

基于 Sentinel-1A 的全球有效波高的反演研究*

穆珊珊¹ 李海艳¹ 吴明柏^{1,2}

(1. 中国科学院大学 北京 100049; 2. 中国科学院地理科学与资源研究所 北京 100101)

摘要 本文利用神经网络的技术手段, 针对 Sentinel-1A 二级波模式数据提出一种用于海浪有效波高(Hs)反演的模型——N_N 模型。该模型在基于 ERS2 SAR 波模数据开发的双参数模型的基础上, 加入经度、纬度、方位向截断波长(λ_c)、图像偏斜(skewness, skew)、图像峰度(kurtosis, kurt)、卫星平台距目标物的距离与卫星飞行速度之比(β)等其他参数信息, 根据不同输入参数的组合, 建立了 14 个模型用于 Hs 反演, 旨在分析各参数对有效波高反演的影响。通过分析表明, 14 个 N_N 模型相关系数都在 0.8 以上。随着 λ_c 、 β 参数的加入, N_N 模型性能均大幅上升, 且 λ_c 参数对模型性能的改善作用更加明显, 相关系数提升 0.06 左右, 均方根误差(Root Mean Squared Error, RMSE)下降 0.12m 左右。另外, skew 与 kurt 的加入也使 N_N 模型性能有所改善, RMSE 下降 0.03m 左右, 相关系数提升 0.01 左右。其中, N_N10 模型效果最佳且性能最稳定, 与欧洲中程天气预测中心(the European Centre for Medium-Range Weather Forecasts, ECMWF)数据对比, 相关系数(CORR)达到 0.905, 散射指数(Scattering Index, SI)与 RMSE 最低, 分别为 18.74%、0.502m, 与独立测量的浮标数据的相关系数达到了 0.894。

关键词 神经网络; 有效波高; 方位向截断波长; 归一化雷达后向散射系数

中图分类号 P7; TP3 doi: 10.11693/hyhz20190900177

海浪是海洋最明显的表面特征, 波长范围从几厘米到数百米, 波高范围从海洋表面的微小扰动到数十米, 对海洋工程、船舶设计、海上运输以及海洋污染的消散等都有很大的影响。因此, 通过有效的技术手段了解海浪的统计特性, 如有效波高、平均波周期等尤为重要。

自 1978 年发射 Seasat1 搭载合成孔径雷达(Synthetic Aperture Radar, SAR)开始, ERS-1/2、RADARSAT-1 和 ENVISAT、Sentinel-1 持续运行, 星载 SAR 不断提供全球范围内实时动态的海面波浪信息, 凭借其间接的、大范围的测量方式和全天候、全天时、高分辨率的测量能力, 成为海浪信息获取的重要途径之一(Jackson *et al*, 2004)。利用 SAR 进行海浪统计参数的反演有两种常见的方式, 一种是通过 SAR 图像谱获取二维海浪方向波谱, 继而获取海浪统计参

数。例如, 有效波高(Hs)可以表示为方向波谱的积分:

$$H_s = 4 \sqrt{\iint F(f, \varphi) df d\varphi}, \quad (1)$$

其中, $F(f, \varphi)$ 表示二维海浪方向谱, f 为频率, φ 为方向。另一种方式是通过直接建立 SAR 图像与海浪参数之间的关系, 在无需反演得到海浪方向谱的情况下进行海浪参数反演。

第一种通过 SAR 图像谱获取海浪谱, 反演海浪参数的方式在海浪遥感应用中是很常见的。但海洋的 SAR 图像常常在方位方向显得十分模糊且导出的波谱容易发生畸变(Grieco *et al*, 2016; Stopa *et al*, 2017)。这是由于 SAR 特殊的成像机制——速度聚束调制引起的。受这一调制作用的影响, 海浪的随机运动会引起 SAR 后向散射回波信号的多普勒频移, 造成 SAR 不能对低于某一波长(即方位向截断波长)的

* 国家自然科学基金项目, 41776197 号; 中国科学院大学优秀青年教师科研能力提升项目, Y95401N 号。穆珊珊, 硕士研究生, E-mail: mushanjiangnan@163.com

通信作者: 李海艳, 硕士生导师, 副教授, E-mail: lihaiyan@ucas.edu.cn

收稿日期: 2019-09-21, 收修改稿日期: 2019-12-07

波浪进行成像。在这种情况下,海浪的成像过程中常表现出很强的非线性,对 SAR 图像影响很大(Hasselmann *et al*, 1985; Jackson *et al*, 2004)。因此,通过 SAR 图像推导二维海浪谱绝非一项简单的任务,必须通过引入其他数值模式结果作为先验信息才有可能估计完整的二维波谱(Hasselmann *et al*, 1991; Hasselmann *et al*, 1996; Schulz-Stellenfleth *et al*, 2005)。或者利用 SAR 图像交叉谱计算得到海浪谱,此计算虽不需要初猜信息,且可以消除海浪传播方向 180°模糊的问题,但产生的海浪谱无法完全解析高频波,即丢失短波信息,多数情况下是涌浪部分的谱分量(Engen *et al*, 1995)。由此可见,通过 SAR 图像谱获取海浪谱,进一步获得 Hs 等海浪统计参数这一途径,具有一定的困难性和局限性。

因此,很多学者针对第二种方法,即在不获取二维海浪谱的情况下反演海浪参数的方法进行了研究。Schulz-Stellenfleth 等(2007)基于 ERS2 数据,提出了一个经验二次模型 CWAVE-ERS,在不需要先验信息的条件下,通过 SAR 图像直接获取海浪积分参数。Li 等(2011)与 Stopa 等(2017)在 CWAVE-ERS 模型的基础上,分别提出了针对 ENVISAT ASAR 数据的 CWAVE-ENV 模型以及针对 S1A 数据的 CWAVE-S1A 模型,用于计算有效波高、平均周期等海浪参数。但由于上述 CWAVE 算法,仅针对特定的 SAR 数据,因此对于其他卫星数据的普适性不强(Stopa *et al*, 2017)。

除以上两种方法之外,随着海浪参数反演研究的不断进步,许多学者认识到方位向截断波长与海况条件之间具有强相关性,可用于海浪统计参数反演的研究(Jackson *et al*, 1985; Kerbaol *et al*, 1998; Ren *et al*, 2016; Wang *et al*, 2012)。方位向截断波长为 SAR 数据所特有的海况参数,可作为对 SAR 方位向分辨率的一种度量(Greico *et al*, 2016)。在假设线性波的情况下,方位向截断波长可表示为(Lyzenga, 1986; Kerbaol *et al*, 1998):

$$\lambda_c = \pi\beta\sqrt{\iint\omega^2F(f,\varphi)d\varphi}, \quad (2)$$

其中, $\beta = \frac{R}{V}$, 表示为卫星平台距目标物的距离 R 与卫星飞行速度 V 之比; $F(f, \varphi)$ 表示二维海浪方向谱; f 是频率, φ 为方向, $\omega = 2\pi f$, 为角频率; $\iint\omega^2F(f, \varphi)d\varphi$, 表示为海浪谱二阶矩。

Beal 等(1983)研究发现 λ_c 与 Hs 的平方根有经验依赖关系,而且对于 Hs 在 1—8m 的范围内,二者成

正比关系。Marghany 等(2002)依据 λ_c 与 $\sqrt{H_s}$ 的依赖关系,建立了二者之间的经验公式,利用 ERS-1 方位向截断波长反演了有效波高,并发现 λ_c 与 Hs 随着 ERS-1 图像时间的变化具有相似的变化趋势, λ_c 可用于模拟有效波高的季节变化。Stopa 等(2015)提出 SAR 方位向截断波长包含海浪轨道速度方差信息,并通过海浪谱二阶矩,建立了二者的理论关系,进一步证实了方位向截断波长可作为有效的海浪参数反演信息。Shao 等(2016)基于 S1A 卫星 SAR 图像,根据公式(1)、(2)表示的有效波高、方位向截断波长与海浪谱之间的关系,提出了一种波浪参数反演的半经验算法,用来描述有效波高与 λ_c 、雷达入射角(θ)、波浪传播方向与距离向的夹角之间的关系,同时根据平均波周期与海浪谱之间的关系,推导出利用 Hs 和 λ_c 表示的平均波周期计算公式。Greico 等(2016)基于 S1A 图像,建立了 λ_c 与 $\sqrt{H_s}$ 、海表面 10m 风速(U_{10})的地球物理模型函数,首次考虑到不同入射角及平均波传播方向下经验模型的差异,对不同海况下, λ_c 对有效波高及海表面风速的依赖关系进行了详细分析。分析表明, λ_c 与所有海况条件下的 Hs 强相关,而与 U_{10} 之间仅在完全发展的海况条件下表现出很高的相关性。Stopa 等(2017)利用神经网络,建立了 SAR 图像与海浪参数之间的非线性关系,进行了有效波高以及平均波周期的反演,分析了归一化雷达后向散射系数(Normalized Radar Cross-Section, σ_0)、归一化图像方差(the normalized image variance, NV)、图像偏斜、图像峰度、峰值波长(λ_p)等 SAR 参数对其建立的神经网络模型反演效果的影响。综上,不同学者的研究均证实了 λ_c 与 Hs 之间的强依赖关系,但大多研究均基于 SAR 图像数据进行的,算法的计算量及处理过程相对来说较为复杂,面向全球范围的 Hs 反演,仍具有一定的挑战性。

因此,本文拟在相关有效波高反演研究的基础上进行拓展,利用 S1A 二级波模式数据,采用神经网络的技术手段建立有效波高与 σ_0 、 λ_c 等 SAR 参数之间的联系,旨在分析各参数对有效波高反演的影响。本次实验建立的神经网络模型,除用于模型训练的欧洲中程天气预测中心(the European Centre for Medium-Range Weather Forecasts, ECMWF)模式数据外,不需要额外模式数据作为先验信息,且模型输入的 SAR 参数可在 S1A 二级 WV 数据中直接获取,大大降低了数据存储内存,减化了数据处理过程,对于硬件条件受限的用户尤为重要。

1 数据源介绍

本文采用了三种类型的数据, 分别为 S1A 卫星二级波模式数据、ECMWF 再分析数据和美国国家数据浮标中心(National Data Buoy Center, NDBC)浮标数据。其中, S1A 数据与 ECMWF 再分析数据进行时空匹配, 用于神经网络模型的训练, 独立测量的浮标数据用于神经网络训练结果的验证。

1.1 Sentinel-1A 二级波模式数据

Sentinel-1A 卫星于 2014 年 4 月发射成功, 在太阳同步轨道运行, 高度(H)约为 693km, 飞行速度约为 7570m/s, 倾角 98.18° , 重复周期为 12d, 搭载了基于 C 波段的雷达成像系统。S1A 卫星具有四种成像模式, 其中波模式(Wave Mode, WV)是 S1A 在大洋上的操作模式, 主要应用于海洋参数的获取。在此模式下, S1A 沿卫星轨道每 100km 进行一次采集, 以 23° (WV1)和 36° (WV2)两个入射角交替工作, 在近距

处获取一个图斑, 在远距处获取下一个图斑, 具有相同入射角的图斑间隔为 200km, 空间分辨率为 5m, 图斑大小约为 $20\text{km}\times 20\text{km}$ 。

本研究使用的卫星数据为 S1A 二级 WV 海洋产品(L2 Ocean Product, OCN)中的海洋涌浪谱(Ocean Swell spectra, OSW)数据, 可通过 ESA 网站(<https://scihub.copernicus.eu/dhus/#/home>)免费下载获取。该数据可提供 σ_0 、NV、 θ 、skew、kurt、对数极坐标系下的海浪方向谱、 λ_c 、 H_s 等参数。但受到速度聚束调制作用的影响, 其测量的海浪 H_s 被严重低估, 且受方位向截断波长的影响较大, 仅可用于较低海况(Li *et al*, 2011)。如图 1 所示, 我们将 S1A 二级数据提供的 H_s 以及根据公式(1)将 S1A 提供的海浪谱数据进行积分获得的 H_s 与 ECMWF 再分析数据提供的 H_s 进行了比较, 可以看出, 图 1a、b 中散点基本分布在 $x=y$ 直线下方, 表明 S1A 二级数据提供的以及通过海浪谱计算的 H_s 低于 ECMWF 再分析数据中的 H_s 。




图 1 S1A 二级波模式数据提供的 H_s 与 ECMWF 再分析数据提供的 H_s 的对比散点图

Fig.1 Scatter plots of H_s provided by S1A level2 wave mode data and ECMWF reanalysis data

注: a: S1A 二级波模式数据提供的 H_s 与 ECMWF 再分析数据提供的 H_s 的比较散点图; b: 通过 S1A 二级波模式数据提供的海浪谱积分获得的 H_s 与 ECMWF 再分析数据提供的 H_s 的比较散点图; H_s : 有效波高

为保证本研究实验结果不受船舶、海冰、溢油等影响, 选择雷达截面的归一化方差在 1—2 之间, 纬度在 $\pm 60^\circ$, 时间为 2018 年 1—12 月的 S1A 数据作为实验数据。

1.2 ECMWF 再分析数据

由于本研究选用的 S1A 波模式数据通常为全球公海数据, 而在公海仅有少量浮标测量数据可用。考

虑到神经网络对训练数据高准确度、广覆盖度的要求, 因此, 本研究同时选择 ECMWF 再分析数据 ERA5 与 S1A 数据进行时空匹配, 组成神经网络训练数据集。

ERA5 是第五代 ECMWF 再分析数据集, 是 ECMWF 使用其预测模型和数据同化系统“重新分析”存档的观测结果, 用于创建描述大气、陆地表面和海洋最近历史的全球数据集, 可由 ECMWF 网站下载获

得(<http://www.ecmwf.int/>)。本研究主要采用 ERA5 海浪数据中的有效波高数据,其网格大小为 $0.5^\circ \times 0.5^\circ$,时间间隔为 1h。本研究按照小于 0.25° 的空间窗口、小于 30min 的时间窗口对二者进行时空匹配,共获得 982351 对匹配数据对,其中 328081 对用于模型训练,其余数据用于模型应用。

1.3 NDBC 浮标数据

为了对神经网络模型输出结果进行对比分析,本文采用独立测量的具有海浪谱信息的浮标数据对其进行验证,其数据可由 NDBC 网站下载获得(<https://www.ndbc.noaa.gov/>)。浮标多布放于北半球,数据获取频率约为 1 次/h,根据其频率测量范围分为两类: 0.03—0.4Hz,离散为 38 个频率; 0.02—0.485Hz,离散为 47 个频率。可根据公式(1),将海浪谱进行积分获取有效波高。本研究将浮标数据和 S1A 数据按照小于 0.5° 的空间窗口和小于 0.5h 的时间窗口进行时空匹配,获得 400 对数据用于模型验证。

2 研究方法

本研究拟在 Schulz-Stellenfleth 等(2007)开发的利用 ERS2 SAR 数据 σ_0 、NV 及其乘积项(σ_0^2 、 NV^2 、 $\sigma_0 \times NV$)共 5 个参数用于海浪参数反演的双参数模型基础上,加入经纬度、 λ_c 等信息进行反演研究。同时,为增加模型的计算效率,本文将利用神经网络技术进行多元非线性回归,用于描述 SAR 不同输入参数与有效波高之间的关系。首先将 S1A 数据与时空匹配后的 ECMWF 数据用于模型的训练,然后利用独立的浮标数据对模型性能进行验证,同时,选取均值偏差(Bias)、均方根误差、散射指数、相关系数四个统计参数对模型性能进行定量评估。

2.1 神经网络的选取

神经网络是一种方便而通用的预测结果的方法,近年来被多次应用于遥感研究中。本研究基于 MATLAB 进行神经网络训练,选用的 BP(back propagation)神经网络,是一种多层前馈神经网络,包括输入层,输出层和隐藏层。其主要特点是信号前向传递,误差反向传播。当神经网络的输入和输出数据确定后,可调整的只有隐藏层的神经元数目,而优化隐藏层结点数,成为神经网络训练的首要任务。实验表明,如隐藏层结点数过少,网络则不能具有必要的学习和信息处理能力。反之,若过多,不仅会增加网络结构的复杂性,还会降低网络学习的速度。因此,在神经网络模型测试过程,可对隐藏层结点数进行

调整,最终取最优结果来确定神经元数目(王小川等, 2013; Stopa *et al.*, 2017)。本文在进行神经网络训练的实验中,根据不同 N_N 模型输入参数的个数,将隐藏层神经元个数设定为 4—30 之间,发现其性能均在隐藏层神经元个数大于输入参数个数时有所提升,且在大于 20 时趋于稳定,但随着神经元数目增多,训练时间也逐渐增加,因此,考虑到不同模型之间的对比,本文将 N_N 模型的隐藏层神经元数目均定为 20。

基于输入与输出参数之间非线性关系的考虑,神经网络采用正切 S 型传递函数(tansig)隐藏神经元和线性传递函数(purelin)输出神经元。另外,基于 Levenberg-Marquardt 反向传播算法(trainlm)是现阶段应用最广泛的优化算法,可为非线性最小二乘问题提供解决方案,本研究采用 trainlm 进行神经网络训练。最后,使用均方误差(MSE)和回归分析评估其性能(王小川等, 2013)。

$$MSE = \frac{1}{N} \sum_{i=1}^N (X_{out_i} - X_{in_i})^2, \quad (3)$$

其中, X_{in_i} 表示 N_N 模型训练的输入数据, X_{out_i} 表示 N_N 模型训练的输出数据, N 表示数据量。

2.2 N_N 模型建立

为避免神经网络训练效果受到进行不同范围的 Hs 数据分层筛选等人为因素影响,同时考虑到对全球范围内的有效波高反演的目的以及有效波高随季节明显变化的特性,本文拟在 2018 年所有 S1A 数据以及时空匹配后的 ECMWF 的 Hs 数据中每个季节选择一个月份的数据(本文选择 1、4、7、10 月份的数据)作为训练数据,同时拟采用常规神经网络模型训练方法,在模型训练过程中将训练数据随机分为 60%、20%、20%,分别用于模型建立过程中的训练、测试和验证。

本文首先对 2018 年 4 个月训练数据的 ECMWF 的 Hs 数据的分布及其占 2018 年总 Hs 数据的比例分布进行了分析。1、4、7、10 月份数据包括了全球范围内不同的海况,且分别代表冬、春、夏、秋四个季节,因此最终选择 1、4、7、10 月份的数据进行训练,并将 2018 年其他月份数据作为独立的数据(应用数据)用于神经网络的应用,不参与模型的训练。训练数据的 Hs 分布情况以及在 2018 年所有数据中的比例分布情况的柱状图,分别如图 2a 和 b 所示,可以看出,其主要 Hs 范围在 1—4m,且在 2018 年总数据中分布较均匀,比例均在 33%左右。

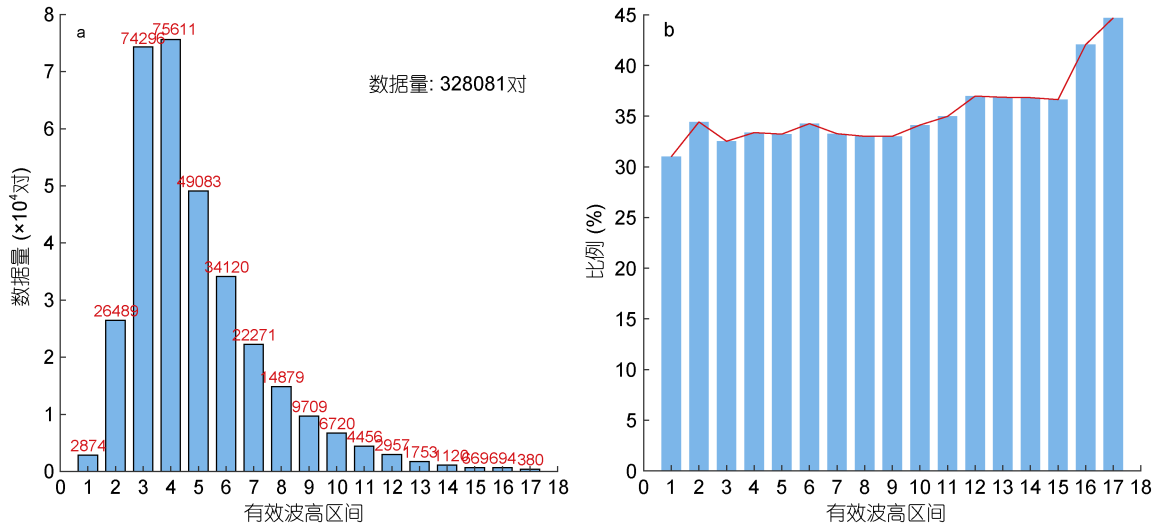


图 2 训练数据的 Hs 分布情况

Fig.2 Hs distribution of training data

注: a: 训练数据的 Hs 在每个区间内的数据量分布情况; b: 训练数据的 Hs 与总数据在每个区间内的比例, 其中, 由于较低海况以及高海况的数据较少, 因此将 Hs 按照以下方式进行划分: 横轴代表不同的 Hs 区间, 共 17 个, 1 代表 $H_s < 1m$; 2—15 代表 $1 < H_s \leq 8m$, 间隔为 $0.5m$; 16 代表 $8 < H_s \leq 9m$; 17 代表 $H_s > 9m$

本文选用 σ_0 、NV、 σ_0^2 、 NV^2 、 $\sigma_0 \times NV$ 、 λ_c 、skew、kurt、lon、lat、 β 作为神经网络训练模型的输入参数,

通过改变输入参数的个数, 进行神经网络模型调整, 共建立 14 个 N_N 模型, 如表 1 所示。

表 1 不同有效波高反演模型一览表
Tab.1 List of different Hs inversion models

模型	模型输入参数	输出参数	输入参数个数(个)	隐藏层节点数(个)
N_N 1	lon, lat, σ_0 , NV	$\sqrt{H_s}$	4	20
N_N 2	lon, lat, σ_0 , NV, λ_c	$\sqrt{H_s}$	5	20
N_N 3	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2	$\sqrt{H_s}$	7	20
N_N 4	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , β	$\sqrt{H_s}$	8	20
N_N 5	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , λ_c	$\sqrt{H_s}$	8	20
N_N 6	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , λ_c , β	$\sqrt{H_s}$	9	20
N_N 7	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , β , skew	$\sqrt{H_s}$	9	20
N_N 8	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , β , kurt	$\sqrt{H_s}$	9	20
N_N 9	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , β , skew, kurt	$\sqrt{H_s}$	10	20
N_N 10	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , λ_c , skew	$\sqrt{H_s}$	9	20
N_N 11	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , λ_c , kurt	$\sqrt{H_s}$	9	20
N_N 12	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , λ_c , skew, kurt	$\sqrt{H_s}$	10	20
N_N 13	lon, lat, σ_0 , NV, λ_c , σ_0^2 , NV^2 , λ_c^2 , $\sigma_0 \times NV$, $\sigma_0 \times \lambda_c$, $NV \times \lambda_c$	$\sqrt{H_s}$	11	20
N_N 14	σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , λ_c , skew	$\sqrt{H_s}$	7	20

N_N 模型输入参数中, σ_0 通常与风速和风向有关, 常用于风场反演算法中, 因此可表示海浪的短波信息(Horstmann *et al*, 2003; Li *et al*, 2011)。NV 提供关于图像均匀性和海况的信息, 反映了由于 SAR 图像中的波浪而引起的回波强度调制(Stopa *et al*, 2017)。

考虑到有效波高具有明显的纬向分布的特征, 因此在进行神经网络训练时, 加入经纬度信息, 增加输入与输出参数之间的空间对应性。 λ_c 反映 SAR 非线性成像机制, 与 Hs 具有很强的相关性(Beal *et al*, 1983; Shao *et al*, 2016)。另外, 有研究表明, 海表面的随机

运动对 SAR 成像的影响取决于 SAR 卫星系统的表征参数 β , β 值越大, SAR 成像海洋表面波的能力就越差, 因此, β 信息可用于提供海表面运动的信息(Beal *et al.*, 1983)。最后利用 skew、kurt 来考虑 SAR 图像重要的高阶特征信息(Stopa *et al.*, 2017)。

本研究选用 $\sqrt{H_s}$ 作为 N_N 模型的输出参数, 一方面考虑到 $\sqrt{H_s}$ 可避免在模型训练过程中出现 H_s 为负值的情况, 另一方面, 鉴于历史研究中半经验的建立了 λ_c 和 $\sqrt{H_s}$ 的关系(Beal *et al.*, 1983; Marghany *et al.*, 2002; Grieco *et al.*, 2016), 直接将 $\sqrt{H_s}$ 作为输出参数, 可增加输入与输出参数之间的相关性, 提高模型的性能。

2.3 统计分析

本研究对上述 N_N 模型反演得到的海浪有效波高, 进行对比分析, 选择 Bias、RMSE、SI、CORR 四种统计参数进行评价, 定义如下:

$$\text{Bias} = \frac{1}{N} \sum_{i=1}^N (X_i - Y_i), \quad (4)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - Y_i)^2}, \quad (5)$$

$$\text{SI} = \frac{1}{Y_i} \sqrt{\frac{1}{N} \sum_{i=1}^N [(X_i - \bar{X}_i) - (Y_i - \bar{Y}_i)]^2}, \quad (6)$$

$$\text{CORR} = \frac{\sum_{i=1}^N [(X_i - \bar{X}_i) - (Y_i - \bar{Y}_i)]}{\left[\sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \bar{X}_i)^2} \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \bar{Y}_i)^2} \right]}, \quad (7)$$

其中, X_i 表示 N_N 模型训练的结果, Y_i 表示 ECMWF 数据的反演结果, N 表示时空匹配后的数据量, 公式(7)中横杠表示取均值。

3 结果分析

为了更全面的对不同 N_N 模型的反演结果进行分析, 本研究分别从模式数据、独立测量的浮标数据以及不同环境条件下的模型性能分析三个方面对海浪有效波高反演结果进行了对比分析。

3.1 N_N 模型反演结果与模式数据对比

为评估上述 14 个神经网络模型的性能, 本研究对应用数据进行了有效波高的反演, 对其结果进行了统计分析。本节主要分析输出结果与进行时空配后的 ECMWF 数据之间的对比, 统计参数如表 2 所示。

表 2 不同神经网络模型输出的 H_s 与 ECMWF 数据提供的 H_s 对比统计参数一览表

Tab.2 Comparison statistical parameters between H_s output from different N_N models and H_s provided by ECMWF

模型	模型输入参数	Bias(m)	RMSE(m)	CORR	SI(%)
N_N 1	lon, lat, σ_0 , NV	-0.017	0.654	0.832	24.38
N_N 2	lon, lat, σ_0 , NV, λ_c	-0.009	0.534	0.892	19.93
N_N 3	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2	-0.013	0.643	0.838	23.98
N_N 4	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , β	-0.010	0.557	0.882	20.77
N_N 5	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , λ_c	-0.012	0.532	0.892	19.86
N_N 6	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , λ_c , β	-0.010	0.533	0.892	19.89
N_N 7	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , β , skew	-0.011	0.535	0.891	19.97
N_N 8	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , β , kurt	-0.011	0.539	0.889	20.11
N_N 9	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , β , skew, kurt	-0.010	0.535	0.891	19.94
N_N 10	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , λ_c , skew	-0.010	0.502	0.905	18.74
N_N 11	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , λ_c , kurt	-0.012	0.510	0.902	19.02
N_N 12	lon, lat, σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , λ_c , skew, kurt	-0.011	0.503	0.905	18.76
N_N 13	lon, lat, σ_0 , NV, λ_c , σ_0^2 , NV^2 , λ_c^2 , $\sigma_0 \times NV$, $\sigma_0 \times \lambda_c$, $NV \times \lambda_c$	-0.009	0.531	0.893	19.80
N_N 14	σ_0 , NV, σ_0^2 , $\sigma_0 \times NV$, NV^2 , λ_c , skew	-0.014	0.512	0.901	19.10

注: Bias: 均值偏差; RMSE: 均方根误差; CORR: 相关系数; SI: 散射指数

根据表 2 不同模型间的 Bias、RMSE、CORR、SI 四个统计参数对比可知:

1) N_N 2 与 N_N 1 相比, 方位向截断波长的加入使神经网络模型的性能显著提高, 散射指数明显下降为 19.93%, Bias 与 RMSE 分别由 -0.017m、0.654m

降为 -0.009m、0.534m, 相关系数由 0.832 提升至 0.892, 这与 Stopa 等(2017)中的结果相近, 证明了方位向截断波长与有效波高之间的强相关性。

2) N_N 3 模型在 N_N 1 模型的基础上, 加入 σ_0^2 、 NV^2 、 $\sigma_0 \times NV$ 三个参量, 使得模型的统计参数略有提

升, 均方根误差的由 0.654m 降为 0.643m, 以下模型均在 N_N3 基础上进行改进。

3) N_N4、N_N5 模型分别加入 β 、 λ_c 参数, N_N6 模型则同时加入 β 、 λ_c 参数, N_N5 与 N_N6 的统计参数相差较小, N_N4 与 N_N5 相比, RMSE 由 0.557m 降为 0.532m, 这可能是由于 λ_c 与 β 成比例, 且其包含除 β 信息外的更多信息的关系 (Beal *et al*, 1983)。但 N_N4 与 N_N3 相比, 性能有明显提升, 相关系数由 0.838 升为 0.882, 因此在方位向截断波长信息缺失或者不准确时, 可以选择 β 信息作为有效波高反演模型的输入参数。

4) N_N7、N_N8、N_N9 与 N_N10、N_N11、N_N12 这两组模型分别在 N_N4 和 N_N5 的基础上依次加入 skew、kurt、skew 和 kurt。通过分别对这两组模型进行分析, 可以看出, skew 加入比 kurt 的加入, 对模型性能的改善更有优势, 而二者的同时加入与单独加入 skew 对模型的影响相近, 统计参数的差别均在千分之一数量级。另外, 在模型训练过程中, skew 对模型的稳定性有所提升, 而 kurt 的单独加入会造成模型结果出现与 ECMWF 数据相差 5m 以上的奇异点。

5) N_N13 是参照 Schulz-Stellenfleth 等(2007)的双参数模型, 在 N_N5 基础上加入方位向截断波长的乘积参数 (λ_c^2 、 $\sigma_0 \times \lambda_c$ 、 $NV \times \lambda_c$)。研究表明, N_N13 和 N_N5 统计参数之间的差别均在千分之一的数量级, RMSE 下降了 0.001m, 相关系数提升了 0.001, 对模型的结果影响很小, 但输入参数却增加了 8 个。

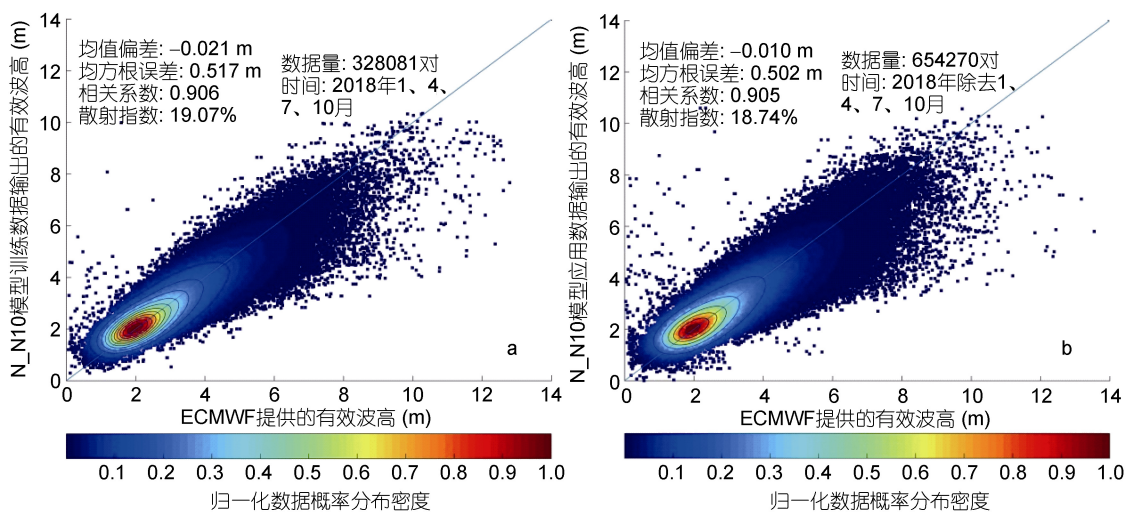
6) N_N14 在 N_N10 基础上去掉了经纬度信息,

旨在分析经纬度信息对有效波高反演的重要性。研究表明, N_N14 模型较 N_N10 模型, RMSE 提升 0.01m, SI 增大 0.36%, N_N10 模型的性能优于 N_N14 模型, 表明经纬度信息对有效波高的反演具有一定的影响, 但影响很小。

综上所述, 14 个神经网络模型中, N_N10 为最佳模型, 其性能最稳定, 相关系数最高达到 0.905, SI 与 RMSE 最低, 分别为 18.74%、0.502m。

为了更加直观的对模型的性能进行分析, 本研究将 N_N 模型的输出结果与 ECMWF 数据的输出结果的对比散点图及二者之间的残差全球分布图展示如下, 由于篇幅限制, 本文仅对 N_N5、N_N10 模型的输出结果与 ECMWF 数据的对比散点图由图 3 表示, 将 N_N10 模型与 ECMWF 数据的对比残差全球分布图由图 4 表示。

通过与 ECMWF 数据相比, 由图 3a 可知, N_N10 模型训练结果较为理想, 相关系数接近 0.91, SI 为 19.07%。图 3cN_N5 模型与 N_N10 的散点图分布相似度极高, 且相关系数也接近 0.9, 但其 Bias、RMSE 均低于 N_N10 模型。图 3b 的应用效果也较好, Bias 接近于零, RMSE 为 0.502m, SI 低于 20%。其数据点集中在 1—4m 之间, 且基本围绕在 $x=y$ 左右, 与 Stopa 等(2017)中的结果类似。当 Hs 大于 4m 时, 随着训练数据点的减少, 训练效果也逐渐变差, 尤其当 Hs 大于 10m 时, 数据点基本在 $x=y$ 以下, 这是由于在极端海况下, 数据点较少, 神经网络模型不能达到较好的学习效果造成的。



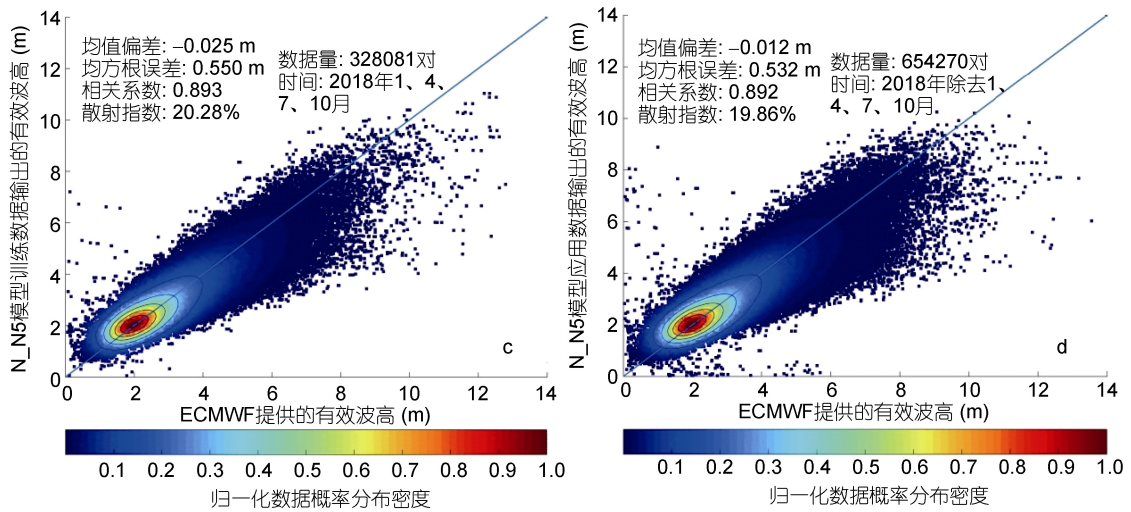


图3 S1A 数据通过神经网络模型得到的 Hs 与 ECMWF 再分析数据提供的 Hs 的对比散点图

Fig.3 Scatter plots of Hs obtained from S1A data through N_N Model and ECMWF reanalysis data

注: a: N_N10 训练数据的输出结果; b: N_N10 应用数据的输出结果; c: N_N5 训练数据的输出结果; d: N_N5 应用数据的输出结果; 蓝色实线表示 $x=y$

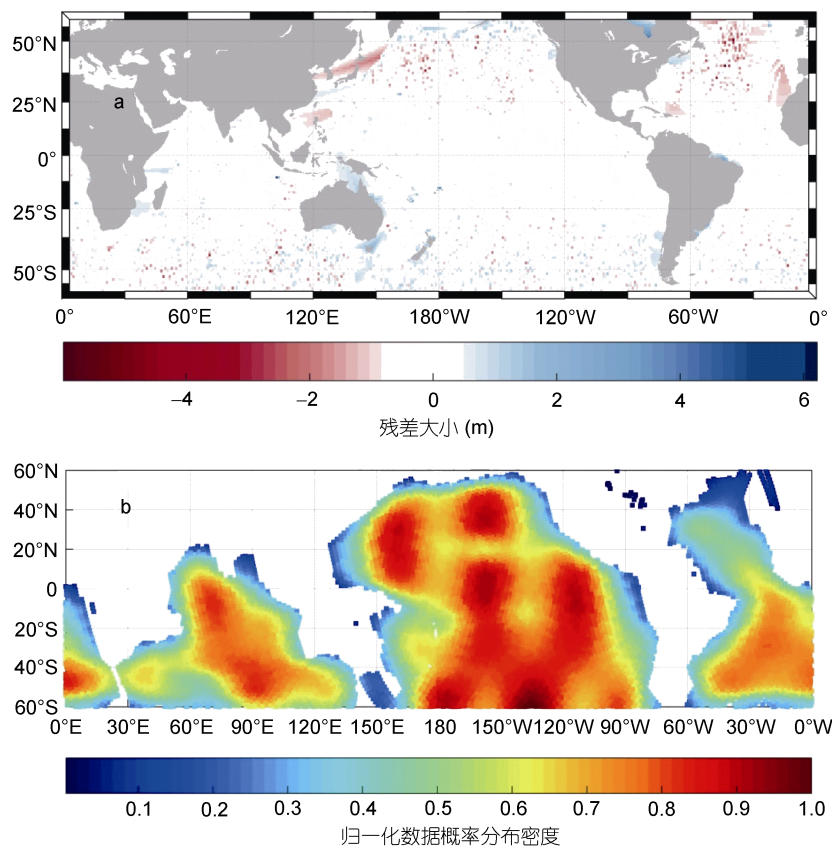


图4 Hs 的残差及 S1A 应用数据密度的全球分布图

Fig.4 Global distribution map of Hs residuals and the density of S1A application data

注: a: S1A 数据通过 N_N10 模型得到的 Hs 与 ECMWF 再分析数据提供的 Hs 的残差全球分布图;

b: 2018 年 S1A 应用数据全球分布密度图

虽然图 3dN_N5 模型的结果较图 3bN_N10 模型稍差, 但二者的统计参数差别在百分之一的数量级, 均值偏差接近, 相关系数仅相差 0.013。也就是说, 即使无法获取代表雷达截面高阶特征的 skew、kurt 时, 神经网络模型反演的 H_s 仍然可接受。

图 4a 展示了 S1A 二级波模式数据通过 N_N10 模型反演得到的 H_s 与 ECMWF 模式数据提供的 H_s 之差的全球分布图。可以看出, 二者之间的残差整体在 $\pm 1\text{m}$, 南半球残差正值居多, 而北半球残差多为负值, 且中高纬度地区残差水平高于低纬度地区, 整体色调为白色, 沿海地区有少量的红色和蓝色。数据分析得到, 二者之间的残差小于二者的 RMSE(0.502m) 的数据占整体数据的 90% 左右, 而残差水平大于 3 倍的 RMSE ($H_{sN_N10} - H_{sECMWF} > 3 * RMSE$) 的数据异常值仅为整体数据的 0.1%, 异常值在全球分布且没有空间相关性, 这与 Stopa 等(2017)的结果类似。表明整体残差控制在理想的范围之内。由图 4b 可知, 在太

平洋海域, S1A 数据最多, 沿海地区相对稀疏, 这是由于在一些沿海地区, SAR 天线经常以其他模式(例如, 干涉宽幅模式)获取数据, 无法获得波模式数据造成的(Li *et al.*, 2011)。通过对比图 4a、b 还可以观察到, 残差值的大小与应用数据点的密度成正相关关系, 数据点密集区域, 残差为正值, 数据点稀疏的区域, 残差为负值, 这是由于训练数据点过少导致的神经网络模型不能达到较好的学习效果, 使得训练结果限制在一定范围内, 相反, 数据点过于密集的区域, 可能存在过拟合现象。由图 4a 可以看出, 残差的高值分布区域, 一般为数据点比较少的区域, 证明了神经网络模型对训练数据的高要求。

3.2 N_N 模型反演结果与浮标数据对比

本节拟将 N_N 模型的反演结果与独立测量的浮标数据结果进行比较, 由于篇幅限制, 本文只将 N_N10 模型的与浮标数据的对比分析结果进行展示, 如图 5 所示。

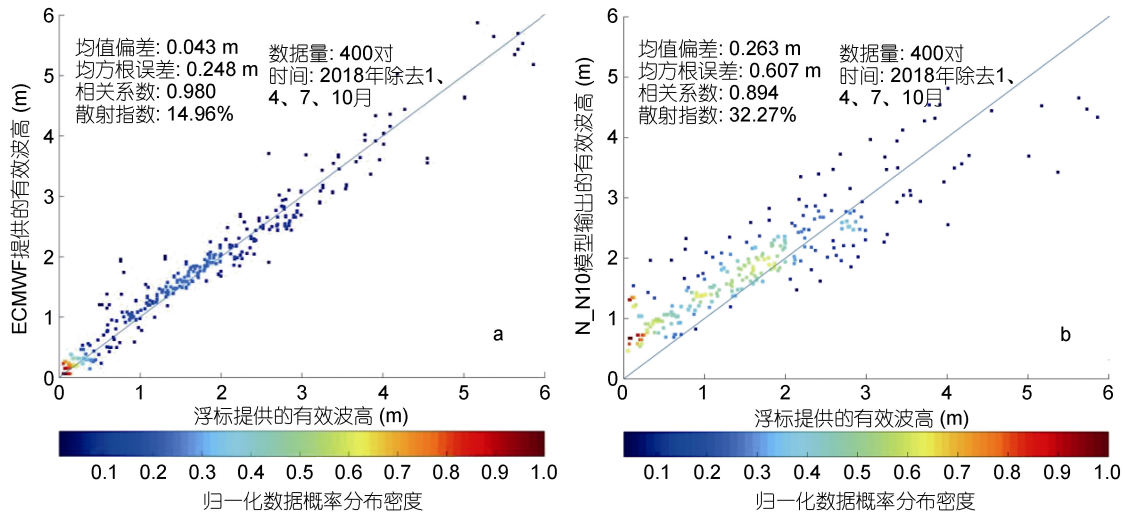


图 5 浮标数据提供的 H_s 与 ECMWF 再分析数据提供的 H_s 及 S1A 数据通过 N_N10 模型得到的 H_s 的对比散点图

Fig.5 Scatter plots of H_s provided by buoy and H_s obtained from ECMWF reanalysis data and S1A data through N_N10 Model

注: a: 浮标数据提供的 H_s 与 ECMWF 再分析数据提供的 H_s 比较结果; b: 浮标数据提供的 H_s 与 S1A 数据通过 N_N10 模型得到的 H_s 的比较结果; 蓝色实线表示 $x=y$

为了更好的分析 N_N10 模型输出结果与浮标数据的差别, 本研究首先对浮标数据与时空匹配后的 ECMWF 模式数据进行对比, 见图 5a。由于 N_N10 模型是以 ECMWF 数据为基准进行训练的神经网络, 因此本文判断其结果应与 ECMWF 数据具有相似的趋势。

由图 5a 可知, 浮标和 ECMWF 的有效波高整体上围绕着 $x=y$ 直线, 相关系数高达 0.980, 散射系数为 14.96%, 这表明了 ECMWF 再分析数据的可靠性及

其用于提供可靠海况信息的能力。当 $H_s < 2\text{m}$ 时, 分布于 $x=y$ 直线上方的数据点居多, 表明二者之间存在一个正偏差($H_{sECMWF} - H_{sbuoy}$), 数据点比较集中; 当 $H_s > 2\text{m}$ 时, 数据点分布在 $x=y$ 直线左右, 数据点相对较为离散。

图 5b 中散点图分布趋势与图 5a 类似, 当 $H_s < 2\text{m}$ 时, 数据点基本分布于 $x=y$ 直线上方, 当 $H_s > 2\text{m}$ 时, 数据点则离散的分布于 $x=y$ 直线两侧。与图 5a 相比, 图 5b 的数据点则更加离散, SI 值更大, 为 32.27%, 图

5a、b 的 Bias 分别为 0.043m 和 0.263m, 均为正值, 这是由 $H_s < 2\text{m}$ 部分的数据所造成的。图 5b 相关系数为 0.894, 虽然没有图 5a 相关性高, 但也达到了较好的结果, 且二者之间相似的分布趋势也进一步证明 N_N10 模型提供了可靠的 H_s 估计。

3.3 不同环境条件下 N_N10 模型的性能分析

本节拟对不同 SAR 观测模式(WV1/2), 不同的 λ_c 以及不同海况下的 N_N10 模型的 H_s 反演情况进行分析, 以有效波高的大小表示海况的变化。不同条件下的统计参数变化如表 3 所示。

表 3 不同环境条件下的 N_N10 模型性能分析统计参数一览表(N_N10 VS ECMWF)

Tab.3 List of statistical parameters for performance analysis of N_N10 Model under different environment conditions (N_N10 VS ECMWF)

参数	阈值	数据点个数(个)	Bias(m)	RMSE(m)	CORR	SI(%)
	全部数据	654270	-0.010	0.502	0.905	18.74
入射角 (θ)	约 23°(WV1)	314717	-0.008	0.487	0.909	18.19
	约 36°(WV2)	339553	-0.011	0.516	0.901	19.22
有效波高(H_s)	$H_s < 1\text{m}$	6393	0.351	0.601	0.077	57.17
	$1 < H_s < 4\text{m}$	564197	0.049	0.393	0.846	16.61
	$H_s > 8\text{m}$	1426	-1.807	2.388	0.137	17.61
方位向 截断波长(λ_c)	$\lambda_c > 500\text{m}$	1419	0.102	1.062	0.944	35.94
	$100 < \lambda_c < 300\text{m}$	575720	-0.011	0.441	0.849	18.27
	$\lambda_c < 100\text{m}$	3112	-0.061	0.407	0.418	32.93

由表 3 对不同入射角、 H_s 、 λ_c 条件下的统计参数比较可知:

1) S1A 卫星在 WV 模式下以 23°(WV1)和 36°(WV2)两个入射角交替工作, WV2 模式的数据点较 WV1 的数据点略多, 但 N_N10 模型在 WV2 模式的反演结果比 WV1 稍差, RMSE 相差 0.029m, WV2 的 SI 为 19.22%, WV1 的 SI 为 18.19%, WV2 的低性能是由于它的倾斜调制较弱, 信噪比较低, 在 σ_0 和 λ_c 中产生较大噪声值的比率造成的(Stopa *et al.*, 2017)。整体上 N_N10 模型在两种 SAR 观测模式下均取得了较好的反演结果。

2) 对于不同的 H_s , N_N10 模型性能具有明显差异。其中, 平稳海况($1 < H_s < 4\text{m}$)下的数据点占总体数据的 86%以上, N_N10 模型的性能最佳, Bias、RMSE 分别为 0.049m、0.393m, 且 SI 低于 17%, 表明了 N_N10 模型对于一般海况下有效波高反演的有效性。对于低海况($H_s < 1\text{m}$)以及高海况($H_s > 8\text{m}$), N_N10 模型性能大幅降低, 相关系数均在 0.15 以下。分析可知, 针对低海况的情况, 一方面由于用于进行模型训练的低海况数据点较少, 神经网络的学习要求未达标, 另一方面, 当 $H_s < 1\text{m}$ 时, 存在一些 N_N10 模型输出结果与 ECMWF 相差很大的数据点(由图 3 可知)。而高海况下, 数据点更少, N_N10 与 N_N5 模型均处于低估的状态。

3) 方位向截断波长表示为 SAR 图像谱在方位方向上受约束的程度, 当方位向截断波长较大时(如,

$\lambda_c > 500\text{m}$), SAR 图像谱将变得不清楚, 多数波谱成分将不可靠(Kerboal *et al.*, 1998), 但 N_N10 模型在高 λ_c 条件下, 却取得了较好的结果, 相关系数高达 0.944, Bias 仅为 0.102m, 而 SI 为 35.94%表明数据较为离散。对于 λ_c 小于 100m 的情况, 其 Bias 接近于 0, 但相关系数很低, 为 0.418, 分析可知, 由于 λ_c 较小的情况下, 海面大多处于较为平稳的状态, 训练数据较少, 训练效果不佳导致相关系数降低。

图 6 进一步对 S1A 的 λ_c 、N_N10 模型输出的 H_s 、以及 N_N10 模型与 ECMWF 对比的残差全球分布进行展示, 从全球分布的角度, 分析三者之间的关系, 本研究选择春秋两个季节的数据进行分析, 以 1°的经纬度窗口进行季度平均计算。

从图 6a、b、d、e 可知, λ_c 与 H_s 均具有纬向分布的特征, 且二者具有明显正相关关系。春、秋两个季节, 南半球平均海浪有效波高均高于北半球, 尤其在 30°—50°S, 平均 H_s 达到 5m 以上, 与 λ_c 分布一致, 秋季则更为明显。秋季时期北大西洋与南印度洋均出现了 H_s 高值区, H_s 在 5m 左右, 此处 λ_c 也处于高值区, 而春季时期, 南印度洋、南太平洋与南大西洋 H_s 较秋季时期减小, 但也为高值区与相应的 λ_c 的全球分布情况一致, 这也表明 λ_c 可用于表示 H_s 的季节变化。从两个季节的平均残差分布图可知, N_N10 模型整体性能良好, 其残差水平在沿岸地区高于大洋内部, 且随着 λ_c 与 H_s 的提高, 残差有增大的趋势, 且中高纬度地区的残差水平高于低纬度地区。

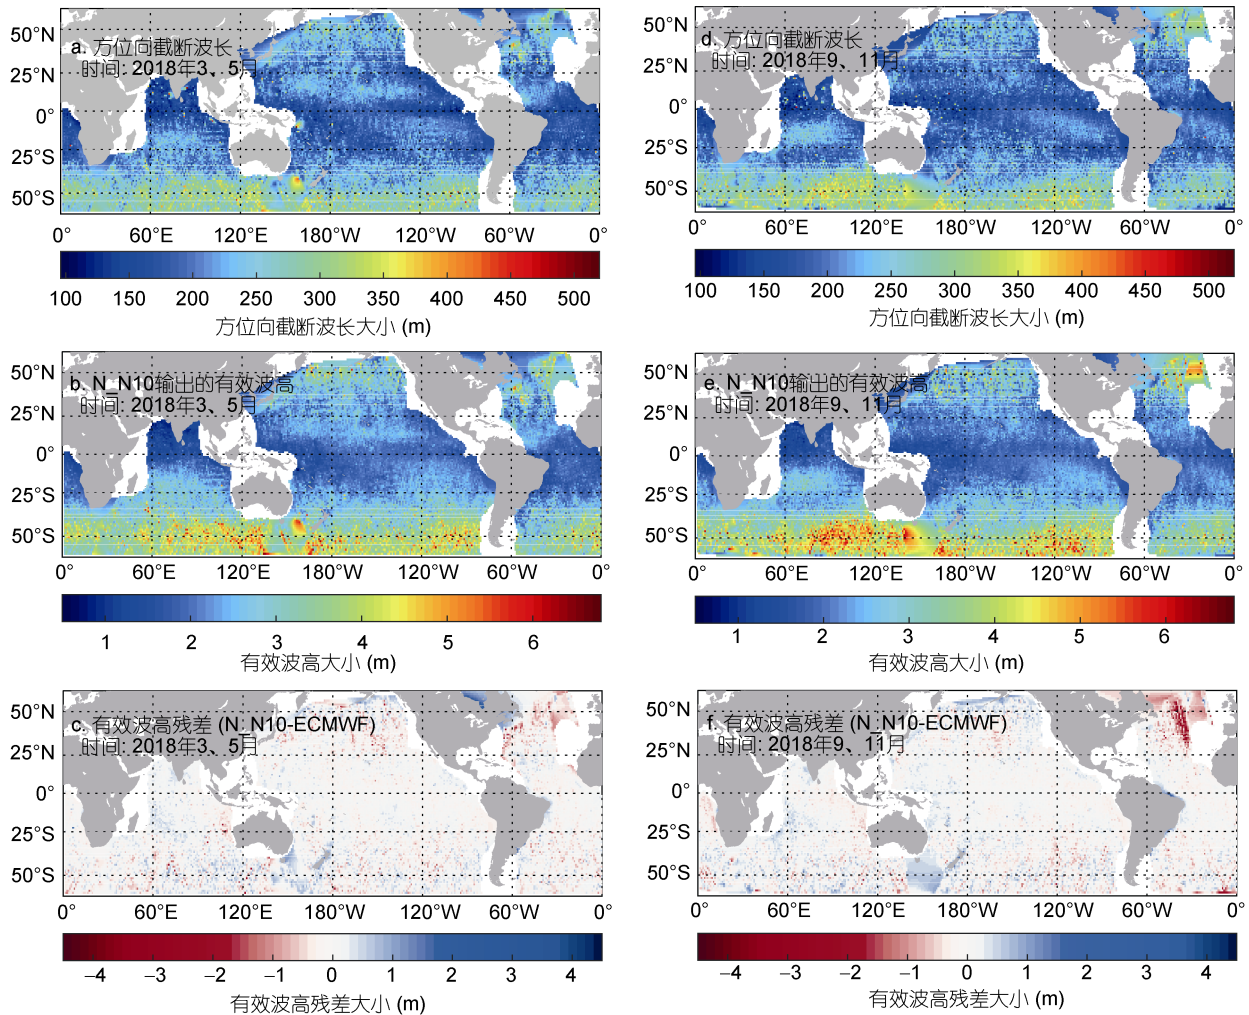


图 6 S1A 数据的 λ_c 、N_N10 模型输出的 Hs 及 Hs 残差的全球分布图

Fig.6 Global distribution of λ_c , Hs obtained from S1A data through N_N10 Model and Hs residuals

注: a、d 表示 S1A 数据的 λ_c 全球分布图; b、e 表示 S1A 数据通过 N_N10 模型得到的 Hs 分布图; c、f 表示 N_N10 模型输出的 Hs 以及 ECMWF 再分析数据提供的 Hs 对比的残差 ($H_{sN_N10} - H_{sECMWF}$) 分布情况; 以上数据均为季度平均的结果, 其中图 a、b、c 为春季, 时间为 2018 年三月、五月, 图 d、e、f 为秋季, 时间为 2018 年九月、十一月

4 结论

本文在 Schulz-Stellenfleh 等(2007)提出的双参数模型的基础上, 利用神经网络技术对 2018 年的 S1A 二级波模式数据进行了海浪有效波高的反演, 对具有不同输入参数的神经网络模型的性能进行了分析。为了更准确的进行全球范围的 Hs 反演, 本文在 N_N 模型中加入经纬度的信息。对模型反演结果, 除利用 ECMWF 再分析数据进行对比外, 还利用独立测量的浮标数据进行了验证, 初步得到以下结论:

1) 总体上, 14 个 N_N 模型的反演结果与 ECMWF 数据相比, 均达到了可接受的训练结果, 相关系数均在 0.8 以上, 且大部分模型 RMS 控制在

0.6m 以内, 其中 N_N10 的性能最佳, 相关系数达到 0.9 以上, 散射指数在 19% 以内。

2) 通过表 2 对 14 个模型性能的分析, 随着 λ_c 的加入, N_N 模型的性能大幅提升, 相关系数达到 0.88 以上。其次, β 参数的加入也会小幅度提高模型反演的准确度, 因此, 在 λ_c 缺失或者不准确时, 可选择 β 信息作为 Hs 反演模型的输入参数。

3) 浮标测量数据用于验证 N_N 模型算法, N_N10 与浮标对比的 RMS 为 0.607m, Bias 为 0.263m, 且相关系数达到了 0.894, 表明将 N_N10 模型用于 Hs 的反演, 整体上达到了较好的结果。同时, 通过散点图可知, 当 $H_s < 2m$ 时, N_N10 模型、ECMWF 均与浮标观测结果之间存在较小的正偏差; 当 $H_s > 2.5m$ 时,

数据点的偏差趋于 0, 但数据点相对较为离散, N_{N10} 与浮标的散点图分布情况与 ECMWF 和浮标的对比散点图具有相似趋势, 也进一步表明 N_{N10} 模型提供了可靠的 H_s 估计。由于本研究用于评估的浮标数据仅有 400 对, 数量较少, 因此, 为了更好的确认 N_N 性能, 需要进行更密集的现场浮标测量。

4) 通过对不同入射角下 N_{N10} 模型的性能分析, 在入射角为 36°(WV2)模式的反演结果比 23°(WV1) 较差, RMSE 相差 0.029m, WV1 的 SI 控制在 19% 以内。但总体上 N_{N10} 模型在两种 SAR 观测模式下均取得了不错的反演结果。

5) 对于不同海况条件, N_{N10} 模型性能具有明显差异。其中, 平稳海况(1<H_s 4m)下的数据居多, N_{N10} 模型的性能最佳, Bias、RMSE 分别为 0.049m、0.393m, 且 SI 低于 17%, 这表明了 N_{N10} 模型对于一般海况下有效波高反演的有效性。而对于低海况(H_s<1m)以及高海况(H_s>8m)的模型性能大幅降低, 相关系数均在 0.15 以下, 这是由于用于模型训练的低海况及高海况的数据点较少, 神经网络的学习要求未达标所造成, 但如果通过加入更大的反映所有海况下的数据集, 该模型性能将会有所改进。

6) 历史研究表明, 较大的 λ_c , 会引起 SAR 图像谱, 在方位方向上变得十分模糊, 很难用于海浪参数的提取(Kerbaol *et al*, 1998)。但本研究通过 N_{N10} 模型进行 H_s 反演, 在高 λ_c 条件下, 却取得了较好的结果, 相关系数高达 0.944。同时, 通过对 S1A 数据的 λ_c 以及 N_{N10} 模型反演的 H_s 进行春、秋两个季节的全球分布分析可知, λ_c 与 H_s 的全球分布具有大致相同的纬向分布的特征, 表明 λ_c 还可用来表示 H_s 的季节变化。

7) 通过对 N_{N10} 与 ECMWF 的 H_s 残差全球分布图可知, N_{N10} 模型在全球大部分海域达到了较好的反演效果, 但在沿岸地区的有效波高反演结果仍不理想, 远不及远海地区, 该问题与数据点的分布密度有关。因此, 通过加入包含更多沿岸数据的训练数据用于神经网络的训练, 可以完善 N_N 模型在全球范围内 H_s 反演的性能。

综上所述, 本研究建立的用于 H_s 反演的神经网络模型, 取得了较好的反演效果, 在全球范围内提供了可靠的海浪有效波高估计。尽管本研究仅限于 S1A 卫星, 但该方法还可应用于当前任何具有二级波模式数据的其他合成孔径雷达数据, 如 ENVISAT、Sentinel 1B 等。此外, 若在模型训练过程中考虑海浪

的传播方向以及主波波长等信息, 模型性能将会有所改进(Stopa *et al*, 2017)。

致谢 本文使用的 Sentinel 1A 二级波模式数据由欧洲太空局(ESA)网站提供, ECMWF 再分析数据集 ERA5 由 ECMWF 网站提供, 浮标数据由美国国家数据浮标中心(NDBC)网站下载, 在此表示感谢。

参 考 文 献

- 王小川, 史峰, 郁磊等, 2013. MATLAB 神经网络 43 个案例分析. 北京: 北京航空航天大学出版社, 1—32
- Beal R C, Tilley D G, Monaldo F M, 1983. Large-and small-scale spatial evolution of digitally processed ocean wave spectra from SEASAT synthetic aperture radar. *Journal of Geophysical Research: Oceans*, 88(C3): 1761—1778
- Engen G, Johnsen H, 1995. SAR-ocean wave inversion using image cross spectra. *IEEE Transactions on Geoscience and Remote Sensing*, 33(4): 1047—1056
- Grieco G, Lin W, Migliaccio M *et al*, 2016. Dependency of the Sentinel-1 azimuth wavelength cut-off on significant wave height and wind speed. *International Journal of Remote Sensing*, 37(21): 5086—5104
- Hasselmann K, Hasselmann S, 1991. On the nonlinear mapping of an ocean wave spectrum into a synthetic aperture radar image spectrum and its inversion. *Journal of Geophysical Research: Oceans*, 96(C6): 10713—10729
- Hasselmann K, Raney R K, Plant W J *et al*, 1985. Theory of synthetic aperture radar ocean imaging: A MARSEN view. *Journal of Geophysical Research: Oceans*, 90(3): 4659—4686
- Hasselmann S, Brüning C, Hasselmann K *et al*, 1996. An improved algorithm for the retrieval of ocean wave spectra from synthetic aperture radar image spectra. *Journal of Geophysical Research: Oceans*, 101(C7): 16615—16629
- Horstmann J, Schiller H, Schulz-Stellenfleth J *et al*, 2003. Global wind speed retrieval from sar. *IEEE Transactions on Geoscience and Remote Sensing*, 41(10): 2277—2286
- Jackson C R, Apel J R, 2004. Synthetic aperture radar marine user's manual. U.S. Department of Commerce National Oceanic and Atmospheric Administration. <http://sarusersmanual.com>
- Jackson F C, Walton W T, Baker P L, 1985. Aircraft and satellite measurement of ocean wave directional spectra using scanning-beam microwave radars. *Journal of Geophysical Research: Oceans*, 90(C1): 987—1004, doi: 10.1029/JC090iC01p00987
- Kerbaol V, Chapron B, Vachon P W, 1998. Analysis of ERS-1/2 synthetic aperture radar wave mode images. *Journal of Geophysical Research: Oceans*, 103(C4): 7833—7846
- Li X M, Lehner S, Bruns T, 2011. Ocean wave integral parameter measurements using Envisat ASAR wave mode data. *IEEE Transactions on Geoscience and Remote Sensing*, 49(1): 155—174
- Lyzenga D R, 1986. Numerical simulation of synthetic aperture

- radar image spectra for ocean waves. *IEEE Transactions on Geoscience and Remote Sensing*, GE-24(6): 863—872
- Marghany M, Ibrahim Z, Van Genderen J, 2002. Azimuth cut-off model for significant wave height investigation along coastal water of Kuala Terengganu, Malaysia. *International Journal of Applied Earth Observation and Geoinformation*, 4(2): 147—160
- Ren L, Yang J S, Zheng G *et al*, 2015. Significant wave height estimation using azimuth cutoff of C-band RADARSAT-2 single-polarization SAR images. *Acta Oceanologica Sinica*, 34(12): 93—101
- Schulz-Stellenfleth J, König T, Lehner S, 2007. An empirical approach for the retrieval of integral ocean wave parameters from synthetic aperture radar data. *Journal of Geophysical Research: Oceans*, 112(C3): C03019
- Schulz-Stellenfleth J, Lehner S, Hoja D, 2005. A parametric scheme for the retrieval of two dimensional ocean wave spectra from synthetic aperture radar look cross spectra. *Journal of Geophysical Research: Oceans*, 110(C5): C05004, doi: 10.1029/2004JC002822
- Shao W Z, Zhang Z, Li X F *et al*, 2016. Ocean wave parameters retrieval from Sentinel-1 SAR imagery. *Remote Sensing*, 8(9): 707, doi: 10.3390/rs8090707
- Stopa J E, Ardhuin F, Chapron B *et al*, 2015. Estimating wave orbital velocity through the azimuth cutoff from space-borne satellites. *Journal of Geophysical Research: Oceans*, 120(11): 7616—7634
- Stopa J E, Mouche A, 2017. Significant wave heights from Sentinel-1 SAR: validation and applications. *Journal of Geophysical Research: Oceans*, 122(3): 1827—1848
- Wang H, Zhu J H, Yang J S *et al*, 2012. A semiempirical algorithm for SAR wave height retrieval and its validation using Envisat ASAR wave mode data. *Acta Oceanologica Sinica*, 31(3): 59—66

INVERSION OF GLOBAL SIGNIFICANT WAVE HEIGHT BASED ON SENTINEL-1A

MU Shan-Shan¹, LI Hai-Yan¹, WU Ming-Bo^{1,2}

(1. *University of Chinese Academy of Sciences, Beijing 100049, China*; 2. *Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Science, Beijing 100101, China*)

Abstract By using the technique of neural network, a new neural network model a new neural network model (N_N model) was proposed for the inversion of wave effective wave height (H_s) from Sentinel-1A level-2 wave model data. Based on the two-parameter model developed by ERS2 SAR wave mode data, the model was added with other parameters including longitude, latitude, the azimuth cutoff (λ_c), skewness, kurtosis, and the ratio (β) of the distance between satellite platform and the target to the satellite flight speed. The influence of each parameter on the inversion of significant wave height was analyzed using different combinations of input parameters, based on 14 models which were established for H_s inversion. Results show that the correlation coefficients of all the 14 models were above 0.8. With the addition of λ_c and β parameters, the performance of the N_N model increased significantly, and the improvement effect of λ_c on the model performance was more obvious. The correlation coefficient increased by about 0.06, and RMSE decreased by about 0.12m. In addition, the addition of skewness and kurtosis also improved the performance of the N_N model as the RMSE decreased by about 0.03m, and the correlation coefficient increased by about 0.01. Among them, the N_N10 model had the best effect and the most stable performance. Compared with the ECMWF (European Centre for medium range weather forecasts), the correlation coefficient (CORR) was 0.905, and the scattering index (SI) and RMSE were the lowest, being 18.74% and 0.502m, respectively. The correlation coefficient with the independently measured buoy data reached 0.894.

Key words neural network; significant wave height; azimuth cutoff; normalized radar cross-section