

基于注意力机制的陆地生态系统碳监测 卫星大气层次识别与应用

卢庆锴¹, 么嘉祺^{1*}, 李国元^{2*}, 马晨^{2,3}, 刘诏², 夏皓斌^{1,4}, 徐浩钧¹, 武建军^{1,4}

(1. 天津师范大学 京津冀生态文明发展研究院, 天津 300387;

2. 自然资源部 国土卫星遥感应用中心, 北京 100048;

3. 哈尔滨工业大学 卫星技术研究所, 黑龙江 哈尔滨 150001;

4. 北京师范大学 地理科学学部, 北京 100875)

摘要: 陆地生态系统碳监测卫星(Terrestrial Ecosystem Carbon Inventory Satellite, TECIS/CM-1)通过多波束激光雷达、多光谱相机等多种主被动传感器协同观测,实现了大气云-气溶胶高分辨率综合立体监测。近年来,传统算法在低信噪比、近地表和多层结构混合等复杂环境下存在垂直层次检索精度和鲁棒性差的问题。针对于此,本文拟结合TECIS卫星多波束激光雷达数据特点和深度学习注意力机制,提出一种适用于新型多波束激光雷达的大气层次识别和应用的通用框架TECIS-CASNet。为验证该框架的可靠性,研究团队通过开展多次地基同步观测实验,对其识别精度进行了系统验证。最后,以中国京津冀地区典型沙尘长距离传输过程为研究对象,开展了示范性应用研究,充分展示了该框架的实际应用价值。结果表明:TECIS-CASNet框架对云-气溶胶识别精度较好,准确率达98.41%,在低信噪比、近地表和多层结构混合等复杂环境下能够减少误识别及漏检情况;气溶胶光学厚度反演绝对精度达到0.01,整体精度达到98%。本文围绕TECIS-CASNet框架的相关结论,对激光雷达卫星大气探测数据处理、环境监测应用等方面具有重要意义。

关键词: 陆地生态系统碳监测卫星; 大气激光雷达; 深度学习; 注意力机制

中图分类号: P407.5

文献标识码: A

Atmospheric layer identification and application of Terrestrial Ecosystem Carbon Inventory Satellite based on attention mechanism

LU Qing-Kai¹, YAO Jia-Qi^{1*}, LI Guo-Yuan^{2*}, MA Chen^{2,3}, LIU Zhao², XIA Hao-Bin^{1,4},
XU Hao-Jun¹, WU Jian-Jun^{1,4}

(1. Academy of Eco-civilization Development for Jing-Jin-Ji Megalopolis, Tianjin Normal University, Tianjin 300387, China;

2. Land Satellite Remote Sensing Application Center, Ministry of Natural Resources of China, Beijing 100048, China;

3. Research Center of Satellite Technology, Harbin Institute of Technology, Harbin 150001, China;

4. Faculty of Geographical Science, Beijing Normal University, Beijing 100875, China)

Abstract: The Terrestrial Ecosystem Carbon Inventory Satellite (TECIS/CM-1) utilizes a combination of multi-beam lidar, multi-spectral cameras, and other passive and active sensors for synergistic observations, enabling high-resolution, comprehensive, and three-dimensional atmospheric monitoring of clouds and aerosols. In recent years, traditional algorithms have faced challenges in terms of vertical layer retrieval accuracy and robustness in complex environments with

收稿日期: 2025-01-22, 修回日期: 2025-02-20

Received date: 2025-01-22, Revised date: 2025-02-20

基金项目: 国家自然科学基金项目(42301501); 自然资源高层次科技创新人才基金(B02202)

Foundation items: Supported by the National Natural Science Foundation of China (42301501); the High-Level Science and Technology Innovation Talent Fund for Natural Resources(B02202)

作者简介(Biography): 卢庆锴(2001—), 山东邹城人, 博士研究生, 主要研究领域为激光雷达数据处理、云气溶胶相互作用. E-mail: 18754775103@163.com

*通讯作者(Corresponding authors): E-mail: yaojiaqi@tjnu.edu.cn; ligy@lasac.cn

low signal-to-noise ratios, near-surface observations, and mixed multi-layer structures. To address these issues, this paper proposes TECIS-CASNet, a generalized framework for atmospheric layer recognition and application, designed for the novel multi-beam lidar on the TECIS, leveraging the characteristics of the lidar data and deep learning attention mechanisms. To validate the reliability of this framework, the research team conducted multiple ground-based synchronous observation experiments to systematically evaluate its recognition accuracy. Finally, as a demonstrative application, the study focuses on a typical long-distance dust transport event in the Beijing-Tianjin-Hebei region of China, showcasing the practical application value of the framework. The results indicate that the TECIS-CASNet framework achieves high cloud-aerosol recognition accuracy, reaching 98.41%, and is capable of reducing misidentification and missed detection in complex environments, including low signal-to-noise ratios, near-surface layers, and multi-layer mixed structures. The absolute accuracy of aerosol optical depth retrieval is 0.01, with an overall accuracy of 98%. This paper, centered around the TECIS-CASNet framework, provides significant insights for lidar satellite atmospheric remote sensing data processing and environmental monitoring applications.

Key words: Terrestrial Ecosystem Carbon Inventory Satellite, atmospheric Lidar, deep learning, attention mechanism

引言

对全球云和气溶胶粒子多维度、大视域、高分辨的系统性变化规律的连续观测和反演,能够提高极端气象事件的预测能力、环境监测精确度和气候变化响应速度,对灾害预防、公共健康和可持续发展有重要意义^[1-2]。自从二十世纪九十年代以来,在轨及预研计划中已经有数十颗卫星用于全球范围的云和气溶胶观测,包含红外成像仪、微波辐射计、多角度观测仪和激光雷达(Lidar)等主被动遥感传感器,并广泛应用于地球系统科学、公共环境健康和气候模型等领域^[3-6]。相比于被动光学传感器,Lidar可以全天候和高精度垂直分布观测,并结合多波长和极化模式深化对多层云-气溶胶粒子的理解,逐渐成为理解和研究地球大气的重要工具。

激光雷达已经成为了各国重点发展的星载遥感技术,在地表环境信息和大气海洋环境信息探测等领域取得巨大突破^[7-9]。2006年4月,美国国家航天局(NASA)联合加拿大航天局、法国国家太空研究中心发射了全球首个星载大气环境探测激光雷达云气溶胶激光雷达和红外探路者卫星观测(Cloud-Aerosol Lidar and Infrared Pathfinder Satellite Observations, CALIPSO),它采用双波长具备偏振探测能力的激光雷达,可以实现对全球云-气溶胶要素的立体三维观测^[10]。尽管CALIPSO于2023年8月正式退役,但是其在轨运行以来积累的17年、100亿余次全球观测数据,为气溶胶-云-降水的相互作用、全球沙尘分布、传输和污染、天气和气候变化研究等科学问题提供了科学数据^[11]。在这十余年中,各国依次发射了CATS、Aeolus、DQ-1/2等系列卫星,通过米散射雷达、多普勒激光雷达和高光谱分辨率激光雷达(HSRL)等技术获取更多的云-气溶

胶三维特征,探索云的形成、大气对流、降水和粒子传输等大气过程^[12-14]。在2022年8月,中国成功发射了陆地生态系统碳监测卫星(又称为“句芒号 Gou Mang”, Terrestrial Ecosystem Carbon Inventory Satellite, TECIS),其上搭载了多波束激光雷达、多角度多光谱光学相机、超光谱探测仪等多种载荷,旨在通过主被动相结合的探测手段进行高分辨率大气环境监测、陆地生态系统碳储量估计和地理信息测绘等相关工作^[15]。

在星载激光雷达蓬勃发展的背景下,面向星载激光雷达的大气数据反演算法亟待发展完善,特别是大气气溶胶层次识别与分类。如表1所示,其中罗列了星载大气激光雷达层次分类理论进展,主要涵盖经验法、统计模型、机器学习和深度学习等。激光脉冲可以获取传输路径上的大气垂直分布信息,由于云-气溶胶信号的后向散射强度与背景噪声存在显著区别,所以可以通过设定经验阈值的方式来获取大气层顶部和底部的信息,但是不适用于大范围、复杂情况和自动化识别任务。在此基础上,统计模型突破一维线特征的限制,开始通过沿轨方向云-气溶胶信号的二维面特征来进行大气垂直层次分类,诸如云气溶胶判别(Cloud-Aerosol Discrimination, CAD)算法等,但受到自身计算复杂度和依赖先验参考数据的限制,该类方法不能够快速地完成分类任务并且泛化性能较差^[16-18]。随着统计学习、凸优化理论和人工智能研究的进一步发展,诸如支持向量机(Support Vector Machines, SVM)等机器学习理论通过最大化不同类别之间的间隔,选择合适的决策边界来实现对大气垂直成分的分类^[19-20]。与传统的阈值法相比,机器学习不仅考虑了各类别之间的边界,还能够处理非线性关系,并

且能够在高维空间中有效地区分数据。相较于其他统计模型,机器学习的优势在于其对小样本数据和高维数据的适应性更强,能够更准确地捕捉复杂的数据分布特征,提高了分类的准确性和泛化能力。但同时,机器学习在大范围卫星激光雷达廓线层次识别中,存在对正则化和核函数参数敏感、多分类检测鲁棒性差、可解释性差等问题^[21-22]。随着图形处理器的广泛应用,现有计算能力得到飞跃式的提高,进一步支撑复杂模型在大范围数据处理中的应用。在此背景下,诸如CNN、SegNet等深度学习模型通过多层次结构自动学习和挖掘数据深层次特征,进而实现高效的大气层次识别,包括复杂的云-气溶胶及其子类^[23-24]。同时,Transformer模型通过自注意力机制优化了大区域和长时间序列的数据处理,提高了大气层次分类的准确性和效率,对监测大气变化极为重要,这些技术显著推进了星载激光雷达层次分类的自动化和精细化。

综上所述,现有的传统算法在大范围和复杂环境中的大气层次检索和分类精度中存在不足,无法充分捕捉到复杂大气现象中的微小变化,导致分类精度受到限制。在此背景下,本文提出了基于TECIS卫星多波束激光雷达数据特点、结合深度学习Transformer结构的TECIS-CASNet框架。该框架旨在通过深度学习方法改进大气层次识别,尤其是在云和气溶胶的目标识别和光学厚度反演方面,提供更加精确和可靠的解决方案。具体地,本文将在第1节对实验数据进行介绍,第2节是具体的实验方法,包括云、气溶胶层次化分类和气溶胶光学厚度反演,第3节是实验结果与分析,描述验证识别及反演结果,并分析大范围沙尘区域的传输特征。

1 实验数据

1.1 TECIS卫星数据概况

2022年8月4日,中国成功发射了陆地生态系统碳监测卫星(“句芒号”, Terrestrial Ecosystem Carbon Inventory Satellite, TECIS),如图1(b)所示,该卫星搭载了四种有效载荷,分别为多波束激光雷达(Carbon Sinks and Aerosol Lidar, CASAL)、多角度多光谱光学相机(DMC)、超光谱探测器(SIFIS)以及多角度偏振成像仪(DPC)。其中,多波束激光雷达作为关键技术之一,发挥着重要作用,特别是在生态系统碳监测和大气气溶胶检测方面。该激光雷达系统包括植被激光雷达和大气激光雷达,其中植被激光雷达提供Laser1至Laser5共五个波束的数据,用于捕捉地面植被结构的详细信息;而大气激光雷达则采用Laser6单波束数据,专注于对大气中气溶胶的探测(图1(c))。大气激光雷达的工作原理是基于激光与大气中气溶胶、云层等颗粒物的相互作用。当激光束照射到大气中时,部分激光会被气溶胶粒子散射或吸收,剩余的激光则会返回卫星接收器。通过分析返回信号的强度、时间延迟以及散射角度等信息,可以精确计算出大气中气溶胶的分布情况以及光学厚度。数据处理过程包括信号的去噪、时间延迟的校正、回波信号的反演等,最终得到气溶胶的浓度分布、光学厚度等关键参数^[25-26]。这一过程不仅需要高精度的传感器和复杂的信号处理算法,还需要考虑大气的不同层次、地形因素以及气候条件对测量数据的影响,从而保证数据的准确性和可靠性(图1(a))。本文涉及主要技术参数,如表2所示。接收系统中的望远镜采用了大口径共孔径成像设计,接收光路设置了532 nm波段下的垂直及平行偏振通道用于探测粒子形状。卫星系统

表1 星载大气激光雷达层次分类研究进展概况

Table 1 Research progress of hierarchical classification of spaceborne atmospheric Lidar

分类方法	模型介绍及效果	局限性
经验阈值法	阈值算法通过设定一个阈值范围来扫描概要数据,并通过逐一检索数据点来确定哪些区域的轮廓数据超出了设定阈值,从而准确定位特征边界。	依赖于经验阈值,不适用于大范围、复杂情况和自动化识别任务
CAD	云气溶胶判别(CAD)算法是基于CALIPSO反向散射测量和检索的空间属性,利用了多维概率密度函数(PDFs),概率密度分布特征是从大量的CALIOP测量中获取的,进而准确区分云层和气溶胶层。	不能够快速的完成分类任务,计算复杂度大且可迁移性较差。
SVM	支持向量机等机器学习模型能够处理小规模训练集并有效解决非线性分类问题,通过在特征如后向散射和偏振比率等上自动提取严格阈值的训练样本,该算法能够在区分不同大气层面时达到高准确度。	参数选择对非线性数据的适应性,以及模型结果的解释,限制了其在大规模数据中的应用。
CNN	与传统基于层到层的分类方法相比,深度学习可挖掘后向散射剖面中的类内深层次特征,而非仅依赖集成值,并利用多维特征进一步区分不同气溶胶类型。	需要大量标注数据,且在局部数据上存在过拟合风险。




图1 陆地碳监测卫星介绍:(a) 卫星观测示意图;(b) 卫星载荷分布;(c) 多波束激光雷达相机光轴结构;(d) 532 nm平行通道高增益模式数据

Fig. 1 Introduction to terrestrial carbon monitoring satellites: (a) schematic diagram of satellite observations; (b) distribution of satellite loads; (c) multi-beam LiDAR camera optical axis structure; (d) 532 nm parallel channel high-gain mode data

设计了多种工作模式,当采用大气激光昼夜探测工作模式时,此雷达可对全天的陆地区域气溶胶展开观测。

如图1(d)所示,为陆地碳监测卫星L2A产品高增益模式下可视化的结果,陆地碳监测卫星大气激光雷达在数据获取上采用了两种信号放大方式,用以捕获不同横跨多个数量级范围的大气信号:1)低增益(Low gain):又称为固定增益,将待增强信号幅值的范围和放大倍数设定为固定值,力求能在全球常态化运行中捕获绝大多数云-气溶胶信号;2)高增益(High gain):又称为可变增益,结合定标结果周期性调整待增强信号幅值的范围和放大倍数,目标是提升中国范围内数据信噪比,进而提升微弱云-气溶胶信号的识别能力。对于本文的研究区域和背景而言,决定使用高增益模式产品作为实验数据。这不仅仅是因为实验区域在中国境内,还因为高增益模式包含更多的大气信号,同时理论上适用于高增益模式的模型也能兼容低增益模式。

1.2 CALIPSO 卫星数据概况

CALIPSO 卫星通过激光雷达技术研究云层和气溶胶对地球气候与环境的影响。该卫星装备了云气溶胶激光雷达(CALIOP)、红外成像辐射计和广角相机,这些仪器提供了全面的气象观测视角和关于云层的红外特性数据^[27]。卫星在太阳同步轨道上工作,每16天重复一次轨道轨迹。CALIOP是一种双波长偏振激光雷达,对气溶胶和云垂直分布的连续测量,具有非常高的空间分辨率(水平分辨率

表2 陆地生态系统碳监测卫星主要技术参数

Table 2 Main technical parameters of the terrestrial ecosystem carbon monitoring satellite

项目		陆地碳
卫星信息	轨道高度	506 km
	轨道类型	太阳同步
	轨道倾角	97.421°
	整体质量	2 936 kg
	预期寿命	8 年
载荷信息	激光发散角(2ω)	≤110 μrad
	激光脉冲宽度	≤30 ns
	激光波形采样频率	10 MHz
	激光回波量化位数	16 bit
	波束数量	1
	激光重频	20 Hz
	激光能量	70 mJ
	大气通道范围	-2~40 km
	垂直分辨率	15 m
	大气廓线采样长度	2 800
接收通道		3 个,1 064 nm通道、532 nm P通道、532 nm S通道

*注:S与P分别表示偏振与平行通道

可达333 m,垂直分辨率可达30/60 m)。CALIOP激光雷达的足迹尺寸为100 m,视场角为130 μrad。该激光雷达分别测量波长为532 nm和1 064 nm的后向散射激光信号,得出气溶胶和云的垂直分布特征。为了进一步解析这些激光回波信号,从L1B数据层生成的垂直特征掩模(Vertical Feature Mask,VFM)数据,可详细展示大气中各种颗粒的垂直结

构^[28]。VFM数据不仅标识颗粒存在的层次,还按高度详细分类大气中的颗粒类型,如云层、气溶胶、清洁空气,并进一步区分云层和气溶胶的亚型,将观测到的气溶胶分为七个亚型,包括“清洁海洋”、“尘埃”、“污染大陆”、“清洁大陆”、“污染尘埃”、“烟雾”和“其他”。然而,VFM的数据质量受到大气条件、观测时间和云气溶胶的复杂性影响,导致某些区域的数据不完全或不够精确。特别是在低云、薄云或者地面反射强的情况下,VFM算法可能无法准确区分云层与气溶胶,或者将部分气溶胶误标为云层,导致误分类问题。此外,VFM的层次划分在某些情况下也存在偏差,尤其是对于高层云、冰云和一些特殊类型的气溶胶(如沙尘或火灾烟雾)识别时,往往存在识别困难。因为不同的气溶胶和云层具有类似的光学特性,CALIPSO的激光雷达技术在区分这些类型时可能会受到一些限制,导致分类结果不够精确。

2 实验方法

本文利用TECIS-CASNet框架处理陆地生态系统碳监测卫星数据,对大气目标进行层次化分类,并反演气溶胶光学厚度。包括以下步骤:首先进行层次化分类,构建TECIS-CASNet框架;归一化处理陆地生态系统碳监测卫星 Level 2A 数据,生成单通道图像;将SYBIL算法得到的分类产品作为标签;进行模型训练。然后进行气溶胶光学厚度反演,采用Fernald分析法反演气溶胶特性,通过计算消光系数、对消光系数进行积分,获得气溶胶的光学厚度。最后对气溶胶反演结果进行验证,采用地基太阳光度计、地基激光雷达同步观测结果多源数据进行

验证。

2.1 云、气溶胶层次化分类

(1) TECIS-CASNet网络结构

自Transformer架构在自然语言处理领域取得显著成就以来,其核心机制——自注意力(Self-Attention)已经被扩展应用到语义分割领域。自注意力机制的引入使得模型具备捕捉长距离数据依赖的能力,这对于高级语义特征的建模至关重要。正是基于这种全局感知能力,SwinUNet模型^[29]应运而生,它将Swin Transformer的全局感知优势与U-Net在空间特征传递上的高效性能相结合,构建出一种适用于精确医学图像分割的架构。在遥感大气目标的层次化分类应用中,该模型进一步演化为TECIS-CASNet框架,专门用于处理星载激光雷达数据。

图2展示了TECIS-CASNet整体结构,该框架利用层级结构降低特征图分辨率,这不仅扩大了感受野,也增强了模型对高级语义信息的捕获能力。编码器部分采用Swin Transformer块来提取深层次图像特征,而解码器则利用这些特征逐渐恢复图像分辨率,并生成精确度极高的分割图。模型内置的跳跃连接确保了特征在不同层级间的有效融合,从而关键地提升了分割准确率。

如图3所示,Swin Transformer模块主要由以下几部分组成:层归一化(Layer Normalization, LN)、窗口多头自注意力(Window Multi-head Self-Attention, W-MSA)、多层感知器(Multilayer Perceptron, MLP)和移位窗口多头自注意力(Shifted Window Multi-head Self-Attention, SW-MSA)。特征提取过程如下:首先,对输入的云和气溶胶特征进行标准




图2 TECIS-CASNet整体结构

Fig. 2 Overall structure of TECIS-CASNet




图3 Swin Transformer block 介绍

Fig. 3 Introduction to Swin Transformer block

化处理,得到归一化后的特征,这一过程通过多头自注意力机制在局部窗口内执行(式(1))。标准化操作能够稳定网络训练过程,减少梯度消失或爆炸的风险,同时加快模型的收敛速度。多头自注意力模块用于捕捉云和气溶胶的高度、形态及光学特性差异。云层通常反射性强且边界清晰,而气溶胶层更接近地表,具有更复杂的散射特性。多头自注意力机制通过不同注意力头捕捉不同子空间的特征,尤其是在边界模糊和信噪比低的情况下,有效提升对云和气溶胶细微结构的辨别能力。处理后的特征将与输入特征相加(式(2))。接下来,经过标准化后的特征进入多层感知器(MLP)模块,进行非线性变换,进一步增强模型的表达能力(式(3))。MLP的输出与先前的特征相加(式(3)),这一操作维持了多层次特征流动,增加了模型的鲁棒性。随后,SwiTransformer通过移位窗口机制(SW-MSA)调整窗口边界,以捕捉长距离的依赖关系。移位窗口机制允许模型关注到跨越窗口边界的全局特征,特别是在云和气溶胶层的复杂结构中尤为重要。处理后的特征与原始特征再次相加(式(4)),从而减少因窗口边界引发的特征信息丢失,提升全局特征捕捉能力。最后,经过MLP进一步处理(式(4)),模型能够更全面地捕捉云和气溶胶的全局与局部特征。

$$\hat{z}^l = \text{W-MSA}(\text{LN}(z^{(l-1)})) + z^{(l-1)}, \quad (1)$$

式(1)中, $z^{(l-1)}$ 表示第 $l-1$ 层的输入特征,即从前一层传递下来的特征。 $\hat{z}^l$ 是经过第 l 层中的窗口多头自注意力(W-MSA)模块处理后的特征。

$$z^l = \text{MLP}(\text{LN}(\hat{z}^l)) + \hat{z}^l, \quad (2)$$

式(2)中, z^l 表示经过多层感知器(MLP)处理并与先前的 $\hat{z}^l$ 相加后的特征。

$$\hat{z}^{(l+1)} = \text{SW-MSA}(\text{LN}(z^l)) + z^l, \quad (3)$$

式(3)中, $\hat{z}^{(l+1)}$ 是经过移位窗口多头自注意力(SW-MSA)模块处理后的特征。

$$z^{(l+1)} = \text{MLP}(\text{LN}(\hat{z}^{(l+1)})) + \hat{z}^{(l+1)}, \quad (4)$$

式(4)中, $z^{(l+1)}$ 表示第 $l+1$ 层经过多层感知器(MLP)处理并与 $\hat{z}^{(l+1)}$ 相加后的特征。

(2) 数据预处理

在处理陆碳卫星的L2A原始数据和CALIPSO的L1B原始数据时,首先,如式(5)、(6)所示,利用衰减后向散射系数计算退偏比和颜色比,然后将532 nm的后向散射系数、退偏比和颜色比进行归一化。通过归一化,将像素值标准化到0~255的范围内。不同时间和地点获取的数据将具有一致的亮度和对比度,降低环境噪声的影响,提升图像中特征的可辨识度,确保数据与大多数图像处理算法兼容,并且提高算法对特征的识别能力。将处理后的三个输入数据组合为RGB通道,形成与实际高度相对应的栅格图像格式,高度像素大小为224,沿轨道像素大小为224,与相应的标签一起用于构建数据集,用于模型训练、验证和测试。

$$\text{Dep_ratio} = \beta'_{532\perp}(r) / \beta'_{532\parallel}(r), \quad (5)$$

其中, $\beta'_{532\perp}(r)$ 表示532 nm垂直通道后向散射系数, $\beta'_{532\parallel}(r)$ 表示532 nm平行通道后向散射系数。

$$\text{Col_ratio} = \beta'_{1064}(r) / \beta'_{\text{Total}}(r), \quad (6)$$

其中, $\beta'_{1064}(r)$ 表示1 064 nm总后向散射系数, $\beta'_{\text{Total}}(r)$ 表示532 nm总后向散射系数。

(3) 训练过程

模型训练过程分为两部分,先后训练CALIPSO数据和TECIS数据。CALIPSO训练与测试数据集包括2023年1月至7月的共217轨L1B数据和VFM产品,TECIS训练与验证数据集包括2023年1月至12月的共246轨L2A数据和通过SYBIL算法得到的分类结果。首先由CALIPSO VFM产品训练得到初步模型,之后再基于初步模型进行TECIS数据识别,采用Python 3.9和Pytorch 1.13.1构建了CASNet模型,并在配备64 GB内存的Nvidia V100 GPU上进行训练。在训练过程中,设置初始学习率为0.001,批量大小为2,采用动量为0.9和权重衰减率为 10^{-4} 的

随机梯度下降(SGD)优化器进行模型的优化和反向传播。

(4) 精度评价

在本研究的语义分割训练和验证任务中,使用精确度、召回率、F1 分数来评价和比较 TECIS-CAS-Net 模型的性能。模型将图像分为三类:背景、云和气溶胶。

精确度(Precision)是指在所有被模型预测为正例的样本中,真正为正例的比例。它关注的是模型预测的正例的质量。计算公式如(7)所示,其中,TP (True Positives)是正确预测为正例的数量,FP (False Positives)是错误预测为正例的数量。

$$\text{precision} = \frac{\text{TP}}{(\text{TP} + \text{FP})} \quad (7)$$

召回率(Recall)是指在所有实际为正例的样本中,被模型正确预测为正例的比例。它关注的是模型对正例的覆盖程度。计算公式如式(8)所示,其中, FN (False Negatives)是错误预测为负例的正例数量。

$$\text{recall} = \frac{\text{TP}}{(\text{TP} + \text{FN})} \quad (8)$$

F1 分数(F1 Score)是精确度和召回率的调和平均,用于综合考虑精确度和召回率。当精确度和召回率之间存在权衡时,F1 分数可以提供单一的度量标准来评估模型的总体效果。计算公式如式(9)所示,F1 分数尤其适用于那些正负样本不平衡的情况,能够平衡考虑正例预测的准确性和完整性。

$$\text{F1 - score} = \frac{2\text{TP}}{(2\text{TP} + \text{FP} + \text{FN})} \quad (9)$$

$$\beta_p(z) = -\beta_m(z) + \frac{P(z)z^2 \exp\left[-2(S_p - S_m) \int_{z_c}^z \beta_m(z') dz'\right]}{\frac{P(z_c)z_c^2}{\beta(z_c)} - 2S_p \int_{z_c}^z \left\{ P(z)z^2 \exp\left[-2(S_p - S_m) \int_{z_c}^z \beta_m(z') dz'\right] \right\} dz} \quad (11)$$

当选定一个近端参考位置 z_c (即边界点),并且该参考点上气溶胶粒子的消光系数和后向散射系

$$\alpha_p(z) = \frac{S_p}{S_m} \alpha(z) + \frac{P(z)z^2 \exp\left[-2\left(\frac{S_p}{S_m} - 1\right) \int_{z_c}^z \alpha_m(z') dz'\right]}{\frac{P(z_c)z_c^2}{\alpha(z_c) + \frac{S_p}{S_m} \alpha_m(z_c)} - 2 \int_{z_c}^z \left\{ P(z')z'^2 \exp\left[-2\left(\frac{S_p}{S_m} - 1\right) \int_{z_c}^z \alpha_m(z'') dz''\right] \right\} dz} \quad (12)$$

最后对气溶胶层次部分的气溶胶粒子消光系数进行积分,如式(13)所示,得到气溶胶光学厚度 AOD。

2.2 气溶胶光学厚度反演

使用陆碳卫星激光雷达数据分析时,通过层次识别算法从激光雷达信号中识别含云或气溶胶的区域,算法不仅能细分出它们的子类别,还可以识别出云和气溶胶的位置,为气溶胶特性的精确反演提供了基础数据。Fernald 前向反演法是以激光雷达方程为基础来求解气溶胶消光系数的^[30],激光雷达方程如式(10)所示,由于 Fernald 法是将大气分为大气分子和大气微粒两类,因此,方程中的大气消光系数和后向散射系数都包括两部分,即大气分子贡献的部分和气溶胶贡献的部分:

$$P(z) = P_0 * \frac{c\tau}{2} * \frac{[\beta_m(z) + \beta_p(z)]A}{z^2} * \exp\left\{ -2 \int_0^z [\alpha_m(z') + \alpha_p(z')] dz' \right\} \quad (10)$$

式中, $P(z)$ 表示激光雷达接收到的与卫星相距 z 处的后向散射回波功率; P_0 为激光发射功率; c 为光速; τ 为激光脉冲宽度; A 为系统光学天线接收面积; z 是从卫星至探测目标的距离; $\alpha_m(z)$ 和 $\alpha_p(z)$ 分别表示大气分子和气溶胶粒子的消光系数; $\beta_m(z)$ 和 $\beta_p(z)$ 分别表示大气分子和气溶胶粒子的后向散射系数。

已知大气分子主要发生瑞利散射,消光系数与后向散射系数的比值 $S_m = \alpha_m(R)/\beta_m(R) \approx 8\pi/3$ 。对于气溶胶,定义其消光系数和后向散射系数的比值 $S_p = \alpha_p(z)/\beta_p(z)$ 为气溶胶雷达比,在反演过程中需要对该比值进行假设^[31]。同时选定参考位置为 z_c , z_c 处对应的后向散射系数为 $\beta(z_c)$,则对激光雷达方程进行求解可以得到气溶胶粒子的后向散射系数,如式(11)所示:

数已知时,则可得气溶胶消光系数为式(12)所示,其中 $0 < z_c < z_0$ 。

$$\text{AOD} = \int_{z_c}^z \alpha_p(z') dz' \quad (13)$$

3 实验结果与分析

3.1 层次识别结果精度验证

星载激光雷达可以大范围获取云-气溶胶的垂直分布信息,但是容易受到激光穿透能力限制、多层云和气溶胶的干扰以及高光学厚度的散射与吸收的影响,因此如何实现在低信噪比、近地表和多层结构混合等复杂环境条件下准确区分云和气溶胶的垂直结构是传统理论的难点问题。如图4所示,展示了TECIS-CASNet在低信噪比、仅云层和云-气溶胶层混合等多种情况下的大气垂直层次分类结果,其中第一列代表原始后向散射廓线数据,第二列代表TECIS数据通过SYBIL算法得到的分类结果,第三列代表TECIS-CASNet预测结果。其中Prediction中标记为红色框和紫色框的区域,分别代表VFM中的Missing Data(MD)和Misidentification Data(MDD)。

在低信噪比时,大气信号尤其是近地表部分,受背景噪声影响较大(图4(a1)),存在较多的误识别MD,即存在对弱信号混合层的漏检,同时对于近地表大气信号的云-气溶胶精细化分类存在误分类MDD(图4(a2))。对于这种情况,TECIS-CASNet通过学习海量数据中背景信号与大气信号的显著差异,来精准捕获低信噪比条件下的云-气溶胶分布,尤其是对低信噪比、近地表信号时的TECIS数据有显著作用(图4(a3))。

在处理仅云层情况时,本文区分了高云、中云、低云以及多层云四种具体情况。在低、中、高云情况下,云层由于物理厚度大,影响下层大气的信号强度,传统算法在这些区域可能出现较高的误识别率和漏检率(图4(b3)、(c3)、(d3))。TECIS-CASNet能有效降低这种误识别,尤其是在多层云的情况下(图4(e3)),通过多头注意力机制和深度学习网络的特性,它能更好地区分和识别不同高度云层的交互影响。这一改进大幅提升了模型在复杂云层情况下的分类准确率和可靠性。特别是对于多层云,TECIS-CASNet能更准确地划分各个层次,提高对物理厚度大云层及其下层大气的信号分辨率,进而更精确地捕获中小尺度云-气溶胶边界层的微观物理特性。

云-气溶胶宏微观物理特性复杂多变,且在多层混合时云-气溶胶-噪声三者信号强度呈现交叉梯度跃迁,例如SYBIL等传统迭代算法不能准确捕获这种影响下的层边缘信息,同时对于过于破碎离

散的信号缺乏表达(图4(f1))。TECIS-CASNet框架中的多头注意力机制可以从沿轨方向上的大气后向散射剖面特征中先获取到云-气溶胶-噪声三者信号强度的整体分布,其次再从类间边缘中学习三者信号的差异。基于这种学习能力,框架可以从云-气溶胶混合信号中捕获中小尺度的大气信号及边缘信息,同时提升多层云-气溶胶信号下的底部特征的识别能力,从而减少最终的误识别与漏检(图4(f3))。

综上,532 nm波长的后向散射系数中较高的噪声水平降低了信号的清晰度,特别是在检测较弱的大气特征时(如稀薄的气溶胶或薄云层),导致这些特征难以准确识别。这种噪声干扰使SYBIL算法对大气特征分类的不确定性增加。从表3分类精度结果中可以看出,模型在验证数据中真阳性(TP)和真阴性(TN)预测方面具有较高的准确性,假阳性(FP)和假阴性(FN)值较低。性能指标包括精确率(98.41%)、召回率(98.23%)和F1分数(94.02%),进一步表明模型在预测中的高准确性和普适性。

3.2 气溶胶光学厚度反演精度验证

在大气垂直层次反演精度提升的基础上,本文结合了Fernald理论进行气溶胶光学厚度反演,并将其作为附属模块整合到TECIS-CASNet框架中。光学厚度是表征大气中气溶胶、云层等颗粒物对光线散射和吸收作用的关键参数,为确保光学厚度反演的准确性,当前验证结果常常依赖于地基观测数据,特别是地基太阳光度计和地基激光雷达等设备,这些设备提供的消光系数或整体光学厚度数据是验证反演结果的重要依据。

本文采用了图5和表4中所示的两种方法进行精度评价,进一步验证了本研究方法的有效性和可靠性。具体来说,2023年2月10日,TECIS卫星经过中国台湾地区,并且该轨迹附近有两个地基太阳光度计观测站——Chen-Kung_ Univ 和 Kaohsiung,它们隶属于全球地基气溶胶遥感观测网AERONET。这些站点提供了同步观测的光学厚度数据,将其与TECIS卫星在相同时间范围内获得的光学厚度数据进行比较。为了确保比较结果的可靠性,选择了以站点为中心,半径为30 km的范围进行统计分析。图5(a)展示了TECIS卫星过境期间的光学厚度反演结果,其中红色框标示了TECIS卫星经过这些站点的具体时间段。通过这一比较,发现TECIS-CASNet框架反演的光学厚度绝对精度在0.02左右,且




图4 案例分析,低信噪比下的层次识别结果:(a1~3);不同情形云层次识别结果:(b1~3)高云,(c1~3)中云,(d1~3)低云,(e1~3)多层云;不同情形云-气溶胶混合时的层次识别结果:(f1~3)

Fig. 4 Case analysis, hierarchical recognition results under low signal-to-noise ratio: (a1-3); cloud hierarchical recognition results in different scenarios: (b1-3) high cloud, (c1-3) middle cloud, (d1-3) low cloud, (e1-3) multi-layer cloud; hierarchical recognition results for cloud-aerosol mixtures in different scenarios: (f1-3)

表3 分类精度结果

Table 3 Classification accuracy result				
Metric	Background	Cloud	Aerosol	Overall
FP	56 679	54 248	37 991	
FN	85 525	44 250	19 143	
TP	7 993 205	242 610	15 267	
TN	264 591	8 058 892	8 327 599	
Precision				98.41%
Recall				98.23%
F1 Score				98.31%

在同步观测范围内的精度更为可靠。

此外,2022年12月19日,TECIS卫星经过中国浙江省区域,并与浙江大学研发的双波长高光谱激光雷达ZJU-HRSL进行了同步观测。该区域云气溶胶分布较为复杂,且ZJU-HRSL具有较强的观测能力,可以精确捕捉到大气中的气溶胶和云层信息。

为确保数据的对比性,在该区域选择了50 km的半径范围,对TECIS卫星与ZJU-HRSL测得的垂直消光系数进行了对比分析。图5(b)展示了这两者的对比结果,进一步验证了TECIS-CASNet反演方法的准确性,特别是在较大范围内,消光系数的相对精度达到了85%。不过,对于近地表的云-气溶胶信号而言,地基获取的精度更好。星载激光雷达在近地表时会受到多层云-气溶胶多次散射衰减的影响降低信号强度,同时与近地弱干扰信号发生一定的混合,会导致整体信噪比偏低且精度下降。

表4 气溶胶特性数据反演精度验证结果

Table 4 The inversion accuracy verification results of aerosol characteristics data

案例	站点描述	本研究结果	参考值	整体精度
AERONET	Chen-Kung Univ 站点 (22.993° N, 120.209° E)	Mean AOD 0.16±0.1	0.14~ 0.21	RMSE: 0.02
	Kaohsiung 站点 (22.676° N, 120.292° E)	Mean AOD 0.16±0.1	0.15~ 0.16	Bias: -0.01
	ZJU-HRSL (30.2° N, 120.2° E)	Mean Ex- tinction 0.09 km ⁻¹	0.12 km ⁻¹	±0.03 ±25%

3.3 大范围长距离沙尘传输分析

自从2023年8月CALIPSO任务退役后,TECIS卫星开始作为继任者接力监测全球云-气溶胶时空分布信息。星载激光雷达技术,通过发射激光脉冲并接收其从大气层反射回来的信号,能够准确探测云层、气溶胶的垂直分布,为大气物理研究提供关键的遥感数据。TECIS卫星的激光雷达不仅能测量云气溶胶的空间分布,还能对不同高度的气溶胶浓度进行精确量化,因此在沙尘传输、空气质量监测等领域具有重要应用。超远距离沙尘传输不仅仅影响沙尘源头区域,还对沿途和下风向国家和地区造成广泛的空气污染、健康风险和生态损害。通过气象数据和HYSPLIT模型对沙尘传输路径进行了模拟和预测,同时结合TECIS-CASNet框架对CALIPSO和TECIS卫星数据进行自动层次识别,进而实现量化这种超远距离输送的影响。

在本节,将2023年3月22日发生的春季典型沙尘事件作为案例,追踪影响京津冀区域的沙尘源头。图6(a)为HYSPLIT模型结合气象数据所预测




图5 精度验证结果:(a)光学厚度与中国台湾 Aeronet 站点验证结果;(b)消光系数与 HRSL 验证结果

Fig. 5 Accuracy verification results: (a) verification results of aerosol optical depth and three Aeronet sites in Taiwan, China; (b) verification results of extinction coefficient and HRSL

的沙尘迁徙轨迹和大气团高度,可以看出中国京津冀的典型沙尘主要来自于蒙古国境内,而红色框 A、B 对应 CALIPSO 观测轨迹,红色框 C 对应 TECIS 观测轨迹,它们所获取的后向散射廓线及 TECIS-CAS-Net 层次识别的结果对应图 6(b1~2、c1~2、d1~2)。自 2023 年 3 月以来,中国北方地区降水量偏少,蒙古国和中国西北地区气温显著升高,导致地表无积雪覆盖。3 月 22 日前后,受冷空气的影响,内蒙古、华北及东北部分地区出现了较大范围的沙尘天气。根据图 6(a)所示,影响京津冀地区的沙尘主要来自内蒙古中部和蒙古国南部。这些沙尘颗粒在风力作用下,从地面被吹升至 500~5 500 m 的高度,并向东南方向输送。早在 3 月 19 日,蒙古国和内蒙古地区就已经出现了沙尘(图 6(b1、b2;c1、c2))。到 3 月 20 日,三地均存在沙尘,且垂直跨度较大,这表明内蒙古和蒙古国的沙尘开始远距离传输,主要对京津冀上空造成影响(图 6(b1、b2;c1、c2;d1、d2))。3 月 21 日和 22 日,蒙古国和内蒙古的沙尘主要集中在近

地表(图 6(b1、b2;c1、c2)),这说明沙尘的远距离传输能力逐渐减弱,同时京津冀地区的沙尘也开始对近地表区域造成影响(图 6(d1、d2))。到 3 月 23 日,京津冀地区的沙尘显著减少,几乎没有检测到沙尘气溶胶(图 6(d1、d2)),表明此次沙尘事件接近尾声。

通过多源遥感数据的融合分析,能够有效整合来自不同卫星平台的数据,提供沙尘传输事件的时空演变特征。这些数据的融合使得研究人员能够从多个角度获得对沙尘事件的全面理解,进而为政策制定者和环境保护部门提供更加精确的决策支持。

4 结论

传统云-气溶胶识别算法在低信噪比、近地表和多层结构混合等复杂大气条件下常常出现误检、漏检等现象,从而导致最终的层次识别精度较差。此外,传统算法直接应用于 TECIS 卫星会存在计算复杂度高和鲁棒性差等问题。针对上述问题,本文




图6 典型长距离沙尘区域传输事件分析:(a)2023年3月22日UTC 02:00北京地区48 h后向轨迹模拟图;(b1、b2)蒙古国3月19—22日CALIPSO后向散射系数和TECIS卫星监测图;(c1、c2)内蒙古3月19—22日后向散射系数和TECIS卫星监测图;(d1、d2)京津冀3月20—23日CALIPSO后向散射系数和TECIS卫星监测图

Fig. 6 Analysis of typical long-distance regional transport events of sand and dust: (a) 48 h backward track simulation diagram over Beijing at UTC 02:00 on March 22nd, 2023; (b1, b2) CALIPSO backscattering coefficient and TECIS satellite monitoring map of Mongolia from March 19th to 22nd; (c1, c2) backscattering coefficient and TECIS satellite monitoring map of Inner Mongolia from March 19th to 22nd; (d1, d2) CALIPSO backscattering coefficient and TECIS satellite monitoring map of Beijing, Tianjin and Hebei from March 20th to 23rd

基于 TECIS 卫星后向散射廓线数据和深度学习 Transformer 结构,提出一种大气层次识别和应用的通用框架 TECIS-CASNet 来改善传统方法的不足,并结合中国京津冀的典型沙尘长距离传输进行了大范围分析,主要结论如下:

1)TECIS-CASNet 框架能够通过多头注意力机制精确捕获云-气溶胶信号的精细变化,可有效解决复杂大气条件下的云-气溶胶层次识别漏检、误检等问题,整体精度达到 98%,相比于 SYBIL 传统算法可大幅提升分类精度、计算效率和水平分辨率。试验区的结果与地基激光雷达、太阳光度计的对比验证表明,框架反演的云-气溶胶光学厚度绝对精度达到 0.01、整体精度达到 98%,具有较强的可靠性和稳定性;

2)自 2023 年 3 月以来,京津冀及周边地区因气温升高、降水减少,频繁遭受沙尘天气影响,特别是在蒙古国和中国西北无积雪覆盖的地表条件下。3 月 19 日—22 日,受冷空气驱动,蒙古国南部和内蒙古中部的沙尘被风力升至 500~5 500 m,并向东南传输至京津冀。19 日,沙尘在源头显现并快速扩散至京津冀,显示其远距离传输能力。21 日,沙尘集中在近地表,传输能力减弱。3 月 23 日,沙尘几乎消散,标志事件结束。

通过这些研究和应用,TECIS-CASNet 框架为全球生态系统碳监测提供了一个有效的工具,有望推动环境保护和气候变化应对策略的进一步发展。在未来的研究工作中,将重点从多个维度对模型进行进一步优化:首先,考虑去噪算法来对输入数据进行处理;其次,增加标签的准确性;最后,针对云和气溶胶的复杂性,研究将致力于实现更精细的子类别识别。通过优化深度学习和多源数据融合策略,确保模型能够更精确地捕捉大气层中各类微观现象,提供更高质量的时空分布信息。

References

- [1] Rosenfeld D, Andreae M O, Asmi A, et al. Global observations of aerosol-cloud-precipitation-climate interactions: Aerosol-cloud-climate interactions [J]. *Reviews of Geophysics*, 2014, 52(4): 750-808.
- [2] Liu S, Xing J, Zhao B, et al. Understanding of aerosol-climate interactions in China: aerosol impacts on solar radiation, temperature, cloud, and precipitation and its changes under future climate and emission scenarios [J]. *Current Pollution Reports*, 2019, 5(2): 36-51.
- [3] Stubenrauch C J, Cros S, Lamquin N, et al. Cloud properties from atmospheric infrared sounder and evaluation with cloud-aerosol Lidar and infrared pathfinder satellite observations [J]. *Journal of Geophysical Research: Atmospheres*, 2008, 113(D8): 2008JD009928.
- [4] Wang D, Stachlewska I S, Delanoë J, et al. Spatio-temporal discrimination of molecular, aerosol and cloud scattering and polarization using a combination of a Raman lidar, Doppler cloud radar and microwave radiometer [J]. *Optics Express*, 2020, 28(14): 20117.
- [5] Shen F, Zhang Q, Ma J, et al. Identification of polluted clouds and composition analysis based on GF-5 DPC data [J]. *Journal of Quantitative Spectroscopy and Radiative Transfer*, 2021, 269: 107659.
- [6] Yorks J E, Selmer P A, Kupchock A, et al. Aerosol and cloud detection using machine learning algorithms and space-based Lidar data [J]. *Atmosphere*, 2021, 12(5): 606.
- [7] Yao J, Tang X, Li G, et al. Influence of atmospheric scattering on the accuracy of laser altimetry of the GF-7 Satellite and corrections [J]. *Remote Sensing*, 2022, 14(1): 129.
- [8] Yao Jia Qi, Gao Xiao Ming, Li Guo Yuan, et al. Retrieval of cloud optical thickness using ICESat/GLAS echo energy data [J]. *Infrared and Laser Engineering*, 2019, 48(S1): 132-140.
么嘉祺, 高小明, 李国元, 等. ICESat/GLAS 回波能量数据的云光学厚度反演 [J]. *红外与激光工程*, 2019, 48(S1): 132-140.
- [9] Yao Jia Qi, Tang Xin Ming, Li Guo Yuan, et al. Cloud detection of laser altimetry satellite ICESat-2 and the related algorithm [J]. *Laser & Optoelectronics Progress*, 2020, 57(13): 248-256.
么嘉祺, 唐新明, 李国元, 等. 激光测高卫星 ICESat-2 云检测及其相关算法 [J]. *激光与光电子学进展*, 2020, 57(13): 248-256.
- [10] Oreopoulos L, Cho N, Lee D. New insights about cloud vertical structure from CloudSat and CALIPSO observations [J]. *Journal of Geophysical Research: Atmospheres*, 2017, 122(17): 9280-9300.
- [11] Li J L F, Xu K M, Jiang J H, et al. An overview of CMIP5 and CMIP6 simulated cloud ice, radiation fields, surface wind stress, sea surface temperatures, and precipitation over tropical and subtropical oceans [J]. *Journal of Geophysical Research: Atmospheres*, 2020, 125(15): e2020JD032848.
- [12] Yorks J E, McGill M J, Palm S P, et al. An overview of the CATS level 1 processing algorithms and data products [J]. *Geophysical Research Letters*, 2016, 43(9): 4632-4639.
- [13] Huo J, Lu D, Duan S, et al. Comparison of the cloud top heights retrieved from MODIS and AHI satellite data with ground-based Ka-band radar [J]. *Atmospheric Measurement Techniques*, 2020, 13(1): 1-11.
- [14] Zha C, Bu L, Li Z, et al. Aerosol optical property measurement using the orbiting high-spectral-resolution lidar on board the DQ-1 satellite: retrieval and validation [J]. *Atmospheric Measurement Techniques*, 2024, 17(14): 4425-4443.
- [15] Du S, Liu L, Liu X, et al. The solar-induced Chlorophyll fluorescence imaging spectrometer (SIFIS) onboard the first Terrestrial Ecosystem Carbon Inventory Satellite (TE-

- CIS-1): specifications and prospects[J]. *Sensors*, 2020, 20(3): 815.
- [16] Naeger A R, Christopher S A, Ferrare R, et al. A new technique using infrared satellite measurements to improve the accuracy of the CALIPSO cloud-aerosol discrimination method[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(1): 642-653.
- [17] Liu Z, Kar J, Zeng S, et al. Discriminating between clouds and aerosols in the CALIOP version 4.1 data products[J]. *Atmospheric Measurement Techniques*, 2019, 12(1): 703-734.
- [18] Vaillant De Guélis T, Ancellet G, Garnier A, et al. Assessing the benefits of imaging infrared radiometer observations for the CALIOP version 4 cloud and aerosol discrimination algorithm [J]. *Atmospheric Measurement Techniques*, 2022, 15(6): 1931-1956.
- [19] Ma Y, Gong W. Evaluating the performance of SVM in dust aerosol discrimination and testing its ability in an extended area[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, 5(6): 1849-1858.
- [20] Brakhasi F, Matkan A, Hajeb M, et al. Atmospheric scene classification using CALIPSO spaceborne lidar measurements in the Middle East and North Africa (MENA), and India[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2018, 73: 721-735.
- [21] Yao J, Raffuse S M, Brauer M, et al. Predicting the minimum height of forest fire smoke within the atmosphere using machine learning and data from the CALIPSO satellite [J]. *Remote Sensing of Environment*, 2018, 206: 98-106.
- [22] Zeng S, Omar A, Vaughan M, et al. Identifying aerosol subtypes from CALIPSO Lidar profiles using deep machine learning[J]. *Atmosphere*, 2020, 12(1): 10.
- [23] Lu H, Ma Y, Zhang S, et al. Daytime sea fog identification based on multi-satellite information and the ECA-TransUnet model[J]. *Remote Sensing*, 2023, 15(16): 3949.
- [24] Lolli S. Machine learning techniques for vertical Lidar-based detection, characterization, and classification of aerosols and clouds: a comprehensive survey[J]. *Remote Sensing*, 2023, 15(17): 4318.
- [25] Li Guo Yuan, Yao Jia Qi, Zhao Yi Ming, et al. Current status and prospects of atmospheric scattering delay correction for laser altimetry satellites[J]. *Infrared and Laser Engineering*, 2020, 49(11): 65-75.
李国元, 么嘉棋, 赵一鸣, 等. 激光测高卫星大气散射延迟改正现状及展望[J]. *红外与激光工程*, 2020, 49(11): 65-75.
- [26] Yao Jia Qi, Zhai Hao Ran, Liu Ren, et al. Analysis of photon-based laser altimetry satellite atmospheric detection algorithms[J]. *Progress in Laser and Optoelectronics*, 2022, 59(22): 318-327.
么嘉棋, 翟浩然, 刘仁, 等. 光子体制激光测高卫星大气探测算法分析[J]. *激光与光电子学进展*, 2022, 59(22): 318-327.
- [27] Kim M H, Omar A H, Tackett J L, et al. The CALIPSO version 4 automated aerosol classification and lidar ratio selection algorithm [J]. *Atmospheric Measurement Techniques*, 2018, 11(11): 6107-6135.
- [28] Liu Z, Vaughan M, Winker D, et al. The CALIPSO Lidar cloud and aerosol discrimination: version 2 algorithm and initial assessment of performance [J]. *Journal of Atmospheric and Oceanic Technology*, 2009, 26(7): 1198-1213.
- [29] Gao Z J, He Y, Li Y. A novel lightweight swin-unet network for semantic segmentation of COVID-19 lesion in CT images[J]. *IEEE Access*, 2023, 11: 950-962.
- [30] Fernald F G. Analysis of atmospheric lidar observations: some comments [J]. *Applied Optics*, 1984, 23(5): 652-653.
- [31] Omar A H, Winker D M, Kittaka C, et al. The CALIPSO automated aerosol classification and Lidar ratio selection algorithm[J]. *Journal of Atmospheric & Oceanic Technology*, 2009, 26(10): 1994-2014.