

基于神经网络的 L 波段星载微波辐射计 快速大气校正模型

朱博雯^{1,2} 张成¹ 刘浩¹

1(中国科学院国家空间科学中心 中国科学院微波遥感技术重点实验室 北京 100190)

2(中国科学院大学电子电气与通信工程学院 北京 100049)

摘要 大气校正是星载微波辐射计应用的一个关键环节, 通常需要建立快速大气辐射传输模型。首次采用神经网络方法对 L 波段星载微波辐射计大气校正问题进行研究。首先对传统的大气层顶亮温模型进行变换, 得到一种新的关于地表亮温的线性大气校正方程, 将其斜率和截距作为校正系数进行建模以简化校正过程并提高计算效率; 其次基于 MPM93 大气辐射传输模型和 ERA5 逐小时再分析数据对地表水汽密度和总柱水含量进行敏感度分析, 以此优化模型输入参数; 然后采用神经网络方法对大气校正系数进行参数化建模, 得到一种新的大气校正模型: A-B 神经网络模型; 最后利用 Peng 模型和 SMAP 卫星 L1B 亮温数据对 A-B 神经网络模型进行综合测试和验证。结果表明, A-B 神经网络模型与 Peng 模型吻合良好, 其校正亮温与 SMAP 数据的平均误差约为 0.03K, 从而验证了该模型的准确性和可行性, 可为星载 L 波段微波辐射计的大气校正工程应用提供一种备选方案。

关键词 星载微波辐射计, 大气校正, L 波段, 神经网络。

中图分类号 (TP722.6)

A Fast Atmospheric Correction Model for L-band Spaceborne Microwave Radiometer Based on Neural Network

ZHU Bowen^{1,2} ZHANG Cheng¹ LIU Hao¹

1 (Key Laboratory of Microwave Remote Sensing, National Space Science Center, Chinese Academy of Sciences, Beijing 100190)

2 (School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 100049)

Abstract Atmospheric correction is critical for the application of spaceborne microwave radiometers, which generally requires to develop fast atmospheric radiative transfer models. In this work, the neural network is used for the atmospheric correction of L-band spaceborne microwave radiometers for the first time. Firstly, the traditional top-of-atmosphere brightness temperature model was reformulated, yielding a novel linear atmospheric correction equation with respect to the Earth's surface brightness temperature. The slope and intercept of this equation can serve directly as the atmospheric correction coefficients for modeling purposes, thus improving efficiency and accuracy. Secondly, based on the MPM93 atmospheric radiative transfer model and ERA5 hourly reanalysis data, the sensitivity of surface water vapor density and total column water vapor was analyzed for the purpose of optimizing

* 基金项目: 正式的名称类型 (编号)

投稿日期:

E-mail:

the model input parameter. Thirdly, a new atmospheric correction model, A-B neural network model, was developed using the neural network method, which can greatly simplify the atmospheric correction process. Finally, comprehensive comparative tests were performed using the Peng model and SMAP L1B data. The results demonstrate that the A-B neural network model has good consistency with the Peng model, and has an average error of about 0.03K compared to the SMAP L1B data. This proves the accuracy and reliability of the A-B neural network model, which can be served as an alternative solution for the atmospheric correction in spaceborne L-band microwave radiometers.

Key words Spaceborne microwave radiometer, Atmospheric correction, L-band, Neural network

0 引言

海表盐度是描述海洋基础状态、驱动全球环流和影响气候变化的核心要素,海表盐度探测对了解全球水循环和海洋环境预报具有重要意义^[1,2]。由于海水辐射亮温在 L 波段对盐度变化十分敏感,因此 L 波段星载微波辐射计成为目前全球海表盐度探测的主要手段^[3,4]。目前欧洲空间局(ESA)和美国国家航空航天局(NASA)已经先后发射了多颗搭载 L 波段微波辐射计的遥感卫星,例如 2009 年发射的土壤湿度与盐度观测卫星 SMOS^[5],2011 年发射的“水瓶座”卫星 Aquarius^[6],以及 2015 年发射的土壤湿度主被动探测卫星 SMAP^[7],这些卫星在海表盐度探测领域发挥了重要作用。后续欧空局计划 2028 年发射哥白尼成像微波辐射计卫星 CIMR^[8],也将搭载 L 波段辐射计并有望在后续盐度探测领域中继续发挥重要作用。我国在 2024 年 11 月成功发射了海洋盐度探测卫星-海洋四号 01 星(HY-4A)。卫星搭载了两台 L 波段微波辐射计,分别为二维综合孔径微波辐射计(LASMR)^[9]和主被动探测仪一维综合孔径微波辐射计(MICAP-LMR)^[10,11],二者可联合应用,进一步提升盐度探测精度。

L 波段微波辐射计虽然工作频率较低,对大气云雨的穿透性较强,但是海面微波辐射信号在大气层长距离传播过程中,大气对微波的吸收和发射作用不可忽视,尤其是对于高精度海洋环境要素探测卫星,如果不对大气影响进行校正,将严重影响海表参数反演的准确性。

大气校正的基本思路是基于大气辐射传输模型并结合同步气象数据用来计算大气的辐射贡献和衰减影响,进而实现对观测亮温的大气校正,最终得到地面辐射亮温,因此大气辐射传输模型是大气校正的关键。最早 Liebe 等人以辐射传输理论为核心,对由大气成分的散射、吸收等作用导致的微波信号变化进行了参数化建模,从而创立了 MPM 模型^[12],

奠定了大气辐射传输的理论基础,同时也为微波辐射计大气校正提供了技术保障。Aquarius 卫星便是在忽略云中液态水的情况下利用 MPM 模型进行大气校正^[13]。

利用物理模型进行大气校正虽然具有较高的精度,但是计算量大,需要沿传播路径进行积分运算,而且需要准确的大气温度、压强、湿度等廓线数据作为输入,难以满足实时业务化反演和大规模观测模拟的需求。为此研究人员提出利用参数化简化大气辐射模型来进行大气校正,可以在保证计算精度的同时,既避免了对复杂大气廓线数据的依赖,又降低了计算复杂度,大大提升了计算效率。参数化大气辐射模型已经广泛用于卫星数据处理,例如:SMOS 卫星便采用了一种统计大气辐射模型并用于 L2 盐度原型处理器 L2SPP 中^[14],SMAP 卫星也采用了一种参数化统计回归模型用于专用大气快速模拟器^[15]以及用于 L1B 数据处理器中进行大气校正^[16]。国内学者也针对 Aquarius 卫星利用 MPM 模型建立了辐射-水汽(R-V)统计回归模型^[17]。

目前针对 L 波段微波辐射计的快速大气辐射模型都是基于参数化统计回归模型,其基本思想是利用全球代表性大气廓线样本,通过采用主成分分析或多元线性回归等统计分析方法将物理模型计算结果与主要大气参数进行多项式拟合,实现对大气辐射传输物理模型的简单参数化统计映射。这种方法虽然在特定角度下取得了较高的拟合精度,但其本质仍然是一种线性模型,仅能通过高阶项模拟有限的非线性,因此泛化能力受到一定的限制,对于复杂环境下的大入射角范围仍然存在一定的不足。虽然可以通过分段拟合的方式缓解此问题,但增加了模型的复杂性。神经网络模型通过多层非线性激活函数的叠加具有万能逼近特性,大数据下能捕捉数据深层模式,特别适用于复杂、高维、非线性的数据建模任务。神经网络模型正逐渐成为新一代、更具潜力的“广义参数化模型”。神经网络模型已开始应

用于红外和可见光遥感领域的大气校正^[18]，但目前尚未用于 L 波段微波辐射计大气校正。

此外，目前的微波遥感领域的大气校正方法都是一种分步式间接校正方法，所建立的回归模型都是针对大气辐射亮温和大气衰减，不能直接用于大气校正，还需要结合宇宙银河等地外辐射和地表物理温度等辅助数据对大气层顶亮温方程进行求解，计算过程较复杂，不够直观简洁。

针对上述问题，本文从兼顾效率和精度的角度出发对 L 波段星载微波辐射计的大气校正方法进行优化和改进。首先对大气层顶亮温模型进行推导和变换，将其转化为由大气校正系数表征的简洁线性表达形式，然后基于广泛应用的大气辐射传输物理模型 MPM93 模型^[19]，并借鉴已有简化模型的输入参数配置，采用神经网络方法直接对大气校正系数进行参数化建模，最终得到一种新的参数化快速大气校正模型，并基于 SMAP 数据对模型进行验证。

1 大气校正原理

1.1 大气层顶亮温模型

星载微波辐射计在天顶角 θ 处观测到的大气层顶辐射亮温包括以下几个部分：大气上行辐射亮温、经大气衰减后的地表辐射亮温以及经大气衰减后的地面反射亮温，其中地面反射亮温还包括大气下行辐射亮温和经大气衰减后的宇宙银河辐射。大气层顶亮温 T_{toa} 的表达式为^[15]：

$$T_{toa,p} = T_{up} + \{[T_{sky}L^{-1} + T_{dn}]\rho_p + T_{E,p}\}L^{-1} \quad (1)$$

式中， T_{up} 为大气上行辐射亮温， T_{dn} 为下行辐射亮温， L 是大气总损耗因子， T_{sky} 为地外天空辐射亮温，包括银河辐射亮温和宇宙背景辐射亮温， ρ 为地面反射率， T_E 为地表亮温，下标 p 代表 H 或 V 极化。

1.2 大气辐射传输模型

在 L 波段大气可认为是无散射媒质，大气损耗主要来自于大气成分的吸收作用。根据大气辐射传输理论，大气辐射亮温和大气损耗因子可表示为^[20]：

$$T_{up} = \sec \theta \int_0^H k_a(z)T(z)e^{-\tau(0,z)\sec \theta} dz \quad (2)$$

$$T_{dn} = \sec \theta \int_0^H k_a(z)T(z)e^{-\tau(z,H)\sec \theta} dz \quad (3)$$

$$L_\theta = e^{\tau(0,H)\sec \theta} \quad (4)$$

其中， $k_a(z)$ 为高度为 z' 处的大气吸收系数， $T(z)$ 为

高度为 z 处的大气绝对温度， $\tau(z_1, z_2)$ 为从高处 z_1 到高度 z_2 之间的大气在垂直方向上的光学厚度，其计算公式为：

$$\tau(z_1, z_2) = \int_{z_1}^{z_2} k_a(z')dz' \quad (5)$$

在微波波段，晴空条件下大气吸收主要来自氧气和水汽的吸收。目前已有多种氧气和水汽吸收系数计算模型，其中最经典、最广泛应用的是 MPM93 模型。需要注意的是，在 L 波段大气下行辐射亮温与上行辐射亮温近似相等，在 40° 入射角时仅相差 $0.002K$ ^[15]，在实际应用时可忽略。

1.3 大气校正方法

大气校正的目的是对观测亮温所受到的大气影响进行校正，即根据辐射传输模型计算大气上行和下行辐射亮温以及大气损耗因子，然后根据式(1)实现大气层顶亮温和地表亮温之间的转换，因此计算大气辐射亮温和大气损耗因子是进行大气校正的关键。由大气辐射传输模型可知，计算大气辐射亮温和大气损耗因子需要对大气吸收系数沿大气路径进行积分，而根据 MPM93 模型大气吸收系数与大气温度、湿度和气压有关，因此大气校正过程需要利用大气参数的廓线分布数据并对整个大气路径进行积分，依赖参数数据量大，计算复杂度高。

为了避免对大气廓线数据的依赖和耗时的积分运算，现有研究建立了多个回归统计模型，其中以 Peng 针对 SMAP 卫星任务建立的简化模型最具代表性^[15]。该模型基于全球大气探空数据进行统计回归建模，将大气辐射亮温和总损耗因子建模为地表附近气压、温度、水汽密度和入射角的简单的多项式函数，从而构建了一个全球适用的参数化大气辐射传输模型，Peng 模型的计算公式如下：

$$L(\theta) = (1.00938 - 2.96074 \times 10^{-5}T_{surf} + 1.65183 \times 10^{-5}P_{900} + 1.07106 \times 10^{-5}V)\cos 40 \sec \theta \quad (7)$$

$$T_{up}(\theta) = (2.3058 - 3.2699 \times 10^{-3}T_{surf} + 4.2328 \times 10^{-3}P_{900} + 1.4417 \times 10^{-3}V) \cdot f(\theta) \quad (8)$$

其中， T_{surf} 为地表温度，单位为 $^\circ C$ ； $P_{900} = P - 900$ ，其中 P 为地表气压，单位为 mbar； V 为地表水汽密度，单位为 g/m^3 ； $f(\theta)$ 为角度拟合函数，在不同角度区间的表达式为：

$$f_{0^\circ < \theta < 20^\circ}(\theta) = 1.2855 \times 10^{-4}\theta^2 - 1.3361 \times 10^{-4}\theta + 0.7625 \quad (9)$$

$$f_{20^\circ \leq \theta \leq 60^\circ}(\theta) = 8.2724 \times 10^{-6} \theta^3 - 5.7129 \times 10^{-4} \theta^2 + 2.0411 \times 10^{-2} \theta + 0.5655 \quad (10)$$

$$f_{60^\circ < \theta \leq 70^\circ}(\theta) = 2.4189 \times 10^{-3} \theta^2 - 0.2458 \theta + 7.5624 \quad (11)$$

2 改进大气校正方法

2.1 A-B 系数校正法

传统大气校正方法是对大气损耗因子 L 和大气辐射亮温 T_{up} 进行参数化建模,然后再利用地外辐射亮温和地面温度等辅助数据对式(1)进行求解进而得到地表亮温。对 L 和 T_{up} 进行参数化建模虽然物理意义明确,但却仅能得到大气校正的中间变量,还需借助其它辅助数据来完成最终的大气校正,因此传统的大气校正方法本质上属于分步校正法。

因为 L 波段大气上行和下行辐射亮温相等,且地面反射率可由地表亮温和地表物理温度表示,即:

$$\begin{cases} T_{up} = T_{dn} \\ \rho_p = 1 - \frac{T_{E,p}}{T_{surf}} \end{cases} \quad (12)$$

将式(12)带入式(1)后大气层顶亮温模型可转化为由斜率和截距决定的关于地表亮温的线性方程:

$$T_{toa} = A \cdot T_E + B \quad (13)$$

其中校正系数 A 和 B 的计算公式为:

$$\begin{cases} A = \frac{1}{L} - \frac{T_{up}}{T_{surf}L} - \frac{T_{sky}}{T_{surf}L^2} \\ B = T_{up} + \frac{T_{up}}{L} + \frac{T_{sky}}{L^2} \end{cases} \quad (14)$$

因此可直接对大气校正系数 A 和 B 进行参数化建模,从而得到一种整体校正法,即 A-B 系数校正法,可简化大气校正过程,避免中间环节、提高计算效率。

2.2 A-B 系数与大气辐射参数转换

由式(14)可知校正系数 A 和 B 为大气辐射参数 L 和 T_{up} 的函数,因此对校正系数完成参数化建模后可以进一步计算出 L 和 T_{up} ,从而实现两种模型的转化。具体计算方法如下:根据式(13)和式(14),通过消元法可得关于 L 的一元二次方程:

$$aL^2 + bL + c = 0 \quad (15)$$

其中:

$$\begin{cases} a = AT_{surf} \\ b = AT_{surf} - T_{surf} + B \\ c = T_{sky} - T_{surf} \end{cases} \quad (16)$$

由于 $a > 0$, $c < 0$, 且 $L > 1$, 所以式(15)的解为:

$$L = \frac{-b + \sqrt{b^2 - 4ac}}{2a} \quad (17)$$

进而得到:

$$T_{up} = \frac{BL}{(1+L)} - \frac{T_{sky}}{(1+L)L} \quad (18)$$

因此,利用 T_{surf} 和 T_{sky} 等辅助数据,根据式(17)和式(18)可实现从 A 、 B 到 L 、 T_{up} 的转换。

3 数据样本处理

3.1 数据样本

本文采用 MPM93 模型对大气校正系数 A 和 B 进行计算,计算过程需要输入大气温度、湿度、压强的廓线数据和地表数据。数据来源采用欧洲中期天气预报中心(ECMWF)的 ERA5 逐小时再分析数据,包括表面数据^[21](即表面温度、表面气压、表面露点温度和总柱水含量)和剖面数据^[22](即 37 个标准气压层的温度和湿度)。为满足辐射传输计算对垂直分辨率的要求,将 ERA5 的 37 层标准廓线插值至 60 层非均匀垂直网格,同时利用表面数据优化近地层廓线,确保地表大气界面的连续性,最终获得 60 层的气压、温度和湿度廓线,以提高路径积分的精度。

由于 ECMWF 不直接提供水汽密度数据,对于地面水汽密度数据,需要根据 ERA5 表面数据中的温度和露点温度数据进行计算。首先使用经典的马格努斯 (Magnus) 公式计算露点温度 d 对应的水面或冰面的饱和水汽压 e :

$$\begin{cases} e = 6.112 \times 10^{7.5d/(d+237.3)}, & d \geq 0 \\ e = 6.112 \times 10^{9.5d/(d+265.5)}, & d < 0 \end{cases} \quad (19)$$

其中, d 为露点温度,单位($^{\circ}\text{C}$), e 为饱和水汽压,单位(hPa)。然后利用温度数据计算水汽密度:

$$V = \frac{216.74e}{t + 273.15} \quad (20)$$

其中 t 为温度,单位($^{\circ}\text{C}$); V 为水汽密度,单位(g/m^3)。

对于水汽密度廓线数据,需要根据 ERA5 剖面数据中的温度、压强和比湿数据进行计算:

$$V = \frac{q \cdot p \cdot 10^5}{R_d \cdot (t + 273.15) \cdot (1 + 0.608q)} \quad (21)$$

其中, q 为比湿,单位(g/g); p 为压强,单位(hPa); R_d 为干空气比气体常数,为 $287.058(\text{J}/\text{kg}\cdot\text{K})$ 。


3.2 输入数据集筛选

为构建具有代表性的数据集,本文对输入参数和大气数据进行筛选。模型设计时在保证精度的同时尽量简化输入参数。根据式(14), A 、 B 主要由大

表 1 输入数据及参数设置

Table 1 Input datasets and parameter settings

数据参数	筛选范围
入射角 θ (°)	0~70
地表温度 T_{surf} (K)	270-310
地表气压 P_{surf} (hPa)	980-1040
地表水汽密度 V_{surf} (g/m ³)	0-30
总柱水含量 $TCWV$ (Kg/m ²)	0-80
地外辐射亮温 T_{sky} (K)	0-20



审图号: GS(2016)1666 号

图 1 筛选数据集地理位置分布图


Fig. 1 Geolocation map of the filtered training datasets

气辐射亮温、大气衰减和地表温度决定, 因此选取输入参数时参考现有简化大气辐射传输模型的经验, 选取地表温度 T_{surf} 、地表气压 P_{surf} 和表征湿度的地表水汽密度 V 和总柱水含量 $TCWV$ 等参数作为模型输入。此外, 与传统的大气辐射模型不同, 地外辐射亮温也会对大气校正系数产生影响。具体输入数据及参数设置如表 1 所示。

数据筛选时选取 2025 年每月的第 1、16、26 日, 全球纬度 -60°至 60°范围内的晴空海洋区域的数据进行计算。采用布尔掩码控制筛选过程, 确保每个网格单元仅保留一个代表性数据点, 避免参数空间中的样本聚类。该处理方法最终生成了覆盖广泛海洋的大气参数数据集, 样本数量共计 9924380 个, 其地理位置全球分布图如图 1 所示。根据此数据集计算相应的校正系数, 为后续神经网络训练提供可靠的样本数据。

3.3 湿度敏感性分析

湿度是影响大气辐射特性的关键因素, 简化大气辐射传输模型常用总柱水汽含量 $TCWV$ 来衡量大气湿度的影响, 例如 SMOS 卫星便采用了 $TCWV$ 作为模型的输入参数^[14]。然而由于 L 波段的穿透性较

图 2 大气校正系数 A 、 B 对 V 和 $TCWV$ 的关联散点图Fig. 2 Scatter plots of A and B against V and $TCWV$

强, 辐射传输主要受近地表大气参数影响, 因此 Peng 模型采用 V 作为输入参数^[15]。为了能够充分发挥输入参数的合理性和有效性, 并提高模型的精度和可靠性, 本文基于所建立的数据集, 利用皮尔逊 (Pearson) 相关系数和斯皮尔曼 (Spearman) 相关系数对 $TCWV$ 和 V 相对于校正系数 A 、 B 的敏感性进行分析, 选择相关性强的作为模型输入参数。

Pearson 相关系数 R_p 和 Spearman 相关系数 R_s 的计算公式如下^[23]:

$$R_p = \frac{\sum_{i=1}^n (x_i - \bar{X})(y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{X})^2 \sum_{i=1}^n (y_i - \bar{Y})^2}} \quad (22)$$

$$R_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (23)$$

其中, x_i 和 y_i 为两个变量的第 i 个样本, $\bar{X}$ 和 $\bar{Y}$ 为分别为两个变量的平均值, d_i 为第 i 对样本的排序位次之差。相关系数的绝对值越大说明两者的相关性越强。

R_p 和 R_s 可分别用来衡量两个随机变量的线性和非线性相关性, 所有相关性检验的显著性水平均以 $p < 0.05$ 作为显著相关判定标准。 $TCWV$ 和 V 分别对于 A 和 B 的相关性散点分布情况和相关系数如图 2 所示, 结果表明, V 对于 A 和 B 的线性和非线性相关性均比 $TCWV$ 强, 因此其敏感度也更高, 更适合作为大气校正模型中衡量水汽的输入参数。

4 神经网络模型

基于万能逼近定理, 一个包含单隐藏层、非线性激活函数且具有足够数量节点的多层感知机能够以任意精度逼近定义在紧集上的连续非线性函数。鉴于大气校正系数与输入大气参数之间存在确定且




图 3 A-B 神经网络模型的结构图
Fig. 3 Architecture of the A-B NN model

连续的非线性映射关系，同时输入特征均为结构化的低维数值变量，因此本文采用 BP 神经网络对该映射关系进行端到端回归建模。

4.1 模型建立

BP 神经网络是一种使用反向传播算法进行训练的前馈神经网络^[24]，由输入层、隐藏层和输出层组成，通过最速下降法计算每层的误差对输出误差的贡献并调整网络权重，因此具有较强的自适应性和容错能力。本文即采用一种结构紧凑的单隐层 BP 神经网络作为 A 、 B 系数的预测模型

在构建神经网络时，以入射角(θ)、地表温度(T_{surf})、地表水汽密度(V)、地表气压(P)、地外辐射亮温(T_{sky})等参数作为网络输入，以大气校正系数 A 、 B 作为预测网络模型的输出，网络结构图如图 3 所示。

激活函数是影响神经网络表达能力的关键，使其可以无限逼近任何非线性函数。选择双曲正切 $\tanh$ 函数作为隐藏层的激活函数，其表达式为：

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (24)$$

$\tanh$ 函数在零点附近具有较大的梯度响应，有利于捕捉输入参数的细微变化同时加快模型的收敛速度。

最终 A-B 神经网络模型的表达式为：

$$A, B = \sum_{j=1}^m W_j \cdot \tanh\left(b_j + \sum_{i=1}^n a_{ij} x_i\right) + k \quad (25)$$

其中， x_i 为输入参数， a_{ij} 和 W_j 为网络权重系数， b_j 和 k 为网络偏置系数， i 和 n 分别代表输入参数的索引和数量， j 和 m 分别代表神经元的索引和数量。

为了与 $\tanh$ 函数的输入区间和取值范围保持一致，同时提高模型训练稳定性并加速收敛，对输入和输出参数均进行归一化处理至 $[-1, 1]$ 区间。在网络训练方面，采用 AdamW 与 L-BFGS 相结合的




图 4 5-折交叉验证结构图
Fig. 4 5-fold cross validation diagram

混合优化策略对模型参数进行学习，以兼顾全局搜索能力与局部精细收敛性能。训练初期采用 AdamW 优化算法进行参数更新，有效抑制参数过大带来的过拟合同时具有较快的收敛速度和较强的鲁棒性；训练后期，引入二阶优化方法 L-BFGS 对网络进行精细优化，以进一步提升模型在最优解附近的收敛精度。由于大气校正系数的训练精度要求较高，在模型训练过程中以均方根误差(Root Mean Square Error, RMSE)作为性能函数，其计算公式为：

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (26)$$

其中， y_i 和 $\hat{y}_i$ 分别表示第 i 个样本的真实值和模型预测值， N 为样本数量。

4.2 k 折交叉验证

由于采用固定的单隐藏层网络，隐藏层神经元个数对神经网络模型的泛化性能具有重要影响，数量过少的神经元不足以描述数据集特征，造成欠拟现象；数量过多的神经元显著增加模型复杂度，同时引发过拟合并增加训练时间，因此需要在模型复杂度和泛化能力之间进行权衡。

采用 k 折交叉验证方法对隐藏层神经元个数进行选择。 k 折交叉验证(k -fold cross validation)^[25]是机器学习领域中的一种常用的模型评估与选择方法，可以对模型结构的性能进行系统性评估，其计算过程为：将原始数据集划分为 k 个大小相同且分布一致的子集。每次验证选取其中一个子集作为测试集，其余 $k-1$ 个子集作为训练集，以 RMSE 作为性能指标，重复 k 次循环直至每个子集均被用作一次测试集，最终以 k 次测试的 RMSE 的平均值为最终模型性能的评价结果。 k 值选择需要权衡，较大 k 值需要更多的训练轮次，虽然能更充分利用数据，但计算成本高。通常 $k=5$ 时具有较低计算成本和良好的评




图 5 不同神经元的平均误差统计结果

Fig. 5 Average errors for different neuron numbers

估可靠性，其结构图如图 4 所示。

测试过程中隐藏层神经元个数设定为 3、4、5、7、10，最终测试结果如图 5 所示。从图中可知，随着神经元数量的增加，模型误差逐渐降低。但是考虑到过高的神经元数量不但会提高模型的复杂度，而且会带来一定的记忆风险从而导致过度拟合并降低泛化能力，因此综合考虑模型复杂度和拟合精度后最终选择神经元数量为 5，此时 A 网络模型具有近似最低的误差，B 网络模型误差只比最低值高约 0.01%，而模型复杂度却降低了一倍，因此在拟合精度、结构复杂度以及泛化能力之间达到了很好的平衡，并且有助于缩短模型的训练时间。

4.3 模型参数

基于前述神经网络结果对式(25)所定义的 A-B 神经网络模型进行训练，拟合得到全球晴空海洋条件下的大气校正系数。需要注意的是，由于模型训练是基于归一化处理后的数据，因此需对输出结果进行反归一化处理，同时网络模型参数也需要进行相应的尺度变换，以使得模型拟合函数能够与真实的输入参数和大气校正系数相匹配。最终 A-B 神经网络模型参数的拟合结果分别如表 2 和表 3 所示，其中，输入参数的顺序为： $i=1$ 代表角度， $i=2$ 代表地表温度， $i=3$ 代表地表水汽密度， $i=4$ 代表地表气压， $i=5$ 代表地外辐射亮温。

4.4 模型拟合效果

为了对模型拟合效果进行分析，本文采用多种统计指标进行评价，包括式(22)所定义的相关系数和式(26)定义的均方根误差 RMSE。另外还包括偏差 Bias 和无偏均方根误差 uRMSE，其计算公式为：

$$\text{Bias} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i) \quad (27)$$

表 2 A 神经网络模型的参数

参数	$j=1$	$j=2$	$j=3$	$j=4$	$j=5$
a_{1j}	5.2331e-4	-3.4900e-4	-4.6670e-4	3.5809e-2	-9.9905e-5
a_{2j}	9.5626e-4	3.7229e-3	2.2019e-5	-2.3102e-3	-1.7923e-3
a_{3j}	-8.4065e-5	7.5001e-4	1.6541e-4	-1.8690e-4	-2.3005e-4
a_{4j}	2.9137e-4	-8.9094e-5	2.2732e-4	1.1232e-3	-3.9141e-4
a_{5j}	4.0169e-2	-3.0218e-2	-2.2364e-2	-2.1116e-3	-1.3161e-2
b_j	-3.4280e-1	4.4636e-2	1.9691	-4.0756	-1.0951e-1
w_j	-4.8873e-2	1.0200e-1	-6.9511e-2	-1.2158e-1	6.9765e-2
k	9.1787e-1				

表 3 B 神经网络模型的参数

参数	$j=1$	$j=2$	$j=3$	$j=4$	$j=5$
a_{1j}	8.1200e-2	4.0171e-4	2.4149e-2	-5.2841e-4	6.0218e-2
a_{2j}	-5.3518e-4	1.2785e-4	-3.3443e-4	-2.4740e-4	2.7456e-4
a_{3j}	-4.8967e-4	1.1198e-4	-4.0714e-4	-1.2942e-4	3.4319e-5
a_{4j}	6.4882e-4	-2.8425e-4	8.4464e-4	3.3002e-4	-7.5177e-4
a_{5j}	-6.6933e-3	-4.8924e-2	-2.7290e-3	4.9314e-2	-1.0825e-2
b_j	-6.9271	1.3942	-2.9469	-2.6725e-2	-4.9989
w_j	9.2329	-1.5739e1	1.2136e1	1.5531e1	-1.4429e1
k	1.9848e1				

$$\text{uRMSE} = \sqrt{\text{RMSE}^2 - \text{Bias}^2} \quad (28)$$

其中， y_i 表示由辐射传输模型计算得到的参考校正系数， $\hat{y}_i$ 为神经网络预测结果， N 为样本数量。

A-B 神经网络模型的真值预测散点图及其误差统计图如图 6 所示，从图中结果可以看出，A-B 神经网络模型的拟合结果与数据集真值之间高度一致，误差分布集中且对称，相关系数近似为 1，偏差近似为 0，因此可以认为 A-B 神经网络模型能够准确拟合 MPM93 模型以实现晴空海洋环境下的 L 波段微波辐射计大气校正应用。

4.5 多角度对比测试

基于筛选的数据集，在 $0^\circ \sim 70^\circ$ 入射角范围内分别利用 A-B 神经网络模型和 Peng 模型计算多角度情况下的大气校正参数 A 、 B 、 L 和 T_{up} ，同时利用 MPM93 模型计算这些参数并将其作为真值，然后针对不同入射角统计模型计算结果与真值的误差，结果如图 7 所示。可以看出，两个模型的误差均随入射角的增大而增大， 70° 入射角时误差比常用的 40°




图6 模型预测值与真值的散点图(上)和误差直方图(下)

Fig. 6 Truth vs. prediction plots (top) and error histograms(bottom) of the A-B neural network model

入射角误差增加了约 1 倍，这符合大入射角时大气影响更显著的特征。另外 A-B 神经网络模型的拟合误差更小，体现了其在非线性拟合方面的优势。

以 40° 入射角为例进一步分析模型误差，并与文献[15]的统计结果进行对比，结果如表 4 所示。由于文献[15]采用 NOAA 提供的 IGRA2 探空数据集，与文本数据不同，因此统计结果略有差异，但二者一致性良好，其中 T_{up} 的差异仅为 0.002K，从侧面验证了文本统计结果的可靠性。统计结果显示，尽管 A-B 神经网络模型的误差略低于 Peng 模型，但对于关键的 B 和 T_{up} 两个参数，两个模型的误差仅相差 0.004K，在实际应用中可忽略，因此可认为二者的精度水平相当。

5 模型测试与验证

5.1 实验数据

利用 SMAP 卫星搭载的 L 波段微波辐射计实测数据以及 ERA5 同步大气变量数据对模型的实际可行性进行测试验证。SMAP 卫星数据为美国国家冰雪数据中心 (NSIDC) 发布的 SMAP-L1B 数据产品^[26]，包含了 SMAP 卫星 L 波段辐射计的经过定标和外部辐射校正后的水平极化和垂直极化大气层顶亮温和地表亮温。选取 2025 年 3 月、6 月、9 月和 12 月四个月，每月的 1-3 号三天的数据作为测试数据集，并利用同期的 ERA5 大气参数数据根据 SMAP-L1B 数据的经纬度和时间进行插值，最终得




图7 模型误差随入射角的变化曲线

Fig. 7 Variations of model errors versus incident angle

表 4 40° 入射角时模型误差对比

Table 4 Comparison of model errors at 40° incident angle

模型	A	B	L	Tup
Peng in [15]	/	/	2.074×10^{-4}	0.028
Peng	3.43×10^{-4}	0.047	2.850×10^{-4}	0.026
NN	2.10×10^{-4}	0.043	1.811×10^{-4}	0.022

到与卫星观测数据相匹配的大气参数辅助数据。

5.2 校正系数对比验证

针对 SMAP 卫星数据，分别采用 A-B 神经网络模型和 Peng 模型计算大气校正系数，同时利用 SMAP-L1B 亮温数据直接计算大气校正系数 A、B，以此作为对比测试的参考基准。具体计算过程如下：

1、基于匹配的 ERA5 表面数据(地表温度、地表气压、地表水汽密度) 利用式(25)所示的神经网络模型计算大气校正系数 A_{NN} 和 B_{NN} ，计算时设定 $\theta=40^\circ$ ， $T_{sky}=0$ ，并对模型偏置系数进行适应性修正： $k_A=0.91677$ ， $k_B=20.1567$ ；

2、基于匹配的 ERA5 表面数据，利用式(7)-式(11)所示的 Peng 模型，并根据式(14)计算大气校正系数 A_{Peng} 和 B_{Peng} ，计算时设定 $\theta=40^\circ$ ；

3、利用 SMAP-L1B 大气层顶亮温数据 T_{toa} 和地表亮温数据 T_E ，根据式(13)计算大气校正系数 A_{SMAP} 和 B_{SMAP} ，计算公式为：




图 8 不同模型与 SMAP 数据的 A-B 系数对比图

Fig.8 Comparisons of A-B between models and SMAP data

表 5 模型校正系数与 SMAP 校正系数的均方根误差结果

Table 5 RMSEs of A and B between models and SMAP data

参数	模型	3 月	6 月	9 月	12 月	平均
A	Peng	0.0002	0.0002	0.0002	0.0002	0.0002
	NN	0.0002	0.0002	0.0002	0.0002	0.0002
B	Peng	0.0180	0.0180	0.0176	0.0191	0.0182
	NN	0.0228	0.0219	0.0240	0.0194	0.0220

$$\begin{cases} A_{\text{SMAP}} = \frac{T_{\text{toa}_H} - T_{\text{toa}_V}}{T_{E_H} - T_{E_V}} \\ B_{\text{SMAP}} = T_{\text{toa}_H} - \frac{T_{\text{toa}_H} - T_{\text{toa}_V}}{T_{E_H} - T_{E_V}} \cdot T_{E_H} \end{cases} \quad (29)$$

将两个模型得到的校正系数与 SMAP 数据得到的校正系数进行对比,3 月份的对比散点图如图 8 所示,四个月的 RMSE 统计结果如表 5 所示。结果显示, A-B 神经网络模型与 Peng 模型吻合良好,校正系数 A 的 RMSE 基本相同,校正系数 B 的 RMSE 差别小于 0.007K,此微小差异在实际应用中可忽略。同时模型误差随时间变化很小,月度起伏小于 0.005K,表明 A-B 神经网络模型在不同季节条件下均具有较好的稳定性和泛化能力。

5.3 校正亮温对比验证

进一步对最终亮温校正效果进行测试验证,利用 A-B 神经网络模型对 SMAP-L1B 数据中的大气层顶亮温进行大气校正得到地表亮温 $T_{E_{AB}}$,并与 SMAP-L1B 数据中的地表亮温 $T_{E_{\text{SMAP}}}$ 进行对比测




图 9 $T_{E_{AB}}$ 分布图及其与 $T_{E_{\text{SMAP}}}$ 的误差图

Fig. 9 $T_{E_{AB}}$ images and the errors between $T_{E_{AB}}$ and $T_{E_{\text{SMAP}}}$




图 10 大气校正误差随纬度(左)和水汽密度(右)的变化情况

Fig.10 Atmospheric correction error versus latitude (left) and

water vapor density (right)

试。2025 年 3 月 1 日的 $T_{E_{AB}}$ 以及其与 $T_{E_{\text{SMAP}}}$ 的误差图如图 9 所示,从图中结果可以看出 A-B 神经网络模型计算的海表亮温与 SMAP 卫星官方数据吻合良好,误差幅度限制在 ± 0.1 K 以内,在赤道区域和西风带部分区域误差较大,这主要是因为这些区域

表 6 不同月份的 T_{E_AB} 与 T_{E_SMAP} 的均方根误差

Table 6 Monthly RMSEs of T_{E_AB} compared with T_{E_SMAP}

极化	3 月	6 月	9 月	12 月	平均
H	0.0230	0.0259	0.0256	0.0225	0.0243
V	0.0266	0.0312	0.0298	0.0268	0.0286

受降雨影响较严重，而本文模型未考虑云雨因素。进一步针对纬度和水汽密度对所有测试数据的大气校正误差统计，结果如图 10 所示，与上述现象一致，在低纬赤道区域，水汽密度较大，校正误差较高，约 0.03K。随着纬度升高，水汽密度降低，校正误差也降低，在 $\pm 20^\circ$ 附近降低至约 0.02K。随着纬度的进一步升高，受西风带影响，校正误差有所升高。在高纬度区域，虽然水汽密度最低，但由于接近极区，受海冰影响，校正误差反而升高，尤其是 V 极化，误差最高约 0.05K。此外 V 极化亮温的误差略大于 H 极化，是由于 V 极化亮温对海表状态更为敏感。

2025 年不同月份的误差统计结果如表 6 所示。结果显示 AB 神经网络模型计算的海表亮温与 SMAP-L1B 海表亮温的平均 RMSE 小于 0.03K，而且不同季节条件下均能保持稳定的误差水平，这表明 A-B 神经网络模型具有良好的校正精度和可行性。

6 结论

L 波段星载微波辐射计是获取全球海表盐度的核心遥感技术，结合辅助气象数据的大气校正是实现高精度盐度反演的关键。SMOS 卫星团队和 SMAP 卫星团队均采用多项式回归拟合的方法建立了各自的大气辐射传输模型，以用于在其数据处理和参数反演过程中对大气辐射和衰减的贡献进行校正。本文首次采用神经网络方法对 L 波段星载微波辐射计大气校正方法开展研究，首先对大气层顶亮温模型进行了改进，将其转换为关于地表亮温的线性方程形式，从而得到了一种新的以斜率和截距为校正系数的线性大气校对方程，以此为基础，并借鉴以往模型的输入参数配置，建立了一种新的大气校正模型：A-B 神经网络模型。与以往的大气校正模型相比，其优势主要体现在两个方面：

在模型构建方面，以往的 L 波段大气校正模型均是对大气辐射亮温和大气衰减进行参数化建模，然后再基于地表温度和地外辐射等辅助信息计算地表反射率和外太空辐射影响，最终再根据大气层顶亮温计算公式实现大气校正，属于一种间接校正模

型，校正过程比较复杂。而 A-B 神经网络模型是基于新建立的大气校对方程直接对大气校正系数进行参数化建模，属于直接校正模型，显著简化了大气校正流程，避免了中间环节，不但可以提高计算效率，便于开展业务应用，而且缩短了误差传递链路，有助于提高大气校正精度。

在建模方法方面，以往的 L 波段大气校正模型均采用了多项式统计回归的方法进行建模，其本质仍然是一种线性模型，非线性表达能力较低，仅能通过高阶项模拟有限的非线性特征。Peng 模型采用分段拟合的方法可以一定程度上缓解此问题，但增加了模型的复杂度。A-B 神经网络模型采用基于 tanh 函数的单层神经网络，利用少量神经元便可拟合复杂的非线性关系，具有结构简单、可解释性强、精度高等优势。

在模型测试和验证环节，首先利用 MPM93 模型开展测试，并与 Peng 模型进行对比分析，结果表明 A-B 神经网络模型在拟合精度方面具有一定的微弱优势，然后利用 SMAP 实际亮温数据进行测试，平均校正误差小于 0.03K，进一步验证了 A-B 神经网络模型的精度和可行性。后续将进一步考虑云水和降雨的影响，并且涵盖极区和陆地区域对模型进行完善和验证。

致谢：感谢中国科学院国家空间科学中心，中国科学院微波遥感重点实验室王振占研究员在使用 MPM93 大气辐射传输模型方面提供的指导和帮助。

参考文献

- [1] SWIFT C T, MCINTOSH R E. Considerations for microwave remote sensing of ocean-surface salinity[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1983, **GE-21**(4): 480-491. DOI: 10.1109/TGRS.1983.350511
- [2] ZHANG Qingjun, YIN Xiaojun, JIANG Yu. Developing sea surface salinity satellite to promote ocean dynamical environments observation[J]. *Spacecraft Engineering*, 2017, **26**(1): 1-5. DOI: 10.3969/j.issn.1673-8748.2017.01.001 (张庆君, 殷小军, 蒋昱. 发展海洋盐度卫星 完善我国海洋动力卫星观测体系[J]. *航天器工程*, 2017, **26**(1): 1-5. DOI: 10.3969/j.issn.1673-8748.2017.01.001)
- [3] REUL N, GRODSKY S A, ARIAS M, *et al.* Sea surface salinity estimates from spaceborne L-band radiometers: an overview of the first decade of observation (2010–2019)[J]. *Remote Sensing of Environment*, 2020, **242**: 111769. DOI: 10.1016/j.rse.2020.111769
- [4] WANG Zhenzhan, WANG Wenyu, TONG Xiaolin, *et al.* Progress in spaceborne passive microwave remote sensing technology and its application[J]. *Chinese Journal of Space Science*, 2023, **43**(6): 986-1015. DOI:10.11728/cjss2023.06.yg15 (王振占, 王文煜, 佟晓林,

- 等. 星载被动微波遥感技术及其应用进展[J]. 空间科学学报, 2023, **43**(6):986-1015. DOI:10.11728/cjss2023.06.yg15)
- [5] KERR Y H, WALDTEUFEL P, WIGNERON J P, *et al.* The SMOS mission: new tool for monitoring key elements of the global water cycle[J]. *Proceedings of the IEEE*, 2010, **98**(5): 666-687. DOI: 10.1109/JPROC.2010.2043032
- [6] PIEPMEIER J R, HONG L, PELLERANO F A. Aquarius L-band microwave radiometer: 3 years of radiometric performance and systematic effects[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, **8**(12): 5416-5423. DOI: 10.1109/JSTARS.2015.2435493
- [7] YUEH S H, ENTEKHABI D, O'NEILL P E, *et al.* SMAP mission status and plan[C]//IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium. Waikoloa: IEEE, 2020: 3319-3322. DOI: 10.1109/IGARSS39084.2020.9324635
- [8] GALEAZZI C, DONLON C, SALLUSTI M, *et al.* The Copernicus Imaging Microwave Radiometer (CIMR) mission: project status and system overview[C]//IGARSS 2023-2023 IEEE International Geoscience and Remote Sensing Symposium. Pasadena: IEEE, 2023: 993-996. DOI: 10.1109/IGARSS52108.2023.10283267 <https://ieeexplore.ieee.org/document/10283267>
- [9] LI Y N, JIN R, LIANG S, *et al.* Strong RFI mitigation based on channel response adjustment for SAIR on Chinese ocean salinity satellite[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, **63**: 5301913. DOI: 10.1109/TGRS.2025.3566498
- [10] LIU H, ZHU D, NIU L J, *et al.* MICAP (microwave imager combined active and passive): a new instrument for Chinese ocean salinity satellite[C]//2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Milan: IEEE, 2015: 184-187. DOI: 10.1109/IGARSS.2015.7325730
- [11] LI B X, GUO X, LIU H, *et al.* MICAP radiometer airborne campaign: preliminary results of L/C/K tri-frequency interferometric radiometer[C]//IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium. Athens: IEEE, 2024: 6713-6716. DOI: 10.1109/IGARSS53475.2024.10642716
- [12] LIEBE H J. An updated model for millimeter wave propagation in moist air[J]. *Radio Science*, 1985, **20**(5): 1069-1089. DOI: 10.1029/RS020i005p01069
- [13] LE VINE D M, DINNAT E P, ABRAHAM S, *et al.* The Aquarius simulator and cold-sky calibration[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, **49**(9): 3198-3210. DOI: 10.1109/TGRS.2011.2161481
- [14] ZINE S, BOUTIN J, FONT J, *et al.* Overview of the SMOS sea surface salinity prototype processor[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46**(3): 621-645. DOI: 10.1109/TGRS.2008.915543
- [15] PENG J Z, KIM E, PIEPMEIER J. Global simplified atmospheric radiative transfer model at L-band[J]. *IEEE Geoscience and Remote Sensing Letters*, 2013, **10**(3): 437-440. DOI: 10.1109/LGRS.2012.2208213
- [16] PIEPMEIER J, MOHAMMED P, DE AMICI G, *et al.* Soil Moisture Active Passive (SMAP) Project Algorithm Theoretical Basis Document SMAP L1B Radiometer Data Product: L1B_TB [R/OL]. NASA Goddard Space Flight Center, 2016. <https://ntrs.nasa.gov/citations/20160003317>
- [17] DU Yanlei, MA Wentao, YANG Xiaofeng, *et al.* A rapid atmospheric correction model for L-band microwave radiometer under the cloudless condition[J]. *Acta Physica Sinica*, 2015, **64**(7): 079501. DOI: 10.7498/aps.64.079501 (杜彦磊, 马文涛, 杨晓峰, 等. 无云情况下L波段微波辐射计快速大气校正方法[J]. 物理学报, 2015, **64**(7): 079501. DOI: 10.7498/aps.64.079501)
- [18] LIU M K, WANG X T, SHENG Z C, *et al.* A physically based neural network for fast infrared atmospheric transmittance simulation[J]. *IEEE Geoscience and Remote Sensing Letters*, 2025, **22**: 1501805. DOI: 10.1109/LGRS.2025.3555238
- [19] LIEBE H J, HUFFORD G A, COTTON M G. Propagation modeling of moist air and suspended water/ice particles at frequencies below 1000 GHz[C]//AGARD Conference Proceedings 542: Atmospheric Propagation Effects through Natural and Man-Made Obscurants for Visible to MM-Wave Radiation. Palma de Mallorca, Spain: AGARD, 1993
- [20] ULABY F T, MOORE R K, FUNG A K. Microwave remote sensing: active and passive, volume I: microwave remote sensing fundamentals and radiometry[M]. Norwood: Artech House, 1981
- [21] HERBACH H, BELL B, BERRISFORD P, *et al.* ERA5 hourly data on single levels from 1940 to present[DB/OL]. Reading, UK: Copernicus Climate Change Service (C3S) Climate Data Store (CDS), 2023, DOI: 10.24381/cds.adbb2d47 (Accessed on 03-Nov-2025)
- [22] HERBACH H, BELL B, BERRISFORD P, *et al.* ERA5 hourly data on pressure levels from 1940 to present[DB/OL]. Reading, UK: Copernicus Climate Change Service (C3S) Climate Data Store (CDS), 2023, DOI: 10.24381/cds.bd0915c6 (Accessed on 03-Nov-2025)
- [23] STEPANOV A. On correlation coefficients[OL]. arXiv preprint arXiv: 2405.16469, 2024
- [24] WRIGHT L G, ONODERA T, STEIN M M, *et al.* Deep physical neural networks trained with backpropagation[J]. *Nature*, 2022, **601**(7894): 549-555. DOI: 10.1038/s41586-021-04223-6
- [25] BATES S, HASTIE T, TIBSHIRANI R. Cross-validation: what does it estimate and how well does it do it?[J]. *Journal of the American Statistical Association*, 2024, **119**(546): 1434-1445. DOI: 10.1080/01621459.2023.2197686
- [26] PIEPMEIER J R, MOHAMMED P N, DE AMICI G, *et al.* SMAP L1B radiometer half-orbit time-ordered brightness temperatures, (SPL1BTB, Version 6)[DB/OL]. Boulder, Colorado USA: NASA National Snow and Ice Data Center Distributed Active Archive Center, 2023, DOI: 10.5067/GWYQTF307Y9Y (Accessed on 03-Nov-2025)

作者简介



朱博雯 女, 2001 年 7 月出生于辽宁省大连市, 现为中国科学院国家空间科学中心硕士研究生, 主要研究方向为微波辐射计数据处理与应用。
E-mail: zhubowen23@mailsucas.ac.cn



张成（通信作者）男，1978年11月
出生于河北省深泽县，现为中国科学院国
家空间科学中心研究员，主要研究方向为
综合孔径微波辐射计成像技术及应用。
E-mail: zhangcheng@mirslab.cn

最新录用