

李倩倩, 李宏琳, 曹守莲, 等. 基于遥感数据和表层声速的全海深声速剖面反演[J]. 海洋学报, 2022, 44(12): 84–94, doi:10.12284/hyxb2022149

Li Qianqian, Li Honglin, Cao Shoulian, et al. Inversion of the full-depth sound speed profile based on remote sensing data and surface sound speed[J]. Haiyang Xuebao, 2022, 44(12): 84–94, doi:10.12284/hyxb2022149

基于遥感数据和表层声速的全海深声速剖面反演

李倩倩^{1,2}, 李宏琳¹, 曹守莲¹, 严娴¹, 马志川¹

(1. 山东科技大学 测绘与空间信息学院, 山东 青岛 266590; 2. 哈尔滨工程大学 水声工程学院, 黑龙江 哈尔滨 150001)

摘要: 海洋声速剖面严重影响着水下声传播特性, 近实时地获取声速剖面对水下声通信、水下定位、鱼群探测等都有重要意义。单经验正交函数回归 (single Empirical Orthogonal Function regression, sEOF-r) 方法通过建立声速剖面的经验正交系数与海面遥感数据之间的线性回归关系来反演声速剖面。但是, 海洋是一个复杂的动力系统, 声速与海面遥感数据并不是简单的线性关系, 因此, 本文基于 Argo 历史网格数据, 通过自组织映射 (Self-Organizing Map, SOM) 生成海平面高度异常 (Sea Level Anomaly, SLA)、海表面温度 (Sea Surface Temperature, SST) 等海表遥感数据以及表层声速仪测量的表层声速与声速剖面异常之间的非线性映射; 然后利用近实时的海表遥感数据和表层声速反演三维海洋声速场。声速剖面反演的结果表明, 在多源信息融合的优势下, 本文方法的反演性能最稳定且精度最高, 声速剖面的平均反演精度比经典 sEOF-r 方法提高约 2 m/s, 比未考虑表层声速的经典 SOM 方法提高约 1 m/s。

关键词: Argo 数据集; 海表面温度; 海平面高度异常; EOF 分解; 表层声速仪; sEOF-r 方法; SOM 方法

中图分类号: P733.2

文献标志码: A

文章编号: 0253-4193(2022)12-0084-11

1 引言

海水声速是海洋环境观测的基本要素之一, 对于水下声波定位与目标探测、海洋环境监测和资源勘探等一系列活动至关重要^[1-2]。获取声速剖面最直接的方法是现场观测, 但此类方法费时费力, 且由于声速的时空变化特性, 这些现场观测资料都不能获得大范围实时声速剖面。随着时间推移, 海洋垂向观测资料(船只走航、站点观测、潜标、水下滑翔机和浮标等)日益增多, 特别是中国 Argo 实时资料中心^[3]提供的大量观测剖面以及网格产品, 在海洋科学研究和应用中发挥了重要作用。然而, 现有垂向观测资料的空间分辨率仍然较低, 且不能实时地描述海洋内部的结构变化特征。而另一方面, 随着遥感卫星传感器的不

断发展, 海面温度和海面高度等资料逐渐完善, 它们能实时地提供海面信息且具有较高的空间分辨率。但通过遥感卫星资料得到的信息仅仅停留在海洋表层或者近表层, 无法获得海表面以下的信息。因此, 利用遥感卫星观测数据和 Argo 剖面数据相结合的方式反演海洋声速剖面成为重要的研究课题。

理论上, 声速剖面可以表示为深度和时间的矩阵形式, 然而, 该表示形式需要大量参数, 不利于声速剖面的反演估计, 为此 Tolstoy 等^[4]提出了经验正交函数(EOF)的表示方法。从而声速剖面可以利用有限几阶 EOF 系数进行表示, 声速剖面的反演问题最终变为 EOF 系数的反演^[5-6]。自 20 世纪 80 年代以来, 世界各国海洋学家提出将海面信息映射到海洋内部, 从而反演温度、盐度剖面。早期, Hurlburt 等^[7]通过考虑

收稿日期: 2022-02-17; 修订日期: 2022-05-23。

基金项目: 中国博士后科学基金(2020M670891); 山东科技大学科研创新团队支持计划(2019TDJH103); 山东省高等学校青年创新团队人才引进计划; 山东省自然科学基金(ZR2020MA090, ZR2022MA051)。

作者简介: 李倩倩(1984—), 女, 山东省青岛市人, 副教授, 主要从事研究海洋环境声学反演和水下声源定位等水声逆问题。E-mail: liqianqian@sdust.edu.cn

水动力和能量交换特征, 构建数值海洋预测模型, 将模拟的高度计数据动态传递到海洋内部得到模拟数据对温跃层的敏感性。Carnes 等^[8-9]在墨西哥湾流区域发现了关于海面高度、海面温度与海洋标准层之间的统计关系, 随后, 他们对西北太平洋和西北大西洋的温度剖面进行 EOF 分解, 建立海面数据与温度剖面的回归关系, 即单经验正交函数回归 (single Empirical Orthogonal Function regression, sEOF-r) 方法。该方法已被美国海军海洋预报系统^[10]采用。Chen 等^[11]利用海面数据结合 sEOF-r 方法重构了全球范围的声速剖面, 并证明声速误差与动态漩涡活动相关。

近年来, 人工神经网络 (Artificial Neural Networks, ANN) 在海洋环境参数反演估计中的应用越来越多。Liu 等^[12-13]首次提出将自组织映射 (Self-Organizing Map, SOM) 神经网络应用在气象与海洋方面, 发现自组织映射神经网络可以从联合高频雷达和声学多普勒流速剖面仪 (ADCP) 数据集中提取非均匀的、各向异性的三维沿海海洋流场变化。Charantonis 等^[14], Chapman 和 Charantonis^[15]使用自组织映射方法逐步重建高度相关的海洋滑翔机稀疏数据集中的缺失数据 (温度、盐度剖面)。随后进一步提出基于数据空间局部相关性改进的 SOM 神经网络新方法, 根据卫星提供的海洋表面信息以及 Argo 浮标测量的深海海流速度提高深海洋流的重构速度精度。Chen 等^[16-17]利用 SOM 神经网络建立了温度剖面对应的经验正交系数与西北太平洋海表面等多维信息的自组织特征映射图, 从而获取待反演的系数并有效地重构了 1 000 m 以内的温度剖面。Jain 和 Ali^[18]采用人工神经网络的方法根据海表面参数以及温、盐剖面直接反演 250 m 深度的声速剖面。与传统线性反演方法相比, 神经网络等非线性方法可以捕捉海表面数据与声速剖面异常之间的非线性关系, 从而提高反演精度。

为此本文在前人研究的基础上, 利用人工神经网络的方法根据遥感卫星观测数据和 Argo 历史数据建立局域时空海洋声速场。即利用中国 Argo 实时资料中心提供的历史声速剖面生成 EOF 基函数与系数, 联合实时测量的海面遥感数据和表层声速仪测量的固定深度处数据, 利用 SOM 神经网络实现对全海深声速剖面的实时反演。

2 数据与方法

2.1 数据来源

本文所使用的温度、盐度剖面数据来自中国 Argo

实时资料中心提供的全球海洋 Argo 网格数据集^[3]。其时间覆盖范围为 2004 年 1 月至 2020 年 12 月, 空间分辨率为水平 $1^\circ \times 1^\circ$, 垂向标准层共有 58 层 (0~1 975 m) 的逐年逐月网格化资料。

卫星遥感数据主要包括海表面温度 (Sea Surface Temperature, SST) 数据和海平面高度异常 (Sea Level Anomaly, SLA) 数据产品。SST 产品来源于美国国家海洋和大气管理局 (Nation Oceanic and Atmospheric Administration, NOAA) 的每日最优插值 SST (Optimum Interpolation Sea Surface Temperature, OISST)^[19]。该数据集将来自不同观测平台 (卫星、船舶和浮标) 的数据构建在一个常规全球网格上, 其空间分辨率为 $0.25^\circ \times 0.25^\circ$ 。SLA 数据为海面高度减去长时间序列的平均海面高度, 其来自于卫星海洋数据存储、验证、插值处理中心 (Archivings Validation and Interpretation of Satellite Oceanographic, AVISO) 提供的 $0.25^\circ \times 0.25^\circ$ 的月平均网格数据, 该数据融合了 TOPEX/POSEIDON、JASON-1/2 和 ERS 等多颗卫星的测高资料^[20]。

2.2 数据时空匹配

本文选取东南印度洋 ($14.5^\circ \sim 17.5^\circ \text{S}$, $85.5^\circ \sim 90.5^\circ \text{E}$) 范围为研究区域, 海表面遥感数据对应截取 $14.375^\circ \sim 17.625^\circ \text{S}$, $85.375^\circ \sim 90.625^\circ \text{E}$ 之间的数据。如图 1 所示, 蓝色圆点表示海表面遥感数据所在位置, 红色圆点表示 Argo 数据所在位置。图 1 表明, 遥感数据与 Argo 数据在经度、纬度方向都相差 0.125° , 即 Argo 数据格点和海表面数据格点之间存在空间不匹配的问题。本文通过对 Argo 数据点周围的 4 个海表面数据取算数平均, 将遥感数据降采样为 $1^\circ \times 1^\circ$ 。从而保证 SST 和 SLA 数据与 Argo 数据在水平方向上的采样位置一致。同时, 海表面数据中的 SST 是日平均数




图 1 Argo 网格数据与海表面温度、海平面高度异常数据位置匹配示意图

Fig. 1 Schematic diagram of location matching between Argo grid data and sea surface temperature and sea level anomaly data

据,与 SLA 和 Argo 的月平均数据在时间上不匹配,因此本文将 SST 数据按月进行算数平均,从而实现 3 组数据在时间采样上的一致性。

2.3 构建声速剖面 EOF 函数

利用 EOF 方法表示声速剖面可以大大降低声速剖面反演所需要的参数个数,基函数确定后,利用有限的几阶系数即可表示声速剖面。假如某测区内有 N 条实测声速剖面,将其插值到 M 个深度标准层,从而声速剖面可以表示为矩阵 $C_{M \times N}$

$$C_{M \times N} = \begin{bmatrix} c_1(1) & c_1(2) & \cdots & c_1(N) \\ c_2(1) & c_2(2) & \cdots & c_2(N) \\ \vdots & \vdots & \vdots & \vdots \\ c_M(1) & c_M(2) & \cdots & c_M(N) \end{bmatrix}, \quad (1)$$

式中,每一列代表一个声速剖面,每一行代表 N 条剖面在同一深度处的声速。

对式(1)中每行取平均,获得平均声速 $\bar{C}_{M \times 1}$,声速剖面矩阵与平均声速矩阵之间的差值称为声速扰动 $\Delta C_{M \times N}$,求声速扰动的协方差矩阵 $COV_{M \times M}$

$$COV_{M \times M} = \frac{1}{N} \Delta C_{M \times N} \times \Delta C_{M \times N}^T, \quad (2)$$

并对其进行特征分解得:

$$COV_{M \times M} \times V_{M \times M} = \lambda_{M \times M} \times V_{M \times M}, \quad (3)$$

式中, $\lambda_{M \times M}$ 为特征值矩阵; $V_{M \times M}$ 是特征向量矩阵,即为 EOF 基函数。

将 EOF 投影到声速扰动 $\Delta C_{M \times N}$, 可得到:

$$PC_{M \times N} = V_{M \times M}^T \times \Delta C_{M \times N}, \quad (4)$$

式中, $PC_{M \times N}$ 中的每一列为对应声速扰动剖面的 EOF 系数。

每一个特征向量对应的特征值表示此特征向量的权重,计算前 k 阶的贡献率为

$$Q = \sum_{i=1}^k \lambda_i / \sum_{m=1}^M \lambda_m. \quad (5)$$

当 $Q \geq 0.95$ 时,认为前 k 阶经验正交函数可以表示当前海域内声速剖面的主要特征。因此,前 k 阶经验正交函数即可重构样本中的任一声速剖面,其中 N 个重构声速剖面表示为

$$\begin{bmatrix} c_1(1) & c_1(2) & \cdots & c_1(N) \\ c_2(1) & c_2(2) & \cdots & c_2(N) \\ \vdots & \vdots & \vdots & \vdots \\ c_M(1) & c_M(2) & \cdots & c_M(N) \end{bmatrix} = \begin{bmatrix} \bar{C}_1 \\ \bar{C}_2 \\ \vdots \\ \bar{C}_M \end{bmatrix} + \begin{bmatrix} V_{11} & V_{12} & \cdots & V_{1k} \\ V_{21} & V_{22} & \cdots & V_{2k} \\ \vdots & \vdots & \vdots & \vdots \\ V_{M1} & V_{M2} & \cdots & V_{Mk} \end{bmatrix} \begin{bmatrix} PC_{1N} \\ PC_{2N} \\ \vdots \\ PC_{kN} \end{bmatrix}. \quad (6)$$

2.4 SOM 神经网络

SOM 是在 1981 年由芬兰学者 Kohonen^[21] 提出的一种无监督竞争式学习前馈型神经网络模型。SOM 算法步骤如下:

(1) 初始化神经网络。对输入层的输入变量与竞争层输出神经元的初始连接权值赋予一个较小的常数,一般在 $[0, 1]$ 之间。设置学习率初始值为 $(0, 1)$ 之间某一数值,初始化邻域函数,确定邻域半径及邻近神经元集合,该集合随着训练进行而减小。

(2) 构建输入向量。输入层输入变量,对于输入层的 $X = \{x_1, x_2, \dots, x_n\}$, X 中各元素分别对应研究海域内声速剖面的 EOF 系数、地理位置以及对应的 SST、SLA 数据。首先对输入变量进行归一化处理,然后输入到网络。

(3) 计算输入向量与神经元之间距离。对于每一个输入变量,计算出输入数据与所有的输出神经元 j 之间的欧式距离 d_j 。计算公式如下:

$$d_j = \sqrt{\sum_{i=1}^n [x_i(t) - w_{ij}(t)]^2}, \quad (7)$$

式中, w_{ij} 为输入层第 i 个神经元和输出层第 j 个神经元之间的权值。

(4) 找出获胜神经元 c 。通过计算得到最小距离 d_j 的神经元 j , 距离最小的神经元 j , 作为获胜神经元 c 或最佳匹配单元 (Best Matching Unit, BMU)。

(5) 确定获胜邻域 $S_n(t)$ 。确定获胜神经元的邻域范围,邻域范围一般由邻域函数确定,本文的邻域函数 H 采用 Gaussian 函数,函数形式如下:

$$H_{ij} = \begin{cases} \exp(-\|d_i - d_j\|^2 / 2\sigma^2) & d_i - d_j \leq \sigma, \\ 0 & d_i - d_j > \sigma. \end{cases} \quad (8)$$

根据式(9)对获胜神经元 c 及邻域内的权值向量进行更新,使其向输入向量不断靠拢,

$$w_{ij}(t+1) = w_{ij}(t) + \eta(t) H_{ij} [x_i(t) - w_{ij}(t)], \quad (9)$$

式中, $w_{ij}(t+1)$ 为第 $t+1$ 次迭代过程中第 j 个节点的权重向量; $H(t)$ 为邻域函数; $\eta(t)$ 为学习速率。

(6) 更新学习率以及邻域函数,学习率随着学习次数的增加而减小。

(7) 重复步骤(3)和(4),直到完成所有输入数据的学习。

本实验中,根据 Liu 等^[12] 提出的一种基于海面以下和现有数据之间相关性的距离度量函数,即式(11),计算已知信息与 SOM 输出层单元之间的欧氏距离,通过寻找 SOM 输出层中最佳匹配单元得到参考向量,将输入数据匹配到最佳单元来实现。

$$d_e^c(X, m_i) = \sum_{j \in \text{avail}} \left\{ 1 + \sum_{k \in \text{missing}} [\text{Cov}(X_i, PC_k)]^2 \right\} \times (X_i - m_i)^2, \quad (10)$$

$$\text{Cov}(X, PC) = E\{[X - E(X)][S - E(PC)]\}, \quad (11)$$

式中, d_e^c 是输入数据与自组织映射单元之间的距离; m_i 是参考向量, 即单元类别的平均值; avail 为已知数据; missing 是未知数据; X_i 是已知数据集; PC_k 是待反演的经验正交系数; $\text{Cov}(X_i, PC_k)$ 是 X_i 与 PC_k 的互相关性。

为了验证反演方法的精度, 利用均方根误差 (Root Mean Squar Error, RMSE) 来表示声速剖面估计值与测量值之间的误差, 定义均方根误差为

$$\text{RMSE} = \sqrt{\frac{1}{M} \sum_{i=1}^M [C_{(z_i)} - C'_{(z_i)}]^2}, \quad (12)$$

式中, M 为深度点数; $C_{(z_i)}$ 和 $C'_{(z_i)}$ 分别为测量和反演剖面在深度 Z_i 处的声速值。

图 2 给出了反演声速剖面的流程, 具体步骤如下:

(1) 将实验海域的声速剖面、海表面温度 (SST) 与海表面高度异常 (SLA) 数据分成训练集和测试集;

(2) 对训练集的声速剖面进行 EOF 分解, 得到该区域的历史平均声速剖面、基函数以及系数 PC (基函数在扰动矩阵上的投影) 来表示训练集声速剖面;

(3) 将步骤 (2) 中的系数与 SST、SLA、纬度 (LAT)、经度 (LON) 以及表层声速之间利用 SOM 神经网络建立映射关系, 通过验证集不断调整参数, 得到最优训练模型;

(4) 反演测试集 EOF 的系数, 将测试集的 SST、SLA、LAT、LON 以及表层声速输入训练模型, 计算与模型结果的最佳匹配单元 (BMU), 得到 EOF 系数;

(5) 将步骤 (4) 反演的 EOF 系数结合步骤 (2) 的历史平均声速剖面 and 基函数得到声速剖面反演值。

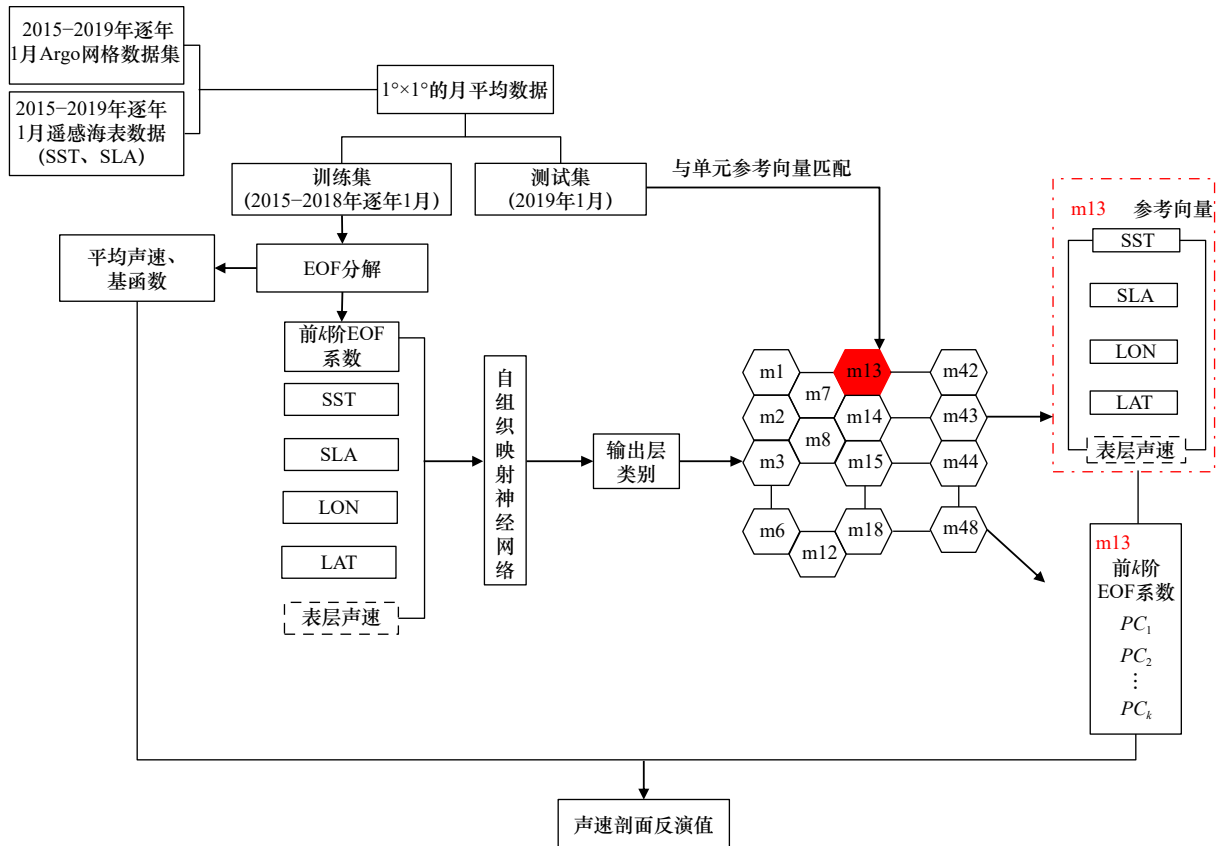


图 2 声速剖面反演流程

Fig. 2 Flow of sound speed profile inversion

黑色虚线框表示增加的先验信息, 红色虚线框表示测试集中已知信息与输出层参考向量匹配

The black dashed box indicates the added prior information, and the red dashed box indicates that the known information in the test set matches the reference vector of the output layer

3 实验数据处理及分析

从 Argo 网格数据集中提取东南印度洋 (14.5°~

17.5°S, 85.5°~90.5°E) 范围内的月平均数据, 利用该数据集的深度、温度和盐度数据, 通过 Dell Grosso 声速经验公式^[22] 计算声速剖面。利用上文提到的时

空匹配方法,将海表遥感数据集和 Argo 网格数据集进行时空对准。将数据分为两部分,其中 2015–2018 年逐年 1 月的声速剖面 and 对应的 SST、SLA 数据为训练集,主要用来生成声速剖面的平均值以及 EOF 基函数,并且训练 sEOF-r 和 SOM 的模型参数。本文 76 条声速剖面用于训练 SOM,为了调整神经网络模型的超参数,20 条声速剖面作为验证集对模型的能力进行初步评估,测试集的 24 条剖面用来评估模型的泛化能力。

3.1 EOF 基函数

该训练集中声速剖面的个数为 $N=76$, 深度上的分层数为 $M=1976$ 。图 3a 的灰色细线为训练集中的声速剖面,黑色粗线为平均声速剖面。声速扰动如图 3b 所示,最大值约为 9 m/s,可以看出扰动主要位于水深 400 m 以浅。图 3c 为前 6 阶 EOF 的累积方差贡献率,可以看出,前 5 阶 EOF 的累积贡献率可达 95.51%,已大于 95%,所以此海域的海水声速剖面可用前 5 阶 EOF 近似表示。




图 3 训练集中的声速剖面(灰色线为实测剖面,黑色线为平均剖面)(a)、声速扰动(b)和前 6 阶经验正交函数(EOF)的累积方差贡献率(c)

Fig. 3 The sound speed profile in the training set (gray lines are the measured profile, black line is the average profile) (a), residual sound speed (b) and the cumulative variance contribution rates of the first 6-order empirical orthogonal function (EOF) (c)

声速剖面反演精度主要取决于 3 个方面:第一,训练集提取出的 EOF 基函数是否具有代表性;第二,历史平均声速剖面是否具有代表性;第三,反演方法估计得到的 EOF 系数是否准确。首先分析 EOF 基函数的代表性,图 4 为训练集和测试集前 5 阶基函数之间的相关系数矩阵。该图表明,同组基函数相互正交,而测试集中的基函数与训练集中的基函数有明显差异,其中第 1、3 阶表现为极强相关,第 2 阶为中等程度相关,而第 4、5 阶表现为极弱相关。

图 5 分别给出了训练集和测试集的前两阶基函数,测试集中前 6 阶 EOF 的累积贡献率以及训练集和测试集平均声速剖面的差值。图 5a 表明,两组集合的第 1 阶基函数非常相似,而第 2 阶基函数的差异显著,尤其是在 250 m 深度处,二者差异明显。图 5b 表明前 2 阶基函数的累积方差贡献率就达到 95.6%,其中第 2 阶的累积方差贡献率为 9%。以上分析表明,由测试集获取的基函数具有一定的代表性误差,

其误差主要由第 2 阶基函数造成,因此基函数的选取对声速剖面的反演很重要。图 5c 是训练集与测试集平均声速剖面的差值,可以发现误差主要分布在上

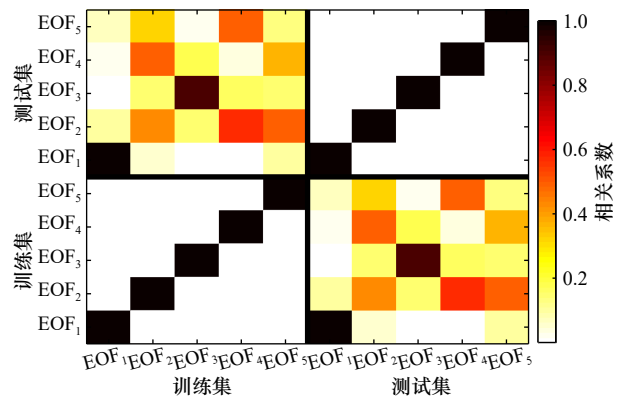


图 4 训练集和测试集的经验正交函数基函数之间的相关系数

Fig. 4 Correlation coefficient between empirical orthogonal function (EOF) basis functions of training set and test set




图5 训练集和测试集的前两阶基函数(a)、测试集前6阶经验正交函数(EOF)的累积方差贡献率(b)和训练集和测试集的平均声速误差(c)

Fig. 5 The first two order basis functions of the training set and the test set (a), the cumulative variance contribution rate of the first six orders of empirical orthogonal function (EOF) in the test set (b) and the average sound speed error of the training set and test set (c)

层, 误差在 2.66 m/s 之内。

为了验证 EOF 基函数和平均声速剖面的代表性误差对重构声速精度的影响, 图 6 利用训练集中提取出的基函数和平均声速剖面, 通过最小二乘法对测试集中的声速剖面进行重构。图 6 给出了利用前 5 阶 EOF 重构测试集的声速剖面与实际测试集声速剖面之间的绝对误差, 误差范围为 0~2.48 m/s。可以看出误差主要分布在 400 m 以浅, 即声速剧烈扰动的深度。图 6 中的白色虚线为利用式(12)计算得到的声速剖面均方根误差, 最大均方根误差约 0.56 m/s。

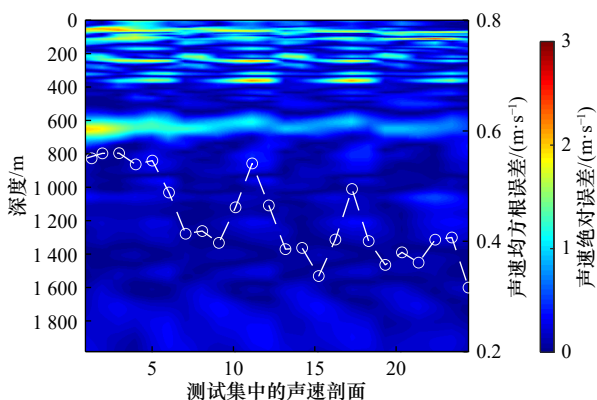


图6 声速剖面重构误差

Fig. 6 The reconstruction error of the sound speed profile

白色虚线为重构声速剖面的均方根误差

The white dashed line is the root mean square error of the reconstructed sound speed profile

经验正交函数(EOF)是目前使用最广泛的声速剖面表示方法, EOF 方法对于一定数量的声速剖面在

提取其主要特征时, 获取的基函数比较准确, 因此在这里暂不考虑 EOF 基函数的代表性误差, 历史平均声速剖面可以替换为现场观测的少数 CTD 平均数据, 这部分在文章后面会有讨论, 研究表明利用现场 CTD 数据可以提高声速剖面的反演精度。若是不考虑 EOF 基函数和历史平均声速剖面的代表性误差, 图 6 的结果可以认为是 EOF 系数准确时, 声速剖面反演精度的最高值, 因此本文将之作为衡量反演方法优劣的标准。Casagrande 等^[23]曾在研究中给出了 EOF 系数的物理解释, 第 1 阶 EOF 系数 α_1 表示了温跃层的垂直位移, 即 α_1 越大则代表温跃层越浅, 跃层深度的变化周期也反映在 α_1 的演化趋势中, 第 2 阶 EOF 系数 α_2 则表示了温度梯度的改变, 在温跃层变化剧烈的时刻, α_2 取值也比较大。从物理意义来看, 第 3 阶及以上的 EOF 对声速剖面的调制效果不显著。

3.2 海表面遥感数据与声速剖面的相关性分析

如图 7a 为平均声速剖面的声速梯度, 可以发现 60~130 m 的跃层部分梯度较大, 130~400 m 的跃层部分梯度较小, 梯度极大值约在 106 m。图 7b 为 SST、SLA 和声速剖面 (Sound Speed Profile, SSP) 在 0~1975 m 深度的相关图, 从图中可以发现, SST 与 SSP 的相关性在上层随着深度增加不断减小, 说明 SST 可以约束剖面的表层精度; SLA 在 60~130 m 深度内, 具有中度相关性, SLA 与 SSP 的相关性最大值约在 103 m, 与平均声速剖面声速梯度的极大值深度 106 m 相近。在 130~400 m 跃层深度内, 声速梯度在

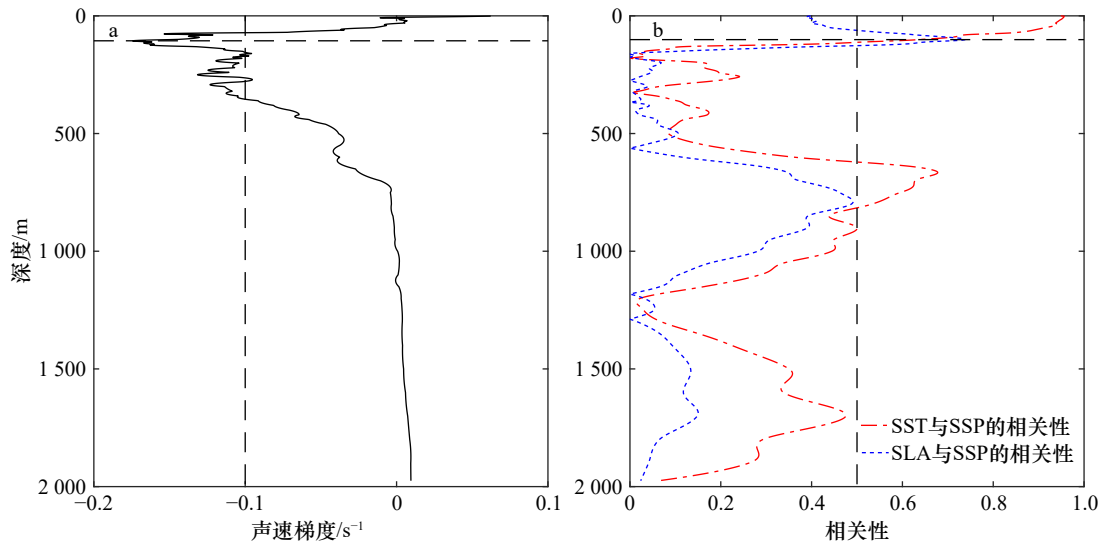


图7 平均声速剖面的声速梯度(a), 海表面温度(SST)、海表面高度异常(SLA)和声速剖面(SSP)的相关性(b)
Fig. 7 Sound speed gradient of mean sound speed profile (a), correlation between sea surface temperature (SST), sea level anomaly (SLA) and sound speed profile (SSP) (b)

0.1 s⁻¹ 附近, 该梯度相比于 60~130 m 深度梯度较小, 但比其他深度的梯度要大, 而该范围的声速与 SST、SLA 的相关性很弱, 这也是误差集中在 130~>400 m 深度的主要原因。由以上分析可知, 由于海面遥感数据可以反映表层声速剖面的结构变化, 又由于深层海水的声速比较稳定, 因此这两部分反演结果的误差较小。但是对于梯度较小的跃层部分(130~400 m), 其声速相对深海来讲扰动较强烈, 然而该深度处的声速与 SST、SLA 的相关性极弱, 从而导致该深度范围的声速反演误差较大。

3.3 声速剖面反演及结果分析

SOM 神经网络是将训练集的 SST、SLA、经度(LON)、纬度(LAT)、表层声速仪测量数据和前 5 阶 EOF 系数利用自组织网络算法映射到输出层不同单元上, 每个单元代表一类聚类分析的参考向量。由于缺少表层声速仪实测数据, 本文将 Argo 剖面在 10 m 深度处的声速 c_{10} 假设为表层声速仪的测量值, 若具备表层声速仪的实测数据, 那么该固定深度替换为表层声速仪的实际测量深度。反演声速剖面的过程是在输出层单元上寻找与待反演剖面已知信息的最小欧氏距离对应的单元, 已知信息包括位置信息(LON, LAT), 对应位置的海面遥感数据(SST, SLA)以及 10 m 深度处声速 c_{10} , 最佳匹配单元中的参考向量即为反演的 EOF 系数 PC_k , 结合利用训练集得到的 EOF 基函数和平均声速剖面得到声速剖面的估计值。

竞争层节点数由经验公式(13)确定, 经过调试发现使用 48 个类, 初始邻域半径和最终邻域半径分别为 4 和 0.1 时, 均方根误差最小, 声速剖面估计效果最好。

确定竞争层最少节点数的经验公式如下:

$$j = 5\sqrt{N}, \quad (13)$$

式中, N 代表训练样本的个数。

经典 sEOF-r 方法的计算过程大致为: 由声速剖面的重构方程(6)计算出训练集中每条剖面对应的 EOF 系数。将 EOF 系数 PC 与海面数据建立一阶线性回归关系, 利用训练集中的 SLA、SST 数据, 得到拟合系数的最小二乘估计。进而利用测试集中的 SST 和 SLA 数据可以计算得到声速剖面的估计值。

EOF 系数与海面遥感数据建立线性回归关系的表达式为

$$PC_k(c) = a_{0k} + a_{1k}SLA(c) + a_{2k}SST(c) + a_{3k}SLA(c) \times SST(c), \quad (14)$$

式中, k 为选取的 EOF 阶数; a_k 为拟合系数。利用训练集中的 SLA、SST 数据, 得到拟合系数的最小二乘估计。进而利用测试集中的 SST 和 SLA 数据可以计算得到声速剖面的估计值。

为了表述方便, 这里将本文提出的方法表示为 SOM- c_{10} 方法。图 8 给出不同方法反演得到的声速剖面绝对误差, 其中图 8a 为 SOM- c_{10} 方法的反演结果, 与实际测试集声速剖面在 0~1975 m 海深所有剖面的绝对误差约不超过 5.02 m/s。图 8b 为未考虑表层声速仪数据的经典 SOM 神经网络, 利用 SST、SLA、经度(LON)、纬度(LAT)以及前 5 阶 EOF 系数训练模型的反演结果, 可以发现 17 号剖面在 350 m 附近的反演误差最大, 约为 6.20 m/s。图 8c 为 sEOF-r 方法的反演结果, 可以发现第 20 号剖面在 220 m 附近的反演误差最大, 约为 7.22 m/s。与经典 SOM 神经网络




图8 测试集中声速剖面反演误差

Fig. 8 The inversion error of the sound speed profiles in the test set

a. SOM- c_{10} 方法; b. SOM 方法; c. sEOF-r 方法a. SOM- c_{10} method; b. SOM method; c. sEOF-r method

相比, SOM- c_{10} 方法的最大误差降低约 1 m/s, 并且 15~18 号剖面反演结果明显变好; 与经典 sEOF-r 方法相比 SOM- c_{10} 方法的最大误差降低约 2 m/s。

根据均方根误差公式(12), 图9给出不同方法的均方根误差随测试集声速剖面的变化, 其中最小二乘解与图6中的一致。可以看出, SOM- c_{10} 方法的最大均方根误差约为 1.36 m/s, 最小均方根误差约为 0.57 m/s, 标准差为 0.16 m/s; 经典 SOM 神经网络的最大均方根误差约为 1.69 m/s, 最小均方根误差约为 0.59 m/s, 标准差为 0.24 m/s; sEOF-r 方法的最大均方根误差约为 1.86 m/s, 最小均方根误差约为 0.67 m/s, 标准差为 0.35 m/s。图9表明, 本文提出的 SOM- c_{10} 方法性能最稳定, 除第 13~18 号剖面以外, 其他情况下的反演精度最高。相反, sEOF-r 方法的性能最不稳定, 其对第 13~18 号剖面的反演精度最高, 然而对其他剖面的反演精度却是很低。

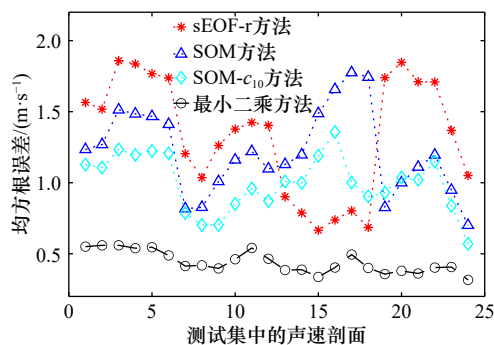


图9 不同方法的均方根误差

Fig. 9 The root mean square error for different methods

图10绘制出了测试集中的第13~18号声速剖面, 可见这6条剖面大致可以分为两类, 第I类为黑色实线表示的剖面(第13, 14号声速剖面), 有两个较明显的负跃层; 第II类为红色实线表示的剖面(15~18号声速剖面), 在 100~300 m 水深处, 其声速梯度变化较小, 而在 320 m 附近出现正梯度。




图10 测试集中的13~18号声速剖面

Fig. 10 The 13th-18th sound speed profiles in the test set

以第13号和16号剖面为例, 图11给出了 sEOF-r 方法和 SOM- c_{10} 方法的反演结果, 从图中不难看出, sEOF-r 方法的反演结果与实测值更加吻合, 而 SOM- c_{10} 方法在跃层处的误差显著。相比于 sEOF-r 方法, SOM 神经网络不仅利用海面遥感数据, 还考虑了剖面的位置信息。然而更多的先验信息却带来较高的反演误差, 其原因有可能是训练集的水平位置分辨率不高。因为研究表明, SOM 神经网络在反演该6条剖面的 EOF 系数时, 匹配到训练结果的同一个神经元, 即相同的 EOF 系数。从图9不同方法的均方根误差结果

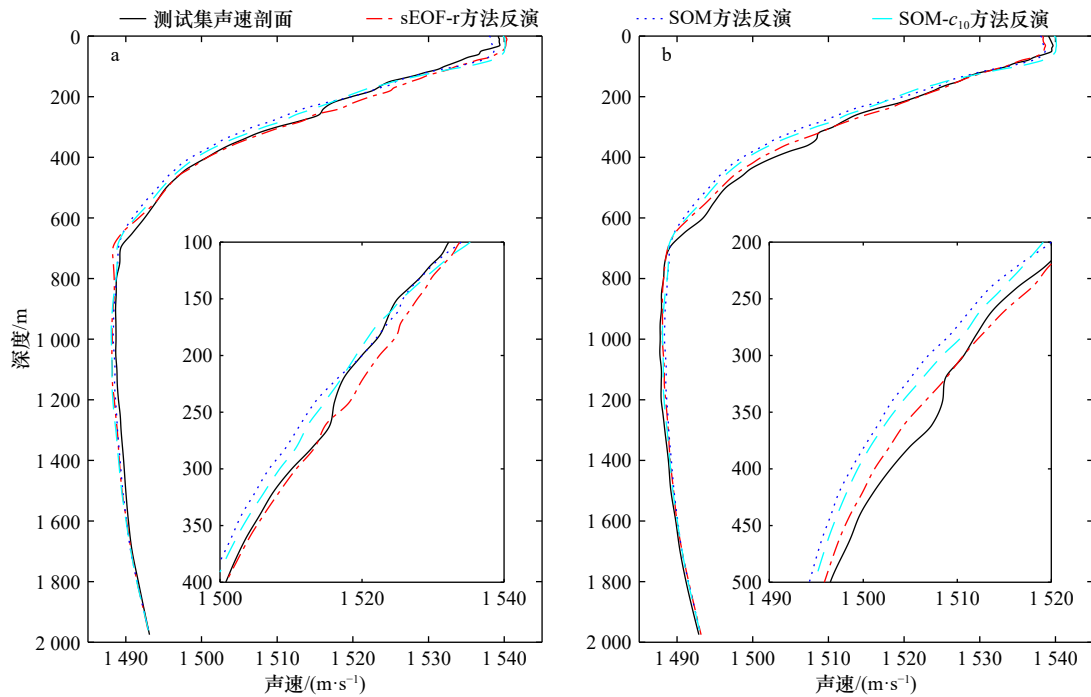


图 11 测试集中第 13 号剖面 (a) 和第 16 号剖面 (b) 的反演情况
 Fig. 11 The inversion of 13th profile (a) and 16th profile (b) in the test set

可以发现, SOM- c_{10} 方法反演的 13 号、14 号剖面比 15~18 号剖面的均方根误差要小, 说明反演的 EOF 系数得到的声速剖面与测试集的 13 号、14 号这类剖面更接近。

对于减小平均声速剖面的代表性误差, 是比较容易实现的, 通常在海上作业时利用 CTD 通过定点测量方式获取几个站点的海水声速剖面来消除声速误差的影响, 该实时测量的声速剖面一般会比历史平

均声速剖面更具有代表性, 在一定程度上可以提高反演精度。因此本文从测试集中选取具有代表性的第 13 号和 17 号剖面, 取其平均值作为现场平均声速剖面。图 12a 是 sEOF-r 方法的反演结果, 可见选取新的平均声速剖面之后, 大部分均方根误差都略有降低; 图 12b 是 SOM- c_{10} 方法的反演结果, 选取新的平均声速剖面之后, 大部分均方根误差都有明显降低, 且部分均方根误差与最小二乘法结果相近。

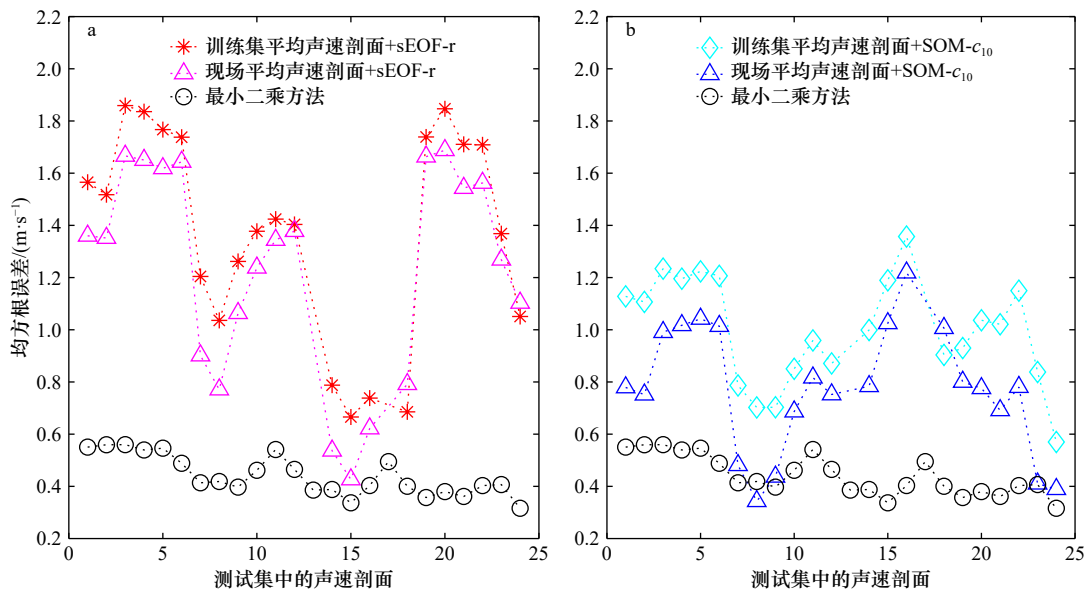


图 12 不同平均声速剖面下 sEOF-r 和 SOM- c_{10} 方法的反演结果
 Fig. 12 Prediction results of sEOF-r and SOM- c_{10} method with different mean sound speed profiles

4 结论

本文提出一种联合表层声速的自组织映射的非线性反演方法, 海表面遥感数据和表层声速仪测量的固定深度处数据(本文选取 10 m 深度声速值作为表层声速)作为输入, 寻找最佳匹配单元以获得声速剖面的 EOF 系数, 再结合历史平均声速剖面 and 基函数来实时反演全海深声速剖面。就印度洋中部海域的实验结果来看, 综合考虑表层声速仪的数据后, 本文提出的方法反演性能最稳定且精度最高。选择前 5 阶 EOF 系数可以满足反演方法的精度相关要求, 重

构的均方根误差在 0.5 m/s 附近, 该方法也初步解释了海表面遥感数据与声速剖面扰动之间存在关系, 同时, 在表层和跃层梯度较大的深度范围内, 声速剖面与海表面遥感数据具有较高的相关性。

在反演全海深声速剖面时有两点需要引起注意, 一是, 本文方法对测试集中 6 个剖面的反演精度略差于经典 sEOF-r 方法, 其原因有可能是训练集的水平位置分辨率不高所造成的, SOM 神经网络在处理该 6 条剖面时, 获得的为同一个最佳匹配单元, 即 EOF 系数相同。二是, 声速剖面基函数的代表性问题。这也是作者下一步拟进行研究的问题。

参考文献:

- [1] 宋海润, 叶松, 王晓蕾, 等. 声速剖面仪测量技术综述[J]. 海洋技术学报, 2020, 39(2): 105–112.
Song Hairun, Ye Song, Wang Xiaolei, et al. A review of the measurement techniques of sound velocity profilers[J]. *Journal of Ocean Technology*, 2020, 39(2): 105–112.
- [2] Li Haipeng, Qu Ke, Zhou Jianbo. Reconstructing sound speed profile from remote sensing data: nonlinear inversion based on self-organizing map[J]. *IEEE Access*, 2021, 9: 109754–109762.
- [3] Li Hong, Xu Fanghua, Zhou Wei, et al. Development of a global gridded Argo data set with Barnes successive corrections[J]. *Journal of Geophysical Research: Oceans*, 2017, 122(2): 866–889.
- [4] Tolstoy A, Diachok O, Frazer L N. Acoustic tomography via matched field processing[J]. *The Journal of the Acoustical Society of America*, 1991, 89(3): 1119–1127.
- [5] 沈远海, 马远良, 屠庆平, 等. 浅水声速剖面的反演方法与实验验证[J]. 西北工业大学学报, 2000, 18(2): 212–215.
Shen Yuanhai, Ma Yuanliang, Tu Qingping, et al. Inversion of sound speed profile for shallow-water environment with experimental verification[J]. *Journal of Northwestern Polytechnical University*, 2000, 18(2): 212–215.
- [6] Yang T T, Chen Z B, He Y J. A new method to retrieve salinity profiles from sea surface salinity observed by SMOS satellite[J]. *Acta Oceanologica Sinica*, 2015, 34(9): 85–93.
- [7] Hurlburt H E, Fox D N, Metzger E J. Statistical inference of weakly correlated subthermocline fields from satellite altimeter data[J]. *Journal of Geophysical Research: Oceans*, 1990, 95(C7): 11375–11409.
- [8] Carnes M R, Mitchell J L, de Witt P W. Synthetic temperature profiles derived from Geosat altimetry: Comparison with air-dropped expendable bathythermograph profiles[J]. *Journal of Geophysical Research: Oceans*, 1990, 95(C10): 17979–17992.
- [9] Carnes M R, Teague W J, Mitchell J L. Inference of subsurface thermohaline structure from fields measurable by satellite[J]. *Journal of Atmospheric and Oceanic Technology*, 1994, 11(2): 551–566.
- [10] Fox D N, Teague W J, Barron C N, et al. The modular ocean data assimilation system (MODAS)[J]. *Journal of Atmospheric and Oceanic Technology*, 2002, 19(2): 240–252.
- [11] Chen Cheng, Ma Yuanliang, Liu Ying. Reconstructing sound speed profiles worldwide with sea surface data[J]. *Applied Ocean Research*, 2018, 77: 26–33.
- [12] Liu Yonggang, Weisberg R H, Mooers C N K. Performance evaluation of the self-organizing map for feature extraction[J]. *Journal of Geophysical Research: Oceans*, 2006, 111(C5): C05018.
- [13] Liu Yonggang, Weisberg R H, Shay L K. Current patterns on the West Florida shelf from joint self-organizing map analyses of HF radar and ADCP data[J]. *Journal of Atmospheric and Oceanic Technology*, 2007, 24(4): 702–712.
- [14] Charantonis A A, Testor P, Mortier L, et al. Completion of a sparse GLIDER database using multi-iterative self-organizing maps (IT-COMP SOM)[J]. *Procedia Computer Science*, 2015, 51: 2198–2206.
- [15] Chapman C, Charantonis A A. Reconstruction of subsurface velocities from satellite observations using iterative self-organizing maps[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(5): 617–620.
- [16] Chen Cheng, Yang Kunde, Ma Yuanliang, et al. Reconstructing the subsurface temperature field by using sea surface data through self-organizing map method[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(12): 1812–1816.
- [17] Chen Cheng, Yan Fenggang, Gao Ya, et al. Improving reconstruction of sound speed profiles using a self-organizing map method with multi-source observations[J]. *Remote Sensing Letters*, 2020, 11(6): 572–580.
- [18] Jain S, Ali M M. Estimation of sound speed profiles using artificial neural networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2006, 3(4): 467–470.

- [19] Reynolds R W, Smith T M, Liu Chunying, et al. Daily high-resolution-blended analyses for sea surface temperature[J]. *Journal of Climate*, 2007, 20(22): 5473–5496.
- [20] AVISO. SSALTO/DUACS User Handbook: (M)SLA and (M)ADT near-real time and delayed time products[M]. Paris: CNES, 2012.
- [21] Kohonen T. The self-organizing map[J]. *Neurocomputing*, 1998, 21(1/3): 1–6.
- [22] Chen C T, Millero F J. Speed of sound in seawater at high pressures[J]. *The Journal of the Acoustical Society of America*, 1977, 62(5): 1129–1135.
- [23] Casagrande G, Stephan Y, Varnas A C W, et al. A novel Empirical Orthogonal Function (EOF)-based methodology to study the internal wave effects on acoustic propagation[J]. *IEEE Journal of Oceanic Engineering*, 2011, 36(4): 745–759.

Inversion of the full-depth sound speed profile based on remote sensing data and surface sound speed

Li Qianqian^{1,2}, Li Honglin¹, Cao Shoulian¹, Yan Xian¹, Ma Zhichuan¹

(1. College of Geodesy and Geomatics, Shandong University of Science and Technology, Qingdao 266590, China; 2. College of Underwater Acoustic Engineering, Harbin Engineering University, Harbin 150001, China)

Abstract: The ocean sound speed profile (SSP) determines the underwater acoustic propagation, and it is very important to obtain SSP in near real-time for underwater acoustic communication, positioning, and fish detecting. The single Empirical Orthogonal Function regression (sEOF-r) method inverts the SSP by establishing a linear regression relationship between the empirical orthogonal coefficient of the SSP and the sea surface remote sensing data. However, the ocean is a complex dynamical system, and the SSP and the remote sensing data are not simple linear. Therefore, based on the Argo historical gridded dataset, self-organizing map (SOM) was used to establish the non-linear mapping between sea surface data, such as sea level anomaly (SLA), sea surface temperature (SST) and surface sound speed measured by surface velocimeter, and SSP anomaly. The three-dimensional sound speed field is then inverted by the near real-time remote sensing data and the surface sound speed. The results of the SSP inversion showed that, under the advantage of multi-source information fusion, the algorithm generated a smaller inversion error than linear inversion and had better robustness. It improved the average accuracy of inversion by about 2 m/s than sEOF-r method, and improved by about 1 m/s than classical SOM method that without considering the surface sound speed.

Key words: Argo dataset; sea surface temperature; sea level anomaly; EOF decomposition; surface velocimeter; sEOF-r method; SOM method