

引用格式:Li Yongkang, Wang Xinjun, Ma Yanfei, *et al.* Downscaling Land Surface Temperature through AMSR-2 Observations by Using Machine Learning Algorithms[J]. Remote Sensing Technology and Application, 2022, 37(2): 474-487. [李永康, 王新军, 马燕飞, 等. 基于机器学习算法的AMSR-2地表温度降尺度研究[J]. 遥感技术与应用, 2022, 37(2): 474-487.]
DOI: 10.11873/j.issn.1004-0323.2022.2.0474

基于机器学习算法的AMSR-2地表温度降尺度研究

李永康^{1,2}, 王新军^{1,2}, 马燕飞³, 陈 蓓^{1,2}, 闫立男^{1,2}, 张冠宏^{1,2}

(1. 新疆农业大学草业与环境科学学院, 新疆 乌鲁木齐 830052;

2. 新疆土壤与植物生态过程实验室, 新疆 乌鲁木齐 830052;

3. 邯郸学院地理系, 河北 邯郸 056005)

摘要: MODIS日尺度的地表温度受到天气影响, 有效像元信息严重缺失, 这对数据稀缺区域尤为重要。以古尔班通古特沙漠为研究区, 探索了采用AMSR-2的垂直极化亮度温度与植被指数对地表温度空间降尺度的方法, 并用此方法填补了2018年MODIS的缺失像元。①通过十折交叉验证, 对4种机器学习算法(Cubist、DBN、SVM、RF)、10个波段组合、2个空间尺度(5 km、10 km)下的训练模型进行了分析, 表明RF算法精度明显高于其他3种算法, C09波段组合的验证精度高于其他波段组合。②构建了2个鲁棒性的随机森林算法地表温度降尺度模型(5 km|RF|09、10 km|RF|09), 将AMSR-2亮度温度降尺度到1 km分辨率, 表明5 km|RF|09模型反演结果更为合理, MODIS与站点验证的 R^2 分别为0.971、0.930, RMSE分别为3.38 K、4.71 K, MAE分别为2.51 K、3.84 K。③降尺度结果填补MODIS地表温度缺失像元, 将其应用到古尔班通古特沙漠长时间序列的陆表温度分析, 可为数据稀缺区域数据获取提供科学参考。

关键词: 陆表温度; AMSR-2; 机器学习; 降尺度; 古尔班通古特沙漠

中图分类号: P423; TP79 **文献标志码:** A **文章编号:** 1004-0323(2022)02-0474-14

1 引言

陆表温度(Land Surface Temperature, LST)是长波辐射与地气湍流热通量交换的直接驱动力^[1], 是反映区域乃至全球尺度水热平衡的重要参数之一^[2]。陆表温度提供了地表能量的时空变化信息, 是下垫面最直接的能量体现^[3], 是各种陆面过程模型、环境模拟的重要输入参数^[4-5], 现被广泛应用于气候变化^[6]、环境反演^[2,7]、城市热岛研究^[8-12]、土壤含水量反演^[13-14]、蒸散发反演^[15-17]及干旱监测^[18]等领域。由于地形、土壤、植被和天气等因素的复杂

性, 地表温度空间上具有异质性^[19], 时间上具有波动性, 因此需要高时空分辨率的数据来描述地表温度的空间分布及时间演变。但受到热红外传感器与微波辐射计成像原理的限制, 单一传感器反演的地表温度产品难以同时具有高空间分辨率与高空间连续性特征。天气影响导致热红外地表温度缺失像元较多、空间上不连续, 中纬度地区MODIS数据60%以上受天气影响, 云为最主要原因^[20]。被动微波具有全天候的优点, 可穿透非降雨云团, 获取陆表辐射信息^[21], 但其反演的陆表温度精度相对

收稿日期: 2020-08-31; 修订日期: 2021-11-25

基金项目: 国家自然科学基金项目“古尔班通古特沙漠稀疏固沙植被NPP对水热条件变化的响应”(41761085), 国家自然科学基金项目“古尔班通古特沙漠南缘固沙植被斑块格局对降水脉动的响应研究”(41301205), 国家自然科学基金项目(41701426), 自治区研究生科研创新项目“基于深度学习的古尔班通古特沙漠地表温度降尺度研究”(XJ2020G152), 邯郸学院校级重点项目(2016103)。

作者简介: 李永康(1995—), 男, 河北张家口人, 硕士研究生, 主要从事陆面数据同化研究。E-mail: yongkang_xau@163.com

通讯作者: 王新军(1980—), 男, 新疆沙湾人, 副教授, 主要从事遥感与地理信息系统应用研究。E-mail: wxj8112@163.com

光学较低,且空间分辨率不足^[22-23]。因此发展全天候观测的被动微波数据与高空间分辨率的光学数据的融合算法,成为目前遥感研究热点^[24]。微波地表温度空间降尺度是指确定低空间分辨率微波像元值的基础上,融合高空间分辨率的地表温度信息,使得微波全天候观测地表温度的同时,获取更多的细节信息^[25],为微波反演精细地表温度数据提供了方法论。

自1990年以来,学者们通过各种方法不断探索被动微波观测数据来反演陆表温度^[26-35]。最早,McFarland等^[26]以SSM/I作为数据源,将37 GHz作为最主要的回归因子,其他通道处理后作为修正数据,对地表温度进行了反演。Holmes等^[27,30,32]以AMSR-E为数据源,通过多元线性回归算法,对地表温度进行反演,表明36.5 GHz为地表温度最佳反演波段,受到大气影响较小,能够获取浅层温度信息,但裸地的低含水量及散射作用会降低微波反演的精度。毛克彪等^[33-34]通过人工神经网络,建立AMSR-E亮度温度与MODIS陆表温度的回归关系模型,反演陆表温度,取得了较好的结果且表明89.0 GHz垂直极化是标定MODIS陆表温度的最佳波段。时洪涛等^[35]在土地覆盖类型的基础上,通过多元线性回归建立AMSR-E被动微波亮度温度与MODIS陆表温度之间的关系,对陆表温度进行反演,补充MODIS陆表温度缺失像元。谭建灿等^[24]通过卷积神经网络融合AMSR-2亮度温度数据与MYD11A1数据,对中国范围内的地表温度进行了反演,取得了满意的结果。上述研究多基于被动微波亮度温度数据,对LST进行反演,得到地表温度的空间分辨率与被动微波一致,但空间分辨率上的劣势没有得到解决。许多学者基于空间结构相似性,将粗分辨率下训练模型在细空间分辨率的数据上应用,反演得到精细分辨率的遥感产品^[36-40]。其中Sun等^[39]建立了5通道算法,根据6.9 GHz、18.7 GHz、23.8 GHz、36.5 GHz和89.0 GHz波段的特性,以垂直与水平极化的差作为特征向量,通过回归树算法,将10 km空间分辨率上的微波亮度温度降尺度到5 km,得到地表温度数据。根据被动微波亮温各频率物理特性结合机器学习算法构建降尺度模型,提高被动微波反演地表温度的精度。

陆面过程模型是定量描述沙漠水热变化的一种有效方法,对数据要求较高,需要高分辨率、全天候陆表温度数据输入^[4-5],然而古尔班通古特沙漠区

站点稀少,属于数据稀缺区,仅有位于南缘绿洲区的阜康荒漠生态站,难以满足模型对输入数据的要求。基于此,以古尔班通古特沙漠为研究区,通过多种机器学习算法,建立基于空间结构相似性的精细图像与粗图像之间的非线性映射关系,将AMSR-2数据融入到地表温度降尺度研究中,确定最合理模型并反演高时空分辨率的地表温度产品,为数据稀缺的干旱沙漠区陆表温度数据获取提供简洁有效的方法。

2 研究区与数据

2.1 研究区概况

古尔班通古特沙漠(44°15'~46°5'N,84°50'~91°20'E)位于准噶尔盆地中部,玛纳斯河流域以东及乌伦古河以南地区,是中国最大的固定、半固定沙漠,同时也是世界第三大沙漠,其最有代表性的沙丘类型是沙垅,占沙漠面积的80%^[41]。研究区地势东北高西南低,海拔300~600 m,沙丘形态丰富,多为南北走向的沙垄及新月型沙丘链、蜂窝状沙丘,沙丘高度在10~50 m^[42]。由于常年受西风带控制,且冬季主要受到蒙古—西伯利亚高压带影响,属干旱荒漠气候特征^[43]。古尔班通古特沙漠全年蒸发量为2 000~2 800 mm,全年降水量不超过220 mm,沙漠腹地仅有70~100 mm,集中在5~9月,冬季积雪深度约30 cm,其中有20cm左右的稳定积雪^[44-45]。全年平均温度为5~5.7℃,昼夜温差为10~30℃^[46]。

2.2 数据

采用2018年GCOM-W上AMSR-2传感器L1R数据集,升轨和降轨数据能够在2 d内覆盖除极地以外的全球大部分地区。L1R拥有6.9 GHz、10.7 GHz、18.7 GHz、23.8 GHz、36.5 GHz和89.0 GHz频率垂直与水平极化的两种亮温数据。根据时洪涛等研究,选取与陆表温度高度相关的垂直极化亮温,参与陆表温度反演^[35]。根据毛克彪等^[33,34]研究结果,选取36.5 V GHz为温度反演的主导因子;23.8 V GHz通道与18.7 H GHz通道的亮温作为辅助数据,消除大气、地表水等影响,89 V GHz为消除其他平均影响。10 km空间分辨率的AMSR-2被动微波亮温数据由JAXA提供(<http://gportal.jaxa.jp>)。Aqua与GCOM-W具有相似的过境时间(过境时间差<15 min),因此采用MYD11A1作为陆表温度真值数据。为提高反演精度,选择晴空下质量

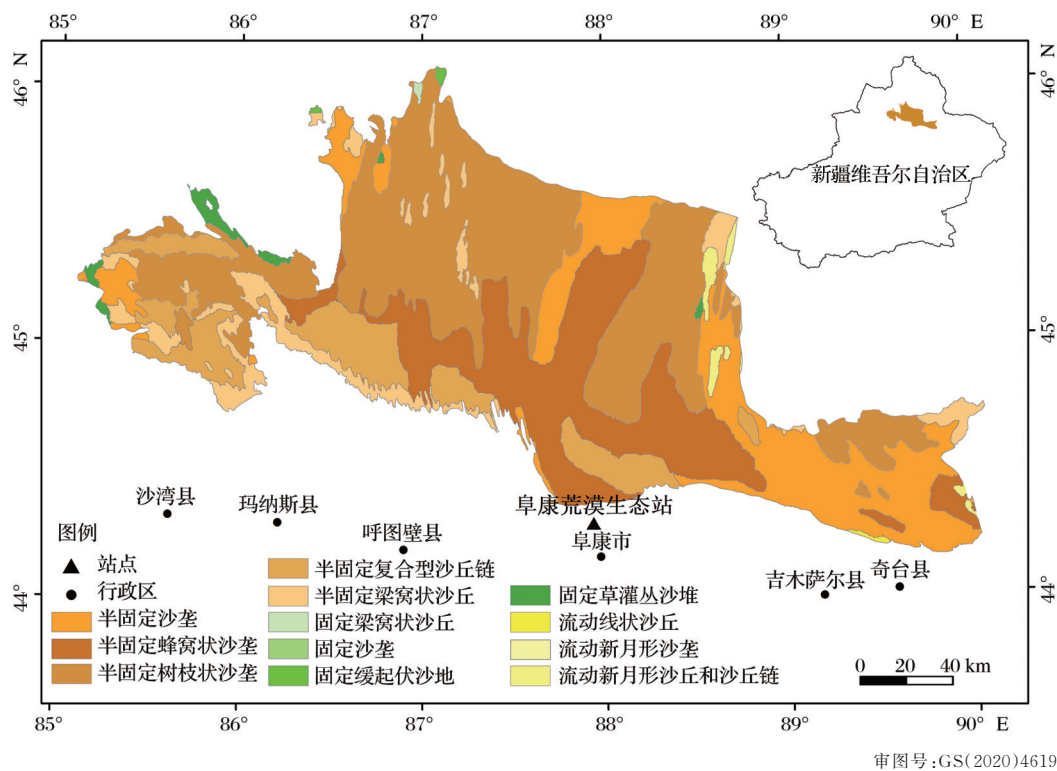


图 1 研究区概况图

Fig.1 Overview of study area

average LST error ≤ 1 K 的像元与 AMSR-2 匹配^[48]。微波亮温对下垫面异质性描述能力较差,因此选择 MYD13A2 的归一化植被指数(Normalized Vegetation Index, NDVI)和增强植被指数(Enhanced Vegetation Index, EVI)作为辅助数据,参与微波地表温度降尺度。遥感数据详情参见表 1。

表 1 AMSR-2 与 MODIS 相关数据参数

Table 1 The information of AMSR-2 microwave brightness temperature and MODIS data

AMSR-2 被动微波亮温数据			MODIS 数据		
中心频率/GHz	极化方式	空间分辨率/km	数据类型	空间分辨率/km	数据集
23.8	V	10	MYD	1	LST_Day_1km
			11A1		QC_Day
36.5	V	10	MYD	1	1 km_16_days_EVI
89	V	5	13A2		1 km_16_days_NDVI

注:H 代表水平极化,V 代表垂直极化

阜康荒漠生态站位于 87°55'E、44°17'N,古尔班通古特沙漠南缘,是绿洲与荒漠之间的过渡区,地面植被较为茂盛,多以荒漠草原以及草甸草原为主^[49],海拔 461 m,提供每日逐时地表温度。由于 AMSR-2 扫描间隙的存在及自动站陆温采集的缺失,共选 253 条数据参与地表温度验证。自动站数据由国家生态科学中心提供(<http://rs.cern.ac.cn/index.jsp>)。

3 研究方法

3.1 被动微波反演地表温度理论基础

被动微波观测反演地表温度的物理基础为辐

射传输理论^[39],通过辐射能量平衡建立地表温度反演算法。辐射传输方程描述了被动微波辐射计接收到到的总能量,包括地面辐射和向上、向下的大气路径辐射以及由大气吸收而减弱的辐射分量^[33-34],通用辐射传输方程表示如下:

$$B_f(T_f) = \tau_f(\theta) \varepsilon_f B_f(T_s) + [1 - \tau_f(\theta)] (1 - \tau_f(\theta) B_f(T_a^\downarrow) + [1 - \tau_i(\theta)] B_f(T_a^\uparrow))$$

(1)

其中: T_s 代表陆表温度; T_a 代表平均大气温度; T_f 代表 f 频率的亮度温度; $\tau_f(\theta)$ 代表 f 频率在观测角 θ 的透射率; ε_f 代表 f 频率的地表发射率; $B_f(T_s)$ 代表地表

辐射; T_a^{\downarrow} 与 T_a^{\uparrow} 分别为大气下行与上行辐射。

基于多通道辐射传输方程反演地表温度,每加入一个频率,将加入一个新的未知数,N个通道加入时,有N+1个未知数,因此基于被动微波的物理模型的地表温度反演为病态反演^[27,57]。为解决此问题,Fily等学者假设同一频率下垂直极化与水平极化的发射率可简化为线性关系 $\varepsilon_V = a\varepsilon_H + b$ 表示^[32,58-60],式(1)亦可简化为:

$$LST = [T_{br} - aT_{bh} - (1 - b - a)\tau_r(\theta)T_a^{\downarrow}] / [b\tau_r(\theta)] \quad (2)$$

其中: ε_{VH} 代表垂直与水平极化方向上地表发射率; a/b 为线性回归系数。但是这种假设简化了先决条件,如恒定的大气校正、地表植被的吸收、忽略大气散射效应等^[32,58-60]。

3.2 地表温度降尺度映射关系的构建

采用机器学习方法反演地表温度,根据各频率的物理特性选择特征向量,克服多通道反演的非线性问题,同时较好解决病态反演问题。选择AMSR-2的36.5、23.8、89 GHz 3个高频垂直极化亮温,反演高质量地表温度;36.5 GHz垂直极化为反演计算的数据,23.8 GHz垂直极化消除大气的平均影响,89 GHz垂直极化的参与用来消除大气水汽的影响^[30,33-34]。对AMSR-2地表温度降尺度反演具体步骤(图2)如下:

(1)将AMSR-2与MODIS数据重采样至10 km与5 km,选取MYD11A1质量average LST error ≤ 1 K的像元匹配AMSR-2微波亮温数据及MYD13A2植被指数数据。其中,10 km的MODIS和AMSR-2数据被标记为“D1”,5 km的MODIS和AMSR-2数据被标记为“D2”。

(2)对重采样后的D1和D2进行波段处理,分别得到10个组合,详情如表2。其中,相同的被动微波亮温波段与不同植被指数的组合,目的是比较不同植被指数对地表温度反演的贡献;单一波段与相同波段的作差处理,目的是评价先验知识对地表温度反演的贡献。

(3)在10 km与5 km空间尺度下,将10个组合输入到随机森林(Random Forest, RF)、Cubist回归树、支持向量机(Support Vector Machine, SVM)、深度信念网络(Deep Belief Network, DBN)4个机器学习算法中。通过“十折交叉验证”(10-fold cross-validation)在10 km与5 km空间尺度下,分别选取一个最优模型。

(4)将被动微波亮温数据重采样至1 km,与对应像元的1 km MODIS植被指数组成特征向量,分别输入到5 km与10 km空间尺度上的最优模型,基于空间结构相似性,反演1 km空间分辨率的地表温度数据。

(5)选用MODIS质量average LST error ≤ 1 K晴空像元及阜康站0~10 cm土壤温度数据,分别对5 km与10 km模型反演的1 km地表温度数据进行精度验证,确定最优训练空间尺度,进而确定最优模型。

3.3 模型验证与评价

本研究使用4个机器学习模型(随机森林, RF、Cubist回归树, Cubist、支持向量机, SVM、深度信念网络, DBN),对2个空间尺度(5 km、10 km),分别采用10种向量组合进行训练,对被动微波亮温与MODIS地表温度映射关系进行构建。机器学习模型的初步评估,选用“十折交叉验证”方案^[50-52]。将

表2 10种特征和详情
Table 2 The details of feature vector

组合 序号	AMSR-2 被动微波亮温				MYD13A2		MYD11A1
	36.5 Pol.V	23.8 Pol.V	36.5 Pol.V~23.8 Pol.V	89 Pol.V	NDVI	EVI	LST
C01	✓	-	-	-	✓	-	✓
C02	✓	-	-	-	-	✓	✓
C03	✓	✓	-	-	✓	-	✓
C04	✓	✓	-	-	-	✓	✓
C05	✓	-	✓	-	✓	-	✓
C06	✓	-	✓	-	-	✓	✓
C07	✓	✓	-	✓	-	-	✓
C08	✓	✓	-	✓	-	✓	✓
C09	✓	-	✓	✓	✓	-	✓
C10	✓	-	✓	✓	-	✓	✓

注:C代表波段组合,Combion的缩写;01,表示序号;✓为选择波段;-为未选择波段

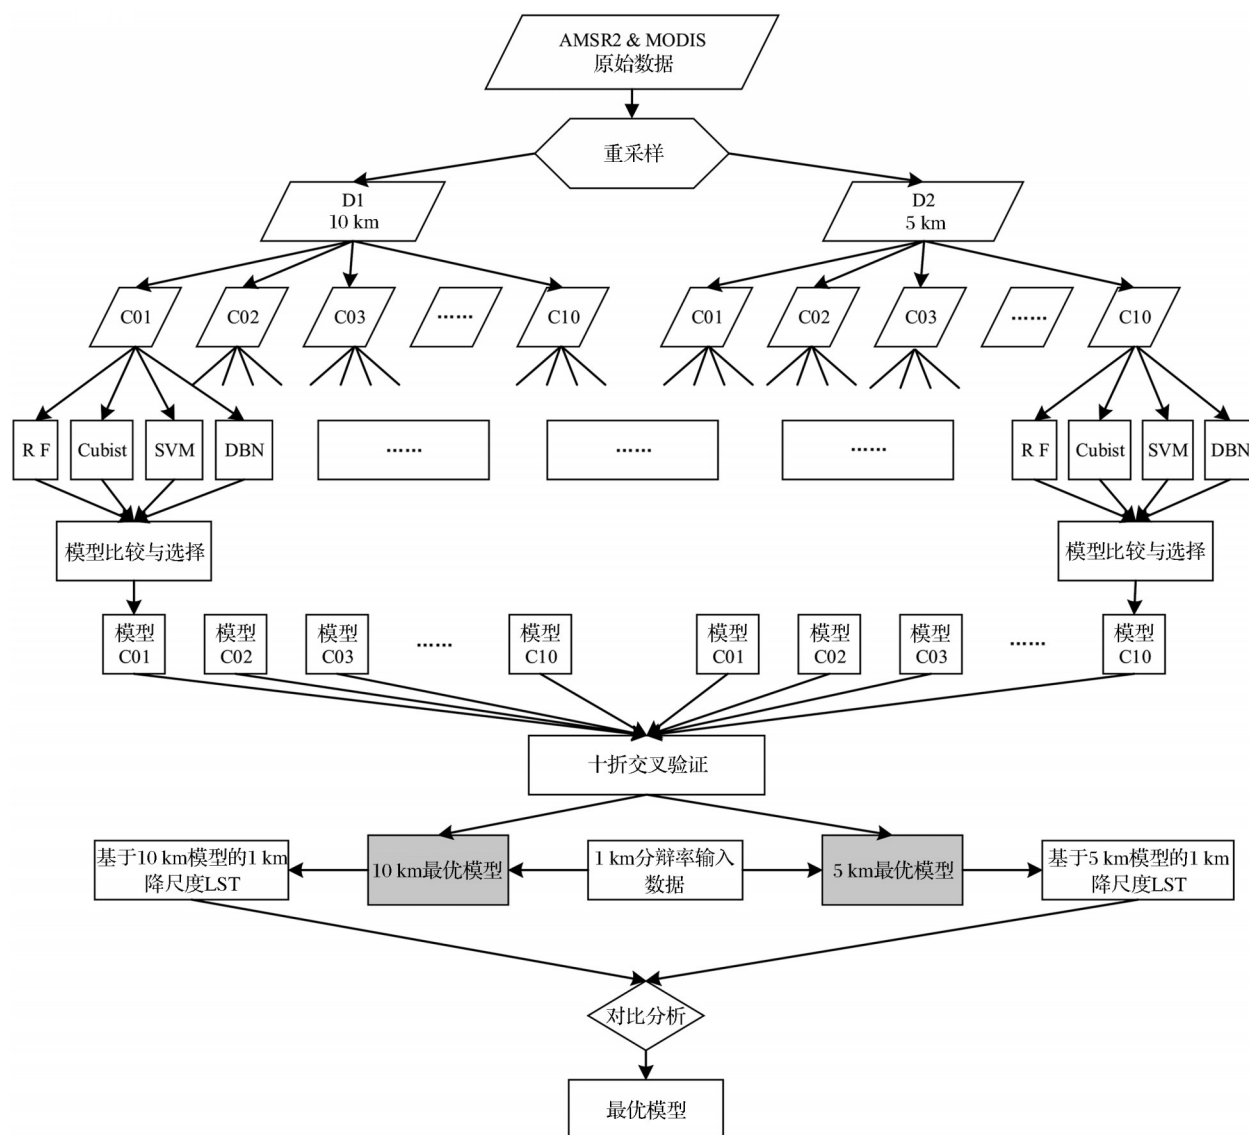


图2 AMSR-2地表温度降尺度流程图

Fig.2 Flow chart of the method for AMSR-2 land surface temperature downscaling

古尔班通古特沙漠的训练数据随机分为10组,循环地将其中9组作为训练数据拟合模型,其余的1组作为验证。将十次的拟合精度均值作为本模型的最终精度。采用十折交叉验证能够有效降低系统误差、随机误差和粗差,使模型测试的精确度达到理论上的最高^[23, 53]。

将决定系数 R^2 (Coefficient of Determination)、平均绝对误差 MAE (Mean Absolute Error) 和均方根误差 RMSE (Root Mean Square Error) 作为评价指标,进行调参、验证和对比^[54]。模型的筛选与评价分为两步,①以 MYD11A1 作为目标向量的十折交叉验证,对模型进行评价,在 5 km 与 10 km 空间尺度下分别确定最优模型,反演 1 km 空间分辨率的陆表温度数据;②将基于 5 km 和 10 km 尺度上反演

的陆表温度分别与 MYD11A1 有值像元及站点实测值对比分析、评价精度。

NDVI 与 EVI 的特征选择。①相同算法及相同微波亮温组合下,比较 NDVI 与 EVI 十折交叉验证精度,初步评估 NDVI、EVI 重要性;②在全年尺度 (365 d) 上进行单个像元 Pearson 相关分析,获取 NDVI 与 EVI 的相关系数 r 及概率 p 数据,绘制相关系数 r 空间分布图,分析 NDVI 和 EVI 与地表温度的相关性及相关性的空间特征,通过区域 r 均值进一步评估 NDVI、EVI 的重要性。

4 结果与分析

4.1 学习算法及特征组合的对比与分析

图3和图4分别为 5 km、10 km 空间尺度十折交

叉验证结果,各空间尺度均使用RF、Cubist、SVM、DBN对10种波段组合进行了训练。5 km与10 km尺度下模型的十折交叉验证结果表明:

(1)在相同特征向量组合的训练集下,总体上模型的性能表现为RF>Cubist>SVM>DBN,RF算法的各个指标的梯度变化较小,其可以使用更少数据来描述各个波段与陆表温度之间的非线性关系,表现出鲁棒性。因此,将选用RF进行1 km陆表温度反演。

(2)垂直极化作差(36.5 GHz Pol. V, 36.5 GHz Pol.V~23.8 GHz Pol. V)与垂直极化分别作为特征向量(36.5 GHz Pol. V, 23.8 GHz Pol. V)的交叉验证对比分析,表明作差特征向量评分>单波段特征向量评分。利用36.5 GHz垂直极化和23.8 GHz垂直极化作差,能够削弱大气水汽的影响,其结果与毛彪等^[33-34]的研究结果一致。因此,将选用36.5 GHz垂直极化和23.8 GHz垂直极化作差参与1 km陆表

温度反演。

(3)通过10个波段组合的验证对比表明,在4种算法中,通过NDVI描述下垫面异质性时,精度总体呈C09>C07>C05>C03>C01;EVI描述下垫面异质性时,精度总体呈C10>C08>C06>C04>C02。表明随着亮温波段数的增加,各个算法精度呈现阶梯状上升,其中RF算法梯度变化最小。

使用归一化植被指数(NDVI)和增强植被指数(EVI)作为降尺度辅助数据,参与降尺度模型构建。在相同算法及相同微波亮温组合下,十折交叉验证MAE差值绝对值<0.18 K, RMSE差值绝对值<0.22 K,差异较小,但NDVI模型精度略高于EVI模型。表明NDVI与EVI对地面异质性描述能力较为一致,原因可能在于沙漠环境下垫面相对其他生态系统较为单一,针对沙漠下垫面的异质性,NDVI与EVI均能够充分描述,需要对植被指数进一步筛选。

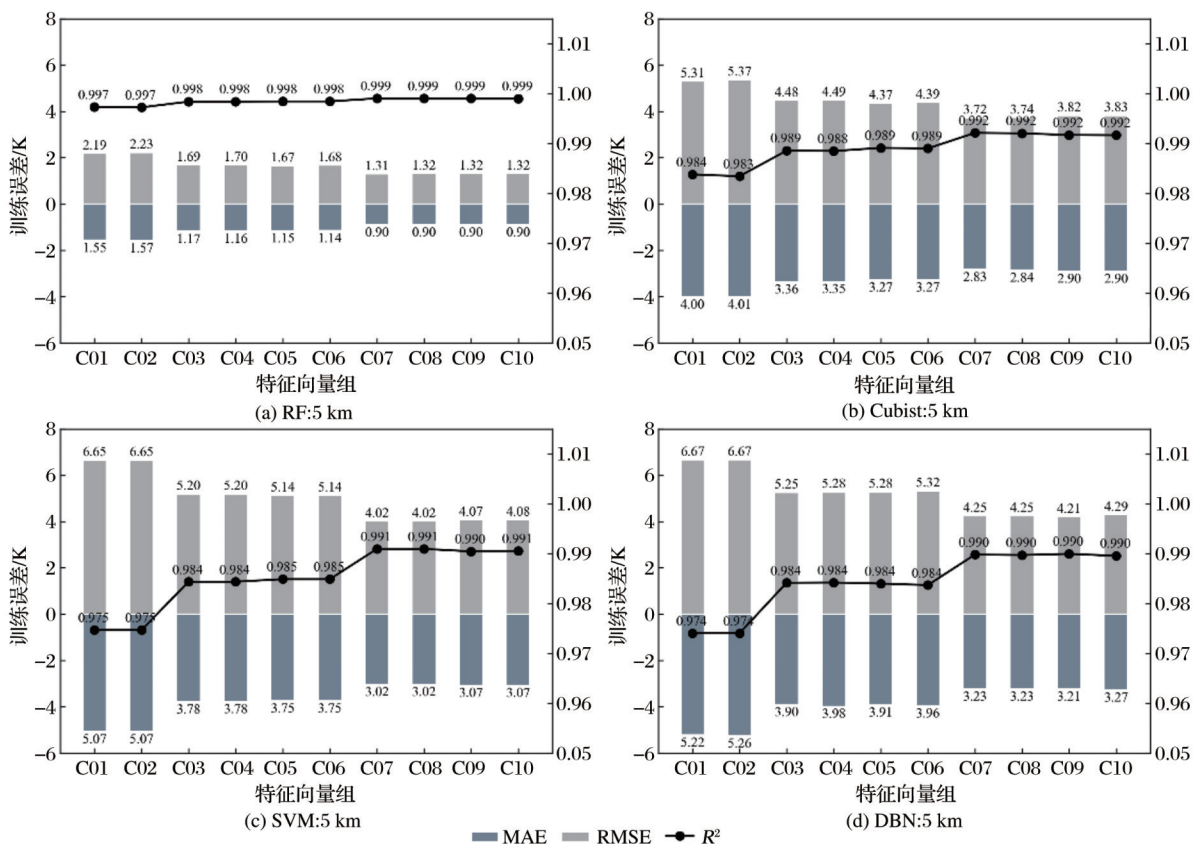


图3 5 km尺度下10种特征组合的十折交叉验证结果

Fig.3 The 10-fold cross-validation result of 5 km scale with 10 band combinations

选用皮尔逊相关系数法(Pearson Correlation)对NDVI与EVI进行特征选择(图5)。NDVI和EVI与地表温度的相关性空间特征相似,均能较好地将沙漠与周边绿洲分离且沙漠区相关性>绿洲

区相关性,印证十折交叉验证结果。5 km空间尺度下NDVI、EVI与地表温度的相关性区域均值分别为0.764、0.755,10 km空间尺度下NDVI、EVI与地表温度的相关性区域均值分别为0.760、0.750;区域

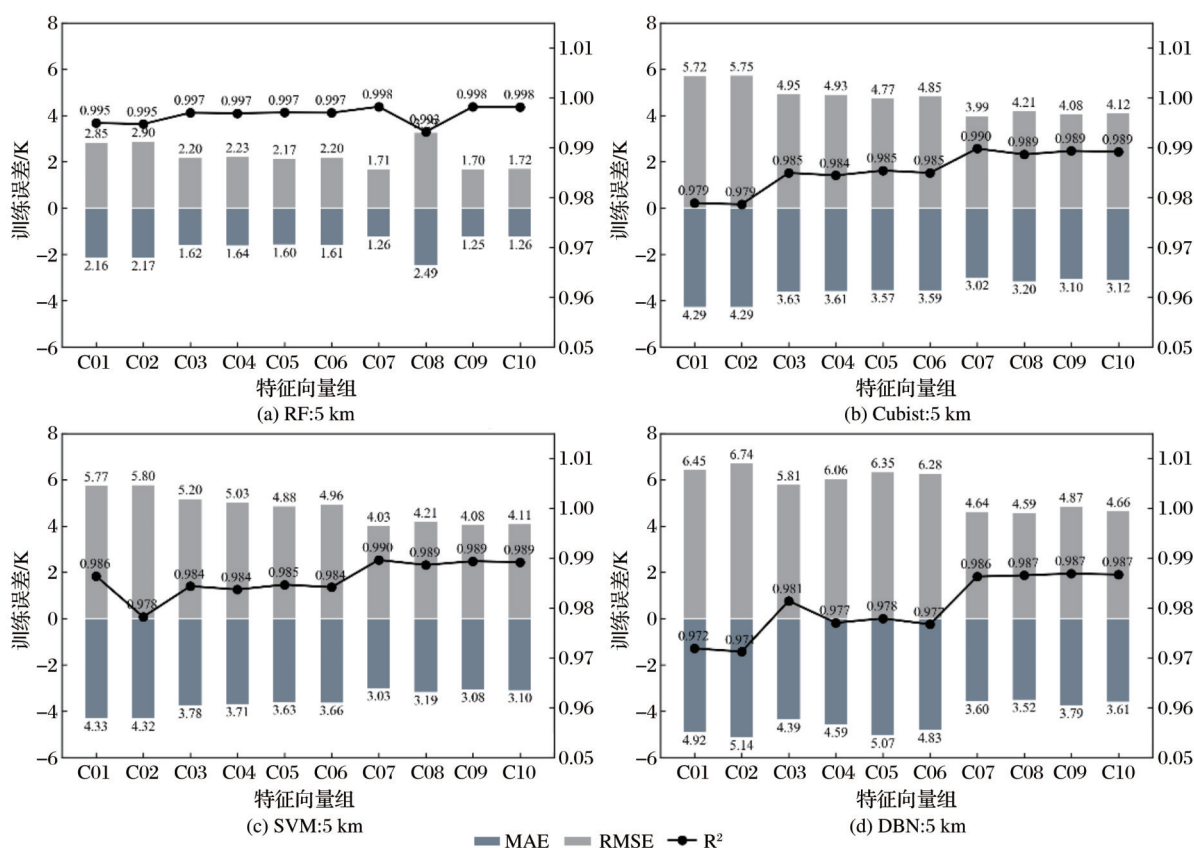


图4 10 km尺度下10种特征组合的十折交叉验证结果

Fig.4 The 10-fold cross-validation result of 10 km scale with 10 band combinations




图5 相关性 r 空间分布图

Fig.5 The spatial distribution of pearson correlation

概率 p 均值 <0.01 ,均呈极显著水平。2个空间尺度下均 $\text{NDVI} > \text{EVI}$,与十折交叉验证评估一致,因此

选用NDVI作为辅助数据,参与模型构建。

综上所述,选取RF作为反演算法,选用C09波

段组合参与1 km陆表温度的反演(NDVI来描述地表植被异质性,36.5 GHz垂直极化和23.8 GHz垂直极化作差方式衰减水汽影响)。确定最优模型为5 km|RF|C09、10 km|RF|C09,十折交叉验证 R^2 分别为0.999、0.998,MAE分别为0.90 K、1.25 K, RMSE分别为1.32 K、1.70 K。

较RF统计模型的10 km交叉验证结果,5 km RF统计模型MAE与RMSE分别降低了0.35 K、0.38 K,表明RF在10 km空间尺度下泛化能力不足。原因可能在于10 km的训练尺度时像元面积为10 km×10 km,5 km训练尺度像元面积为5 km×5 km,这将导致5 km训练尺度的训练样本数量为10 km时样本数量的4倍,在机器学习中,就能得到更多的映射关系;RF通过建立多个回归树,将映射关系进行分类,因此训练样本越多,其优势越明显,可以得到更好的十折交叉验证结果。

4.2 地表温度反演的对比与分析

在实验中,很难获取像元尺度(1 km×1 km)的地表温度真值数据。Wan等^[55]获得了2000~2001

年的地表真值数据,对MODIS数据进行了评估,结果表明MODIS的地表温度产品精度在1 K以内;于文凭和马明国^[56]以黑河流域为研究区对MODIS地表温度产品进行精度验证,表明平均绝对误差小于2.2 K,可以用来间接评估反演产品的质量。将基于RF|C09模型的反演产品与MODIS产品进行对比,得到两种不同空间尺度模型下的评价指标(图6)。

5 km|RF|C09与10 km|RF|C09的 R^2 分别为0.971、0.959, RMSE分别为3.38 K、3.62 K, MAE分别为2.51 K、2.68 K。较谭建灿基于卷积神经网络垂直极化降尺度精度,5 km|RF|C09的 R^2 提高了0.08, RMSE降低了0.7 K;10 km|RF|C09的 R^2 提高了0.065, RMSE降低了0.46 K。5 km与10 km下RF|C09反演效果均较好(图6)。但相较于10 km|RF|C09反演的LST质量,模型5 km|RF|C09反演LST的 R^2 提高了0.012, MAE降低了0.17 K, RMSE降低了0.24 K。5 km|RF|C09反演结果与MODIS地表温度像元的拟合线,更接近1:1对角线。

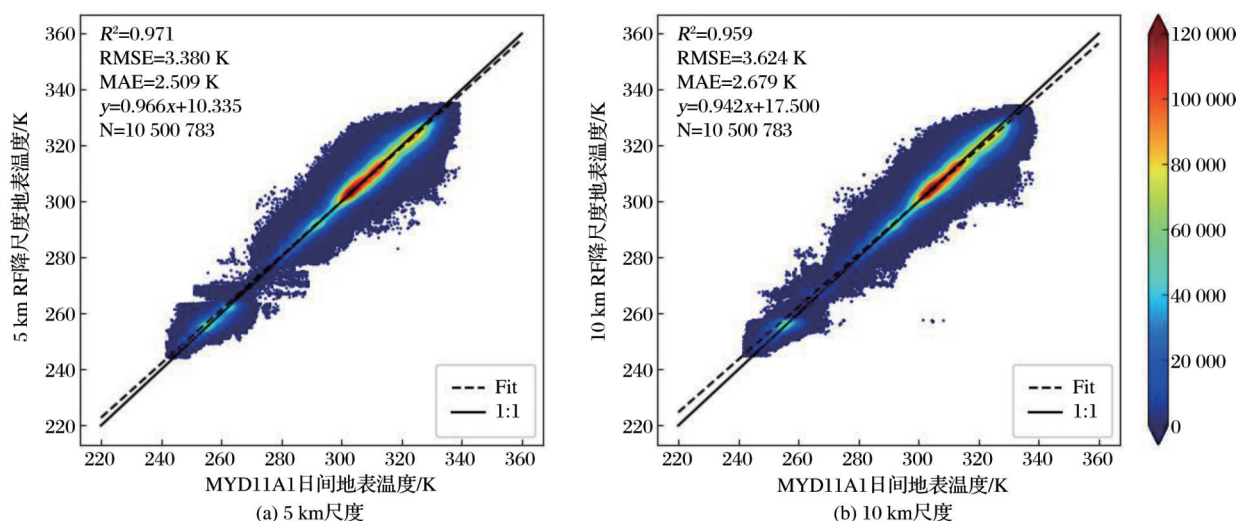


图6 基于5 km RF和10 km RF模型的反演的陆表温度与MODIS陆表温度散点图

Fig.6 The scatter plots for 1km LST derived from 5 km, 10 km RF model with modis LST

较十折交叉验证,5 km|RF|C09模型的MODIS验证, R^2 降低了0.028, MAE增加了1.61 K, RMSE增加了2.06 K;而10 km|RF|C09模型的 R^2 降低了0.039, MAE增加了1.43 K, RMSE增加了1.92 K。在十折交叉验证与MODIS验证中,5 km|RF|C09的精度均高于10 km|RF|C09;但MODIS验证与十折交叉验证对比分析表明,较10 km|RF|C09模型,在训练集向预测集迁移过程中,5 km|RF|C09精度下降较快。原因可能在于,5 km|RF|C09的训练数据

量,相对10 km|RF|C09多约3倍,能够在训练模型过程中建立更多的映射关系,获得更多信息,使得在十折交叉验证结果与MODIS验证中精度更高。随着研究区的扩大,数据量变大,10 km的信息达到饱和,5 km上的信息随之出现过饱和,精度趋近一致。

为进一步验证模型的准确性,将基于RF|C09模型反演的地表温度数据与阜康荒漠生态站观测数据(0~10 cm土壤温度),从时间序列(时间序列

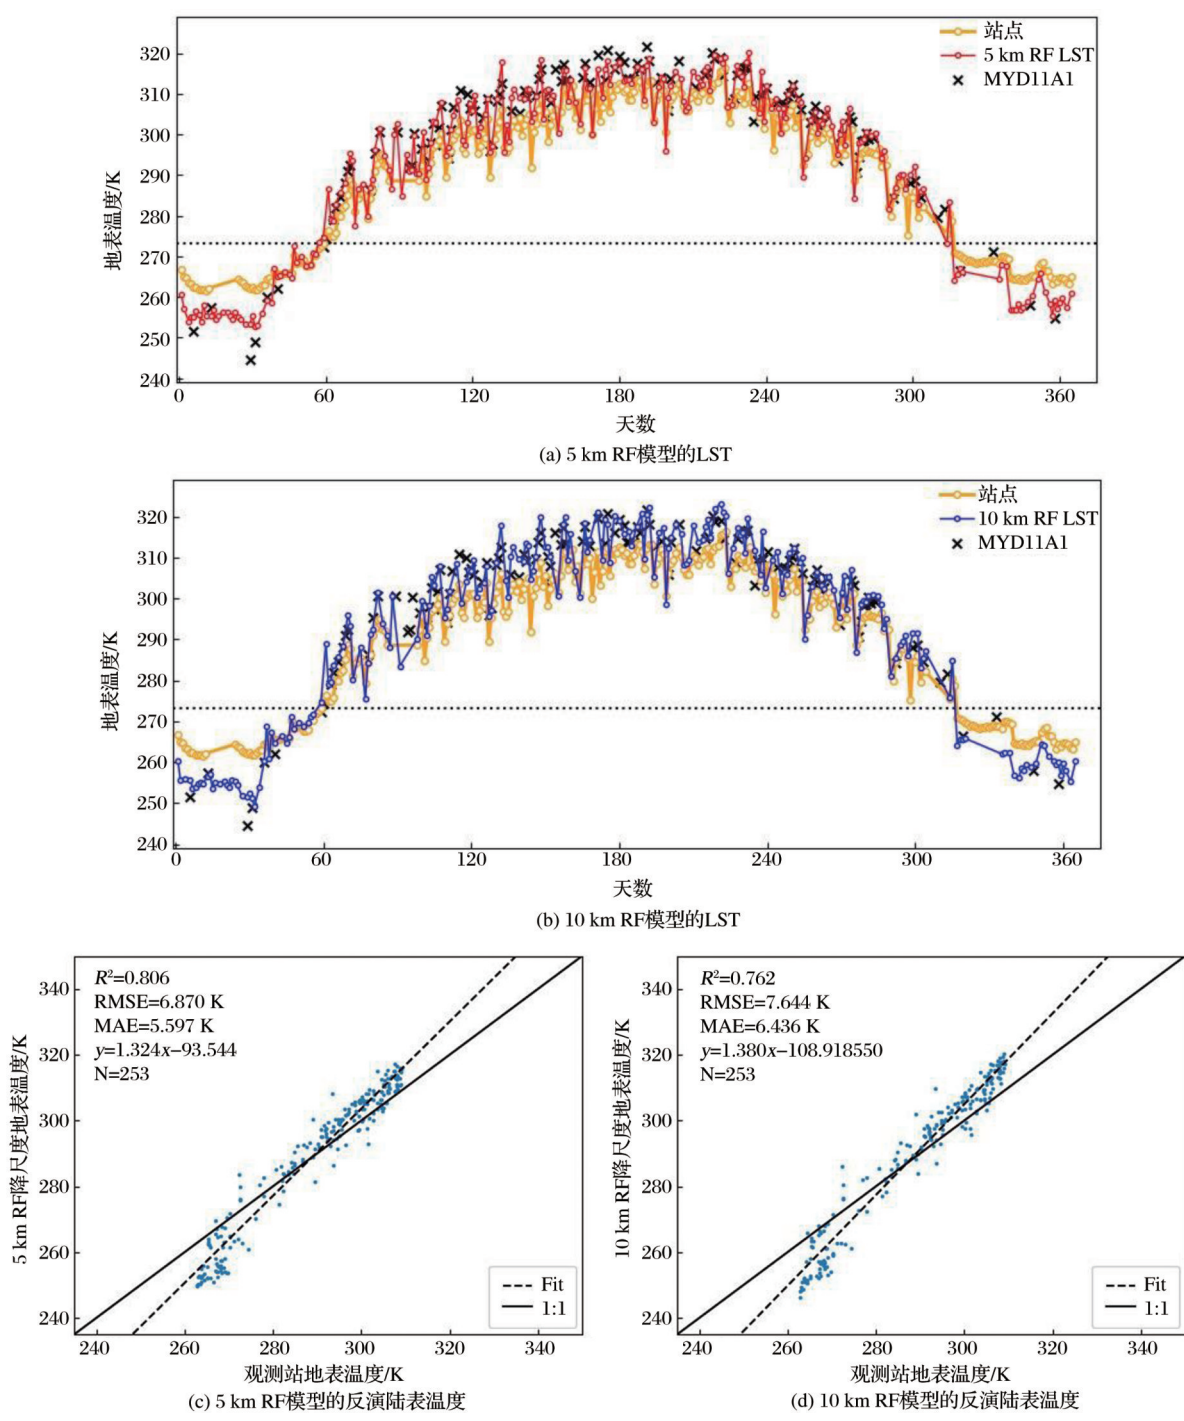


图 7 时间序列上的 5 km RF、10 km RF 模型的 LST,5 km RF、10 km RF 模型的反演的 LST 与阜康站点 LST 散点图

Fig.7 Temporal variability of LST derived from 5 km's and 10 km's RF model, The scatter plots for LST derived from 5 km、10 km RF model with station LST

图)、数值统计(散点图)两个角度进行对比分析。

站点验证(图 7(c)和 7(d))结果表明,5 km|RF|C09、10 km|RF|C09 的 R^2 分别为 0.926、0.899, RMSE 分别为 4.71 K、5.54 K, MAE 分别为 3.84 K、4.66 K。较 10 km RF 模型的反演陆表温度,5 km RF 模型的反演陆表温度在 RMSE 上降低了 0.83 K,在 MAE 上降低了 0.82 K;但是 5 km RF 模型下反演的陆表

温度与站点数据存在较大的差异。

RF 反演 LST 能充分反映陆地表层温度的变化,同站点温度的变化具有一致性(图 7(a)和 7(b),同时可以对反演温度与站点温度差异做进一步分析。随机森林算法能够将 MYD11A1 与地面实测数据的相关性很好地继承到 RF 模型反演的 LST 数据上,但当 MYD11A1 产品与阜康站实测温度存在较

大差异时,RF模型反演的LST将继承这种差异。差异主要来源于两方面:测量尺度与训练数据的特征。MODIS的 $1\text{ km}\times 1\text{ km}$ 像元为面尺度的信息,阜康站数据为点尺度的数据,且周边为非均匀荒漠草甸,因此在尺度匹配时出现系统误差。对卫星数据进行验证,理想的下垫面为均质环境,MODIS波段的地表比辐射率在冬季非均匀草地将被高估,这将导致MODIS LST明显低于实测值。训练数据中,约90%数据为沙漠研究区,约10%数据为沙漠周边绿洲,这在很大程度上反映为沙漠的各种波段的特征。因此模型将会在沙漠范围内表现出高精度,随着向边缘绿洲靠近,精度降低;阜康生态站位于边缘绿洲区,精度会出现一定程度的降低,且在绿洲区表现沙漠区域地表温度特征(夏季极高温,会出现高估;冬季极低温,出现低估)。1~3月、11~12月份的温度低估,也为以上原因做了印证。以上特征反映在时间序列图上(图7(a)、图7(b)):MYD11A1地表温度产品在273.15 K附近出现差异:当温度高于273.15 K时,差异随着地表温度的增高而出现高

估增大,当地表温度小于273.15 K时,随着温度的降低而出现低估增大。RF陆表温度降尺度结果继承了同样的问题。综上,虽然MYD11A1产品的误差传递到了降尺度的地表温度产品上,但是降尺度地表温度产品在时间序列上,能够合理地反映下垫面温度变化,对地表温度的时空分析具有重要意义;克服站点尺度监测范围小的缺陷的同时,弥补了MYD11A1空间上的不连续,使得古尔班通古特沙漠地表温度时空格局研究有据可依;基于 $5\text{ km}| \text{RF}| \text{C09}$ 的降尺度精度高于 $10\text{ km}| \text{RF}| \text{C09}$ 精度,降尺度产品在继承AMSR-2全天候特性的同时,获得了MYD11A1空间分辨率。

4.3 陆表温度降尺度模型的应用

最终,通过融合AMSR-2亮温反演得到日尺度的地表温度数据,填补MODIS由云导致的陆表温度空缺像元,获得陆表温度产品。当晴空时,使用MODIS提供的LST像元值,当有云出现时,使用微波亮温的反演地表温度。图7分别是2018年8月18日和19日的产品生成示意图。

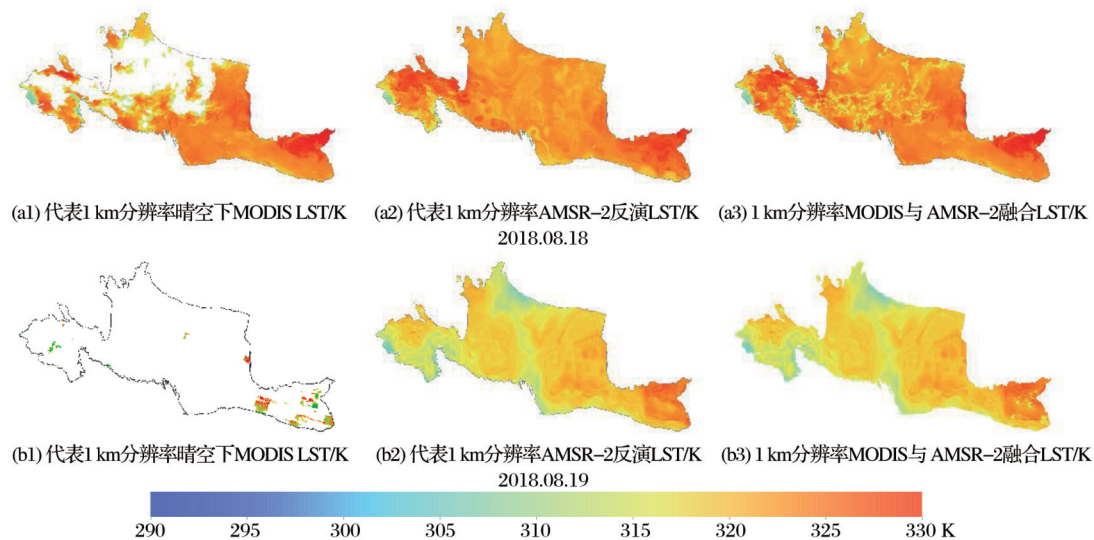


图8 2018年8月18日和19日的产品生成示意图

Fig.8 The a represents the day of 2018.08.18, the b represents the day of 2018.08.19

5 结 语

MODIS日尺度的地表温度受到天气影响,有效像元信息缺失严重,这对数据稀缺区域尤为重要。以古尔班通古特沙漠为研究区,探索了利用AMSR-2的垂直极化亮度温度与植被指数对地表温度空间降尺度的方法,并用此方法填补了2018年MODIS的缺失像元。通过十折交叉验证,对4种机器学习算法(Cubist、DBN、SVM、RF)、10个波段组

合、2个空间尺度(5 km 、 10 km)下的训练模型进行了分析,算法性能表现为 $\text{RF} > \text{Cubist} > \text{SVM} > \text{DBN}$,波段组合的性能表现为 $\text{C09} > \text{C07} > \text{C05} > \text{C03} > \text{C01}$ 和 $\text{C10} > \text{C08} > \text{C06} > \text{C04} > \text{C02}$,且 $\text{C09} > \text{C10}$ 。通过MODIS地表温度产品与站点实测数据,从数值统计、时间序列两方面,对 5 km 与 10 km RF模型微波反演地表温度进行验证分析,结果表明1~3月、11~12月份的反演结果出现低估,4~10月份会出现低估,这是由MODIS陆表温度导致的;

5 km 下的 RF 模型反演结果更合理,MODIS 与站点验证的 R^2 分别为 0.971、0.926, RMSE 分别为 3.38 K、4.71 K, MAE 分别为 2.509 K、3.84 K。最终,构建了考虑鲁棒性的 RF 算法地表温度降尺度模型(5 km|RF|09),将 AMSR-2 亮度温度降尺度到 1 km 分辨率,将降尺度反演的全天候地表温度填补 MODIS 地表温度缺失像元,应用到古尔班通古特沙漠长时间序列的陆表温度分析,为数据稀疏区域数据获取提供科学参考。

总体上亮点有二:①使用植被指数与 3 个垂直极化亮温,应用于古尔班通古特半固定沙漠被动微波地表温度降尺度研究,精度较高,为数据稀缺的沙漠地区提供了高时空分辨率的地表温度数据。②将 10 km 像元重采样为 4 份,增加训练样本数建立更多的模型映射关系,提高了随机森林对地表温度的反演精度。Sun 等^[39]在 10 km 空间尺度下训练回归树模型,基于空间结构相似性,反演 5 km 分辨率地表温度;本研究尝试在 5 km 空间尺度下训练,在 1 km 空间分辨率上反演地表温度,获得了更好的结果。但是其中一些不确定性仍需进一步研究。

(1)传感器过境时间的一致性考虑。搭载在 GCOM-W1 的 AMSR-2 与搭载在 Aqua 的 MODIS,虽然过境时间相似,但是过境时间并不完全符合,后期将深入探讨时间差对反演温度的影响,以便进一步提高反演精度。

(2)训练尺度选择的考虑。本研究仅进行了 5 km 与 10 km 两个训练数据空间尺度的考虑,结果表明 5 km 优于 10 km。推测原因为 5 km 分辨率,增加了 3 倍训练数据的样本量,在训练中能够建立更多的映射关系。具体原因将在今后做进一步研究。

参考文献(References):

- [1] Li Z L, Tang B H, Wu H, *et al.* Satellite-derived land surface temperature: Current status and perspectives[J]. *Remote Sensing of Environment*, 2013, 131(1): 14-37. DOI: 10.1016/j.rse.2012.12.008.
- [2] Anderson M, Norman J, Kustas W, *et al.* A Thermal-based remote sensing technique for routine mapping of land-surface carbon, water and energy fluxes from field to regional scales [J]. *Remote Sensing of Environment*, 2008, 112(1): 4227-4241. DOI: 10.1016/j.rse.2008.07.009.
- [3] Deng Y H, Wang S J, Bai X Y, *et al.* Relationship among land surface temperature and LUCC, NDVI in typical Karst area [J]. *Scientific Reports*, 2018, 641: 1-2. DOI: 10.1038/s41598-017-19088-x.
- [4] Gao Hao, Xu Ronghan, Wu Shengli. Accuracy evaluation of the FengYun-3C global land surface temperature products retrieval from microwave radiation Imager [J]. *Meteorological and Environmental Sciences*, 2018, 41(5): 1-8. [高浩, 徐榕瀚, 武胜利. 风云三号 C 星微波全球地表温度产品精度评估[J]. *气象与环境科学*, 2018, 41(5): 1-8.]
- [5] Liu Wu, Li Yaodong, Shi Xiaokang. Influence of initial condition adjustment using FY-2G satellite surface temperature retrieval product on typhoon heavy rain simulation [J]. *Meteorological and Environmental Sciences*, 2017, 40(1): 26-34. [刘武, 李耀东, 史小康. FY-2G 地表温度反演产品改变模式初值对一次台风暴雨模拟的影响[J]. *气象与环境科学*, 2017, 40(1): 26-34.]
- [6] Hansen J, Ruedy R, Sato M, *et al.* Global surface temperature change [J]. *Reviews of Geophysics*, 2010, 48(4): 1-29. DOI: 10.1029/2010RG000345.
- [7] Kustas W, Anderson M. Advances in thermal infrared remote sensing for land surface modeling [J]. *Agricultural and Forest Meteorology*, 2009, 149(12): 2071-2081. DOI: 10.1016/j.agrformet.2009.05.016.
- [8] Stathopoulou M, Cartalis C. Downscaling AVHRR land surface temperatures for improved surface urban heat island intensity estimation [J]. *Remote Sensing of Environment*, 2009, 113(12): 2592-2605. DOI: 10.1016/j.rse.2009.07.017.
- [9] Hu L, Brunsell N A. The impact of temporal aggregation of land surface temperature data for Surface Urban Heat Island (SUHI) monitoring [J]. *Remote Sensing of Environment*, 2013, 134(1): 162-174. DOI: 10.1016/j.rse.2013.02.022.
- [10] Estoque R C, Murayama Y. Monitoring surface urban heat island formation in a tropical mountain city using landsat data (1987-2015) [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 133(1): 18-29. DOI: 10.1016/j.isprsjprs.2017.09.008.
- [11] Voogt J A, Oke T R. Thermal remote sensing of urban climates [J]. *Remote Sensing of Environment*, 2003, 86(3): 370-384. DOI: 10.1016/S0034-4257(03)00079-8.
- [12] Fan Zhiyu, Zhan Qingming, Liu Huiming, *et al.* Spatial-temporal distribution of urban heat island and the heating effect of impervious surface in summer in Wuhan [J]. *Journal of Geoinformation Science*, 2019, 21(2): 226-235. [樊智宇, 詹庆明, 刘慧民, 等. 武汉市夏季城市热岛与不透水面增温强度时空分布[J]. *地球信息科学学报*, 2019, 21(2): 226-235.]
- [13] Leng P, Song X, Li Z L, *et al.* Bare surface soil moisture retrieval from the synergistic use of optical and thermal infrared data [J]. *International Journal of Remote Sensing*, 2014, 35(3): 988-1003. DOI: 10.1080/01431161.2013.875237.
- [14] Chauhan N S, Miller S, Ardanuy P. Spaceborne soil moisture estimation at high resolution: A microwave-optical/IR synergistic approach [J]. *International Journal of Remote Sensing*, 2010, 24(22): 4599-4622. DOI: 10.1080/0143116031000156837.

- [15] Anderson M C, Norman J M, Mecikalski J R, *et al.* A Climatological study of evapotranspiration and moisture stress across the continental united states based on thermal remote sensing: 1. model formulation [J]. *Journal of Geophysical Research: Atmospheres*, 2007, 112 (D10117) : 1-17. DOI: 10.1029/2006JD007506.
- [16] Lu J, Tang R, Tang H, *et al.* Derivation of daily evaporative fraction based on temporal variations in surface temperature, air temperature, and net radiation[J]. *Remote Sensing*, 2013, 5(10): 5369-5396. DOI:10.3390/rs5105369.
- [17] Anderson M C, Norman J M, Mecikalski J R, *et al.* A Climatological study of evapotranspiration and moisture stress across the continental united states based on thermal remote sensing: 2. surface moisture climatology[J]. *Journal of Geophysical Research*, 2007, 112(D11112):1-13. DOI:10.1029/2006JD007507.
- [18] Wan Z, Wang P, Li X. Using MODIS land surface temperature and normalized difference vegetation index products for monitoring drought in the southern great plains, USA[J]. *International Journal of Remote Sensing*, 2010, 25(1): 61-72. DOI:10.1080/0143116031000115328.
- [19] Neteler M. Estimating daily land surface temperatures in mountainous environments by reconstructed MODIS LST data [J]. *Remote Sensing*, 2010, 1: 333-351. DOI: 10.3390/rs1020333.
- [20] Chen S S, Chen X Z, Chen W Q, *et al.* A simple retrieval method of land surface temperature from AMSR-E passive microwave data—A case study over southern China during the strong snow disaster of 2008[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2011, 13(1): 140-151. DOI:10.1016/j.jag.2010.09.007.
- [21] Zang Lin, Song Dongmei, Shan Xinjian, *et al.* Reconstruction of LST under the cloud based on passive microwave remote sensing and spatio-temporal domain algorithm [J]. *Remote Sensing Technology and Application*, 2016, 31(4): 764-772. [臧琳, 宋冬梅, 单新建, 等. 基于被动微波与时空联合算法的云下像元LST重建[J]. *遥感技术与应用*, 2016, 31(4): 764-772.]
- [22] Colliander A, Jackson T J, Bindlish R, *et al.* Validation of SMAP surface soil moisture products with core validation sites [J]. *Remote Sensing of Environment*, 2017, 191: 215-231. DOI:10.1016/j.rse.2017.01.021.
- [23] Lu Zheng, Han Menglei, Lu Hui, *et al.* Estimating soil moisture in the middle and upper reaches of the Heihe river basin based on AMSR2 Multi-brightness temperature [J]. *Remote Sensing Technology and Application*, 2020, 35(1): 33-47. [陆峥, 韩孟磊, 卢麾, 等. 基于AMSR2多频亮温的黑河流域中上游土壤水分估算研究[J]. *遥感技术与应用*, 2020, 35(1): 33-47.]
- [24] Tan J, Esmaeel N, Mao K, *et al.* Deep learning convolutional neural network for the retrieval of land surface temperature from AMSR2 data in China[J]. *Sensors*, 2019, 19(2987):1-20. DOI:10.3390/s19132987.
- [25] Li Yongkang, Wang Xinjun, Ma Yanfei, *et al.* Downscaling land surface temperature through AMSR-2 passive microwave observations by Catboost semiempirical algorithms [J]. *Arid Zone Research*, 2021, 38(6): 1137-1649. [李永康, 王新军, 马燕飞, 等. 基于Catboost的AMSR-2半经验地表温度降尺度[J]. *干旱区研究*, 2021, 38(6): 1137-1649.]
- [26] McFarland M J, Miller R L, Neale C M U. Land surface temperature derived from the SSM/I passive microwave brightness temperatures [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1990, 28(5): 839-845. DOI: 10.1109/36.58971.
- [27] Holmes T R H, De Jeu R A M, Owe M, *et al.* Land surface temperature from Ka Band (37 GHz) passive microwave observations [J]. *Journal of Geophysical Research*, 2009, 114 (D04113):1-15. DOI:10.1029/2008JD010257.
- [28] André C, Ottlé C, Royer A, *et al.* Land surface temperature retrieval over circumpolar arctic using SSM/I - SSMIS and MODIS data [J]. *Remote Sensing of Environment*, 2015, 162(1):1-10. DOI:10.1016/j.rse.2015.01.028.
- [29] Ermda S L, DaCamara C C, Trigo I F, *et al.* Modelling directional effects on remotely sensed land surface temperature [J]. *Remote Sensing of Environment*, 2017, 190(1): 56-69. DOI:10.1016/j.rse.2016.12.008.
- [30] Njoku E G, Li L. Retrieval of land surface parameters using passive microwave measurements at 6-18 GHz [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1999, 37(1): 79-93. DOI:10.1109/36.739125.
- [31] Prigent C, Jimenez C, Aires F. Toward “all weather,” long record, and real-time land surface temperature retrievals from microwave satellite observations [J]. *Journal of Geophysical Research: Atmospheres*, 2016, 121(10): 5699-5717. DOI: 10.1002/2015JD024402.
- [32] Gao H, Fu R, Dickinson R E, *et al.* A practical method for retrieving land surface temperature from AMSR-E over the amazon forest [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 46(1): 193-199. DOI: 10.1109/TGRS.2007.906478.
- [33] Mao K, Shi J, Tang H, *et al.* A Neural-network technique for retrieving land surface temperature from AMSR-E passive microwave data [C]// *Proceedings of the 2007 IEEE International Geoscience and Remote Sensing Symposium*. Barcelona: IEEE, 2007. DOI:10.1109/IGARSS.2007.4423835.
- [34] Mao K, Shi J, Li Z, *et al.* A Physics-based statistical algorithm for retrieving land surface temperature from AMSR-E passive microwave data [J]. *Science in China Series D: Earth Sciences*, 2007, 50(7): 1115-1120. DOI: 10.1007/s11430-007-2053-x.
- [35] Shi Hongtao, Song Dongmei, Shan Xinjian. *et al.* The corre-

- lation analysis between MODIS_LST and AMSR-E_BT and study of LST retrieval method[J]. Journal of Geo-information Science, 2016, 18(4): 564-574. [时洪涛, 宋冬梅, 单新建, 等. MODIS_LST 与 AMSR-E_BT 的相关性及地表温度反演[J]. 地球信息科学学报, 2016, 18(4): 564-574.]
- [36] Hua Junwei, Zhu Shanyou, Zhang Guixin, *et al.* Downscaling land surface temperature based on random forest algorithm[J]. Remote Sensing for Land and Resources, 2018, 30(1): 78-86. [华俊玮, 祝善友, 张桂欣. 基于随机森林算法的地表温度降尺度研究[J]. 国土资源遥感, 2018, 30(1): 78-86.]
- [37] Yang Y, Cao C, Pan X, *et al.* Downscaling land surface temperature in an arid area by using multiple remote sensing indices with random forest regression[J]. Remote Sensing, 2017, 9(8): 789-807. DOI: 10.3390/rs9080789.
- [38] Yang G, Pu R, Huang W, *et al.* A Novel method to estimate subpixel temperature by fusing solar-reflective and thermal-infrared remote-sensing data with an artificial neural network [J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48 (4) : 2170-2178. DOI: 10.1109/TGRS. 2009. 2033180.
- [39] Sun D, Li Y, Zhan X, *et al.* Land surface temperature derivation under all sky conditions through integrating AMSR-E/AMSR-2 and MODIS/GOES observations[J]. Remote Sensing, 2019, 11(14): 1704-1904. DOI: 10.3390/rs 11141704.
- [40] Hutengs C, Vohland M. Downscaling land surface temperatures at regional scales with random forest regression[J]. Remote Sensing of Environment, 2016, 178(1): 127-141. DOI: 10.1016/j.rse.2016.03.006.
- [41] Wang Xinjun, Zhao Chengyi, Yang Ruihong, *et al.* Landscape pattern characteristics of desertification evolution in southern Gurbantunggut desert [J]. Arid Land Geography, 2015, 38(6): 1213-1225. [王新军, 赵成义, 杨瑞红, 等. 古尔班通古特沙漠南缘荒漠化过程演变的景观格局特征分析[J]. 干旱区地理, 2015, 38(6): 1213-1225.]
- [42] Wang Xinjun, Zhao Chengyi, Yang Ruihong, *et al.* Dynamic characteristics of sandy vegetation landscape pattern based on dimidiate pixel model[J]. Transactions of the Chinese Society of Agricultural Engineering, 2016, 32(3): 285-294. [王新军, 赵成义, 杨瑞红, 等. 基于像元二分法的沙地植被景观格局特征变化分析[J]. 农业工程学报, 2016, 32(3): 285-294.]
- [43] Zhu Bingqi, Yu Jingjie, Qin Xiaoguang, *et al.* Formation and evolution of sandy deserts in Xinjiang: The palaeo-environmental evidences[J]. Acta Geographica Sinica, 2013, 69(5): 661-679. [朱秉启, 于静洁, 秦晓光, 等. 新疆地区沙漠形成与演化的古环境证据[J]. 地理学报, 2013, 69(5): 661-679.]
- [44] Wang Xueqin, Li Binwen, Zhang Yuanming. Stabilization of dune surface and formation of mobile belt at the top of longitudinal dunes in Gurbantunggut desert, Xinjiang, China [J]. Journal of Desert Research, 2003, 23(2): 28-33. [王雪芹, 李丙文, 张元明. 古尔班通古特沙漠沙垄表面的稳定性与顶部流动带的形成[J]. 中国沙漠, 2003, 23(2): 28-33.]
- [45] Ji Fang, Ye Wei, Wei Wenshou. Preliminary study on the formation causes of the fixed and semi-fixed dunes in Gurbantunggut desert[J]. Arid Land Geography, 2000, 23(1): 32-36. [季方, 叶玮, 魏文寿. 古尔班通古特沙漠固定与半固定沙丘成因初探[J]. 干旱区地理, 2000, 23(1): 32-36.]
- [46] Qin Yanfang, Chen Xi, Zhou Kefa, *et al.* Spatial pattern of soil water content in spring of the Gurbantunggut desert [J]. Arid Land Geography, 2013, 36(6): 1041-1048. [秦艳芳, 陈曦, 周可法, 等. 古尔班通古特沙漠春季土壤含水量空间格局[J]. 干旱区地理, 2013, 36(6): 1041-1048.]
- [47] Liu Jing, Ma Hongzhang, Yang Le, *et al.* A Survey of surface temperature retrieval by passive microwave remote sensing[J]. Remote Sensing Technology and Application, 2012, 27(6): 812-821. [刘晶, 马红章, 杨乐, 等. 基于被动微波的地表温度反演研究综述[J]. 遥感技术与应用, 2012, 27(6): 812-821.]
- [48] Wan Z, Zhang Y, Zhang Q, *et al.* Quality assessment and validation of the MODIS global land surface temperature [J]. International Journal of Remote Sensing, 2004, 25(1): 261-274. DOI: 10.1080/0143116031000116417.
- [49] Chen Lin, Wang Shigong, Wang Lili, Variation characteristics and influencing factors of NO_x and ozone in autumn in FUKANG region of Xinjiang [J]. Journal of Arid Meteorology, 2012, 30(3): 345-352. [陈林, 王式功, 王莉莉. 新疆阜康地区秋季大气 NO_x 和 O₃ 变化特征及影响要素[J]. 干旱气象, 2012, 30(3): 345-352.]
- [50] Xiang Hui. Research on Ensemble Model for Credit Scoring and Its Application[D]. Changsha: Hunan University, 2011. [向晖. 个人信用评分组合模型研究与应用[D]. 长沙: 湖南大学, 2011.]
- [51] Fan Yongdong. A summary of Cross-Validation in Model Selection[D]. Taiyuan: Shanxi University, 2013. [范永东. 模型选择中的交叉验证方法综述[D]. 太原: 山西大学, 2013.]
- [52] Hao Jing, Sun Cheng, Guo Xingyu, *et al.* Simulation of the spatio-temporally resolved PM_{2.5} aerosol mass concentration over the inland plain of the Beijing-Tianjin-Hebei region [J]. Environmental Science, 2018, 39(4): 1455-1465. [郝静, 孙成, 郭兴宇, 等. 京津冀内陆平原区 PM_{2.5} 浓度时空变化定量模拟[J]. 环境科学, 2018, 39(4): 1455-1465.]
- [53] Tao Benzao, Qiu Weining, Zhang Shubi, *et al.* Error theory and measurement adjustment [M]. Wuhan: Wuhan University Press, 2012. [陶本藻, 邱卫宁, 张书毕, 等. 误差理论与测量平差[M]. 武汉: 武汉大学出版社, 2012.]
- [54] Wang Gaigai, Zhang Yulong, Yu Na. Soil pedotransfer function of multiple data source and its uncertainty in water simulation [J]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(11): 45-50. [王改改, 张玉龙, 虞娜. 多数据源土壤传递函数模型在水分模拟中的不确定性[J]. 农业机械学报, 2012, 43(11): 45-50.]

- [55] Wan Z, Zhang Y, Zhang Q, *et al.* Quality assessment and validation of the MODIS global land surface temperature[J]. *International Journal of Remote Sensing*, 2010, 25(1): 261–274. DOI:10.1080/0143116031000116417.
- [56] Yu Wenping, Ma Mingguo. Validation of the MODIS land surface temperature products—A case study of the Heihe river basin[J]. *Remote Sensing Technology and Application*, 2011, 26(6):705–712.[于文凭, 马明国. MODIS 地表温度产品的验证研究——以黑河流域为例[J]. *遥感技术与应用*, 2011, 26(6):705–712.]
- [57] Jin Xufeng, Wu Ying, Qian Bo. Retrieval of land surface temperature from AMSR2 data over the Qinghai-tibetan plateau[J]. *Progress in Geophysics*, 2020, 35(4): 1269–1275.[金旭峰, 吴莹, 钱博. 基于 AMSR2 数据的青藏高原地表温度反演[J]. *地球物理学进展*, 2020, 35(4): 1269–1275.]
- [58] Fily M, Royer A, Goïta K, *et al.* A simple retrieval method for land surface temperature and fraction of water surface determination from satellite microwave brightness temperatures in sub-arctic areas[J]. *Remote Sensing of Environment*, 2003, 85(3):328–338. DOI:10.1016/S0034-4257(03)00011-7.
- [59] Weng F, Grody N C. Physical retrieval of land surface temperature using the special sensor microwave imager [J]. *Journal of Geophysical Research: Atmospheres*, 1998, 103(D8): 8839 – 8848. DOI:10.1029/98JD00275.
- [60] Bhagat V S. Space-borne passive microwave remote sensing of soil moisture: A review [J]. *Recent Progress in Space Technology*, 2015, 4(2): 119–150. DOI: 10.2174/221068710402150513123146.

Downscaling Land Surface Temperature through AMSR-2 Observations by Using Machine Learning Algorithms

Li Yongkang^{1,2}, Wang Xinjun^{1,2}, Ma Yanfei³, Chen Bei^{1,2}, Yan Linan^{1,2},
Zhang Guanhong^{1,2}

(1.College of Grassland and Environment Sciences, Xinjiang Agricultural University,
Urumqi 830052, China;

2.Xinjiang Key Laboratory of Soil and Plant Ecological Processes, Urumqi 830052, China;

3.Department of Geography, Handan University, Handan 056005, China)

Abstract: MODIS daily Land Surface Temperature (LST) products are seriously contaminated by weather effects and the effective pixel information missed. It is sincerely important in areas where data is sparse. An approach to downscaling LSTs from AMSR-2 vertical polarizations multi-brightness temperature and vegetation index observations was preliminarily investigated in the Gurbantunggut Desert, and then the downscaled LSTs were used to fill the gaps due to clouds in the MODIS of 2018. (1) In this study, four machine learning methods (Cubist、DBN、SVM、RF), two training spatial resolution (5 km、10 km), ten band combinations, were applied to train the model. The 10-fold cross-validation results show that the RF model and C09 band combination have the best simulation effect. (2) Two robust downscaling methods of land surface temperature using Random Forest algorithm (5 km|RF|09/10 km|RF|09) were developed to retrieve a 1km-resolution land surface temperature product from Advanced Microwave Scanning Radiometer 2 (AMSR2) data. The validation results with MODIS and station LSTs show that 5 km|RF|09 downscaled LSTs has a better performance than 10 km|RF|09. Comparisons of the retrieval results with MODIS LSTs and ground measurement data from Fukang stations yielded that R^2 respectively is 0.971、0.761, RMSE is 3.380 K、7.614 K and MAE is 2.509 K、6.695 K, which indicated that the accuracy of the 5 km|RF|09 LST retrieval model was high. (3) The downscaling results fill the gaps due to clouds in the MODIS, which can be applied to long-term LST sequence analysis in Gurbantunggut Desert. The method of LSTs downscaled provided scientific reference for data acquisition in data sparse area.

Key words: Land Surface Temperature; AMSR-2; Machine learning algorithm; Downscale; Gurbantunggut Desert