



引文格式:景映红,沈焕锋,李星华,等.数据融合视角下的遥感参量空间降尺度[J].武汉大学学报(信息科学版),2024,49(2):175-189.DOI:10.13203/j.whugis20220549

Citation: JING Yinghong, SHEN Huanfeng, LI Xinghua, et al. Spatial Downscaling of Remote Sensing Parameters from Perspective of Data Fusion[J]. Geomatics and Information Science of Wuhan University, 2024, 49(2): 175-189. DOI: 10.13203/j.whugis20220549

## 数据融合视角下的遥感参量空间降尺度

景映红<sup>1</sup> 沈焕锋<sup>1</sup> 李星华<sup>2</sup> 吴金橄<sup>3</sup> 邱中航<sup>1</sup>

<sup>1</sup> 武汉大学资源与环境科学学院,湖北 武汉,430079

<sup>2</sup> 武汉大学遥感信息工程学院,湖北 武汉,430079

<sup>3</sup> 中山大学测绘科学与技术学院,广东 珠海,519082

**摘要:**空间分辨率不足是限制遥感参量数据精细应用的主要瓶颈问题之一,而空间降尺度是提升遥感参量数据空间分辨率与应用能力的有效途径。研究学者针对不同遥感参量已发展了类型多样的降尺度方法,但还未形成统一、通用的分类体系。在深入分析当前各类参量降尺度共性问题的基础上,从降尺度所需的互补信息出发,以数据融合的视角对空间降尺度方法进行系统总结,归纳出多参量融合、时-空融合、遥感-模型融合和超分辨率重建隐式融合4类降尺度方法,剖析了各类方法的优缺点和适用场景,探讨了空间降尺度方法研究的发展趋势,为提升遥感数据精细化应用能力提供理论与技术支持。

**关键词:**遥感参量;空间降尺度;多参量融合;时-空融合;遥感-模型融合;超分辨率重建隐式融合

中图分类号:P237

文献标识码:A

收稿日期:2022-09-02

DOI:10.13203/j.whugis20220549

文章编号:1671-8860(2024)02-0175-15

### Spatial Downscaling of Remote Sensing Parameters from Perspective of Data Fusion

JING Yinghong<sup>1</sup> SHEN Huanfeng<sup>1</sup> LI Xinghua<sup>2</sup> WU Jingan<sup>3</sup> QIU Zhonghang<sup>1</sup>

<sup>1</sup> School of Resource and Environmental Sciences, Wuhan University, Wuhan 430079, China

<sup>2</sup> School of Remote Sensing and Information Engineering, Wuhan University, Wuhan 430079, China

<sup>3</sup> School of Geospatial Engineering and Science, Sun Yat-Sen University, Zhuhai 519082, China

**Abstract:** Low spatial resolution is one of the main bottlenecks restricting the fine application of remote sensing parameters. Spatial downscaling is an effective way to improve their spatial resolution and application capabilities. Researchers have developed various downscaling methods for different remote sensing parameters. However, a unified and general method classification system has not yet been formed. Based on the in-depth commonality analysis of the downscaling of various parameters, this paper systematically summarizes the spatial downscaling methods from the perspective of data fusion, taking into account the required complementary information. Four types of downscaling methods are summarized: Multi-parameter fusion, spatiotemporal fusion, remote sensing-model fusion, and super-resolution reconstruction implicit fusion. The advantages, disadvantages, and applicable scenarios of various methods are analyzed, and the development trend of spatial downscaling method research is discussed. It can provide theoretical and technical support for improving the refined application ability of remote sensing data.

**Key words:** remote sensing parameters; spatial downscaling; multi-parameter fusion; spatiotemporal fusion; remote sensing-model fusion; super-resolution reconstruction implicit fusion

基金项目:国家重点研发计划(2019YFB2102900)。

第一作者:景映红,博士,主要从事水文遥感研究。yhjing@whu.edu.cn

通讯作者:沈焕锋,博士,教授。shenhf@whu.edu.cn

定量遥感基于遥感传感器获取的地物电磁波信息定量观测目标参量<sup>[1]</sup>。在全球气候观测系统定义的142个陆表、大气和海洋的关键参数中,81个参数可通过遥感技术获得<sup>[2]</sup>。因此,遥感参量数据记录了资源环境要素的物理、生化等定量参数信息,是地球表层要素空间格局与过程演变分析的重要基础,是全球与区域资源环境问题应对的关键支撑。

空间尺度问题是遥感科学的核心问题<sup>[1]</sup>。如图1所示,气候研究、气象预报、资源管理、污染治理和农业生产等应用,对遥感参量数据提出了从全球尺度、区域尺度到局地尺度的多样化需求<sup>[3-5]</sup>。

受到卫星遥感系统物理性能的制约,不同来源的遥感参量具有显著差异化的空间分辨率,而

全球定量遥感产品的空间分辨率通常在公里级(如表1所示),难以满足区域精细化监测的需求,空间降尺度是提高遥感数据空间分辨率的有效途径<sup>[6-7]</sup>。

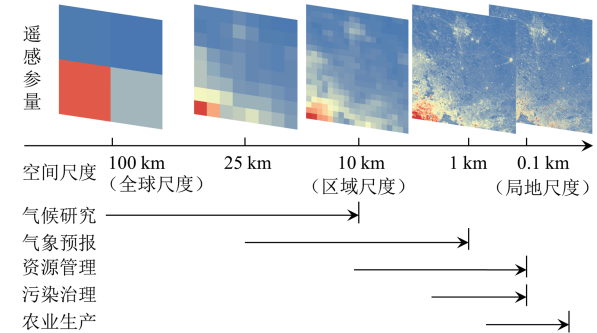


图1 不同研究领域对遥感参量空间分辨率的需求

Fig. 1 Requirements for Spatial Resolution of Remote Sensing Parameters in Different Fields

表1 本文涉及典型目标遥感参量的空间分辨率概况

Tab. 1 Spatial Resolution of Typical Target Remote Sensing Parameters in This Paper

遥感参量	典型参量	分辨率/km	主要数据来源
水循环参量:降水、陆面蒸散、土壤水分、雪水当量、蓄水量等	降水	约25	热带降雨测量任务
		约10	全球降水测量计划
	土壤水分	约40	土壤水分和海洋盐度卫星
地表辐射收支参量:太阳辐射、宽波段反照率、地表温度和热红外发射率、地表长波辐射收支等	地表温度	约36	土壤水分主-被动遥感卫星
		约25	高级微波扫描辐射计/风云三号微波辐射成像仪
		约5	甚高分辨率辐射计/欧洲气象卫星可见光红外成像仪
		约3	欧洲气象卫星自旋增强可见光与红外成像仪
大气循环参量:大气温度、湿度、风速、气溶胶、二氧化碳/甲烷和其他温室气体、臭氧等	气溶胶光学厚度	约1	中分辨率成像光谱仪
		约10	中分辨率成像光谱仪
		约5	葵花8号高像素红外线成像仪/甚高分辨率辐射计
生物物理/化学参量:冠层生化特性、植被指数、吸收光合有效辐射比例、植被覆盖度等	植被指数	约4	地球静止环境业务卫星
		约3	中分辨率成像光谱仪/自旋增强可见光与红外成像仪
海洋参量:海表热通量、海洋水色、海冰、海表温度等	海表温度	约1	中分辨率成像光谱仪/植被传感器
		约25	高级微波扫描辐射计

目前,针对“水-土-气-生”等多类型的遥感参量,研究学者已经提出大量的空间降尺度方法。结合“降尺度(Downscaling)”和“卫星(Satellite)”两个关键词,在Scopus (<https://www.scopus.com/>)数据库中进行文献检索和分析,近十年来遥感参量空间降尺度的研究热度逐步加强,发表论文数量呈指数上升,如图2所示。

已有学者分析和评述了典型遥感参量数据的降尺度研究。从方法原理的角度,土壤水分降尺度方法可分为统计模型方法和物理模型方法,但一些学者将地理统计方法、权重分解方法、数据同化方法和机器学习方法也划分为独立的类

别<sup>[8-10]</sup>。针对地表温度空间降尺度,文献<sup>[11]</sup>将其分为统计回归方法、调制分解方法、图像融合方法和机器学习方法。针对土壤水分空间降尺度,文献<sup>[3-4]</sup>从输入数据类型的角度将其分为基于卫星数据的方法、基于土壤表层属性的方法和模型/数据驱动(数据同化和机器学习)的方法。由此可见,现有的降尺度方法分类体系存在不兼容、不统一问题,缺乏对各类遥感参量降尺度研究的共性分析。

如前所述,空间降尺度是一个提升空间分辨率、增加细节信息的过程。无论何种降尺度方法都需要引入互补信息,才能实现以上目的,其实

质是数据融合<sup>[12-17]</sup>。因此,本文从数据融合的新视角,根据互补信息来源将遥感降尺度方法划分为多参量融合方法、时-空融合方法、遥感-模型融合方法和超分辨率重建隐式融合方法,如图 3 所示。本文旨在打通空间降尺度和数据融合两个领域的壁垒,梳理二者之间的联系。在此基础上,以多种典型特征参量的空间降尺度为例,阐述不同方法之间的共性和特性,剖析其优缺点与适用场景,并探讨未来的发展趋势。

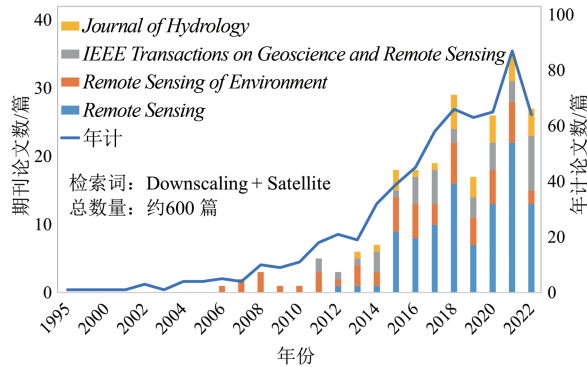


图 2 历年遥感参量降尺度文献数量及数量排名前 4 的期刊(检索截止时间:2022-07-28)

Fig. 2 Number of Downscaling Papers on Remote Sensing Parameters and the Top 4 Journals by Volume

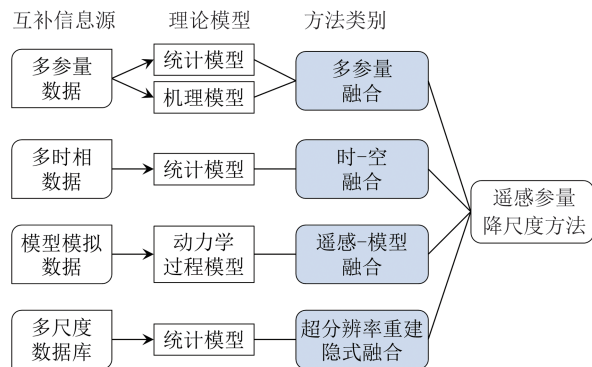


图 3 遥感参量空间降尺度方法体系

Fig. 3 Methodological System for Spatial Downscaling of Remote Sensing Parameters

## 1 多参量融合方法

多参量融合方法通过融合低分辨率的目标参量和高分辨率的辅助参量,实现目标参量的空间降尺度。此类方法首先在粗尺度上构建辅助参量与目标参量之间的关系模型,然后基于尺度不变假设应用于精尺度的数据上,通过输入高分辨率的辅助参量输出高分辨率的目标参量。根据关系模型的构建准则,此类方法分为统计降尺度和物理降尺度。

### 1.1 统计降尺度

统计降尺度方法利用统计模型融合多参量数据,构建低分辨率的辅助参量与目标参量之间的统计关系模型,基于空间尺度不变原则,将高分辨率的辅助参量输入统计关系模型,估算高分辨率的目标参量,如图 4 所示。图 4 中, $Y$  表示低分辨率(low resolution, LR)参量, $X$  表示高分辨率(high resolution, HR)参量, $T$  表示目标参量, $A$  表示辅助参量, $n$  表示辅助参量数目。

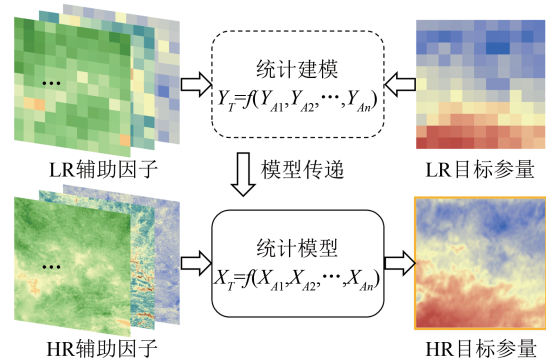


图 4 统计降尺度方法

Fig. 4 Statistical Downscaling Methods

现有统计降尺度方法可分为传统回归方法和机器学习方法。大量研究采用传统回归方法拟合辅助参量与目标参量之间的相关关系,包括广义线性回归模型和非线性回归模型。其中,广义线性回归模型包括普通线性回归<sup>[18-19]</sup>、地理加权回归<sup>[20]</sup>、泊松回归<sup>[21]</sup>等模型;非线性回归模型包括二阶多项式<sup>[22]</sup>、幂函数<sup>[23]</sup>等模型。然而,传统回归模型对多种参量构建统一、显式的关系模型,难以顾及地球表层系统各要素相互作用的复杂性,从而限制了统计回归降尺度的精度。因此,研究者引入机器学习方法建立多参量之间的复杂、隐式关联,包括决策树<sup>[24]</sup>、支持向量机<sup>[25]</sup>和人工神经网络<sup>[26]</sup>等算法。在训练样本充足的条件下,机器学习方法显著提升了统计回归降尺度的效果<sup>[27]</sup>。近年来,由于多层次网络能够深入挖掘各种参量的空间特征和潜在关联,深度学习算法被逐步应用于遥感参量数据的降尺度研究<sup>[28]</sup>。由于其处理高维数据的优势,此类算法在统计降尺度研究领域极具潜力。但实际上,辅助参量与关系模型往往是相互依赖的,统计降尺度方法应根据不同的数据条件选取最优的统计模型<sup>[29]</sup>。

目前,统计降尺度方法仍然是遥感参量空间降尺度的主流方法,已经被广泛应用于土壤水分<sup>[30-37]</sup>、地表温度<sup>[38-43]</sup>、降水<sup>[44-46]</sup>、PM2.5<sup>[47-48]</sup>和水



汽含量<sup>[49]</sup>等多种遥感参量。近期典型的应用案例包括但不限于:如文献[50]提出地理加权面到面回归克里金方法,融合海拔、地表温度和植被指数,估算高分辨率的土壤水分;文献[51]构建二次抛物剖面模型表征降水随海拔和植被指数变化的规律,对每月降水进行空间降尺度;文献[29]设计由7组辅助参量和5种回归模型组成的35种方案,对地表温度进行降尺度测试,发现辅助参量与回归模型相互依赖,机器学习方法对高维辅助数据的适用性更强;文献[52]利用全残差深度神经网络融合多种空间因子、气象因子和社会经济因子,实现二氧化氮参量的空间降尺度。

融合多种参量的统计降尺度方法计算简单,并且充分考虑了环境背景信息,具有较强的实用性。在数据层面,此类方法受辅助参量精度、连续性和各种参量相关性的影响较大;在模型层面,由于地球表层系统的时空复杂性、相互作用复杂性和驱动机制复杂性<sup>[53]</sup>,多参量之间的统计关系在不同尺度条件下可能并不统一,尺度不变假设存在一定的不确定性,缺乏可靠的机理解释。

## 1.2 物理降尺度

物理降尺度方法利用机理模型融合多参量数据,显式地表征辅助参量与目标参量之间的内在物理关联,实现目标参量的空间降尺度,如图5所示。在多参量融合的框架下,物理降尺度与统计降尺度的主要区别在于关系模型的构建方式,由于其主要依赖于确定的物理模型,从而降低了模型构建造成的不确定性,物理降尺度方法对模型参数的要求更高。

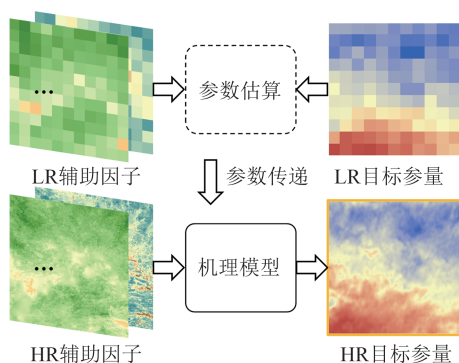


图5 物理降尺度方法

Fig. 5 Physically Deterministic Downscaling Methods

实际应用中,利用低分辨率的辅助参量与目标参量估算模型参数<sup>[54-55]</sup>,将高分辨率的辅助参

量和模型参数输入机理模型,进而输出高分辨率的目标参量。例如,基于物理和理论尺度变化的分解系列经典算法利用蒸散发效率模型融合地表温度、植被指数和土壤水分,通过低分辨率的遥感观测数据估算模型所需的复杂土壤参数,进而反演高分辨率的土壤水分<sup>[56-61]</sup>。文献[62]利用粗尺度上估算的权重参数求解综合土壤水分,有效解决平衡水分模型中如何衡量各收入项和支出项重要程度的难题<sup>[63-64]</sup>。此外,在模型参数已知的少数情况下,研究学者直接将高分辨率的辅助参量输入机理模型,估算高分辨率的目标参量,而低分辨率的遥感观测数据被用于残差校正,进一步提升高分辨率数据的精度<sup>[65-66]</sup>。

物理降尺度方法虽然具有理论严谨、模型相对稳定和物理可解释等优势,但是此类方法受辅助参量精度和连续性的影响较大;难以顾及模型参数的尺度效应,在空间异质性较高的地区适用性较差;机理模型往往对自然界真实过程进行简化,从而增加了模型的不确定性。

## 2 时-空融合方法

时-空融合方法充分利用多传感器数据在时间分辨率与空间分辨率上的互补关系,通过融合其他时相的高-低分辨率参量数据对,构建目标参量时相转换或空间尺度转换的映射关系,实现对目标时相参量的空间降尺度<sup>[67-69]</sup>,如图6为两个传感器时-空融合的示意图。通过上述过程,融合数据同时具备多个传感器中最高的时间和空间分辨率<sup>[70-71]</sup>。Y表示低分辨率数据,X表示高分辨率数据, $t_1$ 和 $t_2$ 表示不同时相。

根据时空转换模型的构建机制,现有的时-空融合方法分为像元分解方法<sup>[72-74]</sup>、时空滤波方法<sup>[68-75]</sup>以及机器学习方法<sup>[76-77]</sup>。像元分解方法借鉴光谱混合理论<sup>[78]</sup>,在假设地表要素不发生突变的前提下,利用邻近时相高分辨率数据估算组分丰度,进一步联合多个低分辨率像元构建线性光谱混合方程,反向求解高分辨率端元光谱值,从而达到空间降尺度的目的。基于上述思想,文献[72]提出一种多传感器多分辨率融合方法,是目前追溯到最早的时-空融合方法,但该模型受解混误差影响较大,并存在较为严重的块状效应问题。因此,研究学者进行了一些改进,如时空反射率解混方法<sup>[73]</sup>、抗块状效应的空间解混方法<sup>[79]</sup>等。

时空滤波方法通过设置时空邻域窗口,基于



空间关系的时域不变性或时域关系的尺度不变性,对邻域内每一个像元进行高-低分辨率转换建模,基于像元相似性信息进行时空滤波,实现对邻域中心像元的求解。基于上述基本思想,文献[68]提出了时空自适应反射率融合方法,研究学者针对该方法在建模方法、相似像元筛选、权重估算等方面的不足,进一步提出相应的优化方

法,如增强型时空自适应反射率融合方法<sup>[75]</sup>、基于非局部滤波的时空融合方法<sup>[80]</sup>等。值得关注的是文献[81]建立了时空一体化融合方法,实现了从两个传感器到多个传感器时空融合的突破。该类方法模型简单、效率较高,是当前应用最为广泛的时-空融合方法,但由于模型简单限制了融合精度的进一步提升。

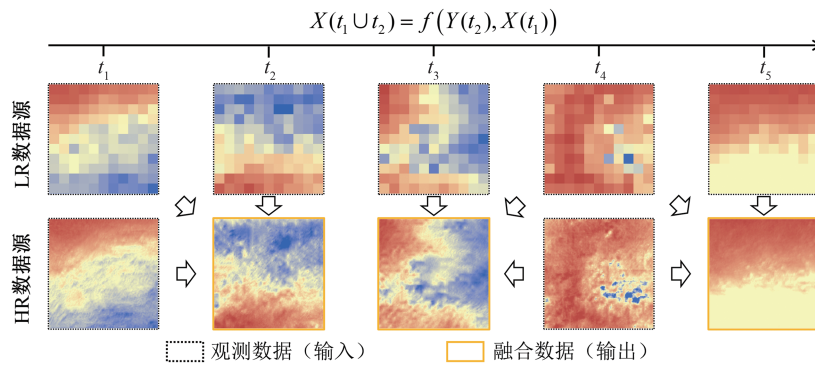


图 6 时-空融合降尺度方法

Fig. 6 Spatiotemporal Fusion Downscaling Methods

传统的时-空融合模型主要采用线性关系建模,对地表要素的复杂空间关系与变化特征考虑不足,从而限制了融合精度。为此,研究学者引入机器学习算法对时空转换关系进行非线性刻画。目前,稀疏表达<sup>[76-82]</sup>、极限学习机<sup>[83]</sup>、随机森林<sup>[84]</sup>、深度学习<sup>[85-87]</sup>等技术被陆续引入到时空融合模型中。由于机器学习具有强大的非线性建模能力,能够深入挖掘地表参量及其变化过程的复杂特征,这类时-空融合方法的处理精度通常更高,对不同变化场景的适用性也更强。其局限在于针对不同传感器组合的应用,通常需要重新训练学习。

目前,时-空融合方法已经被广泛应用到多种遥感参量的空间降尺度研究领域,如地表反射率<sup>[68-75]</sup>、地表温度<sup>[88-90]</sup>、土壤水分<sup>[91-93]</sup>、水汽含量<sup>[94]</sup>、蒸散发量<sup>[95]</sup>、植被指数<sup>[96-97]</sup>和叶面积指数<sup>[98-99]</sup>等。典型的应用案例包括但不限于:如文献[99]应用时空自适应反射率融合方法融合中分辨率成像光谱仪(moderate-resolution imaging spectro-radiometer, MODIS)和 Landsat 叶面积指数,基于空间关系的时域不变性,借助参考时相的空间信息构建尺度转换模型,利用邻域相似像元的加权函数求解中心像元,获得具备较高时空分辨率的叶面积指数;基于类似的思路,文献[100]利用增强型时空自适应反射率融合方法融合 MODIS 和 Landsat 地表温度数据,进一步实现了高分辨率土壤水分的反演;文献[91]顾及时

域关系的尺度不变性,采用基于非局部滤波的时空融合方法融合土壤水分主-被动遥感(soil moisture active-passive, SMAP)卫星的 9 km 和 36 km 土壤水分产品,利用低分辨率的时序信息构建时相转换模型,通过非局部滤波函数估计目标时相的高分辨率数据,从而对 SMAP 雷达传感器损坏后的 9 km 产品生成提供了解决思路。

时-空融合方法顾及多源观测的时间和空间分辨率的互补特征,通过构建同种参量的多时相、多尺度转换关系实现尺度下推,具有较大的应用潜力。时-空融合方法也存在一些瓶颈问题,特别是当地物类型在不同时相中发生较大变化、传感器的空间分辨率相差较大时,融合数据难以精确刻画地物的细节信息。

### 3 遥感-模型融合方法

遥感观测和模型模拟是获取地球表层系统面域信息的两种主要手段,遥感观测通过地物电磁波信息反演目标参量在观测时刻和空间上的“真值”,而模型模拟通过内在的物理过程和动力学机制给出目标参量在时间和空间上的连续演进<sup>[101]</sup>。为了结合两者的优势,遥感-模型融合方法基于动力学过程模型,通过不断融合遥感数据和模型输出,实现目标参量的空间降尺度,也被称为动力降尺度,如图 7 所示。

此类方法主要基于数据同化技术实现降尺

度,即将低分辨率的遥感参量依次输入动力学过程模型,不断改变模型轨迹,进而输出高分辨率的目标参量。主要过程包括:首先,基于先验信息模拟高分辨率的目标参量;其次,同化低分辨率的遥感观测数据至模型,自动调整模型轨迹,提升高分辨率目标参量的估计精度;最后,将同化输出作为先验信息,重复上述步骤以不断更新模型输出,直至所有时刻的观测数据都完成同化<sup>[102-105]</sup>。基于以上思路,一些学者利用集合卡尔曼滤波同化技术融合低分辨率遥感观测数据和高分辨率模型模拟数据,实现土壤水分<sup>[106-107]</sup>和叶面积指数<sup>[108]</sup>等典型遥感参量的精细化监测。文献<sup>[109]</sup>利用四维变分数据同化方法,将低分辨率的遥感亮度温度数据同化至地表水文模型,不断提升高分辨率土壤水分的模拟精度。此类方法充分顾及多源异质数据的互补性,利用数据同化技术平衡模型误差、初始条件和观测误差的影响,动态融合遥感数据和模型输出,获得高分辨率的目标参量。除同化技术外,一些研究学者利用传统的参数优化算法,以最小化模型输出和观测数据的偏差为目标,不断优化模型参数,进而估算高分辨率的目标参量,实现简化的动力降尺度<sup>[110-111]</sup>。这些方法的复杂程度介于物理降尺度和数据同化降尺度之间,在一定程度上顾及了模型的不确定性。

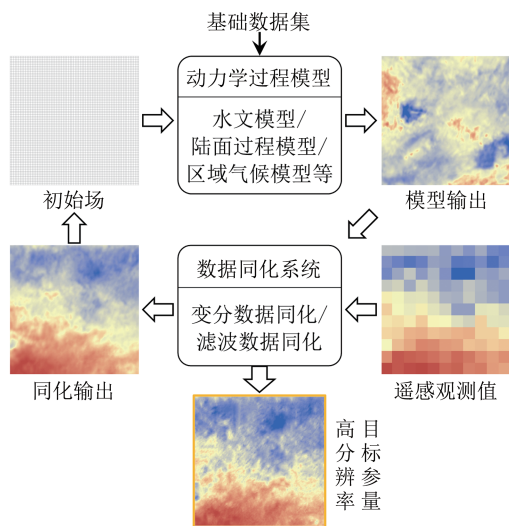


图7 遥感-模型融合降尺度方法

Fig. 7 Remote Sensing-Model Fusion Downscaling Method

总之,遥感-模型融合方法主要通过数据同化技术,动态融合遥感数据和动力学过程模型输出,实现目标参量的空间降尺度。此类方法具有可估算参量全、物理意义明确等优点,能够获取

时间分辨率高、空间连续性强的目标参量。由于空间降尺度研究对分辨率和一致性具有较高要求,通常需要大量的计算资源。由于缺乏高分辨率的驱动场,此类方法难以适用于较高分辨率遥感参量的空间降尺度。

#### 4 超分辨率重建隐式融合方法

超分辨率技术是计算机视觉和图像处理领域的研究热点,旨在通过构建模型从低分辨率图像中重构出高分辨率图像。遥感参量数据与计算机视觉领域的自然影像或视频序列具有相似性<sup>[112]</sup>,因此图像超分辨率技术也被引入到遥感参量的空间降尺度研究领域。此类方法以多尺度数据库为驱动,一般利用机器学习训练高-低分辨率数据对,获得空间降尺度模型并进行应用,如图8所示。虽然此类方法通常被称为单幅影像超分辨率技术,但其核心却是一种隐式融合,即输入遥感参量数据与训练库中大量多尺度数据的融合。

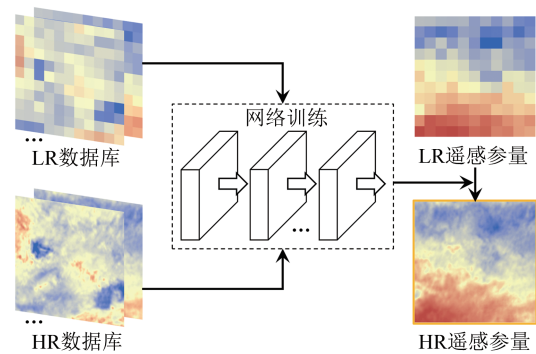


图8 超分辨率重建隐式融合降尺度方法

Fig. 8 Implicit Fusion Downscaling Method Based on Super-Resolution Reconstruction

此类方法通常包括3个步骤:(1)利用具有不同空间分辨率的已有数据,构建配对的训练数据集;(2)基于低-高分辨率配对数据集,训练生成超分辨率降尺度模型;(3)将训练的降尺度模型应用于待处理的低分辨率数据,生成高分辨率的遥感参量数据。近年来,得益于卷积神经网络强大的数据挖掘和非线性拟合能力,基于超分辨率重建方法的降尺度研究取得了显著进展<sup>[113-114]</sup>。例如,文献<sup>[115]</sup>基于海表温度遥感产品构建多尺度数据库,引入超分辨率卷积神经网络<sup>[116]</sup>生成高分辨率的海表温度,相比于传统降尺度方法显著提升了峰值信噪比。文献<sup>[117]</sup>利用MODIS和Landsat湖面水温构建低-高分辨率配对数据集,

引入超分辨率卷积神经网络训练降尺度模型,估算高分辨率的湖面水温。文献[118]利用深度卷积神经网络,借助多尺度数据库反演高分辨率的海洋风速。文献[119-120]利用多种深度学习模型融合高级微波扫描辐射计和 MODIS 海表温度数据库,实现海表温度的空间降尺度。此外,与常规的卷积神经网络相比,生成对抗网络<sup>[121]</sup>能够创建更具有视觉真实感的图像,也逐渐被用于遥感参量的降尺度研究<sup>[122-123]</sup>。

超分辨率重建隐式融合降尺度方法无需其他类型的辅助数据,仅需同一类型的训练数据

库,一旦模型训练之后也具备较高的计算效率。但此类方法缺乏充分的地学约束,在超出训练集范围时则会出现性能的明显下降,即典型的泛化性能不足,一般适合于倍数较低的降尺度应用。

## 5 方法比较

本文以被动微波土壤水分的空间降尺度为例,探讨不同方法降尺度的优缺点。图 9(a)为 SMAP 被动微波土壤水分数据,其空间分辨率为 36 km。图 9(b)~9(e)为不同方法的降尺度结果。

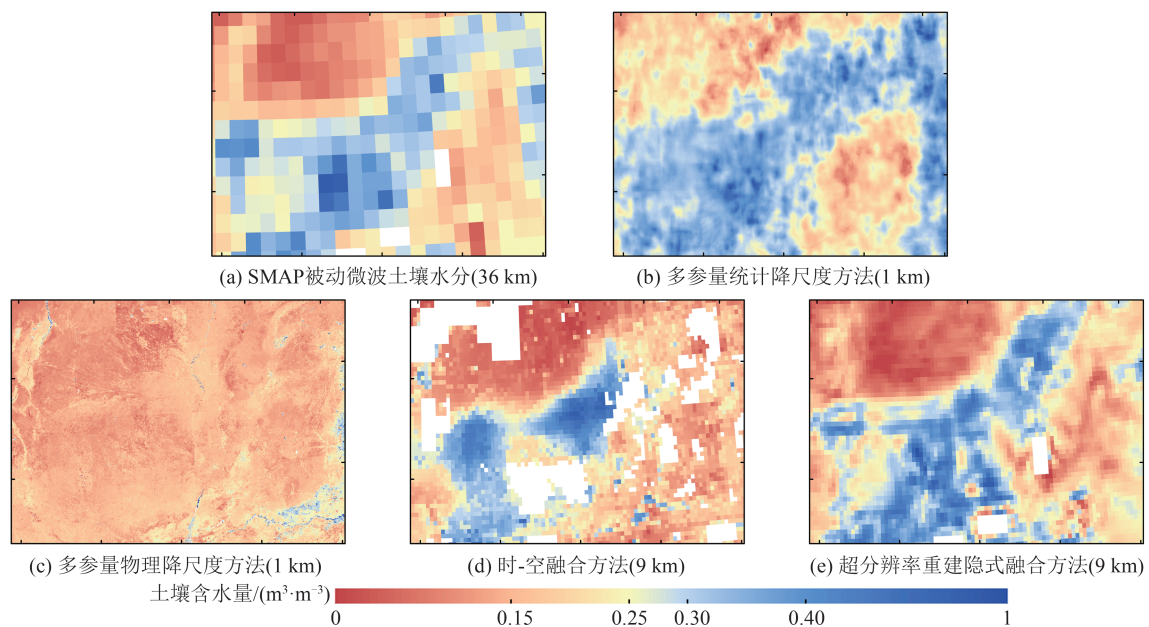


图 9 不同降尺度方法的对比

Fig. 9 Comparison of Different Downscaling Methods

图 9(b)为基于深度学习的多参量统计降尺度结果,辅助的高分辨率数据包括植被指数、地表温度和干旱指数等,得益于从多种辅助数据中提取的互补信息,其结果表现良好,具备较为丰富的细节信息<sup>[124-125]</sup>,整体趋势也与原始数据保持一致;图 9(c)为多参量物理降尺度结果,虽然该类方法理论严谨,但不确定性因素较多,其降尺度结果与原被动微波土壤水分相比存在较大偏差<sup>[61]</sup>,因此在本应用中表现并不理想,这也是该类方法应用并不广泛的原因之一,遥感-模型融合方法与此类方法的优缺点较为类似<sup>[126]</sup>。时-空融合方法在地物变化不大的情况下具有非常大的优势,降尺度结果精度较高<sup>[91]</sup>,但该方法需要选择合适的高-低分辨率数据对,如果时-空融合所需的数据对难以获取,则可能导致其时-空覆盖率的降低,如图 9(d)所示;由于深度学习技术的高

速发展,超分辨率重建隐式融合方法在遥感降尺度领域具有较大的应用潜力,其难点是多尺度数据库构建,并且降尺度后分辨率提升的倍数受限,获得的细节信息相对较少,如图 9(e)所示。

不同遥感降尺度方法各有其优缺点和适用场景。实际应用需要根据不同的数据基础、计算资源和应用需求选取最适合的空间降尺度方法。

## 6 评价方式

在遥感参量的空间降尺度研究中,通常采用模拟实验评价、保真度评价、站点验证、交叉验证、三重组合分析的方式进行精度评价,如图 10 所示。在各种评价方式中,相关系数/决定系数、偏差、均方根误差/无偏均方根误差、峰值信噪比和结构相似性指数等定量评价指标常用于衡量



降尺度结果的空间分布、细节信息和时序变化的准确性。

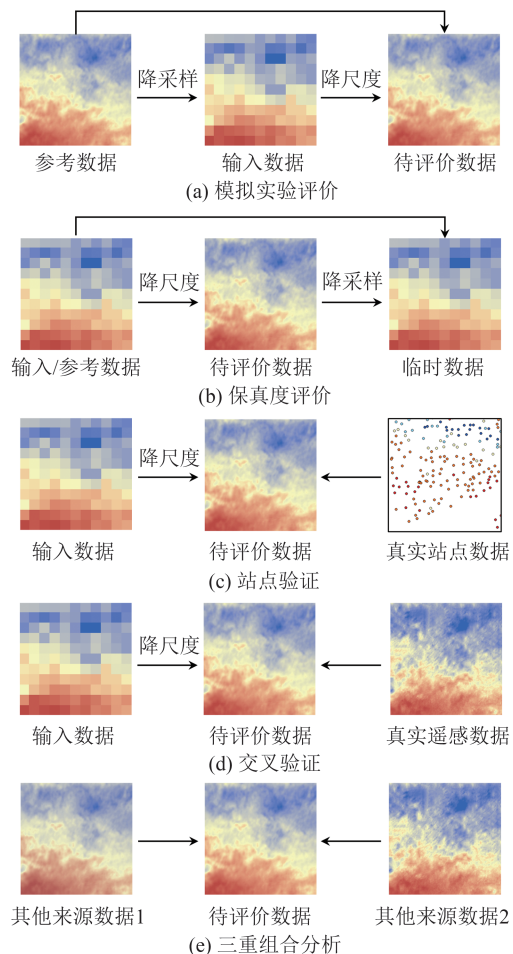


图10 遥感参量降尺度评价方式

Fig. 10 Evaluation Methods for Downscaling of Remote Sensing Parameters

1) 模拟实验评价。以原始高分辨率数据为参考,通过降采样获得低分辨率数据,再降尺度至原始分辨率,根据原始参考数据评价降尺度数据。此类方法能够对降尺度算法的性能进行客观的评价,但难以获取特定区域和时段原始高分辨率数据,因此无法适用于一些具体应用的评价工作。

2) 保真度评价。对经过降尺度后的遥感数据进行降采样,将空间分辨率转换到降尺度之前的状态,比较其与原始输入数据的差异情况。此类方法可以有效评价空间降尺度方法的保真度,能够反映降尺度数据的整体一致性,但难以对降尺度的细节提升效果进行直接评价。

3) 站点验证。地基观测通常具有较高的精度,因此采用地面测量值作为参考进行精度评价是一种通用的方式。地面站点分布稀疏且不均匀,难以对区域进行整体的评价。点数据和面数

据之间尺度差异显著,尺度效应问题使得站点验证存在较大的不确定性。

4) 交叉验证。不同来源的遥感参量具有显著差异化的空间分辨率,因此对低分辨率数据进行降尺度后,可采用其他传感器的高分辨率真实数据作为参考进行精度评价。此类方法更贴近实际情况,但一些遥感参量仍然缺乏高分辨率真实数据,不同传感器的成像方式差异也使得交叉验证存在一定的不确定性。

5) 三重组合分析。当具有目标参量的3种数据集时可采用三重组合分析方法进行评价,假设3种数据集与真值之间均存在线性关系、误差相互独立、误差具有时域稳定性以及误差与真值相互独立的特征,通过计算数据集之间的协方差,能够获得各个数据集的随机误差方差和信噪比<sup>[127-129]</sup>。该方法能够在缺少真值的情况下,有效地评价各种数据集的随机误差和不确定性。

## 7 发展趋势

尽管研究学者已经发展了多种类型的空间降尺度方法,但在理论方法和具体应用上仍然具有较大的发展空间,包括但不限于如下几个方面:

1) 机器学习的深度应用。尽管机器学习在各类降尺度研究中已经得到广泛应用,但在深度上还亟待进一步发展。目前,尽管随机森林、神经网络、深度学习等机器学习方法已经应用于多种参量的空间降尺度,但更多采取拿来即用的方式,没有充分顾及地学参量的独特性。如何构建全新的深度神经网络模型来学习遥感参量的复杂特征,提升降尺度方法在不同时空条件下的鲁棒性,是极具潜力的挑战性方向。

2) 机理-统计方法的耦合。物理方法和统计方法各具优势,进行二者的耦合是遥感参量降尺度的新思路。例如,在多参量融合方法中,机理模型与学习模型耦合可以有效结合物理驱动和数据驱动的科学范式,提高模型的精度、泛化性和可解释性<sup>[130]</sup>;在动力降尺度和统计降尺度联合方面,数据同化与统计方法耦合的策略已被广泛应用于区域气候预报的降尺度研究,文献证明这种耦合方法显著提升了预测准确性<sup>[131-132]</sup>。

3) 多源数据的一体化融合。如前所述,空间降尺度通常需要对多源或多尺度数据提供的互补信息进行融合来实现。当前,不断累积的地基观测、遥感观测、数值模拟和社会感知等多源数

据可以有效支撑各种类型的降尺度方法研究,然而现有研究仍然局限于单类或两类信息的融合。因此,如何充分利用多源数据的互补信息,构建一体化融合降尺度模型,是提升遥感参量空间降尺度效能的潜在途径。

## 8 结 语

面对区域生态环境精细化监测的应用需求,遥感参量数据的空间降尺度研究具有重要意义。本文从数据融合的新视角,将现有降尺度方法划分为4类:多参量融合方法、时-空融合方法、遥感-模型融合方法和超分辨率重建隐式融合方法,并概述了典型遥感参量的降尺度研究,详细介绍了各类方法的理论依据、方法过程及其优缺点,进一步探讨了空间降尺度研究的未来发展趋势,以期对遥感参量空间降尺度的方法研究与深入应用提供参考与支撑。

## 参 考 文 献

- [1] Li Xiaowen, Wang Yiting. Prospects on Future Developments of Quantitative Remote Sensing[J]. *Acta Geographica Sinica*, 2013, 68(9): 1163-1169. (李小文, 王祎婷. 定量遥感尺度效应刍议[J]. 地理学报, 2013, 68(9): 1163-1169.)
- [2] Wu X D, Xiao Q, Wen J G, et al. Advances in Quantitative Remote Sensing Product Validation: Overview and Current Status[J]. *Earth-Science Reviews*, 2019, 196: 102875.
- [3] Peng J, Loew A, Merlin O, et al. A Review of Spatial Downscaling of Satellite Remotely Sensed Soil Moisture[J]. *Reviews of Geophysics*, 2017, 55(2): 341-366.
- [4] Sabaghy S, Walker J P, Renzullo L J, et al. Spatially Enhanced Passive Microwave Derived Soil Moisture: Capabilities and Opportunities [J]. *Remote Sensing of Environment*, 2018, 209: 551-580.
- [5] Luan Haijun, Tian Qingjiu, Zhang Xinxin, et al. Trends on Scaling Research for Land Surface Parameters in Quantitative Remote Sensing[J]. *Advances in Earth Science*, 2018, 33(5): 483-492. (栾海军, 田庆久, 章欣欣, 等. 定量遥感地表参数尺度转换研究趋势探讨[J]. 地球科学进展, 2018, 33(5): 483-492.)
- [6] Atkinson P M. Downscaling in Remote Sensing[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2013, 22: 106-114.
- [7] Tang Yunwei, Zhang Jingxiong. Area-to-Point Cokriging and Multiple-point Geostatistical Simulation for Remotely Sensed Image Fusion [J]. *Geomatics and Information Science of Wuhan University*, 2014, 39(7): 856-861. (唐韵玮, 张景雄. 基于面-点协同克里格和多点地统计模拟的遥感影像融合方法[J]. 武汉大学学报(信息科学版), 2014, 39(7): 856-861.)
- [8] Qu Y Q, Zhu Z L, Montzka C, et al. Inter-Comparison of Several Soil Moisture Downscaling Methods over the Qinghai-Tibet Plateau, China [J]. *Journal of Hydrology*, 2021, 592: 125616.
- [9] Zhou Zhuang, Zhao Shaojie, Jiang Lingmei. Downscaling Methods of Passive Microwave Remote Sensing of Soil Moisture[J]. *Journal of Beijing Normal University (Natural Science)*, 2016, 52(4): 479-485. (周壮, 赵少杰, 蒋玲梅. 被动微波遥感土壤水分产品降尺度方法研究综述[J]. 北京师范大学学报(自然科学版), 2016, 52(4): 479-485.)
- [10] Qin Xiangdong, Pang Zhiguo, Jiang Wei, et al. Progress and Development Trend of Soil Moisture Microwave Remote Sensing Retrieval Method [J]. *Journal of Geo-Information Science*, 2021, 23(10): 1728-1742. (覃湘栋, 庞治国, 江威, 等. 土壤水分微波反演方法进展和发展趋势[J]. 地球信息科学学报, 2021, 23(10): 1728-1742.)
- [11] Zhan W F, Chen Y H, Zhou J, et al. Disaggregation of Remotely Sensed Land Surface Temperature: Literature Survey, Taxonomy, Issues, and Caveats [J]. *Remote Sensing of Environment*, 2013, 131: 119-139.
- [12] Dong Wenquan, Meng Jihua. Review of Spatiotemporal Fusion Model of Remote Sensing Data[J]. *Remote Sensing for Land & Resources*, 2018, 30(2): 1-11. (董文全, 蒙继华. 遥感数据时空融合研究进展及展望[J]. 国土资源遥感, 2018, 30(2): 1-11.)
- [13] Zhang Lifu, Peng Mingyuan, Sun Xuejian, et al. Progress and Bibliometric Analysis of Remote Sensing Data Fusion Methods (1992—2018) [J]. *Journal of Remote Sensing*, 2019, 23(4): 603-619. (张立福, 彭明媛, 孙雪剑, 等. 遥感数据融合研究进展与文献定量分析(1992—2018)[J]. 遥感学报, 2019, 23(4): 603-619.)
- [14] Li Shutao, Li Congyu, Kang Xudong. Development Status and Future Prospects of Multi-source Remote Sensing Image Fusion[J]. *National Remote Sensing Bulletin*, 2021, 25(1): 148-166. (李树涛, 李聪好, 康旭东. 多源遥感图像融合发展现状与未来展望[J]. 遥感学报, 2021, 25(1): 148-166.)
- [15] Ghassemian H. A Review of Remote Sensing Image Fusion Methods [J]. *Information Fusion*, 2016,

- 32: 75-89.
- [16] Schmitt M, Zhu X X. Data Fusion and Remote Sensing: An Ever-Growing Relationship[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2016, 4(4): 6-23.
- [17] Ghamisi P, Rasti B, Yokoya N, et al. Multisource and Multitemporal Data Fusion in Remote Sensing: A Comprehensive Review of the State of the Art [J]. *IEEE Geoscience and Remote Sensing Magazine*, 2019, 7(1): 6-39.
- [18] Jia S F, Zhu W B, Lü A, et al. A Statistical Spatial Downscaling Algorithm of TRMM Precipitation Based on NDVI and DEM in the Qaidam Basin of China[J]. *Remote Sensing of Environment*, 2011, 115(12): 3069-3079.
- [19] Cao Yongpan, Jin Rui, Han Xujun, et al. A Downscaling Method for AMSR-E Soil Moisture Using MODIS Derived Dryness Index[J]. *Remote Sensing Technology and Application*, 2011, 26(5): 590-597. (曹永攀, 晋锐, 韩旭军, 等. 基于MODIS和AMSR-E遥感数据的土壤水分降尺度研究[J]. 遥感技术与应用, 2011, 26(5): 590-597.)
- [20] Xu S G, Wu C Y, Wang L, et al. A New Satellite-Based Monthly Precipitation Downscaling Algorithm with Non-stationary Relationship Between Precipitation and Land Surface Characteristics [J]. *Remote Sensing of Environment*, 2015, 162: 119-140.
- [21] Das D, Ganguly A R, Obradovic Z. A Bayesian Sparse Generalized Linear Model with an Application to Multiscale Covariate Discovery for Observed Rainfall Extremes over the United States[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(12): 6689-6702.
- [22] Piles M, Camps A, Vall-Llossera M, et al. Downscaling SMOS-Derived Soil Moisture Using MODIS Visible/Infrared Data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(9): 3156-3166.
- [23] Wang Y L, Huang X D, Wang J S, et al. AMSR2 Snow Depth Downscaling Algorithm Based on a Multifactor Approach over the Tibetan Plateau, China[J]. *Remote Sensing of Environment*, 2019, 231: 111268.
- [24] He X G, Chaney N W, Schleiss M, et al. Spatial Downscaling of Precipitation Using Adaptable Random Forests[J]. *Water Resources Research*, 2016, 52(10): 8217-8237.
- [25] Weng Q H, Fu P. Modeling Diurnal Land Temperature Cycles over Los Angeles Using Downscaled GOES Imagery[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, 97: 78-88.
- [26] Srivastava P K, Han D W, Ramirez M R, et al. Machine Learning Techniques for Downscaling SMOS Satellite Soil Moisture Using MODIS Land Surface Temperature for Hydrological Application [J]. *Water Resources Management*, 2013, 27(8): 3127-3144.
- [27] Li W, Ni L, Li Z L, et al. Evaluation of Machine Learning Algorithms in Spatial Downscaling of MODIS Land Surface Temperature [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(7): 2299-2307.
- [28] Yuan Q Q, Shen H F, Li T W, et al. Deep Learning in Environmental Remote Sensing: Achievements and Challenges [J]. *Remote Sensing of Environment*, 2020, 241: 111716.
- [29] Dong P, Gao L, Zhan W F, et al. Global Comparison of Diverse Scaling Factors and Regression Models for Downscaling Landsat-8 Thermal Data [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 169: 44-56.
- [30] Chakrabarti S, Bongiovanni T, Judge J, et al. Downscaling Satellite-Based Soil Moisture in Heterogeneous Regions Using High-Resolution Remote Sensing Products and Information Theory: A Synthetic Study [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(1): 85-101.
- [31] Piles M, Petropoulos G P, Sánchez N, et al. Towards Improved Spatio-Temporal Resolution Soil Moisture Retrievals from the Synergy of SMOS and MSG SEVIRI Spaceborne Observations [J]. *Remote Sensing of Environment*, 2016, 180: 403-417.
- [32] Zhao W, Li A N, Jin H A, et al. Performance Evaluation of the Triangle-Based Empirical Soil Moisture Relationship Models Based on Landsat-5 TM Data and in Situ Measurements [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(5): 2632-2645.
- [33] Alemohammad S H, Kolassa J, Prigent C, et al. Global Downscaling of Remotely Sensed Soil Moisture Using Neural Networks [J]. *Hydrology and Earth System Sciences*, 2018, 22(10): 5341-5356.
- [34] Long D, Bai L L, Yan L, et al. Generation of Spatially Complete and Daily Continuous Surface Soil Moisture of High Spatial Resolution [J]. *Remote Sensing of Environment*, 2019, 233: 111364.
- [35] Hu F M, Wei Z S, Zhang W, et al. A Spatial Downscaling Method for SMAP Soil Moisture Through Visible and Shortwave-Infrared Remote Sensing Data [J]. *Journal of Hydrology*, 2020,



- 590: 125360.
- [36] Deng Yawen, Ling Ziyan, Sun Na, et al. Daily Estimation of Soil Moisture over Beijing-Tianjin-Hebei Region Based on General Regression Neural Network Model [J]. *Journal of Geo-Information Science*, 2021, 23(4): 749-761. (邓雅文, 凌子燕, 孙娜, 等. 基于广义回归神经网络的京津冀地区土壤湿度遥感逐日估算研究[J]. 地球信息科学学报, 2021, 23(4): 749-761.)
- [37] Huang S Z, Zhang X, Chen N C, et al. Generating High-Accuracy and Cloud-Free Surface Soil Moisture at 1 km Resolution by Point-Surface Data Fusion over the Southwestern U. S [J]. *Agricultural and Forest Meteorology*, 2022, 321: 108985.
- [38] Zakšek K, Oštir K. Downscaling Land Surface Temperature for Urban Heat Island Diurnal Cycle Analysis [J]. *Remote Sensing of Environment*, 2012, 117: 114-124.
- [39] Hutengs C, Vohland M. Downscaling Land Surface Temperatures at Regional Scales with Random Forest Regression [J]. *Remote Sensing of Environment*, 2016, 178: 127-141.
- [40] Zhang Q, Wang N L, Cheng J, et al. A Stepwise Downscaling Method for Generating High-Resolution Land Surface Temperature from AMSR-E Data [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 5669-5681.
- [41] Zhang Yizheng, Wu Penghai, Duan Sibao, et al. Downscaling of Landsat 8 Land Surface Temperature Products Based on Deep Learning [J]. *National Remote Sensing Bulletin*, 2021, 25(8): 1767-1777. (张义峥, 吴鹏海, 段四波, 等. Landsat 8 地表温度产品降尺度深度学习研究方法研究[J]. 遥感学报, 2021, 25(8): 1767-1777.)
- [42] Zhu Xinming, Song Xiaoning, Leng Pei, et al. Spatial Downscaling of Land Surface Temperature with the Multi-scale Geographically Weighted Regression [J]. *National Remote Sensing Bulletin*, 2021, 25(8): 1749-1766. (祝新明, 宋小宁, 冷佩, 等. 多尺度地理加权回归的地表温度降尺度研究[J]. 遥感学报, 2021, 25(8): 1749-1766.)
- [43] Wang Fei, Qin Zhihao, Song Caiying. An Efficient Approach for Pixel Decomposition of Land Surface Temperature from Landsat TM Data [J]. *Geomatics and Information Science of Wuhan University*, 2017, 42(1): 116-122. (王斐, 覃志豪, 宋彩英. 利用 Landsat TM 影像进行地表温度像元分解[J]. 武汉大学学报(信息科学版), 2017, 42(1): 116-122.)
- [44] Ma Z Q, Shi Z, Zhou Y, et al. A Spatial Data Mining Algorithm for Downscaling TMPA 3B43 V7 Data over the Qinghai-Tibet Plateau with the Effects of Systematic Anomalies Removed [J]. *Remote Sensing of Environment*, 2017, 200: 378-395.
- [45] Hu Shi, Han Jian, Zhan Chesheng, et al. Spatial Downscaling of Remotely Sensed Precipitation in Taihang Mountains [J]. *Geographical Research*, 2020, 39(7): 1680-1690. (胡实, 韩建, 占车生, 等. 太行山区遥感卫星反演降雨产品降尺度研究[J]. 地理研究, 2020, 39(7): 1680-1690.)
- [46] Tan W W, Tian L Q, Shen H F, et al. A New Downscaling-Calibration Procedure for TRMM Precipitation Data over Yangtze River Economic Belt Region Based on a Multivariate Adaptive Regression Spline Model [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 4702819.
- [47] Zhang Lianglin, Pan Jinghu, Lai Jianbo, et al. Estimation of PM<sub>2.5</sub> Mass Concentrations in Beijing-Tianjin-Hebei Region Based on Geographically Weighted Regression and Spatial Downscaling Method [J]. *Acta Scientiae Circumstantiae*, 2019, 39(3): 832-842. (张亮林, 潘竟虎, 赖建波, 等. 基于 GWR 降尺度的京津冀地区 PM<sub>2.5</sub> 质量浓度空间分布估算[J]. 环境科学学报, 2019, 39(3): 832-842.)
- [48] Yang Q Q, Yuan Q Q, Yue L W, et al. Mapping PM<sub>2.5</sub> Concentration at a Sub-km Level Resolution: A Dual-Scale Retrieval Approach [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 165: 140-151.
- [49] Carella G, Vrac M, Brogniez H, et al. Statistical Downscaling of Water Vapour Satellite Measurements from Profiles of Tropical Ice Clouds [J]. *Earth System Science Data*, 2020, 12(1): 1-20.
- [50] Jin Y, Ge Y, Wang J H, et al. Deriving Temporally Continuous Soil Moisture Estimations at Fine Resolution by Downscaling Remotely Sensed Product [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2018, 68: 8-19.
- [51] Zhang T, Li B L, Yuan Y C, et al. Spatial Downscaling of TRMM Precipitation Data Considering the Impacts of Macro-Geographical Factors and Local Elevation in the Three-River Headwaters Region [J]. *Remote Sensing of Environment*, 2018, 215: 109-127.
- [52] Li L F, Wu J J. Spatiotemporal Estimation of Satellite-Borne and Ground-Level NO<sub>2</sub> Using Full Residual Deep Networks [J]. *Remote Sensing of Environment*, 2021, 254: 112257.

- [53] Chen Min, Lü Guonian, Zhou Chenghu, et al. Thinking on the Development and Construction of Geographic Modeling and Simulation System for the Study of Geographical Characteristics in the New Era [J]. *Scientia Sinica (Terrae)*, 2021, 51(10): 1664-1680. (陈旻, 闫国年, 周成虎, 等. 面向新时代地理学特征研究的地理建模与模拟系统发展及构建思考[J]. *中国科学: 地球科学*, 2021, 51(10): 1664-1680.)
- [54] Merlin O, Jacob F, Wigneron J P, et al. Multidimensional Disaggregation of Land Surface Temperature Using High-Resolution Red, Near-Infrared, Shortwave-Infrared, and Microwave-L Bands [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(5): 1864-1880.
- [55] Song Chengyun, Hu Guangcheng, Wang Yanli, et al. Downscaling FY-3B Soil Moisture Based on Apparent Thermal Inertia and Temperature Vegetation Index [J]. *Remote Sensing for Land & Resources*, 2021, 33(2): 20-26. (宋承运, 胡光成, 王艳丽, 等. 基于表观热惯量与温度植被指数的FY-3B土壤水分降尺度研究[J]. *国土资源遥感*, 2021, 33(2): 20-26.)
- [56] Merlin O, Chehbouni A, Walker J P, et al. A Simple Method to Disaggregate Passive Microwave-Based Soil Moisture [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(3): 786-796.
- [57] Merlin O, Walker J P, Chehbouni A, et al. Towards Deterministic Downscaling of SMOS Soil Moisture Using MODIS Derived Soil Evaporative Efficiency [J]. *Remote Sensing of Environment*, 2008, 112(10): 3935-3946.
- [58] Merlin O, Bitar A, Walker J P, et al. An Improved Algorithm for Disaggregating Microwave-Derived Soil Moisture Based on Red, Near-Infrared and Thermal-Infrared Data [J]. *Remote Sensing of Environment*, 2010, 114(10): 2305-2316.
- [59] Merlin O, Bitar A, Walker J P, et al. A Sequential Model for Disaggregating Near-Surface Soil Moisture Observations Using Multi-resolution Thermal Sensors [J]. *Remote Sensing of Environment*, 2009, 113(10): 2275-2284.
- [60] Sun H, Cai C C, Liu H X, et al. Microwave and Meteorological Fusion: A Method of Spatial Downscaling of Remotely Sensed Soil Moisture [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(4): 1107-1119.
- [61] Song P L, Zhang Y Q, Tian J. Improving Surface Soil Moisture Estimates in Humid Regions by an Enhanced Remote Sensing Technique [J]. *Geophysical Research Letters*, 2021, 48(5): e2020GL091459.
- [62] Ranney K J, Niemann J D, Lehman B M, et al. A Method to Downscale Soil Moisture to Fine Resolutions Using Topographic, Vegetation, and Soil Data [J]. *Advances in Water Resources*, 2015, 76: 81-96.
- [63] Hoehn D C, Niemann J D, Green T R, et al. Downscaling Soil Moisture over Regions that Include Multiple Coarse-Resolution Grid Cells [J]. *Remote Sensing of Environment*, 2017, 199: 187-200.
- [64] Cowley G S, Niemann J D, Green T R, et al. Impacts of Precipitation and Potential Evapotranspiration Patterns on Downscaling Soil Moisture in Regions with Large Topographic Relief [J]. *Water Resources Research*, 2017, 53(2): 1553-1574.
- [65] Merlin O, Chehbouni A G, Kerr Y H, et al. A Combined Modeling and Multispectral/Multiresolution Remote Sensing Approach for Disaggregation of Surface Soil Moisture: Application to SMOS Configuration [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(9): 2036-2050.
- [66] Merlin O, Rudiger C, Bitar A, et al. Disaggregation of SMOS Soil Moisture in Southeastern Australia [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(5): 1556-1571.
- [67] Zhang Liangpei, Shen Huanfeng. Progress and Future of Remote Sensing Data Fusion [J]. *Journal of Remote Sensing*, 2016, 20(5): 1050-1061. (张良培, 沈焕锋. 遥感数据融合的进展与前瞻[J]. *遥感学报*, 2016, 20(5): 1050-1061.)
- [68] Gao F, Masek J, Schwaller M, et al. On the Blending of the Landsat and MODIS Surface Reflectance: Predicting Daily Landsat Surface Reflectance [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(8): 2207-2218.
- [69] Feng Chanying, Wang Zihao, Zheng Chengyang. An Albedo Downscaling Method Based on Stratified Linear Regression [J]. *Remote Sensing Technology and Application*, 2019, 34(3): 602-611. (冯婵莹, 汪子豪, 郑成洋. 基于分层线性回归的MODIS反照率产品降尺度方法研究[J]. *遥感技术与应用*, 2019, 34(3): 602-611.)
- [70] Zhu X L, Cai F Y, Tian J Q, et al. Spatiotemporal Fusion of Multisource Remote Sensing Data: Literature Survey, Taxonomy, Principles, Applications, and Future Directions [J]. *Remote Sensing*, 2018, 10(4): 527.
- [71] Li J, Li Y F, He L, et al. Spatio-Temporal Fusion

- for Remote Sensing Data: An Overview and New Benchmark[J]. *Science China Information Sciences*, 2020, 63(4): 140301.
- [72] Zhukov B, Oertel D, Lanzl F, et al. Unmixing-Based Multisensor Multiresolution Image Fusion [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1999, 37(3): 1212-1226.
- [73] Gevaert C M, García-Haro F J. A Comparison of STARFM and an Unmixing-Based Algorithm for Landsat and MODIS Data Fusion [J]. *Remote Sensing of Environment*, 2015, 156: 34-44.
- [74] Zhang Chunsen, Li Hui. The Remote Sensing Image Spectrum Simulation with Mixed Pixel [J]. *Geomatics and Information Science of Wuhan University*, 2013, 38(9): 1052-1056. (张春森, 李辉. 顾及混合像元分解的遥感图像光谱模拟[J]. 武汉大学学报(信息科学版), 2013, 38(9): 1052-1056.)
- [75] Zhu X L, Chen J, Gao F, et al. An Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model for Complex Heterogeneous Regions[J]. *Remote Sensing of Environment*, 2010, 114(11): 2610-2623.
- [76] Huang B, Song H H. Spatiotemporal Reflectance Fusion via Sparse Representation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(10): 3707-3716.
- [77] Song H H, Liu Q S, Wang G J, et al. Spatiotemporal Satellite Image Fusion Using Deep Convolutional Neural Networks [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(3): 821-829.
- [78] Settle J J, Drake N A. Linear Mixing and the Estimation of Ground Cover Proportions [J]. *International Journal of Remote Sensing*, 1993, 14(6): 1159-1177.
- [79] Wang Q M, Peng K D, Tang Y J, et al. Blocks-Removed Spatial Unmixing for Downscaling MODIS Images [J]. *Remote Sensing of Environment*, 2021, 256: 112325.
- [80] Cheng Q, Liu H Q, Shen H F, et al. A Spatial and Temporal Nonlocal Filter-Based Data Fusion Method [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(8): 4476-4488.
- [81] Wu P H, Shen H F, Zhang L P, et al. Integrated Fusion of Multi-scale Polar-Orbiting and Geostationary Satellite Observations for the Mapping of High Spatial and Temporal Resolution Land Surface Temperature [J]. *Remote Sensing of Environment*, 2015, 156: 169-181.
- [82] Wu B, Huang B, Zhang L P. An Error-Bound-Regularized Sparse Coding for Spatiotemporal Reflectance Fusion [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(12): 6791-6803.
- [83] Liu X, Deng C W, Wang S G, et al. Fast and Accurate Spatiotemporal Fusion Based Upon Extreme Learning Machine [J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(12): 2039-2043.
- [84] Ke Y H, Im J, Park S, et al. Downscaling of MODIS One Kilometer Evapotranspiration Using Landsat-8 Data and Machine Learning Approaches [J]. *Remote Sensing*, 2016, 8(3): 215.
- [85] Tan Z Y, Di L P, Zhang M D, et al. An Enhanced Deep Convolutional Model for Spatiotemporal Image Fusion [J]. *Remote Sensing*, 2019, 11(24): 2898.
- [86] Chen J, Wang L Z, Feng R Y, et al. CycleGAN-STF: Spatiotemporal Fusion via CycleGAN-Based Image Generation [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(7): 5851-5865.
- [87] Tan Z Y, Gao M L, Li X H, et al. A Flexible Reference-Insensitive Spatiotemporal Fusion Model for Remote Sensing Images Using Conditional Generative Adversarial Network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5601413.
- [88] Wu P H, Shen H F, Ai T H, et al. Land-Surface Temperature Retrieval at High Spatial and Temporal Resolutions Based on Multi-sensor Fusion [J]. *International Journal of Digital Earth*, 2013, 6(sup1): 113-133.
- [89] Weng Q H, Fu P, Gao F. Generating Daily Land Surface Temperature at Landsat Resolution by Fusing Landsat and MODIS Data [J]. *Remote Sensing of Environment*, 2014, 145: 55-67.
- [90] Wei Ran, Shan Jie. Spatial and Temporal Fusion for Urban Land Surface Temperature Image Mapping [J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(3): 428-435. (魏然, 单杰. 城市地表温度影像时空融合方法研究[J]. 武汉大学学报(信息科学版), 2018, 43(3): 428-435.)
- [91] Jiang H T, Shen H F, Li X H, et al. Extending the SMAP 9-km Soil Moisture Product Using a Spatiotemporal Fusion Model [J]. *Remote Sensing of Environment*, 2019, 231: 111224.
- [92] Xu C Y, Qu J, Hao X J, et al. Downscaling of Surface Soil Moisture Retrieval by Combining MODIS/Landsat and in Situ Measurements [J]. *Remote Sensing*, 2018, 10(2): 210.



- [93] Xiao Yao, Zeng Chao, Shen Huanfeng. Soil Moisture Downscaling Method Combining Parameter Statistics and Spatio-Temporal Fusion [J]. *Remote Sensing Technology and Application*, 2021, 36(5): 1033-1043. (肖窈, 曾超, 沈焕锋. 结合参量统计与时空融合的土壤水分降尺度方法[J]. 遥感技术与应用, 2021, 36(5): 1033-1043.)
- [94] Li X Y, Long D. An Improvement in Accuracy and Spatiotemporal Continuity of the MODIS Precipitable Water Vapor Product Based on a Data Fusion Approach [J]. *Remote Sensing of Environment*, 2020, 248: 111966.
- [95] Cammalleri C, Anderson M C, Gao F, et al. A Data Fusion Approach for Mapping Daily Evapotranspiration at Field Scale [J]. *Water Resources Research*, 2013, 49(8): 4672-4686.
- [96] Liu Wenjie, Zeng Yongnian, Zhang Meng. Mapping Rice Paddy Distribution by Using Time Series HJ Blend Data and Phenological Parameters [J]. *Journal of Remote Sensing*, 2018, 22(3): 381-391. (柳文杰, 曾永年, 张猛. 融合时间序列环境卫星数据与物候特征的水稻种植区提取[J]. 遥感学报, 2018, 22(3): 381-391.)
- [97] Liao C H, Wang J F, Pritchard I, et al. A Spatio-Temporal Data Fusion Model for Generating NDVI Time Series in Heterogeneous Regions [J]. *Remote Sensing*, 2017, 9(11): 1125.
- [98] Wan Huawei, Wang Jindi, Xiao Zhiqiang, et al. Generating the High Spatial and Temporal Resolution LAI by Fusing MODIS and ASTER [J]. *Journal of Beijing Normal University(Natural Science)*, 2007, 43(3): 303-308. (万华伟, 王锦地, 肖志强, 等. 融合MODIS与ASTER数据生成高空间分辨率时间序列LAI方法研究[J]. 北京师范大学学报(自然科学版), 2007, 43(3): 303-308.)
- [99] Houborg R, McCabe M F, Gao F. A Spatio-Temporal Enhancement Method for Medium Resolution LAI (STEM-LAI) [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2016, 47: 15-29.
- [100] Bai L L, Long D, Yan L. Estimation of Surface Soil Moisture with Downscaled Land Surface Temperatures Using a Data Fusion Approach for Heterogeneous Agricultural Land [J]. *Water Resources Research*, 2019, 55(2): 1105-1128.
- [101] Li Xin, Huang Chunlin, Che Tao, et al. Progress and Prospect of Land Surface Data Assimilation System in China [J]. *Progress in Natural Science*, 2007, 17(2): 163-173. (李新, 黄春林, 车涛, 等. 中国陆面数据同化系统研究的进展与前瞻[J]. 自然科学进展, 2007, 17(2): 163-173.)
- [102] Kaheil Y H, Gill M K, McKee M, et al. Downscaling and Assimilation of Surface Soil Moisture Using Ground Truth Measurements [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(5): 1375-1384.
- [103] Nagler T, Rott H, Malcher P, et al. Assimilation of Meteorological and Remote Sensing Data for Snowmelt Runoff Forecasting [J]. *Remote Sensing of Environment*, 2008, 112(4): 1408-1420.
- [104] Boussetta S, Koike T, Yang K, et al. Development of a Coupled Land-Atmosphere Satellite Data Assimilation System for Improved Local Atmospheric Simulations [J]. *Remote Sensing of Environment*, 2008, 112(3): 720-734.
- [105] Verhoest N E C, Berg M J, Martens B, et al. Copula-Based Downscaling of Coarse-Scale Soil Moisture Observations with Implicit Bias Correction [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(6): 3507-3521.
- [106] Sahoo A K, Lannoy G J M, Reichle R H, et al. Assimilation and Downscaling of Satellite Observed Soil Moisture over the Little River Experimental Watershed in Georgia, USA [J]. *Advances in Water Resources*, 2013, 52: 19-33.
- [107] Lievens H, Tomer S K, Al Bitar A, et al. SMOS Soil Moisture Assimilation for Improved Hydrologic Simulation in the Murray Darling Basin, Australia [J]. *Remote Sensing of Environment*, 2015, 168: 146-162.
- [108] Jin H A, Li A N, Yin G F, et al. A Multiscale Assimilation Approach to Improve Fine-Resolution Leaf Area Index Dynamics [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(10): 8153-8168.
- [109] Reichle R H, Entekhabi D, McLaughlin D B. Downscaling of Radio Brightness Measurements for Soil Moisture Estimation: A Four-Dimensional Variational Data Assimilation Approach [J]. *Water Resources Research*, 2001, 37(9): 2353-2364.
- [110] Ines A V M, Droogers P. Inverse Modelling in Estimating Soil Hydraulic Functions: A Genetic Algorithm Approach [J]. *Hydrology and Earth System Sciences*, 2002, 6(1): 49-66.
- [111] Shin Y, Mohanty B P. Development of a Deterministic Downscaling Algorithm for Remote Sensing Soil Moisture Footprint Using Soil and Vegetation Classifications [J]. *Water Resources Research*, 2013, 49(10): 6208-6228.
- [112] Reichstein M, Camps-Valls G, Stevens B, et al.

- Deep Learning and Process Understanding for Data-Driven Earth System Science [J]. *Nature*, 2019, 566: 195-204.
- [113] Liu X M, Wang M H. Deriving VIIRS High-Spatial Resolution Water Property Data over Coastal and Inland Waters Using Deep Convolutional Neural Network [J]. *Remote Sensing*, 2021, 13 (10) : 1944.
- [114] Liu X M, Wang M H. Super-Resolution of VIIRS-Measured Ocean Color Products Using Deep Convolutional Neural Network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59 (1) : 114-127.
- [115] Ducournau A, Fablet R. Deep Learning for Ocean Remote Sensing: An Application of Convolutional Neural Networks for Super-Resolution on Satellite-Derived SST Data [C]//The 9th IAPR Workshop on Pattern Recognition in Remote Sensing, Cancun, Mexico, 2016.
- [116] Dong C, Loy C C, He K M, et al. Image Super-Resolution Using Deep Convolutional Networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295-307.
- [117] Yu Z Y, Yang K, Luo Y, et al. Research on the Lake Surface Water Temperature Downscaling Based on Deep Learning [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 5550-5558.
- [118] Wang H Y, Juang J C. Retrieval of Ocean Wind Speed Using Super-Resolution Delay-Doppler Maps [J]. *Remote Sensing*, 2020, 12(6): 916.
- [119] Ping B, Meng Y S, Xue C J, et al. Can the Structure Similarity of Training Patches Affect the Sea Surface Temperature Deep Learning Super-Resolution? [J]. *Remote Sensing*, 2021, 13(18): 3568.
- [120] Ping B, Su F Z, Han X X, et al. Applications of Deep Learning-Based Super-Resolution for Sea Surface Temperature Reconstruction [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 14: 887-896.
- [121] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative Adversarial Nets [C]// The 27th International Conference on Neural Information Processing Systems-Volume 2, Montreal, Canada, 2014.
- [122] Lambhate D, Subramani D N. Super-Resolution of Sea Surface Temperature Satellite Images [C]// Global Oceans, CoastGulf, Biloxi, USA, 2020.
- [123] Leinonen J, Nerini D, Berne A. Stochastic Super-Resolution for Downscaling Time-Evolving Atmospheric Fields with a Generative Adversarial Network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(9): 7211-7223.
- [124] Jing Y H, Lin L P, Li X H, et al. An Attention Mechanism Based Convolutional Network for Satellite Precipitation Downscaling over China [J]. *Journal of Hydrology*, 2022, 613: 128388.
- [125] Jing Y H, Lin L P, Li X H, et al. Cascaded Downscaling-Calibration Networks for Satellite Precipitation Estimation [J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1506105.
- [126] Chen W J, Huang C L, Yang Z L. More Severe Drought Detected by the Assimilation of Brightness Temperature and Terrestrial Water Storage Anomalies in Texas During 2010—2013 [J]. *Journal of Hydrology*, 2021, 603: 126802.
- [127] Stoffelen A. Toward the True Near-Surface Wind Speed: Error Modeling and Calibration Using Triple Collocation [J]. *Journal of Geophysical Research: Oceans*, 1998, 103(C4): 7755-7766.
- [128] Xu Jianhui, Shu Hong. The Triple-Collocation-Based Fusion of In-Situ and Satellite Remote Sensing Data for Snow Depth Retrieval [J]. *Geomatics and Information Science of Wuhan University*, 2015, 40(4): 469-473. (许剑辉, 舒红. 基于 Triple-Collocation 的地面观测与卫星遥感数据融合的雪深反演 [J]. 武汉大学学报(信息科学版), 2015, 40(4): 469-473.)
- [129] Lü A F, Zhang Z L, Zhu H C. A Neural-Network Based Spatial Resolution Downscaling Method for Soil Moisture: Case Study of Qinghai Province [J]. *Remote Sensing*, 2021, 13(8): 1583.
- [130] Chantry M, Christensen H, Dueben P, et al. Opportunities and Challenges for Machine Learning in Weather and Climate Modelling: Hard, Medium and Soft AI [J]. *Philosophical Transactions Series A, Mathematical, Physical, and Engineering Sciences*, 2021, 379(2194): 20200083.
- [131] Yoon J H, Ruby Leung L, Correia J. Comparison of Dynamically and Statistically Downscaled Seasonal Climate Forecasts for the Cold Season over the United States [J]. *Journal of Geophysical Research: Atmospheres*, 2012, 117(D21): D21109.
- [132] Duchêne F, Van S B, Caluwaerts S, et al. A Statistical-Dynamical Methodology to Downscale Regional Climate Projections to Urban Scale [J]. *Journal of Applied Meteorology and Climatology*, 2020, 59(6): 1109-1123.