

兴趣区域高分辨率叶绿素荧光遥感数据集重建框架^①



于龙龙^{1,2}, 罗泽¹, 阎保平¹

¹(中国科学院 计算机网络信息中心, 北京 100190)

²(中国科学院大学, 北京 100049)

通讯作者: 于龙龙, E-mail: sharkingyl@163.com

摘要: 太阳诱导叶绿素荧光数据是反映全球植被总初级生产力的关键指标, 对于监测全球或地区性的植被生产力变化和气候变化的影响具有重大意义. 然而, 目前为止仍没有高分辨率和全球覆盖的可用原始数据集. 虽然存在一些全球性的重建数据集, 但一般存在区域特异性不够明显等问题, 从而一定程度上限制了该数据在特定的兴趣区域上的可用性. 为了探索重建基于兴趣区域的叶绿素荧光数据的方法, 本研究以华北平原为例, 综合遥感数据处理技术, 机器学习方法和生态学原理, 对原始轨道碳观测者二号卫星所提供的叶绿素荧光数据集和 MODIS 地表反照率数据建模. 重建数据集基于兴趣区域内原始数据的时空特征而建, 具有连续的空间覆盖和更高的空间分辨率, 经过验证, 该框架可以为特定区域提供有效的有针对性的叶绿素荧光数据, 可为兴趣区域的与叶绿素荧光数据有关的研究提供数据支持.

关键词: 叶绿素荧光; 轨道碳观测者二号; 遥感; 机器学习; 兴趣区域; 数据重建

引用格式: 于龙龙, 罗泽, 阎保平. 兴趣区域高分辨率叶绿素荧光遥感数据集重建框架. 计算机系统应用, 2019, 28(9): 133-139. <http://www.c-s-a.org.cn/1003-3254/7086.html>

Reconstruction Framework of High Resolution SIF Remote Sensing Dataset in Region of Interest

YU Long-Long^{1,2}, LUO Ze¹, YAN Bao-Ping¹

¹(Computer Network Information Center, Chinese Academy of Sciences, Beijing 100190, China)

²(University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: Solar-Induced chlorophyll Fluorescence (SIF) is a functional proxy of Gross Primary Production (GPP), and it is crucial to monitor the global or regional vegetation productivity and climate change. However, there is no available original dataset with global continuous coverage at high spatial resolution. Although there are some reconstructed datasets, but they are not specific enough to a region of interest. This disadvantage thus will limit their application for research related to SIF in such a region of interest. In order to explore the method to reconstruct SIF dataset in a region of interest, we built models on MODIS reflectance data and original OCO-2 SIF, combining machine learning, remote sensing technology and ecological principles. The reconstructed SIF dataset was built based on the spatial-temporal features with contiguous spatial coverage and higher spatial resolution. Based on the validation performance, this framework is capable for providing efficient and specific SIF data for a region of interest, and it can support the research related to SIF in this area.

① 基金项目: 国家科技部国家科技基础条件平台项目 (DKA2017-12-02-18)

Foundation item: MOST National Science & Technology Infrastructure Program (DKA2017-12-02-18)

收稿时间: 2019-03-10; 修改时间: 2019-04-04; 采用时间: 2019-04-12; csa 在线出版时间: 2019-09-05

Key words: SIF; OCO-2; remote sensing; machine learning; region of interest; dataset reconstruction

太阳诱导叶绿素荧光 (Solar-Induced chlorophyll Fluorescence, SIF) 信号是当阳光被叶绿素吸收之时所产生的, 属于光合作用生化过程中释放的光学信号。绿色植物特有的叶绿素荧光信号因此成为了反应光合作用强度的一个极为重要的指标。在生态学中, SIF 信号已成为目前大时空尺度或全球尺度下反应总初级生产力以及碳循环的最主要的数据源之一^[1-4]。如今全球气候及生态变化引起越来越多的关注, 叶绿素荧光数据对于监测感兴趣区域生态以及植物生产力的动态具有重要的意义, 可以为生态学, 水文学或农业相关研究提供关键的数据支撑。近年来一些卫星或者航空飞行器被用来检测 SIF 信号, 在相关领域引发了一系列不同时空尺度上的研究^[5-8], 如 Global Ozone Monitoring Experiment-2 (GOME-2) 卫星提供的全球覆盖的 SIF 遥感数据。然而 GOME-2 现有产品的较低的时空分辨率阻碍了细粒度上 SIF 的研究, 如使用地表观测来研究 SIF 与 GPP 之间的耦合关系。从 2017 年 10 月开始, TROPosphere spheric Monitoring Instrument (TROPOMI) 卫星产品开始投入使用^[9], 其空间分辨率约为 7×3.5 公里, 并且为逐天的数据。这套 SIF 卫星数据可以显著的改善由于较低的空间分辨率或者时间分辨率所带来的限制, 但其样点式的观测仍然无法提供感兴趣区域内高分辨率的连续数据, 而且尚无法提供长期历史 SIF 记录来耦合特定感兴趣区域 GPP 数值。

美国国家航空航天局的轨道碳观测者 2 号卫星 OCO-2 (Orbiting Carbon Observatory-2) 在很大程度上改善了这一现状^[10,11]。该卫星自 2014 年 9 月发射之后就持续提供其轨道上的每天的叶绿素荧光数据观测值。OCO-2 卫星的 Footprint 大小为 $1.3 \times 2.25 \text{ km}^2$, 其空间分辨率上是截至目前为止可用的 SIF 遥感产品中最高的, 这样的高分辨率更有利于理解景观的格局和异质性对 SIF 的影响以及 SIF 和 GPP 的关系^[12-17]。但是由于 OCO-2 卫星的轨道是条带状的 OCO-2 SIF 数据并非全球覆盖, 因此之前的研究主要针对恰好落于 OCO-2 轨道之下的有限的区域, 而且其轨道条带之间具有很大的间隙。对于某一特定的感兴趣区域而言, 在特定时间内仅有较少比例的研究区域有可利用的 OCO-2 数据, 极端情况下甚至无数据可用。OCO-2 卫星的巡回周期为 16 天, 为了得到感兴趣区域内空间覆盖范围尽可

能大的数据集产品, OCO-2 原始叶绿素荧光遥感数据集常被整合成某个时间周期内的空间分辨率为 1 度的产品, 但是这样使得 OCO-2 SIF 产品的高空间分辨率优势不复存在, 显著地影响了 OCO-2 SIF 在相关研究之中的充分利用。

为了尝试解决全球遥感 SIF 数据集的空间不连续性, 近来一些全球 SIF 数据集重建研究开始着力解决这一问题^[18-20]。但对于区域或景观尺度上的研究来讲, 一般只关注特定的感兴趣区域, 全球尺度的数据构建体系尺度过大, 其通用的数据重建模型对于特定的感兴趣区域来说, 叶绿素荧光数据的区域特异性或针对性不够, 从而一定程度上影响研究的数据质量。本研究的思路为利用机器学习方法, 遥感影像处理技术, 在景观生态学专家知识系统指导下, 为感兴趣区域内的每一种植被类型在每个 16 天的时间步长上建立有效模型, 这些模型整合在一起形成了特定感兴趣区域在特定时间段的叶绿素荧光数据重建框架。本论文以华北平原为例, 作为感兴趣区域范围。目标重建数据集的分辨率选为 0.05 度, 时间周期选为 2018 年生长峰季 (6, 7, 8 月, 每 16 天)。在本实验中用于重建 SIF 数据的特征源数据是 MODIS 地面反照率数据。

1 基于机器学习和生态控制的数据重建框架

本论文的实验流程包括数据预处理, 训练集生成, 在生态学原理控制之下的多层感知机人工神经网络训练, 感兴趣区域内预测与补全, 空间连续高分辨率数据集的生成。具体如图 1 所示。

1.1 数据预处理

OCO-2 SIF 为条带状数据, 其一个条带上 Footprint 的形状及分布如图 2 所示。其 Footprint 为不规则的四边形。原始数据集提供了每个 Footprint 的中心点和四个角点的地理坐标。由此可以完全确定每个 Footprint 的位置。

OCO-2 SIF 数据集提供的其他重要属性还有: 观测时间, 太阳入射角的值, 观测模式, 757 nm 波段 SIF 数值 (SIF757), 771 nm 波段 SIF 数值 (SIF771), 日均矫正因子 (daily_corrector), 国际陆届生物圈方案 (IGBP) 土地覆盖类型等。

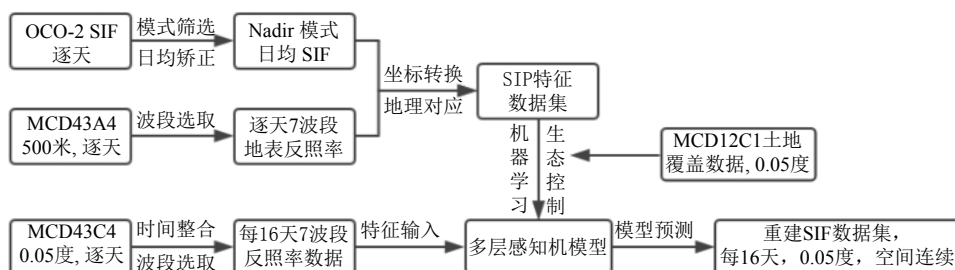


图1 兴趣区域空间连续的高分辨率叶绿素荧光数据集构建框架




图2 OCO-2 卫星条带状轨道局部及其 Footprint 示意图

根据 OCO-2 数据集提供的属性说明, 其观测模式共有三种: Nadir, Target, 以及 Glint. 其中 Nadir 观测模式为卫星传感器近似垂直观测, 本模式的数据受测量角度的影像可以忽略不计. 因此本研究的采用的目标值为 Nadir 观测模式下的叶绿素荧光数值. 另外, 原始数据集提供了 757 nm 以及 771 nm 上的叶绿素荧光数据的瞬时值. 本实验采用 757 nm 波段的数据. 由于 SIF 瞬时值受观测时间影响较大, 在本研究中, 具体采用各波段的日均矫正值, 而不是瞬时值. SIF 的日均矫正值可以由瞬时值乘以日均校正因子得到. 由于 OCO-2 Footprint 尺度上的叶绿素荧光数据的观测本身具有一定的误差, 为了获得更加稳定的目标值, 从而在训练中取得更好的效果, 对于某个中心 Footprint, 我们采用“5 最近邻”Footprint 的平均值作为最后的训练目标值.

$$SIF_y = \sum_{i=1}^5 SIF_{757}(i) * Daily_corrector \quad (1)$$

这种空间整合实质为空间重采样, 经过“5 最近邻”的处理, 参考 Footprint 的空间分辨率大小, 总体来讲可以将源数据的空间分辨率调整至 5 公里的平均精度级

别上, 在中纬度地区折算成纬度跨度约为 0.05 度, 与目标重建数据集的空间分辨率一致. 这种空间整合在牺牲较小幅度的空间分辨率的代价下, 对 OCO-2 SIF 原始数据较大的噪声误差起到了减弱的作用, 更有利于得到更高质量的训练目标数据. 根据 Frankenberg 等人的研究, 当空间重采样过程中单个像元整合的 Footprint 个数为 n 时, 随机误差或噪声会被减少至原来的 $n^{-(1/2)}$, 因此 5 个最近邻 footprint 的整合会将误差大概降至原来的 0.4 左右. 0.05 度的空间分辨率对于区域性空间连续的叶绿素荧光数据来讲, 已属于高分辨率级别, 完全可以满足与 SIF 相关研究的需要.

接下来的数据预处理步骤为地表反照率特征数据源的预处理. MODIS 地表反照率数据有多个系列. 数据集 MCD43A4 系列产品提供每天的全球覆盖的地表反照率数据, 其分辨率为 500 米, 可以为逐天的 OCO-2 Footprint 提供对应的反照率特征数据. MCD43C4 系列产品的空间分辨率为 0.05 度, 来源于 MCD43A4 逐天的数据, 经 MODIS 质量控制体系整合到 0.05 度的空间分辨率. MCD43C4 产品可以很方便的整合到时间分辨率为 16 天的数据, 为模型建立之后, 生产时间分辨率为 16 天, 空间分辨率为 0.05 度的数据集提供特征数据源.

1.2 训练集的构建

本研究基于 MODIS 卫星地表反照率数据提取模型的训练特集. OCO-2 卫星的分辨率为 $1.3 \times 2.25 \text{ km}^2$, 而 MODIS 影像的分辨率为 500 m, 因此会有一些数量的 MODIS 像元落在 OCO-2 的 Footprint 之中. 这也为我们建立基于 MODIS 反照率的训练特征提供了可能性.

由于 OCO-2 SIF 原始条带状的数据为逐天的数据, 因此我们采用了 MODIS 反照率产品系列中的 MCD43A4, 该数据为全球覆盖的逐天数据集, 可以满足实验要求.

对于每一个 Footprint, 我们取所有中心点落在其中的 MODIS 像元作为对应像元群体, 然后取该群体的七个波段各自的均值和方差作为特征集, 以此来获取每个 MODIS 波段的反照率的平均水平以及方差. 因此, 该特征集的特征维度为 14. 该特征集可以反应 MODIS 反照率个波段的平均强度和变异性.

为了生成 OCO-2 SIF 对应的特征数据集, 我们设计了如下算法:

算法 1. OCO-2 SIF 特征集构建算法

- 1) 读取某一天的 SIF 序列, 从文件中读取 SIF757 瞬时值, 日均值校正因子, 中心点坐标, 四个角点坐标, 土地覆盖类型, 将这些变量分别存储为等长向量.
- 2) 读取该日的所有全球 MODIS 影像, 取出 MODIS 左上角顶点坐标, 像元长度, 以及像元宽度. 计算出影像四个角点的范围. 建立 MODIS 该日的影像地理信息词典, 以日期作为词典名, 以影像的文件名作为词典的索引, 上述提到的其他变量作为词条内容.
- 3) 依次读取 OCO-2 SIF 向量中的 footprint, 根据其日期获取对应的 MODIS 词典. 遍历词典中的词条, 判定 OCO-2 SIF footprint 的四个角点是否均落在该 MODIS 影像之中, 如果是, 跳出循环, 进行下一步.
- 4) 根据 MODIS 影像的地理信息, 将 MODIS 像元的坐标转换为与 OCO-2 Footprint 相一致的坐标系 (WCG1984). 计算出该影像中所有落入 Footprint 之中的 MODIS 像元的行列号.
- 5) 读取并在训练集中保存目标值日均 SIF、Footprint 土地覆盖类型, MODIS 像元土地覆盖类型众数以及相对应的 MODIS 波段平均值.

在训练集的生成过程中, 我们通过 OCO-2 的地理信息查询到与其对应的 MODIS 影像的 ID, 满足要求的 MODIS 影像完全覆盖 Footprint, 如果出现一个 Footprint 跨越多幅影像的情况, 该 Footprint 会被忽略. 另外, 为了增强对 Footprint 土地覆盖类型的判断信心, 我们会选择 OCO-2 土地覆盖信息和 MODIS 像元土地覆盖类型的众数相一致的作为训练样本. 这种处理方式适用于空间分辨率不一致的情况, 可以有效增加判断信心.

1.3 模型的训练与数据集生成

为了建立 MODIS 地表反照率与 OCO-2 SIF 数值之间的关系, 我们建立了多层感知机作为数据拟合和重建的算法. 多层感知机是典型的前馈人工神经网络, 在多种机器学习任务中得到广泛的应用^[21-24]. 以 2018 年生长峰季华北地区 OCO-2 SIF 数值的全覆盖、高分辨率数据集的重建为例, 为了有针对性的完成该任务, 我们采取了生态学原理控制下的训练方法. 具体的为仅采用华北地区所在的亚洲生物地理分区内

的有效训练样本. 即 2018 年生长峰季 6 月, 7 月, 8 月的 SIF 数值作为训练目标值, 这样可以确保训练得到的 SIF 与 MODIS 的关系是建立在相应的时空条件下的, 从而保证了预测效果与数据的准确性. 在进行模型训练的同时, 我们采用了 MODIS 与 OCO-2 同时使用的 IGBP 土地覆盖数据划分训练样本, 为每种植被类型建立特异化的模型.

本研究所采用的多层感知机的具体的训练策略为通过 5 折交叉验证来选取多层感知机神经网络的各个参数, 包括激活函数, 最大迭代次数, 神经网络的层数以及每层的神经元数目, 从而在设定的参数空间内寻求最优的参数组合, 建立相对最优的模型, 用于数据的重建任务, 以求尽可能达到更好的效果, 保持原有数据的时空分布特征. 其中激活函数的寻优空间包含 logistic、tanh、以及 relu 函数; 网络层数的寻优空间为 1 至 5 层, 每层的神经元数目的寻优范围为 3 至 21 之间的奇数, 具体如表 1 所示. 由空间分辨率为 0.05 度的 MODIS 反照率数据集 MCD43C4 生成的每 16 天的特征数据, 提供给训练好的模型用于预测, 从而完成目标数据集重建.

表 1 多层感知机参数寻优范围

参数	寻优空间/配置
激活函数	logistic、tanh、relu
网络层数	1, 2, 3, 4, 5
每层的神经元数量	3, 5, 7, ..., 21
最大迭代次数	1 000 000

2 结果评估及分析

本文设置的参数寻优组合数量众多, 受篇幅所限不可能展示每一类植被类型在每种参数组合下的表现, 为了直观的展示参数寻优的过程, 我们以农田 (IGBP index = CROP) 类型在激活函数为 relu, 网络层数为 3 时的神经网络为例, 选取了几个参数组合, 展示模型在不同配置下的表现. 示例结果如表 2 所示.

表 2 多层感知机在不同参数组合上的表现示例

每层神经元数目	验证集表现 (RMSE)
(3, 3, 3)	0.082
(5, 5, 13)	0.079
(13, 17, 9)	0.071
(17, 15, 13)	0.073
(19, 17, 11)	0.074
(21, 21, 21)	0.076

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。

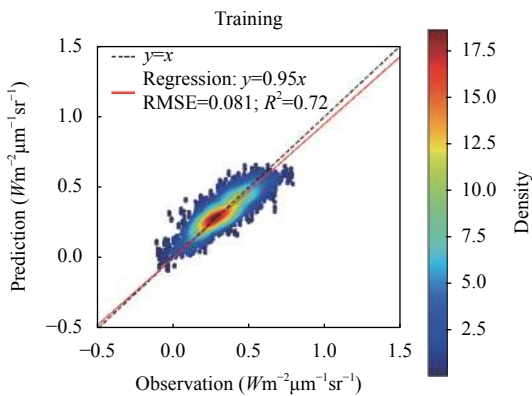


图3 数据重建模型在训练集上的表现

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。

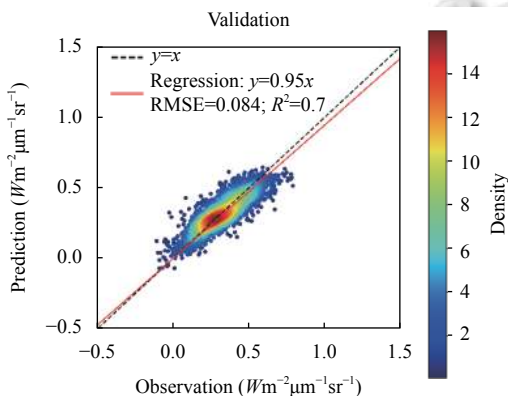


图4 数据重建模型在训练集上的表现

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。

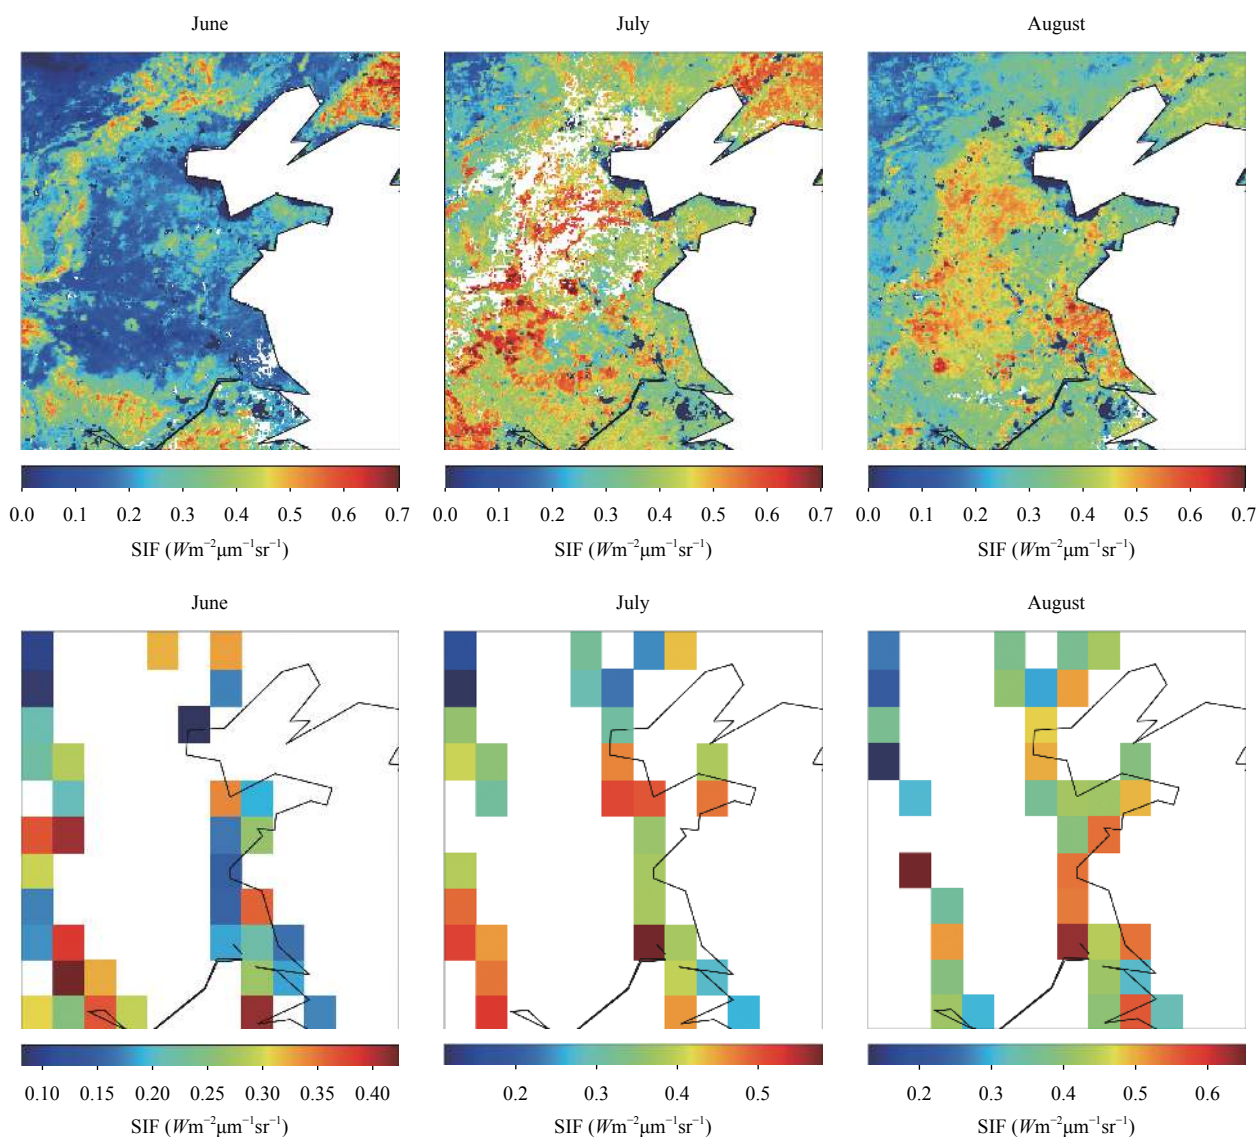


图5 华北地区2018年生长峰季SIF重建数据集以及1度分辨率原始数据集对比图(第一行为重建数据集,第二行为原始数据集重采样到1度;第一列为6月数据,第二列为7月数据,第三列为8月数据)

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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/10.1002/2016JG003580)]
- 16 Wood JD, Griffis TJ, Baker JM, *et al.* Multiscale analyses of solar - induced fluorescence and gross primary production. *Geophysical Research Letters*, 2017, 44(1): 533–541. [doi: [10.1002/2016GL070775](https://doi.org/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](https://doi.org/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](https://doi.org/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](https://doi.org/10.1029/2018GL081109)]
- 20 Bishop CM. *Neural Networks for Pattern Recognition*. Oxford: Oxford University Press, 1995.
- 21 李双成, 吴绍洪, 戴尔卓. 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](https://doi.org/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](https://doi.org/10.1109/72.80266)]