为了评价数据重建模型的数据拟合效果, 我们利用训练集以及预留的验证数据进行了典型的机器学习的验证, 将所有的土地覆盖类型融合到一起后呈现验证结果, 可以反映出模型的综合表现. 图 3 展示了本模型在训练集上的表现. 采用预测值与原始值的拟合线的斜率, 相关系数 R^2 与均方根误差 RMSE 的值来进行评价. 可以从中看到, 拟合线的斜率为 0.95, 相关系数 R^2 的数值达到了 0.72, 均方根误差 RMSE 的数值低至 0.081, 显示出了该模型在训练集上的良好表现.

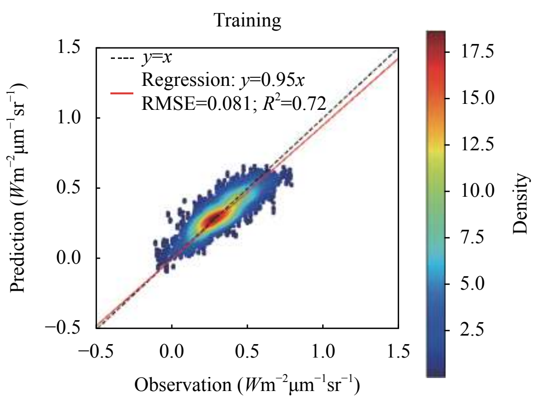

图 3 数据重建模型在训练集上的表现

本实验所建立的多层感知机神经网络模型在验证数据集上的表现如图 4 所示, 拟合线的斜率为 0.95, 相关系数 R^2 的数值达到了 0.7, 均方根误差 RMSE 的数值低至 0.084, 基本与模型在训练数据集上的表现处在同一水平线上, 显示出了该模型在验证集上的依然具有比较稳定的表现.

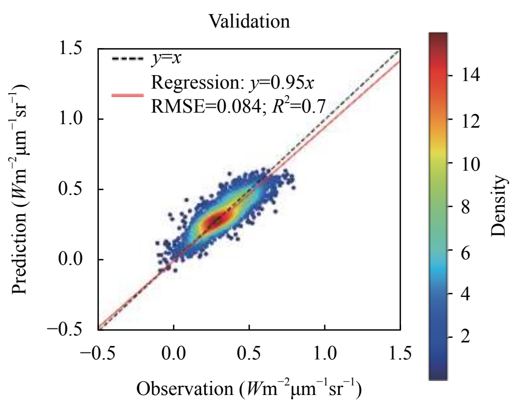

图 4 数据重建模型在训练集上的表现

从图 3 及图 4 可以看出, SIF 预测值与真实值之间具有很高的相关性, 而且在整个值域上具有良好的跟随关系.

华北地区最终的叶绿素荧光重建数据集如图 5 所示. 重建后的叶绿素荧光数据覆盖整个兴趣区域, 具有空间连续性. 同时模型的良好表现说明了其预测数值的有效性. 对比原始 OCO-2 叶绿素荧光数据集空间重采样到 1 度的数据集, 兴趣区域内重建后的叶绿素荧光数据集具有远高于原有 1 度数据集的分辨率. 基于我们在生态原理控制下建立的多层感知机模型, 重建数据集保留了原有数据集的空间分布规律, 同时由于其空间连续性, 该数据集的可用性远大于原有的 OCO-2 SIF 数据集. 新的叶绿素荧光数据集的空间分辨率为 0.05 度, 也远高于现有的空间连续的叶绿素荧光原始遥感数据集, 如 GOME-2, 其空间分辨率约为 40 公里. 从图五中的生长峰季三个月 6 月, 7 月, 8 月的 SIF 高值分布及变化来看, 基本反映出了如下规律: 1) 7 月作为华北地区降水量以及月均温最高的月份, 植被的生产力水平, 或者光合作用强度达到顶峰; 2) 从 6 月到 8 月, 该地区 SIF 平均水平经历了先上升后下降的过程, 而且在下降的时候, 反映出了高纬度或者高海拔先下降, 大型农业种植区所在的低纬度低海拔地区 SIF 峰值维持时间较长等趋势. 这些结论与先验生态学知识基本相符, 进一步证明了重建数据集的有效性.

3 结论与展望

本论文以华北地区 2018 年的生长峰季为例, 通过人工神经网络, 基于 MODIS 地表反照率与轨道碳观测者二号所提供的叶绿素荧光信号遥感数据建立模型, 并用于高分辨率、空间连续的数据集的重建任务. 本研究展示了一种获取兴趣区域特定时间段内高质量叶绿素荧光遥感监测数据集的生成方法, 并通过验证证明了该方法的有效性. 该方法可以与叶绿素荧光或总初级生产力相关的交叉学研究提供相应的数据支撑. 由于轨道碳观测者 2 号的叶绿素荧光数据以及 MODIS 反照率数据均具有数据缺失或者质量较低的情况, 该框架在特殊地区特殊时间, 如热带雨林生长峰季, 会面临较多的源数据缺失问题, 这属于一种不可控因素. 基于各相关学科专家知识系统或者经验模型的数据补全方案或具备一定的可行性, 也可能是未来潜在的一个研究方向.

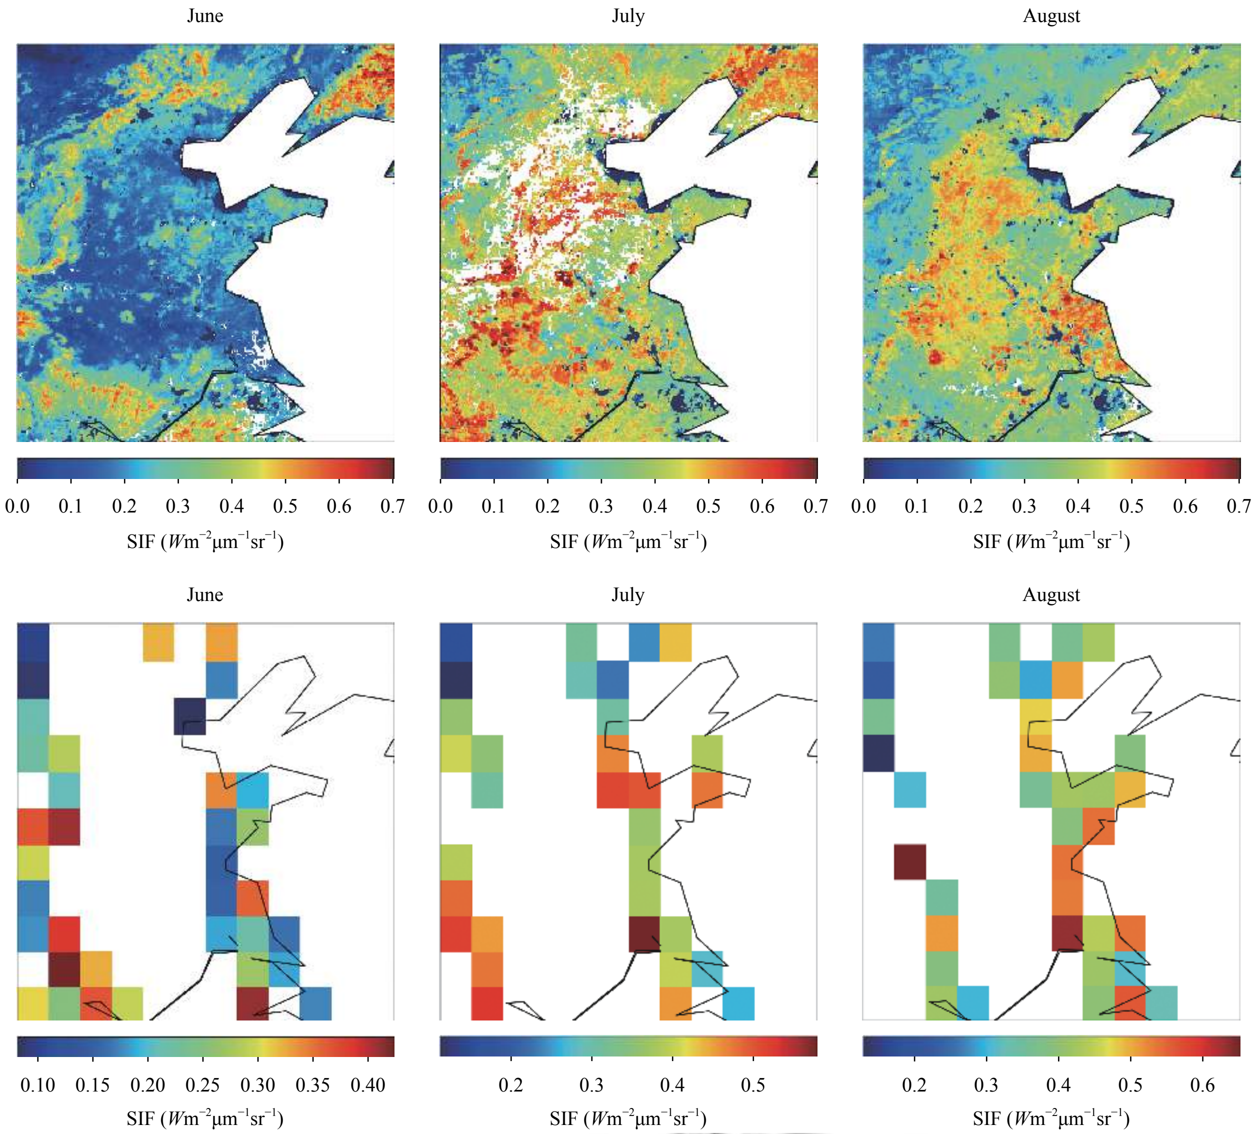

图 5　华北地区 2018 年生长峰季 SIF 重建数据集以及 1 度分辨率原始数据集对比图 (第一行为重建数据集, 第二行为原始数据集重采样到 1 度; 第一列为 6 月数据, 第二列为 7 月数据, 第三列为 8 月数据)

参考文献

1 Damm A, Guanter L, Paul-Limoges E, *et al*. Far-red sun-induced chlorophyll fluorescence shows ecosystem-specific relationships to gross primary production: An assessment based on observational and modeling approaches. Remote Sensing of Environment, 2015, 166: 91–105. [doi: 10.1016/j.rse.2015.06.004]

2 Frankenberg C, Fisher JB, Worden J, *et al*. New global observations of the terrestrial carbon cycle from GOSAT: Patterns of plant fluorescence with gross primary productivity. Geophysical Research Letters, 2011, 38(17): L17706.

3 Porcar-Castell A, Tyystjärvi E, Atherton J, *et al*. Linking chlorophyll a fluorescence to photosynthesis for remote sensing applications: Mechanisms and challenges. Journal of Experimental Botany, 2014, 65(15): 4065–4095. [doi: 10.1093/jxb/eru191]

4 李晓, 冯伟, 曾晓春. 叶绿素荧光分析技术及应用进展. 西北植物学报, 2006, 26(10): 2186–2196. [doi: 10.3321/j.issn:1000-4025.2006.10.037]

5 Guanter L, Zhang YG, Jung M, *et al*. Global and time-resolved monitoring of crop photosynthesis with chlorophyll fluorescence. Proceedings of the National Academy of Sciences of the United States of America, 2014, 111(14): E1327–E1333. [doi: 10.1073/pnas.1320008111]

6 Joiner J, Yoshida Y, Vasilkov AP, *et al*. The seasonal cycle of satellite chlorophyll fluorescence observations and its relationship to vegetation phenology and ecosystem atmosphere carbon exchange. Remote Sensing of Environment, 2014, 152: 375–391. [doi: 10.1016/j.rse.2014.06.022]

7 Liu JJ, Bowman KW, Schimel DS, *et al*. Contrasting carbon cycle responses of the tropical continents to the 2015-2016 El Niño. Science, 2017, 358(6360): eaam5690. [doi: 10.1126/science.aam5690]

8 Sun Y, Fu R, Dickinson R, *et al*. Drought onset mechanisms revealed by satellite solar-induced chlorophyll fluorescence: Insights from two contrasting extreme events. Journal of Geophysical Research: Biogeosciences, 2015, 120(11): 2427–2440. [doi: 10.1002/2015JG003150]

9 Köhler P, Frankenberg C, Magney TS, *et al*. Global retrievals of solar - induced chlorophyll fluorescence with TROPOMI: First results and intersensor comparison to OCO - 2. Geophysical Research Letters, 2018, 45(19): 10456–10463. [doi: 10.1029/2018GL079031]

10 Sun Y, Frankenberg C, Jung M, *et al*. Overview of solar-induced chlorophyll fluorescence (SIF) from the Orbiting Carbon Observatory-2: Retrieval, cross-mission comparison, and global monitoring for GPP. Remote Sensing of Environment, 2018, 209: 808–823. [doi: 10.1016/j.rse.2018.02.016]

11 任杰, 姜纪沂, 程敏, 等. 墨西哥湾轨道碳观测 2 号卫星叶绿素荧光产品分析与评价. 科学技术与工程, 2018, 18(17): 262–268.

12 龚燃. 美国首颗温室气体探测卫星——轨道碳观测-2 于 7 月入轨. 国际太空, 2014, (8): 29–33.

13 Li X, Xiao JF, He BB, *et al*. Solar - induced chlorophyll fluorescence is strongly correlated with terrestrial photosynthesis for a wide variety of biomes: First global analysis based on OCO - 2 and flux tower observations. Global Change Biology, 2018, 24(9): 3990–4008. [doi: 10.1111/gcb.2018.24.issue-9]

14 Smith WK, Biederman JA, Scott RL, *et al*. Chlorophyll fluorescence better captures seasonal and interannual gross primary productivity dynamics across dryland ecosystems of southwestern North America. Geophysical Research Letters, 2018, 45(2): 748–757. [doi: 10.1002/grl.v45.2]

15 Verma M, Schimel D, Evans B, *et al*. Effect of environmental conditions on the relationship between solar - induced fluorescence and gross primary productivity at an OzFlux grassland site. Journal of Geophysical Research: Biogeosciences, 2017, 122(3): 716–733. [doi: 10.1002/2016JG003580]

16 Wood JD, Griffis TJ, Baker JM, *et al*. Multiscale analyses of solar - induced florescence and gross primary production. Geophysical Research Letters, 2017, 44(1): 533–541. [doi: 10.1002/2016GL070775]

17 Gentine P, Alemohammad SH. Reconstructed solar - induced fluorescence: A machine learning vegetation product based on MODIS surface reflectance to reproduce GOME - 2 solar - induced fluorescence. Geophysical Research Letters, 2018, 45(7): 3136–3146. [doi: 10.1002/grl.v45.7]

18 Duveiller G, Cescatti A. Spatially downscaling sun-induced chlorophyll fluorescence leads to an improved temporal correlation with gross primary productivity. Remote Sensing of Environment, 2016, 182: 72–89. [doi: 10.1016/j.rse.2016.04.027]

19 Yu L, Wen J, Chang CY, *et al*. High - resolution global contiguous SIF of OCO - 2. Geophysical Research Letters, 2019, 46(3): 1449–1458. [doi: 10.1029/2018GL081109]

20 Bishop CM. Neural Networks for Pattern Recognition. Oxford: Oxford University Press, 1995.

21 李双成, 吴绍洪, 戴尔阜. 生态系统响应气候变化脆弱性的人工神经网络模型评价. 生态学报, 2004, 25(3): 621–626.

22 韩玲. 基于人工神经网络——多层感知器 (MLP) 的遥感影像分类模型. 测绘通报, 2004, (9): 29–30, 42. [doi: 10.3969/j.issn.0494-0911.2004.09.010]

23 Zhang ZY, Lyons M, Schuster M, *et al*. Comparison between geometry-based and gabor-wavelets-based facial expression recognition using multi-layer perceptron. Proceedings of the 3rd IEEE International Conference on Automatic Face and Gesture Recognition. Nara, Japan. 1998. 454–459.

24 Ruck DW, Rogers SK, Kabrisky M, *et al*. The multilayer perceptron as an approximation to a Bayes optimal discriminant function. IEEE Transactions on Neural Networks, 1990, 1(4): 296–298. [doi: 10.1109/72.80266]