

应用迁移学习的林火烈度初始评估研究

郑忠^{1,2,3}, Jinfei Wang², 邹滨⁴, 高阳华³, 杨世琦³, 王永前¹

1. 成都信息工程大学 资源环境学院, 成都 610225;

2. Department of Geography, the University of Western Ontario, London ON, N6A 5C2 Canada;

3. 重庆市气象科学研究所, 重庆 401147;

4. 中南大学 地球科学与信息物理学院, 长沙 410083

摘要: 林火发生后, 开展森林生态系统烈度信息的初始评估, 能够为灾后生态修复管理措施的快速实施提供定量依据。为了改善传统林火烈度评估模型的时效性, 本研究利用历史过火区域的实地调查数据, 构建基于迁移学习的烈度评估模型, 并将其应用于2020年3月30日发生的西昌泸山森林大火烈度初始评估研究中。研究表明: 迁移学习算法能够将源区域和目标区域的遥感影像光谱转换为多个新的特征变量, 在这些新特征变量构成的投影空间中, 源区域和目标区域样本具有相似的特征分布。在此基础上, 基于源区域历史实地调查数据构建的烈度评估模型, 能够迁移应用于目标区域的烈度评估。在本研究林火烈度的初始评估中, 基于迁移学习的烈度评估模型精度较高, 总体精度为71.20%, Kappa系数为0.64。与该模型对比, 未进行迁移学习的支持向量回归模型精度较低, 其总体精度为58.00%, Kappa系数为0.48。同时, 基于dNDVI、dLST和dNBR指数的经验回归模型精度最低, 其总体精度分别为: 20.80%、34.8%和24.80%, Kappa系数分别为: 0.01、0.19和0.06。本研究可为林火灾后管理措施的快速响应, 提供一种新的思路和参考。

关键词: 林火烈度, 迁移学习, 初始评估, Landsat, 森林火灾, 泸山

引用格式: 郑忠, Jinfei Wang, 邹滨, 高阳华, 杨世琦, 王永前. 2022. 应用迁移学习的林火烈度初始评估研究. 遥感学报, 26(10): 2001-2013

Zheng Z, Wang J F, Zou B, Gao Y H, Yang S Q and Wang Y Q. 2022. Initial assessment of burn severity using the transfer learning model. National Remote Sensing Bulletin, 26(10):2001-2013[DOI:10.11834/jrs.20210156]

1 引言

近年来, 受到全球气候变化、人类活动干扰和自然资源开发等因素的影响, 森林大火在全球范围内频繁爆发, 严重破坏森林生态系统的结构与功能 (Zheng 等, 2017; 陈兴峰 等, 2020; 刘树超 等, 2020; 唐尧 等, 2021; 徐奔奔 等, 2022)。在林火发生后, 开展森林生态系统损害程度的定量评估, 不仅有助于理解林火与森林生态系统相互影响机制, 而且能为森林生态系统修复措施的实施提供决策依据 (蒲东川 等, 2020; 覃先林 等, 2020; 饶月明 等, 2020)。

林火导致森林生态系统的影响/破坏程度, 通常定义为林火烈度 (Burn/Fire severity), 主要采用

人工实地调查方法进行定量评估 (Keeley, 2009)。这种方法虽然能够获得相对准确的评估结果, 但是需要耗费大量的人力、物力和时间, 特别在大尺度范围内同步开展评估时, 其效率相对较低 (谭柳霞 等, 2016)。因此, 基于遥感数据的评估方法, 逐渐成为林火烈度评估研究的重要发展方向 (Loboda 等, 2013; Zheng 等, 2016)。

基于遥感数据的林火烈度评估方法主要包含经验回归模型 (Veraverbeke 等, 2012) 和物理模型 (De Santis 和 Chuvieco, 2009)。其中, 用于经验回归模型构建的经典指标为归一化燃烧指数 NBR (Normalized Burn Ratio), 该指数的计算是基于遥感影像中对于过火区域环境因子较为敏感的近红外波段和短波红外波段 (Chen 等, 2011)。在

收稿日期: 2020-05-13; 预印本: 2020-09-01

基金项目: 国家自然科学基金(编号: 41801315; 41771535); 国家留学基金(编号: 201908510029); 重庆市气象局开放式研究基金(编号: KFJJ-201705); 成都信息工程大学引进人才(编号: KYTZ201742)

第一作者简介: 郑忠, 研究方向为林火遥感应用及大气污染 GIS 环境建模。E-mail: zhengzhong@cuit.edu.cn

NBR 指数的基础上, 顾及林火烈度定义中包含的变化量属性特征, Key 和 Benson (2006) 利用林火发生前后的遥感影像, 进行差分计算得到差分归一化燃烧指数 dNBR (delta Normalized Burn Ratio), 并将其用于林火烈度的定量评估; 为了降低林火发生前稀疏植被覆盖区域对于烈度评估结果的影响, Miller 和 Thode (2007) 进一步构建相对差分归一化燃烧指数 RdNBR (Relative delta Normalized Burn Ratio), 用于经验回归模型的构建; 在此基础上, Parks 等 (2014) 则通过优化 RdNBR 指数中权重的方式, 提出了相对化燃烧指数 RBR (Relativized Burn Ratio)。

作为新一类的模型构建指标, 地表温度也被用于林火烈度的定量评估中。如: Lentile 等 (2006) 讨论了地表温度作为烈度评估指标的可能性; Quintano 等 (2015) 在西班牙西北部的一场森林火中, 研究了一年不同时间段的地表温度指标, 在林火烈度评估方面的性能; Zheng 等 (2016) 利用增强型植被指数 EVI (Enhanced Vegetation Index) 和地表温度综合构建了一种新的指标, 并将其应用于美国西部五场森林火的烈度评估研究中。

在物理模型的研究方面, Chuvieco 等 (2006) 综合了 Prospect 和 Kuusk 辐射传输模型, 反演了不同烈度等级下植被冠层的光谱响应特征, 并以此作为林火烈度研究评估的主要依据; De Santis 和 Chuvieco (2007 和 2009) 则在西班牙中部区域一场森林火的烈度定量评估中, 针对辐射传输模型和经验回归模型的精度进行了具体的对比和分析; 并进一步地结合 Prospect 和 GeoSail 辐射传输模型, 评估了地中海区域三场森林火的烈度空间分布。

另外, 穗帽变换模型 (Patterson 和 Yool, 1998)、多端元光谱混合分析模型 (Quintano 等, 2013) 和支持向量回归模型 (Zheng 等, 2018) 等也被用于林火烈度定量评估的相关研究中。

实地调查数据 (如 CBI 指数) 是上述模型构建与结果评价的基础, 但实地调查工作需要耗费大量的人力、物力和时间。尤其在林火发生以后的初始评估中, 过火区域植被可能存在“假死”和“真死”状态; 另外由于难以快速开展实地调查, 基于遥感数据的林火烈度评估时效性降低, 限制了遥感技术在林火烈度评估中的高效应用 (Zheng 等, 2020)。

针对目标区域的林火烈度初始评估, 如果相

似区域的历史调查数据能应用于模型构建, 在理论上能够改善传统林火烈度评估的时效性。但是, 实地调查和烈度评估通常针对不同林火区域, 其遥感数据具有不同的光谱特征。

目前, 相关的研究表明 (Pan 等, 2011; Matasci 等, 2015; Yan 等, 2018), 迁移学习算法能够实现不同区域之间相似特征变量的提取, 该算法有助于构建具有迁移能力的学习模型。因此, 借助历史过火区域的实地调查数据, 在迁移学习算法的基础上, 构建林火烈度评估模型, 并将其应用于 2020 年 3 月 30 日发生的四川西昌泸山森林大火烈度的初始评估中, 以期为该过火区域森林生态修复措施的制定, 提供初步的定量依据。

2 研究区域与数据

2.1 研究区域

如图 1 所示, 选取的目标区域为 2020 年 3 月 30 日发生在四川省凉山州西昌市城区附近的泸山森林大火。自 3 月以来, 泸山森林区域连续 20 日无降水, 湿度为 5%—10%, 林火发生当日气温高达 31.2 °C, 风力为 7—8 级。该区域属于中国的亚热带高原季风气候, 主要树种为云南松, 其松节油含量高, 易于林火的燃烧和蔓延。至 4 月 2 日, 该场大火共造成 19 人遇难, 过火面积约 10 km²。

选取位于美国中西部的 Mule 和 Bear 林火作为源区域 (Zheng 等, 2016), 主要基于以下因素: (1) 与泸山森林地貌属性相似, Mule 和 Bear 均位于北半球中纬度地区, 且 3 场林火过火区域的地形均属于高原山地; (2) 与泸山森林类型相似, Mule 和 Bear 过火区域的主要树种也属于易燃的常绿针叶林; (3) Mule 和 Bear 过火区域属于高原山地气候, 而泸山森林区域的地理位置靠近于青藏高原山地气候区域, 相邻的气候区域有利于迁移学习的应用。林火区域及气候特征具体如表 1 所示。

2.2 实地调查数据

在林火发生以后开展实地调查, 是基于遥感数据林火烈度评估模型构建的基础。实地调查数据来源于美国 National Park Service 和 US Geological Survey 资助的 JFSP (Joint Fire Science Program) 项目。Mule 和 Bear 林火区域的实地调查数据, 获取

于林火发生后的第一个生长期, 具体为2003年5月和9月, 共110个样地(表2)。在实地调查过程中(图2), 具体采用综合燃烧指数CBI(Composite

Burn Index)方法进行评估, CBI为0—3之间的连续值(Key和Benson, 2006; 王晓莉等, 2013)。

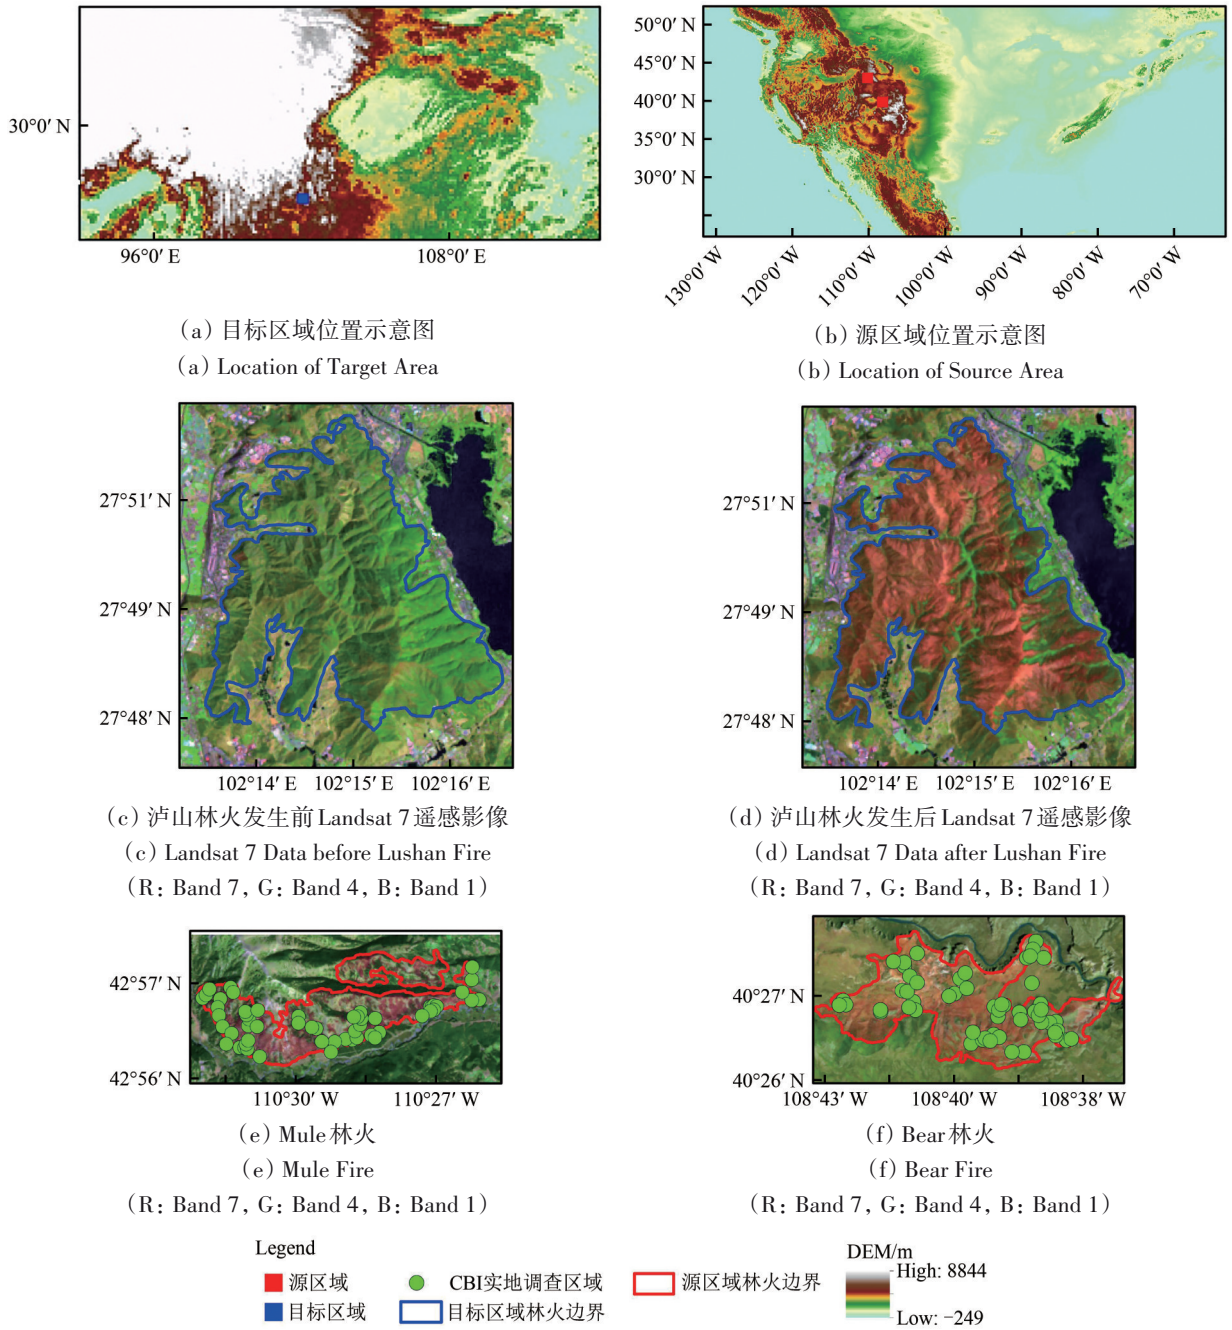


图1 研究区域及地理位置
Fig. 1 Study area and locations

表1 林火区域及气候特征

Table 1 Forest fires and regional climate

区域	林火名称	气候类型	年均降水/mm	高程/m
源区域	Mule	温带高原山地气候	750—1150	1981—3353
源区域	Bear	温带高原山地气候	<300	1700—2740
目标区域	庐山	亚热带高原季风气候	226—1000	1510—2317

表2 卫星遥感数据和实地调查数据

Table 2 Remotely sensed data and field survey data

林火名称	遥感数据				CBI调查数据	
	发生时间	传感器	林火发生前影像	林火发生后影像	实地调查时间	数量
Mule	2002-07-11	TM/MODIS	2001-09-21	2003-09-27	2003-09-08至2003-09-11	55
Bear	2002-06-27	TM/MODIS	2002-06-13	2003-05-13	2003-05-28至2003-05-30	55
庐山	2020-03-30	ETM+/MODIS	2020-03-21	2020-05-08	—	—



图2 CBI实地调查过程

Fig. 2 Field work for CBI data

2.3 遥感数据

如表2所示,为了匹配 Bear 和 Mule 林火的实地调查时间,选取2003年5月13日和2003年9月27日过境的 Landsat 5 Thematic Mapper (TM) 数据 ([https://earthexplorer.usgs.gov/\[2020-05-08\]](https://earthexplorer.usgs.gov/[2020-05-08])),作为源区域林火发生后的遥感影像;相应地,选取2001年9月21日和2002年6月13日过境的 TM 影像 ([https://earthexplorer.usgs.gov/\[2020-05-08\]](https://earthexplorer.usgs.gov/[2020-05-08]))作为源区域林火发生前的遥感影像。

针对目标区域(即庐山森林大火),分别选取2020年3月21日和2020年5月8日过境的 Landsat 7 Enhanced Thematic Mapper (ETM+) 数据 ([https://earthexplorer.usgs.gov/\[2020-05-08\]](https://earthexplorer.usgs.gov/[2020-05-08])),作为林火发生前和林火发生后的遥感影像。如图1所示,Landsat 7 ETM+中的“数据条带丢失”未影响到目标区域,故无需考虑其对后续分析的影响;同时,获取2020年4月6日过境目标区域的少云 GF-1 遥感数据 ([http://www.cresda.com/CN/\[2020-05-08\]](http://www.cresda.com/CN/[2020-05-08])),以用于迁移学习算法参数的优化及烈度评估结果的精度评价。

获取的 Landsat 5 TM 和 Landsat 7 ETM+ 数据均来自于 USGS EarthExplorer 的 C1 Level 1 产品,均已完成了辐射校正和几何校正等处理,后续的预

处理工作:辐射定标、大气校正和裁剪等均在 ENVI 5.1 软件中完成。

相应地获取各景 TM/ETM+ 影像过境日期同期 1 km 分辨率的 MOD05 产品数据,用于单通道地表温度反演算法中大气函数的计算。其重投影、格式转换、重采样等预处理在 ENVI 5.1 软件支持下的 MCTK (MODIS Conversion Toolkit) 工具包中完成。

在上述遥感数据预处理的基础上,利用 ArcGIS 10.2 软件 Spatial Analyst Tools 中的 Extract Multi Values to Points 模块,提取与 CBI 实地调查数据相对应位置的遥感光谱值。

3 烈度评估模型

受到区域环境、大气状况、太阳高度角和地形等因素的影响,源区域与目标区域获取的遥感影像通常存在光谱差异,因此需要利用迁移学习算法,将源区域和目标区域的遥感影像光谱变换得到多个新特征变量,在由这些新特征变量组成的投影空间中,源区域和目标区域样本具有相似分布,能够实现评估模型的迁移应用 (Matasci 等, 2015; Yan 等, 2018)。

3.1 迁移学习算法

基于已报道的研究 (Matasci 等, 2015; Zheng 等, 2020),本研究同样选用迁移学习中的 SSTCA (Semi-Supervised Transfer Component Analysis) 算法进行源区域与目标区域遥感影像光谱的变换。该算法由 Pan 等 (2011) 提出,其基本原理类似于传统的 PCA (Principal Components Analysis) 变换,其目标函数包含以下 3 个部分 (Pan 等, 2011; Matasci 等, 2015; Yan 等, 2018):

3.1.1 目标 1: 减小源区域和目标区域样本光谱差异

经过 SSTCA 变换后,源区域和目标区域样本

光谱差异最小，且变换后样本数据的方差最大。

源区域和目标区域样本的光谱差异利用定量指标 MMD (Maximum Mean Discrepancy) 进行度量 (Pan 等, 2011; Yan 等, 2018):

$$\text{MMD}(X_s, X_{Ta}) = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \Phi(X_{S_i}) - \frac{1}{n_{Ta}} \sum_{j=1}^{n_{Ta}} \Phi(X_{T_j}) \right\|_H^2 \quad (1)$$

式中, X_s 为源区域样本的遥感光谱波段反射率, X_{Ta} 为目标区域样本的遥感光谱波段反射率, Φ 为需要 SSTCA 算法构建的变换方程, n_s 为源区域样本数量, n_{Ta} 为目标区域样本数量, $\|\cdot\|_H^2$ 为希尔伯特空间 (Hilbert Space) 范数。

以矩阵迹的形式, 式 (1) 可改写为 (Pan 等, 2011):

$$\text{MMD}(X_s, X_{Ta}) = \text{tr}((\mathbf{K}\mathbf{W}\mathbf{W}^T\mathbf{K})\mathbf{L}) = \text{tr}(\mathbf{W}^T\mathbf{K}\mathbf{L}\mathbf{K}\mathbf{W}) \quad (2)$$

式中, \mathbf{K} 为参数化核矩阵, \mathbf{L} 为核矩阵 \mathbf{K} 的缩放因子, \mathbf{W} 为光谱反射率变换方程的权矩阵, \mathbf{W}^T 为权矩阵 \mathbf{W} 的转置。

为了保留遥感光谱波段中的有用信息, 以利于后续烈度评估模型的学习, 需要最大化数据的方差。变换后数据方差的计算公式如下 (Matasci 等, 2015; Yan 等, 2018):

$$\Sigma^* = \frac{1}{n_s + n_{Ta}} \sum_{i,j=1}^{n_s + n_{Ta}} (X_i^* - \bar{X}^*)(X_j^* - \bar{X}^*)^T = \mathbf{W}^T\mathbf{K}\mathbf{H}\mathbf{K}\mathbf{W} \quad (3)$$

式中, \mathbf{H} 为中心矩阵, 其值为:

$$\mathbf{H} = \mathbf{I}_{n_s + n_{Ta}} - \mathbf{1}\mathbf{1}^T / (n_s + n_{Ta}) \in \mathbb{R}^{(n_s + n_{Ta}) \times (n_s + n_{Ta})} \quad (4)$$

综合式 (2) 和 (3), 目标 1 对应的目标函数:

$$\begin{cases} \min_{\mathbf{W}} & \text{tr}(\mathbf{W}^T\mathbf{K}\mathbf{L}\mathbf{K}\mathbf{W}) + \mu \text{tr}(\mathbf{W}^T\mathbf{W}) \\ \text{s.t.} & \mathbf{W}^T\mathbf{K}\mathbf{H}\mathbf{K}\mathbf{W} = \mathbf{I}_m \end{cases} \quad (5)$$

式中, $\text{tr}(\mathbf{W}^T\mathbf{W})$ 用于度量变换方程的复杂度, μ 用于调整目标函数中变换方程复杂度的权重。

3.1.2 目标 2: 增强变换方程对于源区域样本信息的依赖

源区域的历史样本通常包含实地调查信息, 利用这些实地调查信息构建的变换方程, 有利于后续烈度评估模型的学习。该目标可以定量地表示为 (Pan 等, 2011):

$$\text{Tr}(\mathbf{H}(\mathbf{K}\mathbf{W}\mathbf{W}^T\mathbf{K})\mathbf{H}\mathbf{K}_{YY}^*) = \text{Tr}(\mathbf{W}^T\mathbf{K}\mathbf{H}\mathbf{K}_{YY}^*\mathbf{H}\mathbf{K}\mathbf{W}) \quad (6)$$

式中, $\mathbf{K}_{YY}^* = \gamma\mathbf{K}_{YY} + (1 - \gamma)\mathbf{I}$, \mathbf{K}_{YY} 为基于实地调查信息计算得到的核矩阵; γ 参数用于调节实地调查信息依赖程度和数据方差之间的均衡。

3.1.3 目标 3: 保留原空间中的距离大小的相对关系

经过变换后, 原光谱空间中距离越近的样本, 新投影空间中样本之间的距离也越近。该目标可以定量地表示为 (Matasci 等, 2015):

$$\frac{1}{(n_s + n_{Ta})^2} \sum_{ij} \mathbf{M}_{i,j} \|X_i^* - X_j^*\|^2 = \frac{1}{(n_s + n_{Ta})^2} \text{tr}(\mathbf{W}^T\mathbf{K}(\mathbf{D} - \mathbf{M})\mathbf{K}\mathbf{W}) \quad (7)$$

式中, \mathbf{D} 为对角矩阵 $D_{i,i} = \sum_j M_{i,j}$; \mathbf{M} 为亲密度矩阵, 其中的元素具体计算为

$$\mathbf{M}_{i,j} = \begin{cases} \exp(-d_{ij}^2/2\sigma^2) & x_i \text{与} x_j \text{互为} k \text{邻域} \\ 0 & \text{其他} \end{cases} \quad (8)$$

综上, 将式 (5)、(6) 和 (7) 进行结合后, 最终得到 SSTCA 迁移学习算法的目标函数方程:

$$\begin{cases} \min_{\mathbf{W}} & \text{tr}(\mathbf{W}^T\mathbf{K}\mathbf{L}\mathbf{K}\mathbf{W}) + \mu \text{tr}(\mathbf{W}^T\mathbf{W}) + \\ & \frac{\lambda}{(n_s + n_{Ta})^2} \text{tr}(\mathbf{W}^T\mathbf{K}\mathbf{L}\mathbf{K}\mathbf{W}) \\ \text{s.t.} & \mathbf{W}^T\mathbf{K}\mathbf{H}\mathbf{K}_{YY}^*\mathbf{H}\mathbf{K}\mathbf{W} = \mathbf{I}_m \end{cases} \quad (9)$$

针对方程 (9), 可通过拉格朗日乘数法求解:

$$\mathbf{A} = (\mathbf{K}(\mathbf{L} + \lambda)\mathbf{L}\mathbf{K} + \mu\mathbf{I})^{-1}\mathbf{K}\mathbf{H}\mathbf{K}_{YY}^*\mathbf{H}\mathbf{K} \quad (10)$$

计算其特征分解矩阵, 并前 m 个特征值对应的特征向量组成光谱变换方程的权矩阵 \mathbf{W} 。

3.2 烈度评估模型

基于 SSTCA 迁移学习的权矩阵 \mathbf{W} , 利用源区域和目标区域遥感光谱波段的原始反射率, 计算得到多个新特征变量。然后, 基于源区域样本数据, 构建支持向量回归模型 (SVR) (Cherkassky 和 Ma, 2004; Zheng 等, 2018)。SSTCA 与 SVR 两种算法构成烈度评估模型 SVR-SSTCA:

$$\begin{cases} \min_{w^*, b} & \frac{1}{2} \|w^*\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\ \text{s.t.} & |Y_{S_i} - f(X_{S_i}^*, w^*, b)| \leq \varepsilon \end{cases} \quad (11)$$

式中, $\|w^*\|^2$ 为模型复杂度, ξ_i 和 ξ_i^* 为松弛变量, ε 为损失边界, C 为惩罚系数用于调节模型复杂度与偏差之间的相对权重。

在这些新特征变量组成的投影空间中, 源区域和目标区域的样本具有相似分布, 因此能够将式 (11) 迁移到目标区域的烈度评估中:

$$Y_{Ta,j} = f(X_{Ta,j}^*, w^*, b) \quad (12)$$

式中, $Y_{Ta,j}$ 和 $X_{Ta,j}^*$ 分别为目标区域的烈度评估值和

新特征变量值。

3.3 模型实现与精度评价

本研究中, SSTCA 算法通过调用 MATLAB 软件的“a domain adaptation toolbox”工具箱实现(<https://www.github.com/viggin/domain-adaptation-toolbox/>[2019-12-09]), SVR 算法则通过调用 MATLAB 软件中的“LIBSVM toolbox”工具箱实现(<https://www.csie.ntu.edu.tw/~cjlin/libsvm/index.html/>[2018-08-06])。

针对 SSTCA 算法, 需要设置的主要参数如表 3 所示。其中, 针对参数 m 和 λ 的优化, 按照等量的原则, 在目标区域(即泸山森林大火)随机选取 110 个样本, 并在 GF-1 遥感影像基础上, 参考 Quintano 等(2013)构建的解译标准(如图 3 所

示), 针对随机样本进行目视解译, 最终将解译结果用于 SSTCA 算法的参数优化。

表 3 SSTCA 算法参数及设置
Table 3 Parameters of SSTCA

参数	参数含义	参数设置
μ	式(5)中方程复杂度权重	1 (Pan 等, 2011; Matasci 等, 2015)
K	式(2)中核矩阵 K 类型	Linear (Pan 等, 2011; Matasci 等, 2015)
k	式(8)中的邻域参数	100 (Pan 等, 2011; Matasci 等, 2015)
γ	式(6)中源区域样本依赖	0.5 (Pan 等, 2011; Matasci 等, 2015)
m	变换后特征变量的数量	参数优化
λ	式(9)中局部信息保留	参数优化

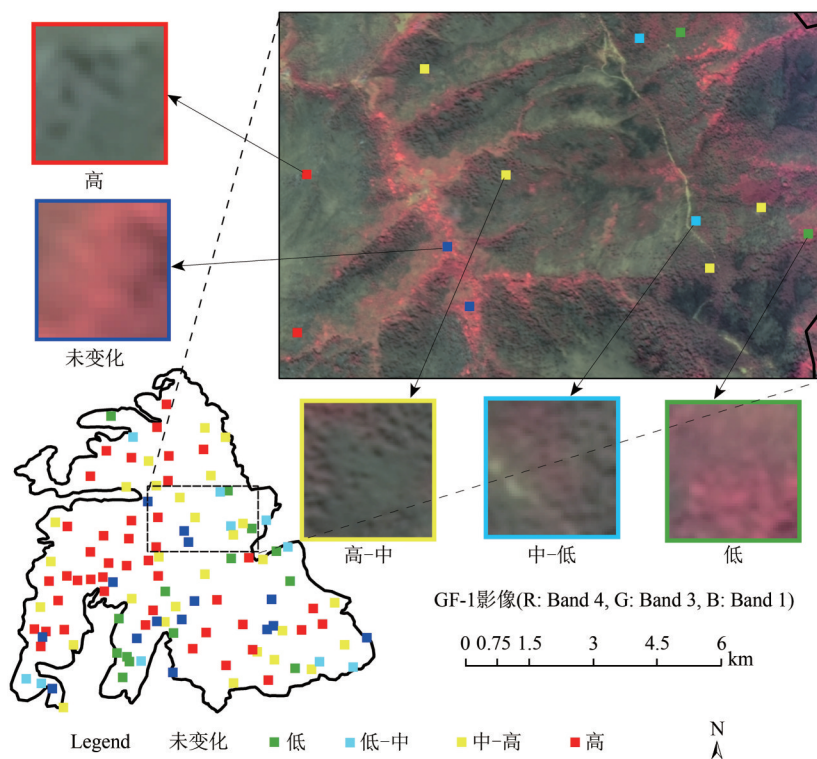


图 3 样本的目视解译

Fig. 3 Visual inspection of field plots

同时, 为了对各模型烈度评估结果进行精度评价, 按照上述同样的解译标准, 针对各烈度等级, 在过火区域内均匀地选取 50 个样点, 共 250 个验证样本, 用于计算各模型评估结果的混淆矩阵。

为了与基于指数的经验回归模型和 SVR 模型的评估结果进行进一步对比分析, 基于遥感光谱原始波段反射率, 利用源区域的实地调查样本, 构建了基于 $dNDVI$ 、 $dLST$ 、 $dNBR$ 指数的经验回归

模型和 SVR 模型。计算各指数的公式如下所示 (Chen 等, 2011; Zheng 等, 2016):

$$dNDVI = NDVI_{pre-fire} - NDVI_{post-fire} \quad (13)$$

$$dLST = LST_{post-fire} - LST_{pre-fire} \quad (14)$$

$$dNBR = NBR_{pre-fire} - NBR_{post-fire} \quad (15)$$

式中, 下标 Pre-fire 代表林火发生前的光谱指数值, 下标 Post-fire 代表林火发生后的光谱指数。

4 结果

4.1 参数优化

如图4所示, SSTCA算法中最优参数取值为:
 $m=8$ 和 $\lambda=0.01$, 其对应的 Kappa 值最高为 0.692。
另外, SVR算法中的优化主要包含参数 C 和 ε , 采用
网格参数寻优法, 进行交叉验证的方式确定。




图4 SSTCA算法中的参数优化
Fig. 4 Parameter optimization of SSTCA

不同模型的参数优化结果如表4所示。在所构建的模型中, SSTCA-SVR精度最高 (RMSE=0.38),

其次为SVR (RMSE=0.59); 在构建的经验回归模型中, dLST的精度最高 (RMSE=0.75)。

表4 各模型参数优化

Table 4 Optimized parameters of different models

参数*	支持向量回归模型			迁移学习模型		
	dNDVI	dLST	dNBR	参数	SVR	SSTCA-SVR
a	-5.7432	-3.9002	-3.5515	C	97.0059	97.0059
b	6.14	6.7279	5.0181	ε	0.3789	0.3789
c	1.2824	0.8767	0.9666	m	—	8
R^2	0.25	0.49	0.40	λ	—	0.01
RMSE	0.91	0.75	0.82	RMSE	0.59	0.37

* dNDVI、dLST和dNBR指数均采用一元二次回归进行拟合, 其回归模型形式为 $CBI = a \times (x)^2 + b \times x + c$ (P 值均小于0.05), 其中 a 、 b 、 c 为这3个模型的系数。

4.2 光谱变换前后特征变量分布

如图5所示, 在不同波段原始光谱值相互组成的大部分特征空间中, 源区域实地调查样本和目标区域随机样本的分布存在较大差异, 这主要与不同区域之间的环境、大气状况、太阳高度角和地形等因素有关。

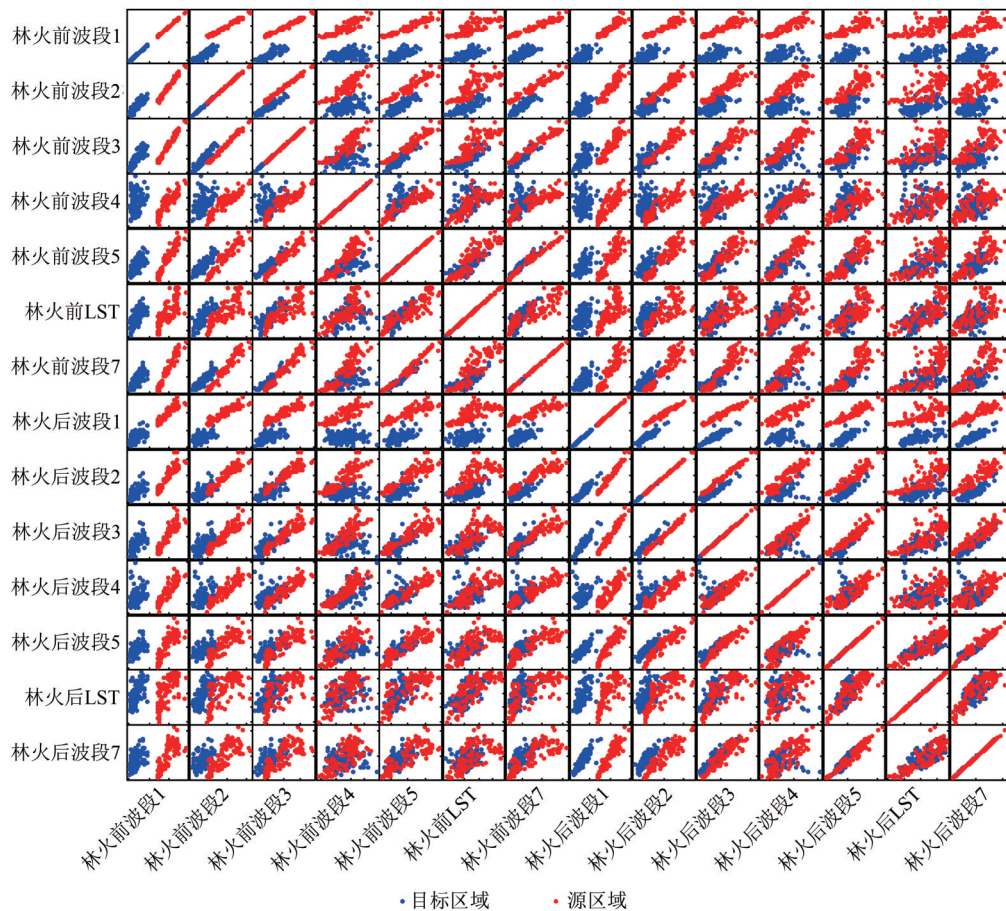


图5 源区域和目标区域遥感影像光谱散点分布图

Fig. 5 Scatter plot matrix of original spectral feature space across source and target domains

基于上述优化后的参数, 利用 SSTCA 迁移学习算法, 将源区域和目标区域样本的遥感波段光谱值进行变换, 得到 8 个新的特征变量, 由这些特征变量组成的投影空间见图 6 所示。经过 SSTCA 变

换, 新特征变量相互组成的大部分投影空间中, 源区域实地调查样本和目标区域随机样本具有相似分布。




图 6 源区域和目标区域特征变量散点分布图

Fig. 6 Scatter plot matrix of projected feature space across source and target domains

4.3 烈度评估结果

在烈度等级传统划分标准的基础上 (Miller 和 Thode, 2007), 为了与 Key 和 Benson (2006) 中的设置的烈度等级相匹配, 构建细分标准: 未变化 ($CBI \leq 0.1$)、低等级 ($0.1 < CBI \leq 1.25$)、低-中等级 ($1.25 < CBI \leq 1.75$)、中-高等级 ($1.75 < CBI \leq 2.25$)、高等级 ($2.25 < CBI \leq 3$)。基于此, 将上述各模型计算获得的连续 CBI 值进行分级, 得到不同模型的林火烈度等级评估结果, 其空间分布如图 7 所示。基于本文 3.3 节中解译得到的 250 个验证样本, 进一步计算各评估结果的混淆矩阵, 其精度评价指标的统计结果如表 5 所示。

在初始评估的过火环境内, 植被部分往往损害严重, 基于植被敏感光谱波段构建的 dNDVI 和 dNBR 指数, 容易低估其余环境因子变化; 因此, 如图 7 (a) 和图 7 (c) 所示: 基于 dNDVI 和 dNBR 的经验回归模型, 出现了烈度等级的高估。表 5 中的定量评价结果也表明, 这两个模型高烈度等级的生产者精度, 虽然较高, 位于 78.00%—98.00% 之

间; 但是其用户精度较低, 位于 27.66%—34.27% 之间。

与 SVR (图 7 (d)) 和 SSTCA-SVR (图 7 (e)) 模型相比, 基于 dNDVI 和 dNBR 的经验回归模型, 其评估结果空间分布的精细程度较低。其主要原因是: 在光谱指数构建时, 通常只选取遥感影像中部分光谱波段进行计算。因此, 表 5 中结果表明: dNDVI 和 dNBR 指数的精度较低, 总体精度位于 20.80%—24.80% 之间, Kappa 系数位于 0.01—0.06 之间。

基于 dLST 的经验回归模型, 其烈度评估结果的空间分辨率最低 (图 7 (b)), 这主要受到 ETM+ 遥感影像中热红外波段低空间分辨率的影响 (60 m)。但是, 该模型的总体精度为 34.8%, Kappa 系数为 0.19, 高于基于 dNDVI 和 dNBR 的经验回归模型。这与 Quintano 等 (2015) 的研究报道较为一致, 即在林火发生后开展的林火烈度初始评估中, 地表温度指标 LST 与 CBI 实地调查结果具有较高的相关性。

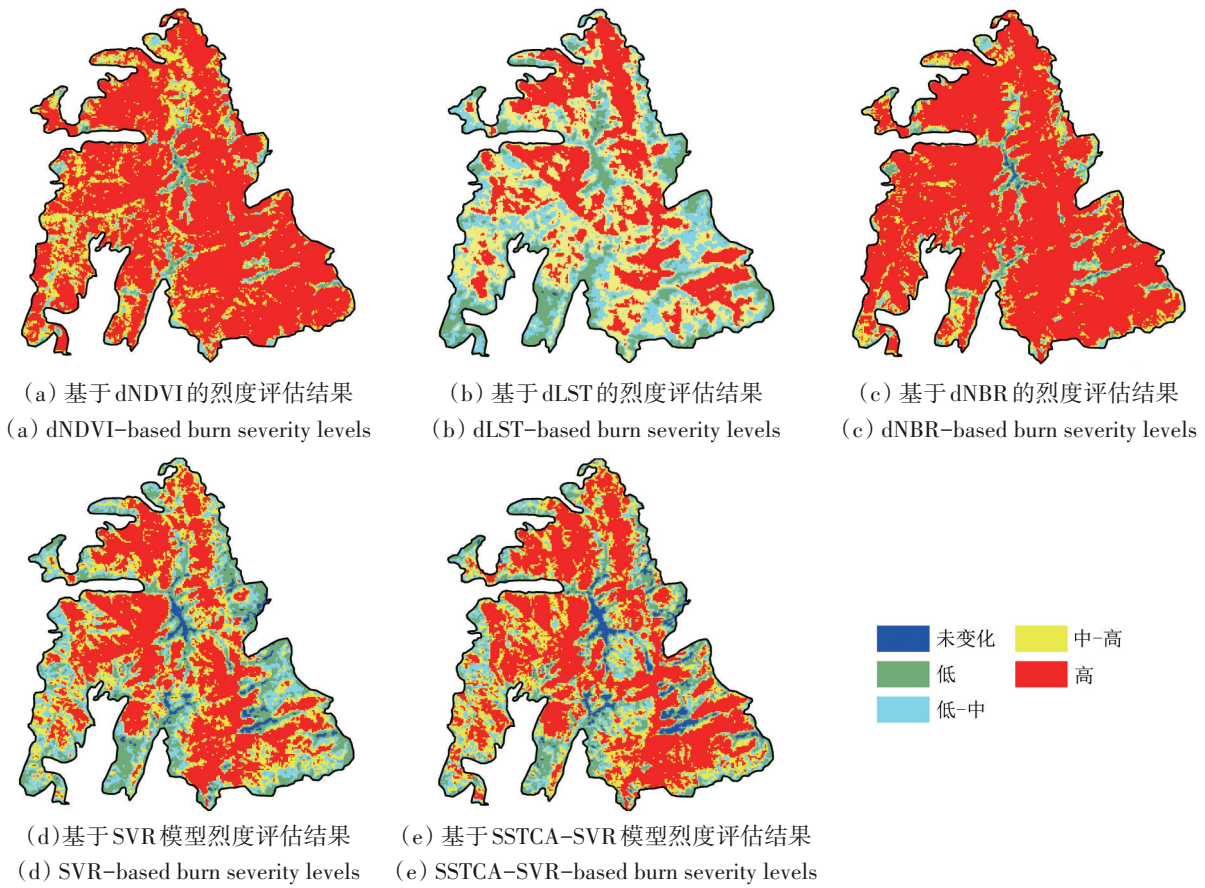


图 7 不同模型烈度等级评估结果空间分布

Fig. 7 Mapped results of burn severity levels using different models

表 5 各模型烈度评估精度评价

Table 5 Accuracy assessment of burn severity levels using different models

烈度等级	dNDVI		dLST		dNBR		SVR		SSTCA-SVR	
	生产者 精度/%	用户 精度/%	生产者 精度/%	用户 精度/%	生产者 精度/%	用户 精度/%	生产者 精度/%	用户 精度/%	生产者 精度/%	用户 精度/%
未变化	4.00	66.67	0.00	0.00	6.00	60.00	40.00	76.92	74.00	78.72
低	6.00	15.79	24.00	24.00	8.00	13.79	56.00	38.89	64.00	58.18
低-中	8.00	12.90	48.00	32.00	4.00	7.14	58.00	51.79	68.00	70.83
中-高	8.00	7.14	56.00	33.33	8.00	8.89	60.00	57.69	60.00	68.18
高	78.00	27.66	46.00	56.10	98.00	34.27	76.00	86.36	90.00	80.36
总体精度/%	20.80		34.80		24.80		58.00		71.20	
Kappa	0.01		0.19		0.06		0.48		0.64	

图 7 (d) 所示的 SVR 模型评估结果，出现了部分区域烈度高估的现象，其总体精度 58.00%，Kappa 系数为 0.48。其主要原因是：该模型的构建是基于源区域的遥感影像，并被直接应用于目标区域的烈度评估。由于未利用 SSTCA 迁移学习算法进行遥感影像原始波段的光谱变换，目标区域与源区域遥感波段存在较大的光谱差异 (图 5)，直接将其迁移于目标区域烈度的评估时，会给评

估结果带来一定的误差。

由于应用了 SSTCA 变换，源区域实地调查样本和目标区域随机样本在新特征变量投影空间中具有相似分布 (图 6)，源区域优化后的 SSTCA-SVR 模型能够适用于目标区域的烈度评估。因此，SSTCA-SVR 模型烈度评估结果 (图 7 (e)) 不仅与 SVR 模型烈度评估结果 (图 7 (d)) 在空间分布上保持较好的一致性，而且其空间精细程度较高。

表5中的评价结果也表明：SSTCA-SVR模型的精度最高，其总体精度为71.20%，Kappa系数为0.64。

进一步将不同模型的烈度评估结果进行统计，其统计结果如表6所示。

表6 各模型烈度评估定量统计
Table 6 Quantitative statistics of burn severity levels using different models

烈度等级	面积/km ²				
	dNDVI	dLST	dNBR	SVR	SSTCA-SVR
未变化	0.04	0.07	0.11	0.78	1.09
低	1.03	5.09	1.36	5.78	4.58
低-中	2.15	7.36	2.12	6.17	5.23
中-高	6.37	10.58	4.67	7.79	7.99
高	23.27	9.77	24.60	12.35	13.97

5 讨论

传统林火烈度评估中，需要过火区域的实地调查才能构建评估模型，这难以在应急响应情境下支撑灾后管理决策。特别在有限的人力、物力和财力的影响下，往往难以保证能在所有的过火区域开展实地调查，因此针对实地调查数据缺失情况下的烈度评估开展研究具有重要意义。

在构建光谱指数时，其主要依据专家知识对物理机制的理解。以经典的NBR指数构建为例，其选取Landsat数据中近红外和远红外波段的主要依据是：林火发生前后的植被区域，近红外波段的反射率会降低，而远红外波段的反射率会增加。当利用林火发生前Landsat 3、4、5、7波段的反射率减去林火发生后对应波段的反射率时，近红外波段唯一出现正值变化，远红外波段的变化幅度最大（Key和Benson，2006）；且在已有研究报道中（Soverel等，2011），该指数也表现出一定的迁移能力。

但是，由于专家知识对物理机制的理解可能存在不足，会导致遥感数据中所包含的烈度信息被忽略。如构建NBR指数时，TM/ETM+中红光和中红外波段等与烈度相关的光谱信息未被充分利用（Key和Benson，2006）。

与其不同的是，迁移学习算法是利用机器学习的方法，从原始遥感光谱信息中转换得到能在源区域和目标区域保持相似分布的多个新特征变量（Pan等，2011；Matasci等，2015）。在该过程

中，与林火烈度相关的光谱信息，能更多地得到保留。因此从表5中的结果可以发现，针对未变化、低、低-中和中-高烈度等级评估，SSTCA-SVR模型的精度相对较高。

随着全球及区域环境的急剧变化，近年来林火呈现频繁爆发的趋势，开展森林火灾历史研究（王敏等，2020）以及林火烈度实地调查数据库建设具有重要意义。基于迁移学习构建烈度评估模型的思路，有利于历史林火烈度数据的回溯，可为特定区域长时间段的林火生态影响研究提供一定的数据支持。

但是，本研究所针对的是林火烈度初始评估IA（Initial Assessment），由于森林刚发生燃烧，过火区域内的植被可能存在“假死”和“真死”状态，会给评估结果带来误差；因此，准确定量的评估EA（Extended Assessment），需要在植被下一个生长季节开展。

同时，本研究中林火烈度评估结果的精度，采用了间接评价方法（Quintano等，2013），在利用可获得的少云GF-1影像解译验证样本时，可能存在一定的主观性，也会给精度评价结果带来一定的误差。

为了与源区域的遥感数据和实地调查数据保持一致，本研究选取Landsat系列遥感数据进行烈度评估，但受到当地云雾天气和卫星重访周期的影响，获取高质量遥感影像的时间较晚，这影响了研究的时效性。在后续的研究中，可以尝试不同来源遥感数据（如Sentinel-2）的验证，以进一步改善林火烈度评估的时效性；同时，后续研究需要进一步构建定量指标，以度量源区域和目标区域特征变量相似度的差异，这将完善本研究中利用目视解译样本，进行迁移学习算法参数优化方法。

6 结论

为了支撑应急响应情境下的林火灾后管理决策，在灾害发生后快速开展林火烈度的初始评估具有重要的意义。基于历史过火区域已有的实地调查数据，本研究构建基于迁移学习算法的SSTCA-SVR烈度评估模型，在四川省凉山州西昌市泸山森林大火区域开展了林火烈度的初始评估，可以得到以下结论：

(1) 由于区域之间环境、大气状况、太阳高

度角和地形等因素的影响,不同区域的遥感影像光谱存在较大的差异,利用迁移学习算法能够将源区域和目标区域遥感影像光谱转换为多个新特征变量,在这些由新特征变量构成的投影空间中,源区域和目标区域特征具有相似的分布。

(2) 由于转换后的新特征变量具有相似的分布,在源区域利用历史实地调查数据构建的高精度烈度评估模型能够迁移应用到目标区域,并实现目标区域的林火烈度初始评估,这能够加快林火灾后烈度评估的响应速度。

(3) 针对林火烈度的初始评估,基于 dNDVI 和 dNBR 指数的经验回归模型精度较低,其总体精度位于 20.80%—24.80% 之间, Kappa 系数位于 0.01—0.06 之间。虽然基于 dLST 指数的经验回归模型的烈度评估结果的空间分辨率最低,但是该模型的总体精度为 34.80%, Kappa 系数为 0.19,高于基于 dNDVI 和 dNBR 指数的经验回归模型。

(4) 与基于 dNDVI、dLST、dNBR 指数的经验回归模型相比, SSTCA-SVR 模型的林火烈度初始评估结果精度最高,总体精度为 71.20%, Kappa 系数为 0.64。并且其精度也高于未进行迁移学习的 SVR 模型(总体精度 58.00%, Kappa 系数为 0.48)。

志 谢 本研究所用的 GF-1 遥感数据来源中国资源卫星应用中心。同时审稿人在本文修订过程中提供了帮助和支持,在此表示衷心的感谢!

参考文献(References)

- Chen X F, Liu L, Li J G, Ou W H and Zhang Y H. 2020. Application and research progress of fire monitoring using satellite remote sensing. *Journal of Remote Sensing*, 24(5): 531-542 (陈兴峰, 刘李, 李家国, 欧文浩, 张玉环. 2020. 卫星遥感火点监测应用和研究进展. *遥感学报*, 24(5): 531-542) [DOI: 10.11834/jrs.20209118]
- Chen X X, Vogelmann J E, Rollins M, Ohlen D, Key C H, Yang L M, Huang C Q and Shi H. 2011. Detecting post-fire burn severity and vegetation recovery using multitemporal remote sensing spectral indices and field-collected composite burn index data in a ponderosa pine forest. *International Journal of Remote Sensing*, 32(23): 7905-7927 [DOI: 10.1080/01431161.2010.524678]
- Cherkassky V and Ma Y Q. 2004. Practical selection of SVM parameters and noise estimation for SVM regression. *Neural Networks*, 17(1): 113-126 [DOI: 10.1016/S0893-6080(03)00169-2]
- Chuvieco E, Riaño D, Danson F M and Martin P. 2006. Use of a radiative transfer model to simulate the postfire spectral response to burn severity. *Journal of Geophysical Research*, 111(G4): G04S09 [DOI: 10.1029/2005jg000143]
- De Santis A and Chuvieco E. 2007. Burn severity estimation from remotely sensed data: performance of simulation versus empirical models. *Remote Sensing of Environment*, 108(4): 422-435 [DOI: 10.1016/j.rse.2006.11.022]
- De Santis A and Chuvieco E. 2009. GeoCBI: a modified version of the Composite Burn Index for the initial assessment of the short-term burn severity from remotely sensed data. *Remote Sensing of Environment*, 113(3): 554-562 [DOI: 10.1016/j.rse.2008.10.011]
- Keeley J E. 2009. Fire intensity, fire severity and burn severity: a brief review and suggested usage. *International Journal of Wildland Fire*, 18(1): 116-126 [DOI: 10.1071/WF07049]
- Key C H and Benson N C. 2006. *Landscape Assessment (LA): Sampling and Analysis Methods*. Fort Collins: USDA Rocky Mountain Research Station: 1-55. [2016-03-17]. https://www.fs.usda.gov/rm/pubs_series/rmrs/gtr/rmrs_gtr164/rmrs_gtr164_13_land_assess.pdf
- Lentile L B, Holden Z A, Smith A M S, Falkowski M J, Hudak A T, Morgan P, Lewis S A, Gessler P E and Benson N C. 2006. Remote sensing techniques to assess active fire characteristics and post-fire effects. *International Journal of Wildland Fire*, 15(3): 319-345 [DOI: 10.1071/WF05097]
- Liu S C, Li X T, Qin X L, Sun G F and Liu Q. 2020. Adaptive threshold method for active fire identification based on GF-4 PMI data. *Journal of Remote Sensing*, 24(3): 215-225 (刘树超, 李晓彤, 覃先林, 孙桂芬, 刘倩. 2020. GF-4 PMI 影像着火点自适应阈值分割. *遥感学报*, 24(3): 215-225) [DOI: 10.11834/jrs.20208297]
- Loboda T V, French N H F, Hight-Harf C, Jenkins L and Miller M E. 2013. Mapping fire extent and burn severity in Alaskan tussock tundra: an analysis of the spectral response of tundra vegetation to wildland fire. *Remote Sensing of Environment*, 134: 194-209 [DOI: 10.1016/j.rse.2013.03.003]
- Matasci G, Volpi M, Kanevski M, Bruzzone L and Tuia D. 2015. Semisupervised transfer component analysis for domain adaptation in remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 53(7): 3550-3564 [DOI: 10.1109/TGRS.2014.2377785]
- Miller J D and Thode A E. 2007. Quantifying burn severity in a heterogeneous landscape with a relative version of the delta Normalized Burn Ratio (dNBR). *Remote Sensing of Environment*, 109(1): 66-80 [DOI: 10.1016/j.rse.2006.12.006]
- Pan S J, Tsang I W, Kwok J T and Yang Q. 2011. Domain adaptation via transfer component analysis. *IEEE Transactions on Neural Networks*, 22(2): 199-210 [DOI: 10.1109/TNN.2010.2091281]
- Parks S A, Dillon G K and Miller C. 2014. A new metric for quantifying burn severity: The relativized burn ratio. *Remote Sensing*, 6(3): 1827-1844 [DOI: 10.3390/rs6031827]
- Patterson M W and Yool S R. 1998. Mapping fire-induced vegetation

- mortality using Landsat Thematic Mapper data: a comparison of linear transformation techniques. *Remote Sensing of Environment*, 65(2): 132-142 [DOI: 10.1016/S0034-4257(98)00018-2]
- Pu D C, Zhang Z M, Long T F, Niu X F, He G J, Wang G Z, Sun J Y, Tang C and Wei M Y. 2020. GABAM2010 accuracy assessment using stratified random sampling. *Journal of Remote Sensing*, 24(5): 550-558 (蒲东川, 张兆明, 龙腾飞, 牛雪峰, 何国金, 王桂周, 孙嘉悦, 唐朝, 魏明月). 2020. 分层随机抽样下全球30 m火烧迹地产品验证. *遥感学报*, 24(5): 550-558 [DOI: 10.11834/jrs.20209171]
- Qin X L, Li X T, Liu S C, Liu Q and Li Z Y. 2020. Forest fire early warning and monitoring techniques using satellite remote sensing in China. *Journal of Remote Sensing*, 24(5): 511-520 (覃先林, 李晓彤, 刘树超, 刘倩, 李增元). 2020. 中国林火卫星遥感预警监测技术研究进展. *遥感学报*, 24(5): 511-520 [DOI: 10.11834/jrs.20209135]
- Quintano C, Fernández-Manso A, Calvo L, Marcos E and Valbuena L. 2015. Land surface temperature as potential indicator of burn severity in forest Mediterranean ecosystems. *International Journal of Applied Earth Observation and Geoinformation*, 36: 1-12 [DOI: 10.1016/j.jag.2014.10.015]
- Quintano C, Fernández-Manso A and Roberts D A. 2013. Multiple Endmember Spectral Mixture Analysis (MESMA) to map burn severity levels from Landsat images in Mediterranean countries. *Remote Sensing of Environment*, 136: 76-88 [DOI: 10.1016/j.rse.2013.04.017]
- Rao Y M, Wang C and Huang H G. 2020. Forest fire monitoring based on multisensor remote sensing techniques in Muli County, Sichuan Province. *Journal of Remote Sensing*, 24(5): 559-570 (饶月明, 王川, 黄华国). 2020. 联合多源遥感数据监测四川木里县森林火灾. *遥感学报*, 24(5): 559-570 [DOI: 10.11834/jrs.20209125]
- Soverel N O, Coops N C, Perrakis D D B, Daniels L D, and Gergel S E. 2011. The transferability of a dnbr-derived model to predict burn severity across 10 wildland fires in Western Canada. *International Journal of Wildland Fire*, 20(4): 518-531 [DOI: 10.1071/WF10081]
- Tan L X, Zeng Y N and Zheng Z. 2016. An adaptability analysis of remote sensing indices in evaluating fire severity. *Remote Sensing for Land and Resources*, 28(2): 84-90 (谭柳霞, 曾永年, 郑忠). 2016. 林火烈度遥感评估指数适应性分析. *国土资源遥感*, 28(2): 84-90 [DOI: 10.6046/gtzyyg.2016.02.14]
- Tang Y, Wang L J, Deng C, Gan Y Q and Zhao J. 2021. Research on the emergency response of forest fires in Sichuan with the help of high-definition remote sensing technology: An example of emergency monitoring of forest fires in Mianning "4·20". *National Remote Sensing Bulletin*, 25(9): 2015-2026 (唐尧, 王立娟, 邓琮, 甘玉泉, 赵娟). 2021. 高分遥感技术助力森林火灾应急扑救及隐患预判—以冕宁“4·20”森林火灾为例. *遥感学报*, 25(9): 2015-2026 [DOI: 10.11834/jrs.20211352]
- Veraverbeke S, Hook S and Hulley G. 2012. An alternative spectral index for rapid fire severity assessments. *Remote Sensing of Environment*, 123: 72-80 [DOI: 10.1016/j.rse.2012.02.025]
- Wang M, Meng H W, Huang L P, Sun Q F, Zhang H C and Shen C M. 2020. Vegetation succession and forest fires over the past 13000 years in the catchment of Yangzonghai Lake, Yunnan[J]. *Quaternary Sciences*, 40(1): 175-189 (王敏, 蒙红卫, 黄林培, 孙启发, 张虎才, 沈才明). 2020. 云南阳宗海流域过去13000年植被演替与森林火灾. *第四纪研究*, 40(1): 175-189 [DOI: 10.11928/j.issn.1001-7410.2020.01.17]
- Wang X L, Wang W J, Chang Y, Feng Y T, Chen H W, Hu Y M and Chi J G. 2013. Fire severity of burnt area in Huzhong forest region of Great Xing'an Mountains, Northeast China based on normalized burn ratio analysis. *Chinese Journal of Applied Ecology*, 24(4): 967-974 (王晓莉, 王文娟, 常禹, 冯玉婷, 陈宏伟, 胡远满, 池建国). 2013. 基于NBR指数分析大兴安岭呼中森林过火区的林火烈度. *应用生态学报*, 24(4): 967-974 [DOI: 10.13287/j.1001-9332.2013.0250]
- Xu B B, Wang W Y, Chen L F, Tao J H, Ji X Y, Zhang C J and Fan M. 2022. Forest fire spread simulation based on VIIRS active fire data and FARSITE model. *National Remote Sensing Bulletin*, 26(8): 1575-1588 (徐奔奔, 王炜焯, 陈良富, 陶金花, 纪轩禹, 张成杰, 范萌). 2022. 基于VIIRS火点数据和FARSITE系统的森林火灾蔓延模拟. *遥感学报*, 26(8): 1575-1588 [DOI: 10.11834/jrs.20219427]
- Yan K, Kou L and Zhang D. 2018. Learning domain-invariant subspace using domain features and independence maximization. *IEEE Transactions on Cybernetics*, 48(1): 288-299 [DOI: 10.1109/TCYB.2016.2633306]
- Zheng Z, Huang W, Li S N and Zeng Y N. 2017. Forest fire spread simulating model using cellular automaton with extreme learning machine. *Ecological Modelling*, 348: 33-43 [DOI: 10.1016/j.ecolmodel.2016.12.022]
- Zheng Z, Wang J F, Shan B, He Y J, Liao C H, Gao Y H and Yang S Q. 2020. A new model for transfer learning-based mapping of burn severity. *Remote Sensing*, 12(4): 708 [DOI: 10.3390/rs12040708]
- Zheng Z, Zeng Y N, Li S N and Huang W. 2016. A new burn severity index based on land surface temperature and enhanced vegetation index. *International Journal of Applied Earth Observation and Geoinformation*, 45: 84-94 [DOI: 10.1016/j.jag.2015.11.002]
- Zheng Z, Zeng Y N, Li S N and Huang W. 2018. Mapping burn severity of forest fires in small sample size scenarios. *Forests*, 9(10): 608 [DOI: 10.3390/f9100608]

Initial assessment of burn severity using the transfer learning model

ZHENG Zhong^{1,2,3}, WANG Jinfei², ZOU Bin⁴, GAO Yanghua³, YANG Shiqi³, WANG Yongqian¹

1. College of Resources and Environment, Chengdu University of Information Technology, Chengdu 610225, China;

2. Department of Geography, the University of Western Ontario, London ON, N6A 5C2 Canada;

3. Chongqing Institute of Meteorological Sciences, Chongqing 401147, China;

4. School of Geosciences and Info-Physics, Central South University, Changsha 410083, China

Abstract: In recent years, forest fires occur frequently around the world, which severely damage the structure and function of the forest ecosystem. The initial assessment of burn severity could provide a quantitative basis for rapid implementations of post-fire restoration measures. In the last decades, remote sensing-based models have become an appropriate choice to assess burn severity, which generally require a certain amount of field survey data. However, this requirement could not be sufficiently satisfied in the first moments after fire, since the field survey work would cost a substantial amount of time and labor. The absence of field survey data in the initial assessment of burn severity would largely limit the efficient application of remote sensing technologies. In this study, a transfer learning algorithm (i.e., SSTCA, semi-supervised Transfer Component Analysis) was employed to propose an initial assessment model of burn severity to improve the time-efficiency of traditional remote sensing-based models. Firstly, the SSTCA algorithm was applied to project a series of new features from original spectral features of remotely sensed data. Based on these projected features, a Support Vector Regression (SVR) model was then trained using historical field survey data from source areas (i.e., Bear fire on June 27, 2002 and Mule fire on July 11, 2002). Thereafter, the SSTCA-SVR model was transferred to the initial assessment of burn severity of a target area (i.e., Lushan fire on March 30, 2020). Finally, the performance of this proposed model was quantitatively compared with those of some traditional models (i.e., dNDVI-, dLST-, dNBR-, and SVR-based models). Results showed that original spectral features of remote sensing images over source and target areas were quite different. After the SSTCA projection, projected features of source and target samples have a similar distribution pattern in the new features-based space. Meanwhile, in the initial assessment of burn severity, dNDVI- and dNBR-based models have overestimated burn severity levels with low accuracies (i.e., overall accuracy was from 20.80% to 24.80% and Kappa value was between 0.01 and 0.06). Compared with them, the dLST-based model has a better performance with an overall accuracy of 34.80% and a Kappa value of 0.19. Although SVR-based model has shown a promising performance with an overall accuracy of 58.00% and a Kappa value of 0.48, this model has overestimated the burn severity levels in some regions of burned areas. The assessment results of burn severity levels using SSTCA-SVR model has the best performance with an overall accuracy of 71.20% and a Kappa value of 0.64. We conclude that the application of a transferring learning algorithm would be helpful for building an assessment model of burn severity with a good transferring ability. In this way, more accurate results could be obtained in the initial assessment of burn severity, and the response of post-fire management might be accelerated after forest fires.

Key words: burn severity, transfer learning, initial assessment, Landsat, forest fire, Lushan

Supported by National Natural Science Foundation of China (No. 41801315, 41771535); China Scholarship Council (No. 201908510029); Open Research Fund of Chongqing Meteorological Bureau (No. KFJJ-201705); Project Supported by the Scientific Research Foundation of Chengdu University of Information Technology (No. KYTZ201742)