

基于深度神经网络的海表盐度反演

高明¹, 黄贤源², 王芳¹, 张海龙¹, 赵红霞¹, 高溪远¹

(1. 中国人民武装警察部队作战勤务保障大队, 北京 100081;

2. 中国人民解放军部队 92859 部队, 天津 300000)

摘要: 海表盐度 (Sea Surface Salinity, SSS) 是研究海洋对全球气候影响的重要参量, 欧洲航天局 (European Space Agency, ESA) 设计研发的 SMOS (Soil Moisture and Ocean Salinity) 是专用于探测海水盐度的卫星之一。受射频干扰 (Radio Frequency Interference, RFI) 等因素的影响, SMOS 卫星盐度产品的精度难以达到预期效果。为了提高 SMOS 卫星海表盐度产品精度, 本文提出一种基于深度神经网络的海表盐度反演算法。以太平洋中部海域 (150°E~180°, 5°~30°N) 为研究区域, 利用 Argo 浮标实测盐度数据为参考真值, 将 SMOS 卫星 L1C、L2 级产品与 Argo 盐度数据进行时空匹配。并根据海洋遥感和辐射传输理论, 选取亮温 (Brightness Temperature, TB)、海表温度 (Sea Surface Temperature, SST)、降雨率 (Rain Rate, RR)、波高 (Significant Wave Height, SWH)、纬向风速 (Zonal Wind Speed, ZWS)、经向风速 (Meridional Wind Speed, MWS) 和蒸发量 (Evaporation, Eva) 七个影响盐度的重要参数, 利用 K 折交叉验证法, 构建了深度神经网络 (Deep Neural Network, DNN) 模型, 对 SMOS 卫星 L2 级数据进行反演。实验结果表明, 利用本文算法计算得到的海表盐度数据平均绝对误差为 0.159, 均方根误差为 0.195, 均明显优于 SMOS 盐度产品精度, 本文提出的算法能够提供更精准的海表盐度产品。

关键词: SMOS 卫星; 海表盐度反演; 深度神经网络

中图分类号: P731.12

文献标志码: A

文章编号: 1671-6647(2022)03-0496-09

doi: 10.12362/j.issn.1671-6647.20210409001

引用格式: 高明, 黄贤源, 王芳, 等. 基于深度神经网络的海表盐度反演[J]. 海洋科学进展, 2022, 40(3): 496-504. GAO M, HUANG XY, WANG F, et al. Seasurface salinity inversion based on DNN model[J]. Advances in Marine Science, 2022, 40(3): 496-504.

海表盐度 (Sea Surface Salinity, SSS) 是研究海洋状态和海水动力循环的重要物理和化学参数。海洋中海-气交换、海冰冻融等许多过程的产生和发展都与盐度的分布及变化规律有关, 研究海表盐度对揭示海洋现象、海洋过程和全球气候变化具有重要意义^[1-2]。

海表盐度探测手段主要包括实地探测和遥感探测。实地探测手段难以实现全球海域的实时连续观测, 但海洋卫星遥感技术可较好地解决这一问题。欧洲航天局 (European Space Agency, ESA, 简称欧空局) 于 2009 年发射的土壤湿度与海水盐度 (Soil Moisture and Ocean Salinity, SMOS) 卫星是一颗专用于探测海表盐度的卫星, 其唯一有效载荷是基于孔径综合技术的微波成像仪 MIRAS (Microwave Imaging Radiometer using Aperture Synthesis), 工作频率在 L 波段, 主要用于探测辐射亮温 (Brightness Temperature, TB)。在发射之初, 该卫星提出的观测目标是提供在空间分辨率为 200 km × 200 km、时间分辨率为 10~30 d 时精度达到 0.1 的全球海表盐度数据。但是, 研究表明^[3-4], 在某些海域, SMOS 卫星的盐度产品难以达到预期要求。对此, 许多学者开展了提高 SMOS 卫星盐度数据精度的研究^[5-8]。例如: 卢红丽等^[5]研究了海面风矢量对海表亮温的影响, 并推导出海表风速、风向、海表亮温以及亮温修正量之间的关系式, 从而消除了风对盐度遥感的影响。李志等^[6]对风速和涌浪两个参数做线性回归, 建立了适用于实验海区的盐度反演模式。邓广等^[7]采用统计学的回归方式, 将亮温数据代入 HYCOM 模式的模拟亮温, 建立回归模型, 提高了南海区域的盐度反演精度。王迎强等^[8]利用 MPM 93 (Millimeter-Wave Propagation Model 93) 模型和最大似然估计法研究不同天

收稿日期: 2021-04-09

作者简介: 高明 (1982—), 男, 工程师, 硕士, 主要从事气象保障方面研究. E-mail: 2510154793@qq.com

(王燕 编辑)

气对盐度反演的影响, 结果表明降雨量和海表面温度对盐度反演的影响不可忽略。

近年来, 深度神经网络(Deep Neural Network, DNN)在智能驾驶、语音识别、医疗和生物等领域得到了广泛的应用^[9-10], 也逐渐在海洋科学领域得到运用^[11-13]。为提高 SMOS 卫星盐度产品精度, 本研究提出了基于深度神经网络的盐度反演算法, 通过学习深层次非线性的网络结构, 实现复杂函数的逼近, 能够有效解决传统海表盐度反演模型中参数拟合复杂、模型适应性差等问题。K 折交叉验证法是机器学习(Machine Learning, ML)数据处理常用的方法, 它能够充分利用有限的数据集, 使其发挥最大效果, 多用于训练数据量较少的情况, 本文利用该方法进行 12 次不同参数的实验, 逐步调整深度神经网络的隐藏层数、层间结点数量、迭代次数、优化器种类以及 Dropout 比例, 进而不断优化模型结构, 最终训练出最佳模型, 以期对 SMOS 盐度精度的提高贡献新的研究思路。

1 数据来源

1.1 研究区域

受射频干扰 RFI(Radio Frequency Interference)的影响, 微波辐射计接收的辐射信号存在不可消除的误差, 大大降低了海表盐度的产品精度^[14]。因此, 本实验选择远离陆地, 受 RFI 影响较小的开阔海域作为研究对象。此外, 银河噪声在 7 月和 8 月波动比较小, 使用此时间段的 SMOS 卫星数据可忽略来自外太空的影响^[8]。基于此, 本文选取太平洋中部海域(150°E~180°, 5°~30°N)作为研究区域(图 1 中红色方框区域), 对该区域内 2013 年 7 月至 8 月的数据进行时空匹配, 构建实验所需要的数据集。

1.2 SMOS 数据

SMOS 探测的亮温不是海面的真实温度, 而是一种用于描述物体辐射强度的假定温度。对于海洋表面, 海水亮温与真实海表温度、海表发射率之间的函数关系^[6]为:


$$SST = \frac{T_b(f, \theta)}{e(f, \theta, SSS)}, \quad (1)$$

式中: SST(Sea Surface Temperature)为海表温度; f 为微波频率; T_b 为亮温; θ 为入射角; e 为海表发射率; SSS 为海表盐度。

海表发射率 e 与海面粗糙度联系紧密。海面粗糙度主要由海面风速包括纬向风速(Zonal Wind Speed, ZWS)和经向风速(Meridional Wind Speed, MWS), 以及有效波高(Significant Wave Height, SWH)表征^[6]。此外, 研究表明^[15], 降雨率(Rain Rate, RR)和海表蒸发量(Evaporation, Eva)也是直接影响海表面实时盐度的重要因子。因此, 本文选取与盐度反演密切相关的 7 个参数, 即: 亮温 TB、海表温度 SST、纬向风速 ZWS、经向风速 MWS、有效波高 SWH、降雨率 RR 和海表蒸发量 Eva 作为模型输入参数。这些参数和 3 种 SMOS 卫星 L2 级盐度产品(SSS1、SSS2、SSS3)均源于欧空局网站^[16], 空间分辨率为 $0.022^\circ \times 0.022^\circ$ 。

1.3 Argo 数据

Argo 浮标(以下简称 Argo)是海洋实地探测的一个典型代表。它是一种自持式剖面漂流浮标, 可以在大洋中自主沉浮、自由漂流, 自动测量深至水下 2 000 m 的海水剖面数据。Argo 所载的泵抽式温盐深仪



注: ●为 Argo 浮标位置。

图 1 研究区域

Fig. 1 Study area

(Conductivity Temperature Depth, CTD) 在距海表 5 m 左右时会自动停止工作, 无法探测到真实的海表盐度。但 5 m 处的盐度与海水表层 1 cm 左右的盐度值几乎一致^[17], 因此, 本文使用 Argo 最浅层的盐度数据来代表海表盐度值。研究数据来自中国 Argo 资料中心^[18], 选择 2013 年 7 月至 8 月太平洋中部海域(150°E~180°, 5°~30°N)的 Argo 浮标, 具体位置见图 1 中蓝点所示位置。

2 研究方法

2.1 数据匹配

SMOS 卫星提供的是 200 km×200 km 的网格亮温数据, Argo 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 SMOS 卫星数据与 Argo 实测盐度数据进行时空匹配。

参考曹凯翔等^[19]的数据匹配方法, 本文采用空间分辨率为 0.5°×0.5°、时间分辨率为 36 h 的匹配原则, 对 2013 年 7 月至 8 月的 SMOS 卫星 L1、L2 级产品与 Argo 盐度数据进行时空匹配, 即: 对于每一个 SMOS 卫星产品数据, 计算其测量点周围 0.5°网格点内和测量时间点(±18) h 内所有 Argo 盐度的平均值, 将其作为匹配后的实测盐度数据。

将 SMOS 卫星数据与 Argo 盐度数据匹配后, 得到 470 组有效数据。每组数据具有 11 个属性值, 即 TB、SST、RR、SWH、ZWS、MWS、Eva, 以及 Argo 实测盐度数据、SSS1 数据、SSS2 数据和 SSS3 数据。其中, 将 TB、SST、RR、SWH、ZMS、MWS 和 Eva 这 7 个参数作为反演模型的输入值, 将 Argo 实测盐度数据作为真实参考值, 将 SMOS 卫星的 3 种 L2 级盐度产品 SSS1、SSS2、SSS3 数据作为与实验结果的比较值。

由于反演模型输入所需的 7 个属性值的单位不同, 所以, 需要消除量纲之间的差异。利用标准归一化的方法, 对每个参数减去其平均值(中心化), 再除以其标准差, 最终得到平均值为 0、标准差为 1 的标准正态分布数据。标准归一化后的参数 x^* 为:

$$x^* = \frac{x - \mu}{\sigma}, \quad (2)$$

式中: x 为原始输入参数值; μ 为参数的均值; σ 为参数的标准差。

2.2 K 折交叉验证法

K 折交叉验证法是机器学习模型调优常用的方法, 可以充分利用有限数据, 发挥小样本的最大效果^[20]。该方法的操作流程为: 首先将数据集划分成数量相同的 K 组数据, 实例化 K 个相同的模型, 让每个模型都在 K-1 个分区上训练; 然后在剩余的一个验证分区上进行评估, 模型的最终验证结果为 k 个结果的平均值。本文采用 4 折交叉验证, 即 K=4, 如图 2 所示。




图 2 四折交叉验证法操作流程

Fig. 2 Four fold cross-validation process

2.3 DNN 深度神经网络

深度神经网络 DNN(Deep Neural Network)是具有多个层级结构的人工神经网络, 包括输入层、多个隐藏层和输出层。模型相邻层的节点间存在连接结构, 而同一层和跨层的节点间没有连接。不同节点间通过全连接层与激活函数组合的形式相连, 构建多层复杂的神经网络模型。模型结构如图 3 所示。

DNN 神经网络的构建包含了全连接层、激活函数、损失函数和优化器等结构。DNN 利用前向与反向传播算法(Backward Propagation, BP)进行训练, 对网络中每个权重 w 和偏置 b 进行不断更新。反向传播算法作为 DNN 的核心内容, 实质是将预测输出值与真值间的误差进行回传, 不断修改网络模型每个连接层中 w 与 b 的数值大小, 使误差值不断减小, 直至满足精度要求。通过大量数据的训练, 损失函数值下降到要求阈值后, 取此时的参数值作为模型参数, 据此进行回归预测。针对不同的实际情况, 隐藏层数、隐藏层节点数、Dropout 比例等结构参数与初始学习率、训练步长等训练参数的选取均会对训练结果产生一定的影响。此外, 选取合适的损失函数与优化器, 还可以提升网络模型精度, 加速网络训练速度。BP 算法的权重与偏置计算公式为:

$$w^* = w - \alpha \frac{\partial J(w, b)}{\partial w}, \quad (3)$$

$$b^* = b - \alpha \frac{\partial J(w, b)}{\partial b}, \quad (4)$$

式中: w^* 和 w 分别为更新后和更新前的权重; b^* 和 b 分别为更新后和更新前的偏置; α 为人为设置的学习率; $J(w, b)$ 为模型的损失函数。通过不断的梯度下降迭代, 得到最优参数 w^* 和 b^* 。

3 实验流程


实验具体流程如图 4 所示。首先将匹配成功的 470 组数据进行标准归一化预处理, 以统一输入变量量纲, 然后按照 7:3 比例随机分为训练集 330 组和测试集 140 组。为使 DNN 模型发挥最佳效果, 本文进行了 12 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。表 1 给出了 12 次实验调参训练结果, 数据为同一参数设置下多次实验的平均值。实验采用 4 折验证法, 将用于训练的 330 个数据分为 4 组, 第一组和第二组均包含 82 个数据, 第三组和第四组均包含 83 个数据。首先以第一组为验证数据集, 在后 3 组数据上训练模型, 训练完成后, 在第一组数据上验证盐度反演精度; 接着以第二组数据为验证数据集。依次类推, 不断修改隐藏层层数 Hidden_Layer、隐藏层节点数 Nodes、Dropout 比例 Dropout_P 和具体优化算法 Optimizer 等参数, 最终得到最优模型。

本实验利用均方根误差(Root Mean Square Error, RMSE)和平均绝对误差(Mean Absolute Error, MAE)两个指标量化分析反演盐度的误差, 计算公式分别为:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m [h(x_i) - y_i]^2}, \quad (5)$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |h(x_i) - y_i|, \quad (6)$$

式中: m 为实验数据总数; $h(x_i)$ 为本文算法得到的海表盐度数据; y_i 为对应的实测 Argo 盐度数据。



注: 圆形为每层的神经元, 连线为相邻层间神经元的连接;
 x_1 、 x_2 和 x_3 为 3 个输入因子, y 为 1 个输出参数。

图 3 DNN 模型结构

Fig. 3 DNN model structure




图 4 基于 DNN 深度学习算法的海表盐度反演流程

Fig. 4 SSS inversion flow based on DNN deep learning algorithm

表 1 12 次实验调参训练结果

Table 1 Training results of 12 experiments

实验序号	隐藏层数	节点数	Dropout 位置	Dropout 概率	优化方式	RMSE	MAE
1	3	14, 7, 7	1/2	0.5	RMSprop	0.256	0.213
2	3	14, 14, 7	1/2	0.5	RMSprop	0.272	0.222
3	3	14, 7, 7	0/1	0.5	RMSprop	0.401	0.325
4	3	14, 7, 7	1/2	0.3	RMSprop	0.319	0.243
5	3	14, 7, 7	1/2	0.5	Adam	0.275	0.223
6	3	14, 14, 7	1/2	0.5	Adam	0.268	0.212
7	3	14, 7, 7	0/1	0.5	Adam	0.462	0.399
8	3	14, 7, 7	1/2	0.3	Adam	0.329	0.264
9	2	14, 7	1/2	0.5	RMSprop	0.249	0.193
10	2	7, 7	1/2	0.5	RMSprop	0.252	0.198
11	2	14, 7	1/2	0.5	Adam	0.264	0.217
12	2	7, 7	1/2	0.5	Adam	0.273	0.218

注：数据加粗行表示第 9 次实验的参数设置获得了误差最小的海表盐度数据。

本文进行的 12 次实验参数设置如表 1 所示。由表 1 可以看出，总的来说，当隐藏层为 2 层时，模型反演得到的盐度误差低于 3 层隐藏层模型反演的盐度。最优的反演盐度数据出现在第 9 组，此时隐藏层为 2 层，各层节点数分别为 14 和 7，Dropout 比例为 0.5。采用 RMSprop 优化方式，获得了 RMSE 和 MAE 分别为 0.249 和 0.193 的海表盐度。实验 9 最优模型的其他重要参数学习率 Learning_rate、激活函数 Activation_function、损失函数 Loss_function 和迭代次数 Iteration 等的设置如表 2 所示。

表 2 最优模型的各项参数及其数值

Table 2 Parameters and values of the optimal model

参数	最优值	参数	最优值	参数	最优值	参数	最优值
Hidden_layer (隐藏层)	2	Dropout_p (Dropout 概率)	0.5	Learning_rate (学习效率)	0.001	Loss_function (损失函数)	MAE
Nodes (节点数)	14/7	Optimizer (优化方式)	RMSprop	Activation_function (激活函数)	ReLU	Iteration (迭代层)	200

4 结果与分析

本文实验 9 的参数设置获得了精度最高的海表盐度数据。在该实验的模型训练过程中,训练集和测试集的平均绝对误差 MAE 下降情况如图 5 所示。在实验的前 100 次迭代内,MAE 快速下降,模型迅速更新权重和偏置,使输出盐度与 Argo 实测盐度尽可能相等。但在进行约 120 次迭代后,MAE 下降速度急缓,直至几乎不再下降,此时精度约为 0.2。

以 Argo 实测盐度数据作为真实参考值,对实验获取的 470 组盐度数据分别与 SMOS 卫星的 SSS1、SSS2、SSS3 三种盐度产品的 RMSE 和 MAE 进行比较(见表 3),可以看出,SMOS 卫星的 3 种盐度产品精度整体相当,但 SSS1 的精度略高,因此选择 SSS1 数据作为 SMOS 卫星盐度产品的代表,与本文实验结果进行比较。

将 140 组测试集数据代入训练完成的 DNN 模型,得到测试集的反演盐度值。由 DNN 反演盐度数据、SMOS 卫星产品 SSS1 数据和 Argo 实测盐度值的对比结果(图 6)可见,DNN 反演数据与 Argo 实测盐度值十分接近,均分布在 34~36,拟合精度明显高于 SSS1 数据。将 Argo 数据作为参考标准,计算 DNN 模型反演得到的盐度值误差($\varepsilon_{\text{DNN}} = S_{\text{DNN}} - S_{\text{Argo}}$)以及 SSS1 产品的误差($\varepsilon_{\text{SSS1}} = S_{\text{SSS1}} - S_{\text{Argo}}$),对比 2 种误差(图 7)可知:SSS1 产品误差起伏较大,最大误差接近于-4;而 DNN 反演盐度数据的误差集中在 0 附近,不大于 1 且不小于-1,说明其质量明显优于 SMOS 数据。此外,SMOS 卫星的 SSS1 产品与 Argo 实测盐度之间的 RMSE 超过 0.8,MAE 超过 0.5;而 DNN 模型反演得到的盐度值与 Argo 实测盐度之间的 RMSE 为 0.249,MAE 为 0.193,均明显优于前者。因此,实验结果充分验证了本文方法的有效性和先进性。




图 6 DNN 模型反演盐度、SMOS 卫星 SSS1 产品、Argo 实测盐度值对比

Fig. 6 Comparison of DNN retrieved SSS, SMOS SSS1, and the Argo measured SSS




图 7 DNN 模型反演盐度与 SMOS 卫星 SSS1 产品误差对比

Fig. 7 Comparison of errors between DNN retrieved SSS and SMOS SSS1

为验证 DNN 模型盐度反演方法的鲁棒性,本文将最佳模型(实验 9)重复进行了 10 次实验。每一次实验都保证模型参数不变,但随机划分出不同的训练集和测试集数据(保持 2 个数据集容量不变),然后验证测试集误差,分别记录每次实验的 RMSE 和 MAE,并计算出 10 次重复实验的平均值(见表 4),结果表明:




图 5 训练过程中训练集和测试集的 MAE 变化

Fig. 5 MAE variation and test-sets during training

表 3 SMOS 海表盐度产品 SSS1、SSS2、SSS3 相较于 Argo 实测盐度的误差对比

误差类型	SSS1	SSS2	SSS3
RMSE	0.817	0.848	0.861
MAE	0.535	0.572	0.59

第 8 次实验误差最小, 其 MAE 为 0.159, RMSE 为 0.195。总体来看, 10 次重复实验的平均 MAE 为 0.216, 平均 RMSE 为 0.262。这 10 次训练的差异较小, 结果较为稳定, 且误差均小于 SMOS 卫星盐度产品。因此, 本文算法具有较高的鲁棒性。

表 4 最优模型 10 次实验结果量化指标
Table 4 Quantitative indexes of 10 experimental results of the optimal model

误差类型	实验序号										平均值
	1	2	3	4	5	6	7	8	9	10	
MAE	0.193	0.209	0.198	0.246	0.189	0.229	0.277	0.159	0.227	0.236	0.216
RMSE	0.249	0.254	0.231	0.297	0.224	0.279	0.331	0.195	0.281	0.281	0.262

注: 数据加粗列表示第 8 次重复实验获得了误差最小的海表盐度数据。

5 结 论

针对目前 SMOS 卫星反演盐度精度未满足预期标准的情况, 本文提出了一种基于深度神经网络 DNN 的海表盐度反演方法。为避免射频干扰 RFI 和银河噪声的影响, 研究数据选择了 2013 年 7 月至 8 月太平洋中部海域(150°E~180°, 5°~30°N)的 SMOS 卫星数据。在建立 DNN 模型之前, 首先将亮温 TB、海表温度 SST、纬向风速 ZWS、经向风速 MWS、有效波高 SWH、降雨率 RR 和海表蒸发量 Eva 共 7 个模型输入参数, 以及 SMOS 卫星 3 种盐度产品(SSS1、SSS2、SSS3)和 Argo 实测盐度数据, 按照空间分辨率为 0.5°×0.5°、时间分辨率为 36 h 的原则进行时空匹配。然后, 将 470 组实验数据按照 7 : 3 比例随机划分为训练集和验证集。在训练集上, 采用 4 折交叉验证的方式, 反复实验, 优化模型参数, 直至训练出最佳模型。最后, 将最佳模型的参数设置固定, 进行 10 次重复实验, 验证了本文方法的鲁棒性。

根据最佳模型的 10 次实验表现, DNN 模型反演盐度数据与 Argo 实测盐度之间平均 MAE 为 0.216, 平均 RMSE 为 0.262; 最优时, MAE 为 0.159, RMSE 为 0.195。精度明显高于 SMOS 卫星 L2 级盐度产品(MAE=0.535, RMSE=0.817)。因此, 本文提出算法的反演盐度精度超过了 SMOS 卫星盐度产品, 且多次实验均取得了较好结果, 验证了方法的先进性和稳定性, 能够为海洋盐度分析提供较好的数据源, 从而有助于推动相关领域的研究进展。

参考文献 (References):

[1] YI D L, MELNICHENKO O, HACKER P, et al. Remote sensing of sea surface salinity variability in the South China Sea[J]. Journal of Geophysical Research: Oceans, 2020, 125(12): e2020JC016827-1- e2020JC016827-26.

[2] 李秀珍, 梁卫, 温之平, 等. 南海盐度对南海夏季风响应的初步分析[J]. 热带海洋学报, 2011, 30(1): 29-34. LI X Z, LIANG W, WEN Z P, et al. Preliminary study on the salinity characteristics of South China Sea and its response to the summer monsoon[J]. Journal of Tropical Oceanography, 2011, 30(1): 29-34.

[3] ALVERA-AZCARATE A, BARTH A, PARARD G, et al. Analysis of SMOS sea surface salinity data using DINEOF[J]. Remote Sensing of Environment, 2016, 180: 137-145.

[4] JIN X C, ZHU Q K, PAN D L, et al. Impact of sea surface temperature on sea surface salinity retrieval by SMOS microwave radiometer[J]. Journal of Remote Sensing, 2017, 21(6): 939-947.

[5] 卢红丽, 王振占, 殷晓斌. 利用SMOS卫星数据反演海洋盐度方法研究[J]. 遥感技术与应用, 2014, 29(3): 401-409. LU H L, WANG Z Z, YIN X B. Research of the sea surface salinity retrieval method based on SMOS data[J]. Remote Sensing Technology and Application, 2014, 29(3): 401-409.

[6] 李志. 海洋表层盐度遥感反演机理及应用研究[D]. 青岛: 中国海洋大学, 2008. LI Z. The study of sea surface salinity retrieval model at L-band[D]. Qingdao: Ocean University of China, 2008.

[7] 邓广, 李洪平. 亮温拟合模型在南海海表盐度反演中的应用[J]. 地理空间信息, 2017, 15(7): 9-13, 39. DENG G, LI H P. The application of

- brightness temperature fitting model to sea surface salinity retrieval of South China Sea[J]. *Geospatial Information*, 2017, 15(7): 9-13, 39.
- [8] 王迎强, 严卫, 王也英, 等. 大气对星载盐度计辐射传输特性及盐度反演的影响研究[J]. 北京大学学报(自然科学版), 2018, 54(2): 350-360. WANG Y Q, YAN W, WANG Y Y, et al. Effects of atmosphere on radiative transfer characteristics and salinity retrieval on spaceborne salinity meter[J]. *Acta Scientiarum Naturalium Universitatis Pekinensis*, 2018, 54(2): 350-360.
- [9] 李德仁. 脑认知与空间认知——论空间大数据与人工智能的集成[J]. 武汉大学学报·信息科学版, 2018, 43(12): 1761-1767. LI D R. Brain cognition and spatial cognition: on integration of geo-spatial big data and artificial intelligence[J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(12): 1761-1767.
- [10] MONTAVON G, SAMEK W, MÜLLER K-R. Methods for interpreting and understanding deep neural networks[J]. *Digital Signal Processing*, 2018, 73: 1-15.
- [11] 徐朝. 基于机器学习的海面盐度遥感反演模型[D]. 北京: 中国地质大学(北京), 2016. XU C. Remote sensing inversion models of sea surface salinity based on machine learning method[D]. Beijing: China University of Geoscience (Beijing), 2016.
- [12] 艾波, 姜英超, 王振华, 等. 基于深度学习的海表温度遥感反演模型[J]. 遥感信息, 2018, 33(5): 15-20. AI B, JIANG Y C, WANG Z H, et al. Remote sensing inversion model of sea surface temperature based on deep learning method[J]. *Remote Sensing Information*, 2018, 33(5): 15-20.
- [13] 张勇. 基于GA-SVM方法的SMOS卫星海表盐度预测模型[D]. 青岛: 中国海洋大学, 2018. ZHANG Y. Sea surface salinity prediction model of SMOS satellite based on GA-SVM[D]. Qingdao: Ocean University of China, 2018.
- [14] 王新新, 王祥, 赵建华, 等. 无线射频干扰对SMOS卫星盐度数据产品准确度的影响研究[J]. 海洋学报, 2017, 39(11): 141-147. WANG X X, WANG X, ZHAO J H, et al. Study on the effect of radio frequency interference on the accuracy of SMOS sea surface salinity data[J]. *Haiyang Xuebao*, 2017, 39(11): 141-147.
- [15] 许金电, 高璐. 热带印度洋降水、蒸发的时空特征及其对海表盐度的影响[J]. 海洋学报, 2018, 40(7): 90-102. XU J D, GAO L. The temporal-spatial features of evaporation and precipitation and the effect on sea surface salinity in the tropical Indian Ocean[J]. *Haiyang Xuebao*, 2018, 40(7): 90-102.
- [16] ESA SMOS Online Dissemination[DB/OL]. [2021-06-01]. <https://smos-diss.esa.int/oads/access/>.
- [17] BOUTIN J, MARTIN N. ARGO upper salinity measurements: perspectives for L-band radiometers calibration and retrieved sea surface salinity validation[J]. *IEEE Geoscience and Remote Sensing Letters*, 2006, 3(2): 202-206.
- [18] 中国Argo资料中心. Argo标准数据集[DB/OL]. [2021-06-01]. <https://www.argo-cndc.org/#/catalog/dataService>. China ARGO Data Center. Argo Standard Dataset[DB/OL]. [2021-06-01]. <https://www.argo-cndc.org/#/catalog/dataService>.
- [19] 曹凯翔, 孙伟富, 孟俊敏, 等. 基于Argo的SMAP与SMOS盐度产品质量评估与比对[J]. 海洋科学进展, 2019, 37(4): 574-587. CAO K X, SUN W F, MENG J M, et al. Assessment and comparison of sea surface salinity data derived from SMAP and SMOS based on Argo measurement[J]. *Advances in Marine Science*, 2019, 37(4): 574-587.
- [20] 牟唯嫣, 王春玲, 赵昕. 基于空间填充准则的交叉验证方法及其应用[J]. 系统科学与数学, 2020, 40(2): 176-182. MU W Y, WANG C L, ZHAO X. A space filling-based cross-validation method and its applications[J]. *Journal of Systems Science and Mathematical Sciences*, 2020, 40(2): 176-182.

Sea Surface Salinity Inversion Based on DNN Model

GAO Ming¹, HUANG Xian-yuan², WANG Fang¹, ZHANG Hai-long¹, ZHAO Hong-xia¹, GAO Xi-yuan¹

(1. *Combat Service Support Brigade of the Chinese People's Armed Police Force*, Beijing 100081, China;

2. *Unit 92859 of the PLA*, Tianjin 300000, China)

Abstract: Sea Surface Salinity is an important parameter to learn oceans' impact on the global climate. SMOS (Soil Moisture and Ocean Salinity) developed by the European Space Agency is one of the satellites dedicated to measuring ocean salinity. However, due to influences like Radio Frequency Interference (RFI), the accuracy of SMOS salinity products hardly achieve the expected results. In order to improve the accuracy of the sea surface salinity products, a deep neural network based sea surface salinity retrieval algorithm is proposed in this paper. The experiment takes the central Pacific Ocean (150°E—180°, 5°—30°N) as the research area, using the Argo measured salinity data as the reference. First, SMOS L1C and L2 level products are matched in time and space with the Argo salinity data. Then, according to the ocean remote sensing and radiative transfer theory, seven parameters that affect ocean salinity are selected, including Brightness Temperature (TB), Sea Surface Temperature (SST), Rainfall Rate (RR), Significant Wave Height (SWH), Zonal Wind Speed (ZWS), Meridional Wind Speed (MWS) and Evaporation (Eva). The DNN (Deep Neural Network) is developed and optimized with the K-fold cross-validation method. And the sea surface salinity data is retrieved using Argo salinity as the ground-truth. The experiments show that the mean absolute error of the sea surface salinity data obtained by the algorithm proposed in this paper is 0.159, and the root mean square error is 0.195, which are better than the accuracy of SMOS salinity products.

Key words: SMOS satellite; sea surface salinity inversion; Deep Neural Network (DNN)

Received: April 9, 2021