评估模型的泛化能力,本文使用 2022 年 10 月 15 日—2023 年 1 月 1 日的数据(共 50 万条)作为测试样本进行实验。各模型的泛化性实验结果如表 5 所示。相较受限于局部特征的卷积神经网络,SIT-TransNET 的自注意力机制能动态分配不同位置的注意力权重,更有效地捕捉海冰厚度序列中的依赖关系,泛化能力更佳,决定系数达 0.966,均方根误差约为 9 cm。

表 5 不同模型的泛化性实验结果

Table 5 Generalization experiment results of different models

模型	MAE/m	RMSE/m	R^2
LR	2.305	2.359	0.08
SVR	0.113	0.191	0.863
GBDT	0.114	0.195	0.866
LSTM	0.136	0.174	0.881
1DCNN	0.103	0.133	0.930
CNN-LSTM	0.086	0.117	0.945
Transformer	0.079	0.107	0.949
SIT-TransNET	0.069	0.091	0.966

图 5(a)~图 5(d)分别为 LSTM、1DCNN、CNN-LSTM 和 SIT-TransNET 模型的海冰厚度真




图 5 不同模型的真实值与反演值散点图

Fig.5 Scatter plot of true values and inverted values for different models

实值与反演值的散点图,颜色越接近黄色表明数据量越多。图 5(a)~图 5(c)中反演值与真实值偏差较大,而图 5(d)中 SIT-TransNET 模型拟合效果最好,但反演值仍存在一定误差。因为训练模型基于 2021 年数据,全球气候变暖导致 2022 年海冰厚度整体低于 2021 年,所以反演值偏高。随着海冰厚度的增加,辐射衰减使得误差增加。

4.6 海冰厚度投影和误差分析

利用 SIT-TransNET 模型反演 2022 年 10 月

20 日、11 月 20 日和 12 月 20 日的海冰厚度,并将真实值、反演值及误差投影在地图上,如图 6 所示。2022 年 10 月 20 日海冰厚度多为 0.6 m,少量达 1.2 m,反演误差最小,决定系数为 0.91,均方根误差为 6.2 cm。11 月 20 日海冰厚度整体增加至 1 m 以上,部分达 1.5 m,由于复杂环境因素,反演精度降低,决定系数为 0.76,均方根误差为 13 cm。12 月 20 日海冰厚度稳定在 1.2~1.5 m,反演精度提高,决定系数为 0.87,均方根误差约为 10 cm。




图 6 海冰厚度的真实值投影、反演值投影和误差投影

Fig. 6 Projection of true values, inversion values, and error projections of sea ice thickness

5 结束语

为充分利用被动微波遥感的多频率多极化观测特征,实现大范围、高精度海冰厚度反演,本文提出了一种基于多特征融合和 SIT-TransNET 的海冰厚度反演方法。通过挖掘被动微波多频率多极化特征与海冰厚度的关联,增加辅助特征,利用 SIT-TransNET 的位置编码和多头注意力机制,构建高精度海冰厚度反演模型。相较传统方法中使用单一频率或极化模式反演海冰厚度,该方法反演精度较高,可以为海洋气象和极地科学研究提供更可靠的数据支持。通过反演 2022 年 10 月 15 日—2023 年

1 月 1 日的海冰厚度,验证了基于多特征融合和 SIT-TransNET 模型的方法在精度和可靠性方面的优势,其均方根误差约为 9 cm,相关系数达 0.96。该方法的成功应用,不仅在海冰监测、气候变化研究、航行安全、资源开发、环境保护等多个领域展现出巨大的应用潜力,也为全球气候变化研究和极地科学提供了新的数据支持与技术手段。但是,由于极地海冰受复杂环境影响,尤其是厚冰反演,仍存在挑战,后续研究将结合多源数据,分析不同特征对于海冰厚度的影响,优化反演模型,以提高其泛化能力,并且针对厚冰展开研究,进一步提升反演精度。

参考文献

- [1] YE Y F, WANG X, SUN S Z, et al. A new sea ice concentration retrieval algorithm from thermal infrared imagery[J]. *International Journal of Digital Earth*, 2024, 17(1): 2353116.
- [2] KAPSCH M L, GRAVERSEN R G, TJERNSTRÖM M, et al. The effect of downwelling longwave and shortwave radiation on arctic summer sea ice[J]. *Journal of Climate*, 2016, 29(3): 1143-1159.
- [3] 于森. 利用 RadarSat-2 SAR 影像反演北极夏季海冰厚度的研究[D]. 大连: 大连理工大学, 2018.
YU M. Study on sea ice thickness retrieval in Arctic summer using RadarSat-2 SAR imagery [D]. Dalian: Dalian University of Technology, 2018. (in Chinese)
- [4] SHAMSHIRI R, EIDE E, HØYLAND K V. Spatio-temporal distribution of sea-ice thickness using a machine learning approach with Google Earth Engine and Sentinel-1 GRD data[J]. *Remote Sensing of Environment*, 2022, 270: 112851.
- [5] ZHAO Y L, SUN Z W, LI W S, et al. Sea ice type and thickness identification based on vibration sensor networks and machine learning [J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 2512111.
- [6] KOENIG L, MARTIN S, STUDINGER M, et al. Polar airborne observations fill gap in satellite data [J]. *Eos, Transactions American Geophysical Union*, 2010, 91(38): 333-334.
- [7] MARTIN S, DRUCKER R, KWOK R, et al. Estimation of the thin ice thickness and heat flux for the Chukchi Sea Alaskan coast polynya from Special Sensor Microwave/Imager data, 1990-2001 [J]. *Journal of Geophysical Research: Oceans*, 2004, 109(C10): 2004JC002428.
- [8] YU Y, ROTHROCK D A. Thin ice thickness from satellite thermal imagery [J]. *Journal of Geophysical Research: Oceans*, 1996, 101(C11): 25753-25766.
- [9] 朱星源, 苏洁, 宋梅, 等. 基于 MODIS 数据的渤海海冰厚度反演算法优化[J]. *海洋学报*, 2022, 44(12): 70-83.
ZHU X Y, SU J, SONG M, et al. Optimization of the Bohai sea ice thickness retrieval algorithm based on MODIS data [J]. *Haiyang Xuebao*, 2022, 44(12): 70-83. (in Chinese)
- [10] 郭井学. 基于电磁感应理论的极地海冰厚度探测研究[D]. 长春: 吉林大学, 2007.
GUO J X. Research of electromagnetic inductive theory on the measurements of polar sea-ice thickness[D]. Changchun: Jilin University, 2007. (in Chinese)
- [11] KARVONEN J, SIMILÄ M, HALLIKAINEN M, et al. Estimation of equivalent deformed ice thickness from Baltic sea ice [EB/OL]. [2024-08-05]. <https://epic.awi.de/id/eprint/14828/1/Kar2005h.pdf>.
- [12] ZHANG X, DIERKING W, ZHANG J, et al. Retrieval of the thickness of undeformed sea ice from simulated C-band compact polarimetric SAR images [J]. *The Cryosphere*, 2016, 10(4): 1529-1545.
- [13] 于森, 卢鹏, 李志军, 等. 基于 SAR 图像纹理的北极海冰厚度的反演研究[J]. *极地研究*, 2018, 30(3): 329-337.
YU M, LU P, LI Z J, et al. Arctic sea ice thickness retrieval based on SAR image texture feature[J]. *Chinese Journal of Polar Research*, 2018, 30(3): 329-337. (in Chinese)
- [14] NAOKI K, UKITA J, NISHIO F, et al. Thin sea ice thickness as inferred from passive microwave and in situ observations[J]. *Journal of Geophysical Research: Oceans*, 2008, 113(C2): 2007JC004270.
- [15] HERBERT C, MUNOZ-MARTIN J F, LLAVERIA D, et al. Sea ice thickness estimation based on regression neural networks using L-band microwave radiometry data from the FSSCat mission[J]. *Remote Sensing*, 2021, 13(7): 1366.
- [16] TATEYAMA K, ENOMOTO H, TOYOTA T, et al. Sea ice thickness estimated from passive microwave radiometers [J]. *Polar Meteorology and Glaciology*, 2002, 16: 15-31.
- [17] CHI J, KIM H C. Retrieval of daily sea ice thickness from AMSR2 passive microwave data using ensemble convolutional neural networks [J]. *GIScience & Remote Sensing*, 2021, 58(6): 812-830.
- [18] 王志勇, 张梦悦, 于亚冉, 等. 一种融合纹理特征与 NDVI 的随机森林海冰精细分类方法 [J]. *海洋学报*, 2021, 43(10): 149-156.
WANG Z Y, ZHANG M Y, YU Y R, et al. A fine classification method for sea ice based on random forest combining texture feature and NDVI [J]. *Haiyang Xuebao*, 2021, 43(10): 149-156. (in Chinese)
- [19] KHALEGHIAN S, ULLAH H, KRÆMER T, et al. Sea ice classification of SAR imagery based on convolution neural networks [J]. *Remote Sensing*, 2021, 13(9): 1734.
- [20] 黄骏捷. 基于主动学习与多特征增强的 GBDT 海冰厚度一体化反演[D]. 上海: 上海海洋大学, 2024.
HUANG J J. Integrated inversion of GBDT sea ice thickness based on active learning and multi-feature enhancement [D]. Shanghai: Shanghai Ocean University, 2024. (in Chinese)
- [21] LI H Y, YAN Q Y, HUANG W M. Retrieval of sea ice thickness from FY-3E data using random forest method [J]. *Advances in Space Research*, 2024, 74(1): 130-144.
- [22] 宋泉臻, 陈作钧, 秦品乐, 等. 基于超像素引导的 Transformer 低光图像去噪方法 [J]. *计算机工程*, 2026, 52(2): 186-196.
SONG Q Z, CHEN Z J, QIN P L, et al. Superpixel guide for Transformer low-light image denoising method [J]. *Computer Engineering*, 2026, 52(2): 186-196. (in Chinese)
- [23] OKUYAMA A, IMAOKA K. Intercalibration of Advanced Microwave Scanning Radiometer-2 (AMSR2) brightness temperature [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(8): 4568-4577.
- [24] TIAN-KUNZE X, KALESCHKE L, MAAß N, et al. SMOS-derived thin sea ice thickness: algorithm baseline, product specifications and initial verification [J]. *The Cryosphere*, 2014, 8(3): 997-1018.
- [25] 郭凤莲, 赵仁宇, 王维滨. 无源微波遥感技术在海冰测厚中的应用研究[J]. *遥感学报*, 2000, 4(2): 112-117.
GUO F L, ZHAO R Y, WANG W B. Application of passive microwave remote sensing to sea ice thickness measurement [J]. *Journal of Remote Sensing*, 2000, 4(2): 112-117. (in Chinese)
- [26] 刘超东, 刘超越, 邱紫鑫, 等. 基于时间感知 Transformer 的交通流预测方法 [J]. *计算机科学*, 2023, 50(11): 88-96.
LIU Q D, LIU C Y, QIU Z X, et al. Time-aware Transformer for traffic flow forecasting [J]. *Computer Science*, 2023, 50(11): 88-96. (in Chinese)
- [27] PETKOVSKI E, MARRI I, CRISTALDI L, et al. State of health estimation procedure for lithium-ion batteries using partial discharge data and support vector regression [J]. *Energies*, 2023, 17(1): 206.
- [28] GUO B L, WANG Y N, PAN W F, et al. Fault diagnosis method for hydro-power plants with Bi-LSTM knowledge graph aided by attention scheme [J]. *Journal of Vibroengineering*, 2023, 25(8): 1629-1641.
- [29] JIJÓN-PALMA M E, AMISSE C, CENTENO J A S. Hyperspectral dimensionality reduction based on SAE-1DCNN feature selection approach [J]. *Applied Geomatics*, 2023, 15(4): 991-1004.
- [30] GAO Y, XIA X J, GUO Y R. A thermal error prediction method of high-speed motorized spindle based on pelican optimization algorithm and CNN-LSTM [J]. *Applied Sciences*, 2023, 14(1): 381.
- [31] COMISO J C, CAVALIERI D J, MARKUS T. Sea ice concentration, ice temperature, and snow depth using AMSR-E data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2003, 41(2): 243-252.

文字编辑 吴云芳
栏目编辑 赖玉玲