

# Sea Surface Wind Field Data Fusion Based on Full Supervision

Wenlong Cui<sup>1</sup>, Yanxin Yao<sup>1†</sup>

1. Beijing Information Science and Technology University, Beijing, 100010, China

Email: yanxin\_buaa@126.com

## Abstract

Sea surface wind field data fusion can realize the complementary advantages of multi-source wind field data. This paper firstly introduces the traditional data fusion method and the data fusion method based on deep learning. The traditional data fusion method is unable to deeply extract data features to form high level features with strong discrimination. This paper proposes a data fusion method based on U-Net network, which uses GRAPES\_1KM model data, HRCLDAS data, satellite wind field data and buoy ship data. When the buoy data is used as the true value of training, the model is difficult to converge due to the sparsity of the buoy data. Therefore, two methods of constructing false tags are proposed in this paper to achieve the convergence of the network model by conducting full supervision training based on U-net network. Experiments show that the loss curve of the network model can converge quickly when the constructed false tags are used for full supervision training, and the effect on data fusion is also obvious.

**Keywords:** Sea Surface Wind Field; Data Fusion; U-net; Full Supervision

## 基于全监督的海面风场数据融合

崔文龙<sup>1</sup>, 姚彦鑫<sup>1\*</sup>

1. 北京信息科技大学, 北京 100010

**摘要:** 海面风场数据融合可以实现多源风场数据之间的优势互补。本文首先对传统的数据融合方法和基于深度学习的数  
据融合方法进行了介绍。传统的数据融合方法, 无法深度提取数据特征形成判别性较强的高层次特征。本文提出一种基于  
U-Net 网络的数据融合方法, 采用 GRAPES\_1KM 模式数据、HRCLDAS 数据、卫星风场数据和浮标船舶数据。当浮标船  
舶数据作为训练真值时, 由于浮标船舶数据的稀疏性, 导致网络模型难以收敛, 因此本文提出了两种构造伪标签的方法,  
基于 U-Net 网络进行全监督训练, 实现网络模型的收敛。实验证明, 采用构造的伪标签进行全监督训练时, 网络模型的损  
失曲线能够很快收敛, 在数据融合上的效果也很明显。

**关键词:** 海面风场; 数据融合; U-Net; 全监督

## 1 引言

海面风场是海洋灾害监测的关键因素, 其描述了海洋表面的局地风速、风向等相关指标的分布情况。海面风场提供了丰富的有用信息, 可用于研究海气相互作用、热带环流、海洋环流、大气对流、天气预报和气候监测<sup>[1]</sup>。海面风场的传统测量方法包括船舶、海上浮标和沿岸海洋观测站等实地测量手段, 其优点是时间间隔短, 数据精度高, 最接近真实值, 可以用来验证其他风场产品的准确性。然而, 这种方法成本高昂, 而且无法实现对大规模海面风场的连续性监测<sup>[2]</sup>。此外, 中国的海洋监测点主要分布在沿海区域, 数量有限,

<sup>†</sup>基金资助: 受北京市自然科学基金支持资助(4172021); 受“北京市属高等学校高层次人才引进与培养计划项目”支持资助(CIT&TCD201704064)

难以满足对长时间、大面积实时监测的需求，导致许多海洋数据无法获得，不能满足日常生活和研究的需要<sup>[3]</sup>。

随着卫星遥感技术的迅速发展，使得广阔海域的风场观测成为可能。20 世纪 70 年代以来卫星遥感技术的发展实现了海面风场的高时空分辨率和大面积同步的观测，星载微波散射计以其覆盖范围广常被用来进行全球海面风场监测。与传统观测手段相比，卫星遥感具有大面积、准同步和全天候的观测能力，为海面风场监测提供了一个崭新的技术手段<sup>[4]</sup>。但卫星资料由于其采样特点，其产生的海面风场数据产品存在数据空白区和无法提供时间、空间上连续等缺点<sup>[5]</sup>。为了解决传统观测手段和卫星遥感风场观测手段存在的问题，海面风场数据融合是非常有效的手段之一。通过数据融合可以优化多传感器信息资源利用，实现多源数据之间的优势互补。在中国近海区域内，通过融合方法把多源风场数据结合起来，形成覆盖近海区域的高分辨率的时间空间连续的风场数据集，这将对近海区域研究以及海洋预报都有着重要的意义。

本文利用 GRAPES\_1KM 模式数据、HRCLDAS 数据、卫星风场数据和浮标船舶数据，基于 U-Net 网络进行多源风场数据的融合，其中 HRCLDAS 数据和卫星风场数据作为网络模型输入数据，浮标船舶数据作为网络模型的训练真值。但是由于海上浮标和船舶分布较为分散，浮标船舶数据具有稀疏性，导致网络模型很难收敛。因此，本文提出了两种构造伪标签的方法来进行全监督训练。

## 2 相关方法

### 2.1 传统的数据融合方法

目前，国内外常用于风场数据融合的方法主要有逐步订正法、时空加权分析法和最优插值法<sup>[6]</sup>。逐步订正法是分析场由分析增量与初估背景场相加得到。每一个分析格点上的分析增量是其影响半径范围内各个测站上观测值与初估值的偏差，即观测增量的加权平均，一般观测权重与观测位置和格点之间距离成反比。不断缩小影响半径，逐次订正，直到分析场逼近实际资料为止<sup>[7]</sup>。时空加权分析法既包含了 Kriging 法对空间数据的插值精度，又继承了 Cressman 法考虑时间变化的优点，引入自适应滑动窗口来计算时间/空间半径内的有效观测点，从而提高风场融合的计算效率，综合考虑了数据之间空间维与时间维上的变异性<sup>[8,9]</sup>。最优插值法利用最小方差估计把带有误差的观测资料有机地融合到预报模式所得到的背景场，从而得到对模式初值的最优估计<sup>[10]</sup>。

### 2.2 基于深度学习的融合方法

传统的数据融合方法在特征融合阶段只是将异构特征简单堆叠形成扩展的特征向量，无法深度融合异构特征形成判别性较强的高层次特征，而基于深度学习的数据融合方法能够很好地弥补传统数据融合方法的不足<sup>[11]</sup>。近年来，深度学习凭借自身优秀的特征表征能力，在目标检测<sup>[12]</sup>、图像处理<sup>[13]</sup>等领域具有广泛的应用，并且也有越来越多的学者对基于深度学习的数据融合方法进行研究。如 Liu 等人采用卷积神经网络 (Convolutional Neural Networks, CNN) 进行图像多尺度融合<sup>[14]</sup>；Zhai 等人采用堆叠式自动编码器 (Stacked Auto-Encoder, SAE) 和 CNN 对合成孔径雷达图像进行融合<sup>[15]</sup>。Chen 等人通过构建深度卷积神经网络数据融合模型 (DCNN) 对多传感器数据进行融合，论文提出一种基于 CNN、GRU 和自适应多模态融合模型的深度学习融合框架，该框架能够完成数据的时间相关特征以及空间相关特征的融合<sup>[16]</sup>，论文<sup>[17]</sup>提出一种以 LSTM 神经元为基本单位的深度长短时记忆网络 (Deep Long Short Term Memory, DLSTM) 对多个传感器数据进行融合。

### 2.3 提出方法

为了能够提取到多源数据的深层次特征，同时网络模型能够很好的收敛。本文提出一种基于 U-Net 网络采用全监督训练方式的数据融合方法。U-Net 网络是基于编码器-解码器结构的典型语义分割模型，该网络由 Ronneberger 等人于 2015 年提出，本文在原有网络的基础上将网络训练深度改为 2，并将其称为 UD2-Net 网络，其网络结构如图 1 所示，整体由左半部分的收缩路径和右半部分的扩展路径两个部分构成，其中收缩

路径包括 1 个连续的无填充卷积并采用 ReLU 激活函数进行非线性处理，其后接着最大池化层，每次池化操作后将特征图通道数量加倍；在扩展路径部分，每次采用转置卷积将输入特征图的尺寸增倍并通过跳跃连接将来自收缩路径对应层的特征图（经过适当裁剪后）进行拼接融合，然后采用 1 个连续的无填充卷积（紧接着采用 ReLU 函数激活）调整融合后的特征图尺寸并将通道数减半，这一过程重复 2 次得到具有 8 个通道数的特征图，最后采用卷积操作调整特征图通道数至 1，最终输出数据融合结果。总的来说，网络包括 2 次下采样和 2 次上采样操作，共有 8 个卷积层，整体呈现“U”形。

针对浮标与船舶数据较少无法形成真正意义上真值标签的问题，考虑为网络模型制作伪标签，采用全监督的方式去进行网络模型的训练。伪标签的制作是网络模型是否能够收敛以及训练精度是否高的关键所在。因此本文提出了两种制作伪标签得方法，如表 1 所示：

表 1 伪标签的种类

序号	伪标签
I	根据模式风场和 HRCLDAS 风场预评估后的 RMSE 求出的伪标签 RFB
II	GRAPES_1KM 模式数据

求伪标签 I 的具体公式如所示：

$$A = \frac{RMSE_{ms}}{RMSE_{ms} + RMSE_{hr}} \quad (1)$$

$$B = \frac{RMSE_{hr}}{RMSE_{ms} + RMSE_{hr}} \quad (2)$$

$$RFB = A * HRCLDAS + B * MS \quad (3)$$

其中， $RMSE_{ms}$ 代表 GRAPES\_1KM 模式数据的均方根误差， $RMSE_{hr}$ 代表 HRCLDAS 数据的均方根误差， $RFB$ 代表伪标签 I。

## 2.4 评价指标

本文选取 RMSE 和 MAE 两个统计参数作为订正评价指标。两个统计参数的具体计算公式如下：

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (u_{sat,i} - u_{grd,i})^2} \quad (4)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |u_{sat,i} - u_{grd,i}| \quad (5)$$

其中， $u_{sat,i}$ 和 $u_{grd,i}$ 分别表示观测格点 i 处的卫星观测值和参考真值，N 代表匹配点总个数， $\overline{u_{sat}}$ 和 $\overline{u_{grd}}$ 分别表示海面风场观测平均值和参考真值平均值。

## 3 实验

本实验基于卫星数据、HRCLDAS 数据和伪标签采用全监督进行训练。网络的输入数据为卫星数据和 HRCLDAS 数据，全监督训练所用的标签为根据模式风场和 HRCLDAS 风场预评估后的 RMSE 求出的伪标签 RFB 以及模式数据。如表 2 所示。

表 2 网络输入数据和训练标签

实验名称	网络输入数据	全监督标签
双层- I	卫星数据和 HRCLDAS 数据	根据模式风场和 HRCLDAS 风场预评估后的 RMSE 求出的伪标签 RFB
双层- II	卫星数据和 HRCLDAS 数据	模式数据

全监督训练的损失曲线如图 1 所示。

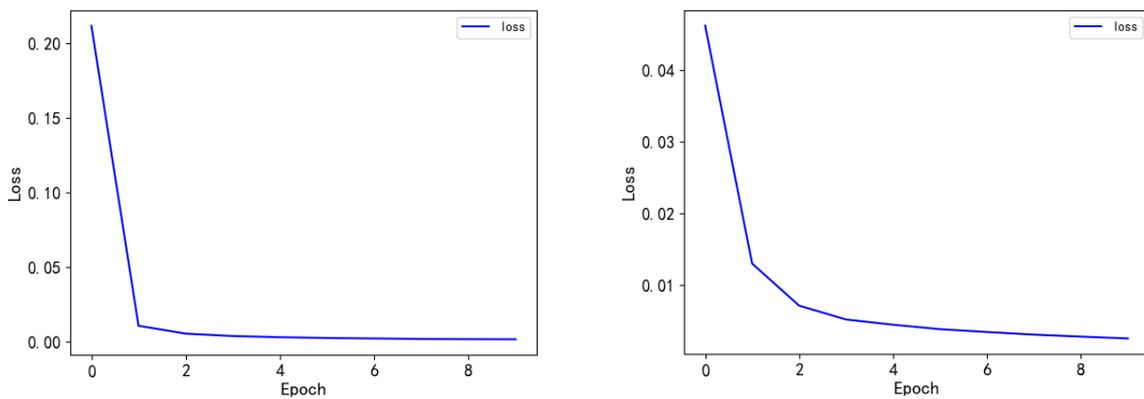


图 1 全监督训练损失曲线（左图为伪标签 I，右图为伪标签 II）

之后加载全监督训练权重进行测试，测试结果如表 3 所示。

表 3 基于全监督训练的测试结果

实验名称	N	RMSE	MAE
双层- I -MS	2628	4.70769	3.57157
双层- II -MS	2628	3.99101	3.14288

实验结果表明,采用两种构造的伪标签进行全监督训练时,网络模型能够很快收敛。同时,测试结果 RMSE 分别为 4.70769 和 3.99101, MAE 分别为 3.57157 和 3.14288。可知,当采用伪标签 II 进行全监督训练时,U-net 网络数据融合的效果更好。

## 4 结论

本文基于 U-Net 网络进行海面风场数据融合,所使用的数据有 GRAPES\_1KM 模式数据、HRCLDAS 数据、卫星风场数据和浮标船舶数据。但是由于浮标船舶数据的稀疏性,网络模型难以提取到输入数据的深层次特征,模型难以收敛。本文提出两种构造伪标签的方法,基于 U-Net 网络进行全监督训练。实验表明,采用构造的伪标签进行全监督训练时,网络模型能够快速收敛,同时数据融合效果也非常好,因此伪标签的制作对网络模型是否能够收敛以及训练精度是否高有所影响。

## 参考文献

- [1] Xinlei Zhang. Study on North Pacific Sea Surface Wind Field based on Multi-Source Remote Sensing Data [D]. Liaoning Normal University,2019.
- [2] Jing Liu. Research on Fusion of Sea Surface Wind Field Data in Offshore China Based on Optimal Interpolation Method [D]. National Marine Environmental Prediction Center,2018.
- [3] Dongxiang Zhang. Research on Testing and Fusion of Multi-source Satellite Sea Surface Wind Field Products [D]. National University of Defense Technology,2018.
- [4] He Fang. Research on Key Techniques of Sea Surface Wind Velocity Inversion in Spaceborne C-band Quad Polarimetric SAR [D]. Nanjing University of Information Science and Technology,2019.
- [5] Hao Gao, Shihao Tang, Xiuzhen Han. Development and Application of Fengyun Meteorological Satellite [J]. Science and Technology Review, 2013,39(15):9-22.
- [6] Jing Liu, Xiaojiang Song, Zhanguai Wang. Sea Surface Wind Fusion Technology Review [J]. Marine Forecast,2018,35(03):81-87.

- [7] Zheng Ling, Guihua Wang, Dake Chen, et al. Sea Breeze Convergence in China [C]// National Oceanographic Information. Proceedings of China "Digital Ocean" Forum. Beijing: National Marine Information Center,2006:90-94.
- [8] Zhang H M, Reynolds R W, Smith T M. Adequacy of The in Situ Observing System in The Satellite Era for Climate SST[J]. Journal of Atmospheric and Oceanic Technology, 2006,23(1):107-120.
- [9] Zhang H M, Reynolds R W, Bates J J. Blended and Gridded High Resolution Global Sea Surface Wind Speed and Climatology from Multiple Satellites:1987-present[C]. Proceedings of the 14th Conference on Satellite Meteorology and Oceanography. Atlant:American Meteorological Society,2006:2-23.
- [10] Yan Q S, Zhang J, Meng J M, et al. Use of An Optimum Interpolation Method to Construct a High-Resolution Global Ocean Surface Vector Wind Dataset from Active Scatter Meters and Passive Radiometers[J]. International Journal of Remote Sensing, 2017, 38(20): 5569-5591.
- [11] Chuanqi Cheng. Research on Data Fusion Method Based on Deep Learning [D]. Lanzhou University of Technology,2021.
- [12] Ruixue Duan, Kaiyue Ma, Yangsen Zhang. Pedestrian Detection Algorithm Based on Multi-Source Data Fusion [J]. Journal of Information Science and Technology University of Beijing (Natural Science Edition),2021,36(01):57-62.
- [13] Weijie Shi, Jingjing Huang, Maofa Wang. Comparison of Steel Image Defect Detection Methods Based on Two U-Shaped Networks [J]. Journal of Information Science and Technology University of Beijing (Natural Science Edition),2021,36(01):63-68
- [14] Liu Y, Zhang C, Cheng J, et al. A Multi-Scale Data Fusion Framework for Bone Age Assessment with Convolutional Neural Networks[J]. Computers in Biology and Medicine, 2019 108(5):161-173
- [15] Zhai J, Dong G, Chen F, et al. A Deep Learning Fusion Recognition Method Based on SAR Image Data[J]. Procedia Computer Science, 2019, 147:533-541
- [16] Chen H, Hu N, Cheng Z, et al. A Deep Convolutional Neural Network Based Fusion Method of Two- Direction Vibration Signal Data for Health State Identification of Planetary Gearboxes[J]. Measurement, 2019, 146(11):268-278.
- [17] Wu J, Hu K, Cheng Y, et al. Data-Driven Remaining Useful Life Prediction Via Multiple Sensor Signals and Deep Long Short-Term Memory Neural Network[J]. ISA Transactions, 2019, 97:241-250.