

传统法与深度学习级联结合的近实时火点监测

王文卓¹ 马成龙² 王关霖¹ 张益明¹ 谭芳雄^{2,*} 韩旭³ 吴磊³

(1 国网甘肃省电力公司, 兰州 730000)

(2 国网甘肃省电力公司酒泉供电公司, 酒泉 735000)

(3 北京深蓝空间遥感技术有限公司, 北京 100020)

摘要 针对山火监测精度和时效性不足的问题, 提出一种级联传统法的多通道卷积神经网络 (Multichannel Convolutional Neural Network, MCNN) 近实时火点监测算法。首先, 结合最大类间方差和空间上下文法, 利用背景亮温空间信息差异筛选出潜在火点。然后, 采用集成学习思想构建三个卷积神经网络通道, 各通道分别输入光谱信息、空间上下文信息及时间地理信息特征的不同组合, 同时, 通过粒子群优化算法搜索各通道的最佳权重, 获取三个通道的火点联合预测概率, 实现火点准确识别。结果表明, 相比于单通道卷积神经网络 (Convolutional Neural Network, CNN) 模型, MCNN 精确度达到 0.88, 漏报率降低 0.16, 并且较日本气象厅官方产品漏报率降低 0.06, 且实验中模型运行平均耗时 172 s。因此, 文章提出的 MCNN 模型可实现较高精度的近实时火点监测, 为火灾应急处理提供科学依据。

关键词 多通道卷积神经网络 集成学习 近实时 火点监测 航天遥感

中图分类号: V1; P237

文献标志码: A

文章编号: 1009-8518(2024)05-0147-10

DOI: [10.3969/j.issn.1009-8518.2024.05.014](https://doi.org/10.3969/j.issn.1009-8518.2024.05.014)

Real-Time Fire Detection by Cascading Traditional Approaches with Deep Learning

WANG Wenzhuo¹ MA Chenglong² WANG Guanlin¹ ZHANG Yiming¹

TAN Fangxiong^{2,*} HAN Xu³ WU Lei³

(1 State Grid Gansu Electric Power Company, Lanzhou 730000, China)

(2 State Grid Gansu Electric Power Company Jiuquan Power Supply Company, Jiuquan 735000, China)

(3 Beijing Deep Blue Space Remote Sensing Technology Co., Ltd., Beijing 100020, China)

Abstract Aiming at the problem of insufficient accuracy and timeliness of wildfire monitoring, a near real-time fire monitoring algorithm using a Multichannel Convolutional Neural Network (MCNN) with a cascaded traditional method is proposed. Firstly, by combining the OTSU method and the spatial context method, potential fire points are identified by exploiting the differences in background brightness temperature spatial information. Secondly, using the idea of ensemble learning, three convolutional neural network channels are constructed. Each channel takes different combinations of spectral information, spatial context information, and temporal-geographical information features as input. The optimal weights for each channel are obtained by using the

收稿日期: 2023-11-24

引用格式: 王文卓, 马成龙, 王关霖, 等. 传统法与深度学习级联结合的近实时火点监测[J]. 航天返回与遥感, 2024, 45(5): 147-156.

WANG Wenzhuo, MA Chenglong, WANG Guanlin, et al. Real-Time Fire Detection by Cascading Traditional Approaches with Deep Learning[J]. Spacecraft Recovery & Remote Sensing, 2024, 45(5): 147-156. (in Chinese)

particle swarm optimization algorithm to search for the best weights, and the joint prediction probabilities of fire points from the three channels are obtained, achieving accurate fire point recognition. The results show that compared to a single-channel Convolutional Neural Network (CNN) model, the MCNN achieves a precision of 0.88 and reduces the omission rate by 0.16. Furthermore, compared to the Japan Meteorological Agency's official product, the omission rate is reduced by 0.06. In addition, the highest runtime of the model in the experiment is 268 seconds. Therefore, the MCNN model proposed in this paper can achieve high-precision near real-time fire point detection, providing a scientific basis for emergency fire response.

Keywords multichannel convolutional neural network; ensemble learning; near-real-time; fire point monitoring; space remote sensing

0 引言

火灾是极具破坏性的自然灾害之一,一般具有突发性强、蔓延迅速的特点,对当地社会、经济、人民生命财产安全等造成重大威胁^[1]。近年来,随着全球气候变化和城市化进程的加速,火灾发生的频率与规模呈现出上升趋势,对火灾的及时监测与有效防控提出了更为迫切的需求。而精确实时获取火场的时间地点信息对于减轻火灾危害至关重要。因此,发展一种大范围和高频次监测火灾的有效方法具有重要的科学意义与实际作用。

卫星遥感具有覆盖范围广、可重复观测、成本低等优势,在火灾的监测中得到广泛应用。基于极轨卫星的热异常监测是火灾监测的重要手段,例如文献[2]基于MODIS数据,提出了一种时空上下文火灾探测模型,相比于传统空间上下文和时序上下文算法具有更高鲁棒性;文献[3]针对传统火灾算法对小范围或低强度火灾难以捕捉的问题,考虑MODIS的4和11 μm 通道在冷热季节的不同阈值,提出了一种改进的火灾探测算法;文献[4]提出一种动态火灾探测算法并应用于NOAA-AVHRR数据;文献[5]基于NOAA-AVHRR数据,提出了一种增强的全自动上下文算法,结果表明该方法相比传统上下文算法的误检数减少了三倍以上;文献[6]根据VIIRS数据特性对空间上下文算法进行针对性改进,结果表明基于VIIRS数据的火灾探测相比于MODIS具有更优的性能。虽然极轨卫星空间分辨率相对较高,可以实现高精度的火灾监测,但重访周期低,每天只能经过地球同一区域数次,两次重访间隔之间的火灾将无法被有效监测,难以满足近实时火灾监测和扑救需求。新一代地球静止轨道卫星“向日葵8号”(Himawari-8),时间分辨率为10 min,其大范围和高频次观测能力在火灾近实时监测中比极轨卫星更有潜力和优势^[7]。

国内外学者针对地球静止轨道卫星数据源提出了一系列火灾监测算法,主要包括单时相火点监测算法、多时相火点监测算法以及基于机器学习或深度学习的火点监测算法^[8]。传统的单时相和多时相法中采用的固定阈值通常是根据历史数据保守选取,容易受季节和气候的影响,使得许多小火灾被忽略;而自适应阈值监测算法又容易受单一波段的影响,导致错检率和漏检率都偏高^[9]。机器学习和深度学习作为近年来备受关注的新技术,凭借其突出的特征学习能力,在火点监测领域中展现出了巨大的潜力。文献[10]基于Himawari-8卫星数据采用原始光谱、光谱的差值比值和光谱的上下文信息三种特征策略进行特征提取,然后利用随机森林模型对这些特征进行训练,不同策略下的模型准确率在65%左右。文献[11]基于Himawari-8卫星数据采用一种新型的双卷积神经网络来解决火灾探测任务,所提出的网络架构由两个并行的流组成,一个火灾估计流用于监测火灾像元,一个云水流用于排除云和水域,比支持向量机、决策树和随机森林等机器学习算法拥有更好的性能。文献[12]提出了一种使用卷积神经网络的主动火灾探测系统,通过采用多尺度卷积并引入残差,能够有效提取火灾的准确特征,准确率比传统阈值法提高了35.2%。

火灾发生时的卫星成像条件、地面温度、烟雾浓度以及气候等的差异，增加了火灾识别的不确定性。因此，本文基于 Himawari-8 卫星数据在最大类间方差（OTSU）法和空间上下文法确定的潜在火点基础上引入多种特征，并构建由三个卷积神经网络通道集成的 MCNN 算法，利用不同通道的互补性提升模型鲁棒性和可信度。

1 数据

Himawari-8 卫星属于地球静止轨道卫星，其上装有的先进的葵花成像仪（The Advanced Himawari Imager, AHI），具有 16 个光谱通道，波长范围从 0.46~13.3 μm，覆盖了可见光到红外范围，空间分辨率为 0.5~2 km^[13]，每 10min 对全圆盘进行一次扫描。该卫星数据包含 NetCDF4 和标准数据（HSD）两种格式。Himawari-8 卫星所具备的高时间分辨率和大范围幅宽为近实时火灾监测提供了有利条件。详细的 AHI 光谱通道及其相应的分辨率信息如表 1 所示，其中 R 表示反射率，T 表示亮温。

表 1 Himawari-8 波段介绍
Tab.1 Himawari-8 band introduction

类别	波段序号	中心波长/μm	空间分辨率/km
可见光	R1	0.47	1.0
	R2	0.51	1.0
	R3	0.64	0.5
近红外	R4	0.86	1.0
	R5	1.6	2.0
	R6	2.3	2.0
红外	T7	3.9	2.0
	T8	6.2	2.0
	T9	6.9	2.0
	T10	7.3	2.0
	T11	8.6	2.0
	T12	9.6	2.0
	T13	10.4	2.0
	T14	11.2	2.0
	T15	12.4	2.0
	T16	13.3	2.0

2 方法

本文提出了一种由三个卷积神经网络通道集成的 MCNN 算法。该算法的主要特点是引入主成分分析（Principal Component Analysis, PCA）优化输入特征、构建多通道网络结构以及采用粒子群优化算法（Particle Swarm Optimization, PSO）获取不同通道的火点识别最佳权重，最终通过加权平均的方式来识别火灾，具体算法流程如图 1 所示。

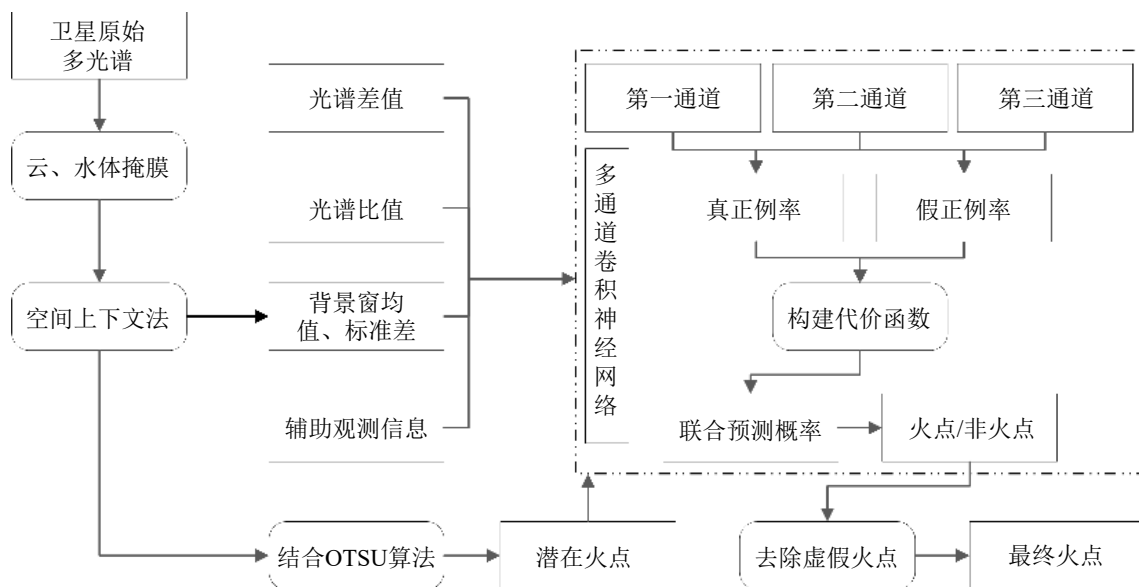


图 1 算法流程图
Fig.1 Algorithm flowchart

首先,将卫星原始光谱信息、亮温差值和比值信息通过 PCA 算法降维后,与空间上下文信息、地理辅助数据分别组成三个通道的输入特征。其中,第一通道 (Model1) 的输入包括卫星原始光谱信息、亮温差值、比值信息和地理辅助数据;第二通道 (Model2) 的输入包括卫星原始光谱信息、空间上下文信息和地理辅助数据;第三通道 (Model3) 的输入包括以上所有数据。其次,针对每个通道的输入特征分别构建卷积神经网络模型,每个通道可以输出样本验证集的真正例率和假正例率。最后,构建代价函数,通过 PSO 寻优搜索各通道的最佳权重,得到三个通道的火点联合预测概率。MCNN 模型的本质是最大化火点样本被预测为火点的概率。

为了降低深度学习算法的不确定性并提高火灾监测效率,去云层和水体后,利用传统法中的 OTSU 和空间上下文法对区域内的潜在火点进行初步判识。然后将潜在火点输入到 MCNN 模型中,并排除耀斑造成的虚假火点,得到最终的火灾识别结果。

2.1 潜在火点判识

云和水体容易造成火灾误判,所以首先需要去除云像元和水体像元。通过云和其他地物在可见光和热红外通道的差异进行云检测^[14]。并通过语义分割网络识别水体,保证水体的连续性^[15]。

通过结合 OTSU^[16]与空间上下文法^[17],对潜在火点进行综合识别。OTSU 是一种非参数且无监督的自动阈值选择方法,在分析空间变化时特别有优势,能够捕捉到由于火点引起的急剧上升的类间方差,特别适用于小型火灾的探测,满足式 (1) 即为潜在火点。

$$T_7 > th \quad (1)$$

式中: T_7 为 7 波段亮温值; th 为 OTSU 确定的最优阈值。

而空间上下文法主要依赖于对中心像元亮温与其邻近像元背景亮温之间的差异进行分析,进而识别出可能受火灾影响的像元,一定程度上解决了传统阈值法中因单一阈值而导致的火点误判或遗漏。运用滑动窗口技术,逐个检查每个中心像元,当满足式 (2) 或式 (3) 时即为潜在火点。为保证窗口中有充分的背景像元,设定一个动态调整机制,即滑动窗口初始为 5×5 ,若背景像元数量不足 25% 时逐渐扩大窗口,如 7×7 、 9×9 ,直至最大的 19×19 。如果在 19×19 的窗口中仍不符合要求,则放弃该像元判定,将其标为非潜在火点,并继续下一个像元窗口判识。

$$T_7 > \bar{T}_c + N_c \times \delta_c \quad (2)$$

式中: \bar{T}_c 和 δ_c 分别是除中心像元外的滑动窗口中晴空像元 7 波段亮温的均值和标准差; N_c 是晴空像元背景系数。

$$T_7 > \bar{T}_s + N_s \times \delta_s \quad (3)$$

式中: \bar{T}_s 和 δ_s 分别是滑动窗口中与中心像元具有相同土地利用类型的其他像元的 7 波段亮温均值和标准差; N_s 是土地利用背景系数。基于尽可能识别所有火灾的原则,根据样本数据和分类结果精度进行参数寻优,最终 N_c 取 1.5, N_s 取 2。

2.2 多通道卷积神经网络模型

2.2.1 特征构建

输入特征的主要依据是选取与火灾发生时有关的观测变量,本文输入特征如表 2 所示。首先,选取 Himawari-8 卫星各个波段的反射率和亮温特征。这是因为在火灾发生时,卫星捕获到的特定位置的反射率和亮温会有所变化。然而,某些波段的变化较为显著,而其他波段的变化不明显。鉴于深度学习对特征深度挖掘的能力,将所有原始光谱信息作为输入特征。但为了避免不同波段间的信息冗余,利用 PCA 算法对原始光谱信息进行降维处理,保留原始信息的 95%。

同时,为了更好地表征火灾和非火灾期间不同波段之间的亮温差异,引入亮温差和亮温比值。考虑到不同亮温通道的差值和比值组合较多,且某些差值和比值之间可能存在较高的相关性,同样利用 PCA 算法进行降维,并保留原始信息的 95%。

表 2 模型输入特征
Tab.2 Model input features

分组	类型	输入特征								
1	原始光谱信息	R1	R2	R3	R4	R5	R6	T7	T8	
		T9	T10	T11	T12	T13	T14	T15	T16	
		T7-T8	T7-T9	T7-T10	T7-T11	T7-T12	T7-T13	T7-T14	T7-T15	T7-T16
		T8-T9	T8-T10	T8-T11	T8-T12	T8-T13	T8-T14	T8-T15	T8-T16	
		T9-T10	T9-T11	T9-T12	T9-T13	T9-T14	T9-T15	T9-T16		
		T10-T11	T10-T12	T10-T13	T10-T14	T10-T15	T10-T16			
		亮温差值	T11-T12	T11-T13	T11-T14	T11-T15	T11-T16			
			T12-T13	T12-T14	T12-T15	T12-T16				
			T13-T14	T13-T15	T13-T16					
			T14-T15	T14-T16						
		T15-T16								
2		T7/T8	T7/T9	T7/T10	T7/T11	T7/T12	T7/T13	T7/T14	T7/T15	T7/T16
		T8/T9	T8/T10	T8/T11	T8/T12	T8/T13	T8/T14	T8/T15	T8/T16	
		T9/T10	T9/T11	T9/T12	T9/T13	T9/T14	T9/T15	T9/T16		
		T10/T11	T10/T12	T10/T13	T10/T14	T10/T15	T10/T16			
		亮温比值	T11/T12	T11/T13	T11/T14	T11/T15	T11/T16			
			T12/T13	T12/T14	T12/T15	T12/T16				
			T13/T14	T13/T15	T13/T16					
			T14/T15	T14/T16						
		T15/T16								
3	空间上下文信息	MEAN_T7	MEAN_T14	MEAN_BT7						
		STD_T7	STD_T14	STD_BT7						
	地理差异	DEM	Slope	Aspect	Landuse	NDVI	Lon	Lat		
4	时间差异	DOY	Hour_minute							
	观测角度	SAZ	SAA	SOZ	SOA					

此外，本文还考虑了空间上下文信息，提取了 Himawari-8 卫星 7 波段、14 波段、7 波段与 14 波段差值开窗计算后的背景亮温的均值和标准差；其中背景亮温指的是窗口内去除云、水体、潜在火点后其他像元的亮温，依次以 MEAN_T7、STD_T7、MEAN_T14、STD_T14、MEAN_BT7、STD_BT7 表示。

最后，火灾的发生在一定程度上具有较大随机性，但也存在一定规律性。如燃烧需要一定可燃物、火的扩散需要一定有力条件、火的发生在一定程度上集中在特定时间和特定地点（比如秸秆焚烧高发季），因此引入经度（Lon）、纬度（Lat）、卫星成像时间在一年中的第几天（DOY）、卫星成像时间的时分（Hour_minute）、归一化植被指数（NDVI）、土地利用类型（Landuse）、高程（DEM）、坡度（Slope）、坡向（Aspect）、观测角度（卫星天顶角 SAZ、卫星方位角 SAA、太阳天顶角 SOZ、太阳方位角 SOA）这些辅助信息作为输入特征。

2.2.2 模型构建

卷积神经网络（Convolutional Neural Network, CNN）是一类包含卷积计算且具有深度结构的前馈神经网络，是深度学习的代表算法之一。其特点在于隐藏层分为卷积层和池化层以及激活层。卷积层通过在原始图像上平移来提取特征，激活层能增加非线性分割能力；而池化层可以压缩数据与参数量，减小过拟合，降低网络的复杂度^[18]。MCNN 实质上是三个卷积神经网络输出的两个类别（火点和非火点）的概率分布通过通道权重获得联合预测概率，进而将联合预测概率中概率最大的那个类别作为样本的预测类别。每个通道的卷积神经网络结构相同，都是一维卷积神经网络^[19]，结构如图 2 所示，包括 3 个卷积

层 (Conv1、Conv2 和 Conv3)、3 个最大池化层 (Max-Pool) 和 2 个全连接层 (FC Layer)，一维卷积核尺寸为 3×1 ，并且在卷积层后添加批标准化层 (Batch Normalization, BN) 用以降低过拟合风险。输出层激活函数采用 Softmax，优化器采用常用的 Adam。

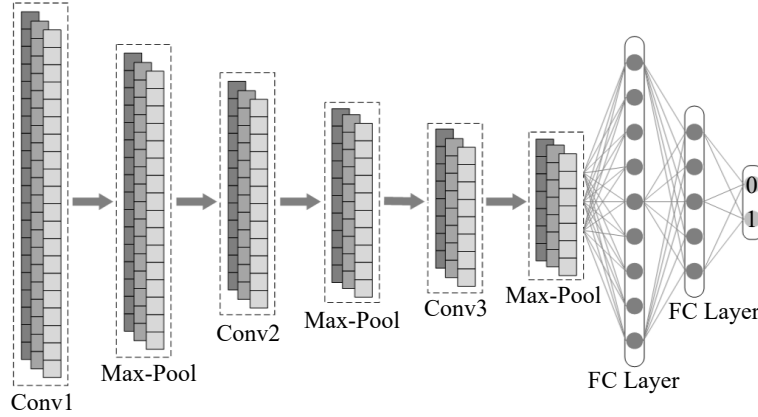


图2 一维卷积神经网络结构

Fig.2 One-dimensional convolutional neural network architecture

构建的三通道联合预测概率 P' 为

$$P' = \sum_{i=1}^3 W'_i P'_i \quad (4)$$

式中： W'_i 代表归一化后的第 i 通道权重，计算方法如式 (5)； P'_i 代表第 i 通道的预测概率。

$$W'_i = \frac{W_i}{W_1 + W_2 + W_3} \quad (5)$$

式中： W_i 表示第 i 通道权重，计算方法为

$$W_i = \left(\frac{c_1}{(1 - \text{TPR}) + \varepsilon} + c_2 \right) \cdot \ln \left(\frac{c_3}{\text{FPR} + \varepsilon} \right) \quad (6)$$

式中： c_1 、 c_2 、 c_3 为待优化系数； ε 为 1×10^{-5} ，用于确保分母不为零；TPR 为真正例率；FPR 为假正例率。权重表达式中，当 TPR 较高时，权重会增加，反之，当 FPR 较高时，权重会减小，旨在最大程度地提高火点样本被正确分类为火点的概率，同时尽可能减小非火点样本被错分为火点的概率。

TPR、FPR 计算如下：

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (7)$$

$$\text{FPR} = \frac{\text{FP}}{\text{TN} + \text{FP}} \quad (8)$$

式中：TP、TN、FP、FN 分别表示模型预测为火点且实际也为火点的个数、模型预测为非火点且实际也为非火点的个数、模型将非火点错分为火点的个数和模型将火点错分为非火点的个数。

c_1 、 c_2 、 c_3 采用 PSO 通过最小化代价函数获取最优值。根据验证集样本的真实标签以及由三通道联合预测概率获得的相应预测标签，构建 PSO 代价函数，如公式 (9) 所示。

$$f = 1 - \text{TPR}' + \text{FPR}' \quad (9)$$

式中： f 为联合预测误差； TPR' 、 FPR' 分别为由验证集样本的真实标签和预测标签获得的真正例率和假正例率。

PSO 种群大小设置为 20，迭代寻优次数设置为 200。通过 PSO 寻优，获取的 c_1 、 c_2 、 c_3 最佳值分别为 1.45、2.09 和 1.74。

2.3 耀斑点去除

太阳耀斑可能导致虚假火点的出现^[20]。由于卫星传感器的观测角度问题,水陆边界和卷云边界等区域常常受到太阳光的强烈干扰,导致中红外波段的亮温观测值异常,影响火灾识别。为了解决这一问题,引入一种基于观测角度的太阳耀斑去除方法,通过计算地球表面到卫星的向量与镜面反射方向之间的角度 θ_r 来进行耀斑点的判定。 θ_r 的计算公式如下^[21-23]

$$\cos\theta_r = (\cos(\theta_v)\cos(\theta_s) - \sin(\theta_v)\sin(\theta_s)\cos(\psi)) \quad (10)$$

式中: θ_r 表示地球表面到卫星的向量与镜面反射方向之间的角度; θ_v 和 θ_s 分别代表卫星天顶角和太阳天顶角; ψ 是相对方位角,通过卫星方位角和太阳方位角的计算获得。当判断为火点像元的 R3 和 R4 均大于 0.3,且计算的 θ_r 小于 30 时,则判断该像元为耀斑点并进行剔除。

3 结果与分析

3.1 样本数据及精度评价指标

本文的样本数据集来源于输电线路附近收集的火灾数据集,时间范围为 2019 年 9 月—2022 年 5 月,包括火灾的时间、地点、面积大小和火灾类型等信息。火灾样本总共 1 424 个,通过多次测试,当火灾样本和非火灾样本的比例约为 1 : 10 时,分类效果最好。所以,在不同时间范围内提取非火点样本 14 240 个。数据集被随机划分为训练集、验证集和测试集,比例设为 7 : 1.5 : 1.5。

为了衡量本文提出的 MCNN 模型性能,需要对火灾识别结果进行精度评价。基于混淆矩阵(如表 3),使用精确度 P (Precision)、漏报率 M (Omission Errors Rate) 和 F 值这 3 个指标进行评估^[21]。 P 反映了被模型预测为正例中实际为正例的概率,代表了对正例的预测准确程度。 M 反映了正例被漏判为负例的概率。而 F 是由 P 和 M 构成的综合评价指标。混淆矩阵和各评价指标计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (11)$$

$$M = \frac{FN}{TP + FN} \quad (12)$$

$$F = \frac{2P(1 - M)}{1 + P - M} \quad (13)$$

3.2 精度评价

为了验证 MCNN 的有效性和泛化能力,将单通道模型与 MCNN 在测试集上进行对比,结果如表 4 所示。Model1-CNN 表示由原始光谱信息、亮温差值和比值信息、地理辅助数据构建的单通道 CNN; Model2-CNN 表示由原始光谱信息、空间上下文信息和地理辅助数据构建的单通道 CNN; Model3-CNN 表示由以上所有输入特征构建的单通道 CNN。

此外,还对不加潜在火点识别步骤的 MCNN (即 PMCNN) 的效果进行了验证。Model1-CNN 和 Model2-CNN 只考虑了部分相关特征,不能很好的区分火点和非火点,更容易将火点识别为非火点,漏报率都较

表 3 混淆矩阵
Tab.3 Confusion matrix

类别	预测为火点	预测为非火点
真实火点	TP	FN
真实非火点	FP	TN

表 4 模型预测结果

Tab.4 Model prediction results

模型	P	M	F
Model1-CNN	0.72	0.27	0.73
Model2-CNN	0.77	0.18	0.79
Model3-CNN	0.83	0.14	0.84
PMCNN	0.81	0.14	0.83
MCNN	0.88	0.11	0.88

高，表明光谱差值、比值信息和空间上下文信息都是火点识别中的重要特征。相比于三个单通道 CNN 模型，MCNN 精确度最高，为 0.88，漏报率最高降低 0.16，且 F 值明显升高，说明 MCNN 能够更深入挖掘火点的不同特征信息，利用不同通道的互补性提高火点识别精度的同时，能有效降低漏报率。此外，通过 OTSU 和空间上下文法预先进行潜在火点判识是必要的，PMCNN 对所有像元进行火点判识后，精确度降低 0.07，误检增多。

3.3 对比分析

WLF 是日本气象厅发布的 Himawari-8 火点产品，有四种时间分辨率，分别为 10 min、1 h、1 d 和 1 月。本文选取 1h 产品与 MCNN 模型识别结果进行对比分析。2023 年 5 月 3 日—8 日期间，验证区域在一周内共发生 106 次火情。图 3 展示了火点分布以及 MCNN 和 WLF 对这些火点的识别情况。如表 5 所示，MCNN 模型共识别到 103 个火点，精确度为 0.85，漏报率为 0.17， F 值为 0.89，误报率和漏报率接近，模型精度较好，较 WLF 产品漏报率降低 0.06。此外，MCNN 模型与 WLF 产品共同识别到 72 个正确火点，并且有 5 个 MCNN 模型误检的火点，WLF 产品也存在误检，这些虚假火点主要受到地膜和大棚的影响。




图 3 火点识别空间分布对比
Fig.3 Comparison of spatial distribution of fire point recognition

表 5 火点识别精度对比
Tab.5 Comparison of fire point recognition accuracy

类别	识别火点总数/个	正确数/个	漏报数/个	P	M	F
MCNN	103	88	18	0.85	0.17	0.84
WLF		82	24		0.23	

3.4 模型运行时间

卫星火点识别的时效性对火灾监测和应急响应至关重要。快速准确地定位火点，有助于及时采取灭火和救援措施，减少火灾的蔓延和危害。为了分析模型的运算效率，对模型在整个云南省区域进行火点识别的耗时进行了统计。实验环境为 Windows 64 位操作系统，CPU 为 Intel(R) Core(TM) i9-10900，显卡

使用 NVIDIA Quadro P1000, 编程语言为 Python。如图 4 所示, 2023 年 4 月 1 日—30 日期间, 对 4 182 景云南省区域的 Himawari-8 卫星影像进行火点识别, MCNN 模型最高耗时 268 s, 平均耗时 172 s, 有较好的近实时火点监测能力。MCNN 模型主要耗时来自于背景窗运算, 在晴空像元较多时耗时明显增加。




图 4 模型运行耗时

Fig.4 Model runtime

4 结束语

本文针对传统火点阈值算法对火点监测依据单一, 造成火点置信度较低的问题, 在潜在火点识别、多特征构建和 PCA 优化的基础上, 采用 MCNN 模型替代传统阈值法进行火点监测, 其优势在于可以针对性挖掘不同通道火点识别的准确度, 基于集成学习的思想在多个分类器基础上构建鲁棒性更强的分类器。与此同时, 通过 OTSU 和空间上下文法设置较宽泛的阈值来初步筛选潜在火点, 随后借助深度学习技术进行火点精确识别, 这一方法不仅能够规避受季节和气候变化影响而引起的阈值问题, 还在一定程度上克服了火点误检问题。

本文基于 Himawari-8 卫星高时效性和高频率观测的优势, 实现了对火点的连续动态近实时监测, 对于火灾预警、快速响应、决策制定和灾害管理具有重要的意义。

参考文献 (References)

- [1] ROSTAMI A, SHAH-HOSSEINI R, ASGARI S, et al. Active Fire Detection from Landsat-8 Imagery Using Deep Multiple Kernel Learning[J]. *Remote Sensing*, 2022, 14(4): 992.
- [2] GONG A, LI J, CHEN Y. A Spatio-Temporal Brightness Temperature Prediction Method for Forest Fire Detection with MODIS Data: A Case Study in San Diego[J]. *Remote Sensing*, 2021, 13(15): 2900.
- [3] POURSHAKOURI F, DARVISHSEFAT A A, SAMADZADEGAN F, et al. An Improved Algorithm for Small and Low-intensity Fire Detection in the Temperate Deciduous Forests Using MODIS Data: A Preliminary Study in the Caspian Forests of Northern Iran[J]. *Natural Hazards*, 2023, 116(2): 2529-2547.
- [4] PU R, GONG P, LI Z, et al. A Dynamic Algorithm for Wildfire Mapping with NOAA/AVHRR Data[J]. *International Journal of Wildland Fire*, 2004, 13(3): 275-285.
- [5] PLANK S, FUCHS E M, FREY C. A Fully Automatic Instantaneous Fire Hotspot Detection Processor Based on AVHRR Imagery—A TIMELINE Thematic Processor[J]. *Remote Sensing*, 2017, 9(1): 30.
- [6] SCHROEDER W, OLIVA P, GIGLIO L, et al. The New VIIRS 375 m Active Fire Detection Data Product: Algorithm Description and Initial Assessment[J]. *Remote Sensing of Environment*, 2014, 143: 85-96.
- [7] BARMPOUTIS P, PAPAIOANNOU P, DIMITROPOULOS K, et al. A Review on Early Forest Fire Detection Systems Using Optical Remote Sensing[J]. *Sensors*, 2020, 20(22): 6442.
- [8] CARTA F, ZIDDA C, PUTZU M, et al. Advancements in Forest Fire Prevention: A Comprehensive Survey[J]. *Sensors*, 2023,

- 23(14): 6635.
- [9] 王尧, 王世新, 周艺, 等. 基于GF-4 PMI数据的亮温差校正火点监测方法研究[J]. 光谱学与光谱分析, 2021, 41(11): 3595-3601.
WANG Yao, WANG Shixin, ZHOU Yi, et al. Research on Brightness Temperature Difference Correction for Fire Point Monitoring Based on GF-4 PMI Data[J]. Spectroscopy and Spectral Analysis, 2021, 41(11): 3595-3601. (in Chinese)
- [10] ZHANG Y, HE B, KONG P, et al. Near Real-Time Wildfire Detection in Southwestern China Using Himawari-8 Data[C]//2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS, July 11-16, 2021, Brussels, Belgium. IEEE, 2021: 8416-8419.
- [11] LI Z, WANG Y, LIANG S. When Convolutional Neural Networks Meet Remote Sensing Data for Fire Detection[C]//Journal of Physics: Conference Series. IOP Publishing, 2021, 1914(1): 012002.
- [12] HONG Z, TANG Z, PAN H, et al. Active Fire Detection Using a Novel Convolutional Neural Network Based on Himawari-8 Satellite Images[J]. *Frontiers in Environmental Science*, 2022, 10: 794028.
- [13] LIU C, YANG S, DI D, et al. A Machine Learning-based Cloud Detection Algorithm for the Himawari-8 Spectral Image[J]. *Advances in Atmospheric Sciences*, 2022, 39(12): 1994-2007.
- [14] GIGLIO L, SCHROEDER W, JUSTICE C O. The Collection 6 MODIS Active Fire Detection Algorithm and Fire Products[J]. *Remote Sensing of Environment*, 2016, 178: 31-41.
- [15] XIANG D, ZHANG X, WU W, et al. DensePPMUNet-a: A Robust Deep Learning Network for Segmenting Water Bodies from Aerial Images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 1-11.
- [16] 刘燕, 张力, 王庆栋, 等. 国产高分辨率卫星影像云检测[J]. *遥感信息*, 2022, 37(1): 134-142.
LIU Yan, ZHANG Li, WANG Qingdong, et al. Cloud Detection in Domestic High-Resolution Satellite Images[J]. *Remote Sensing Information*, 2022, 37(1): 134-142. (in Chinese)
- [17] GIGLIO L, DESCLOITRES J, JUSTICE C O, et al. An Enhanced Contextual Fire Detection Algorithm for MODIS[J]. *Remote Sensing of Environment*, 2003, 87(2/3): 273-282.
- [18] DING C, ZHANG X, CHEN J, et al. Wildfire Detection through Deep Learning Based on Himawari-8 Satellites Platform[J]. *International Journal of Remote Sensing*, 2022, 43(13): 5040-5058.
- [19] GUIDICI D, CLARK M L. One-Dimensional Convolutional Neural Network Land-cover Classification of Multi-seasonal Hyperspectral Imagery in the San Francisco Bay Area, California[J]. *Remote Sensing*, 2017, 9(6): 629.
- [20] 周游, 隋三义, 陈洁, 等. 基于Himawari-8静止气象卫星的输电线路山火监测与告警技术[J]. 高电压技术, 2020, 46(7): 9.
ZHOU You, SUI Sanyi, CHEN Jie, et al. Monitoring and Warning Technology for Transmission Line Wildfires Based on Himawari-8 Geostationary Meteorological Satellite[J]. *High Voltage Technology*, 2020, 46(7): 9. (in Chinese)
- [21] DENG Z, ZHANG G. An Improved Forest Fire Monitoring Algorithm with Three-Dimensional Otsu[J]. *IEEE Access*, 2021, 9: 118367-118378.
- [22] CHEN J, ZHENG W, WU S, et al. Fire Monitoring Algorithm and Its Application on the Geo-kompsat-2A Geostationary Meteorological Satellite[J]. *Remote Sensing*, 2022, 14(11): 2655.
- [23] DI BIASE V, LANEVE G. Geostationary Sensor Based Forest Fire Detection and Monitoring: An Improved Version of the SFIDE Algorithm[J]. *Remote Sensing*, 2018, 10(5): 741.

作者简介

王文卓, 男, 1980年生, 2003年获东北电力学院输电线路工程专业学士学位, 副高级工程师。研究方向为输电专业全业务、全流程管理。E-mail: wwz@gs.sgcc.com.cn。

通讯作者

谭芳雄, 男, 1988年生, 2022年获兰州理工大学工程硕士学位, 副高级工程师。研究方向为输电专业运维检修管理。E-mail: 2449702060@qq.com。

(编辑: 庞冰)