

王建伟, 宫大鹏, 王佩, 等. 福建省森林-城镇交界域火灾驱动因素及风险评估[J]. 西安科技大学学报, 2026, 46(2): 455-464.

WANG Jianwei, GONG Dapeng, WANG Pei, et al. Driving factors and risk assessment of wildland-urban interface fires in Fujian Province[J]. Journal of Xi'an University of Science and Technology, 2026, 46(2): 455-464.

福建省森林-城镇交界域火灾驱动因素及风险评估

王建伟¹, 宫大鹏¹, 王佩¹, 张怡龙²

(1. 中国消防救援学院, 北京 102202;

2. 国家消防救援局机动支队, 北京 100023)

摘要: 森林-城镇交界域(WUI)作为野火侵袭城乡过渡地带的关键区域,其火灾风险评估与防控已成为区域防灾减灾工作的核心议题。基于福建省2007—2024年WUI火点观测,融合气象、地形、植被及人类活动等多元变量,采用支持向量机(SVM)、随机森林(RF)、极端梯度提升(XGBoost)与轻量梯度提升(LGBM)4种机器学习算法,构建福建省WUI火灾发生概率预测模型,并利用DALEX框架解析关键驱动因素及其贡献度。结果表明:福建省WUI火灾年际发生频次呈现显著下降趋势($p < 0.01$),季节性集中于冬春两季,占全年发生总量的71.49%;WUI火点空间分布呈现显著聚集特征,核密度高值区主要分布于西部与北部山区;XGBoost模型在ROC曲线下面积(AUC=0.8701)与Brier评分(0.1435)上均表现最优,RF、LGBM与SVM模型具备良好区分能力(AUC>0.85),基于机器学习的WUI火灾发生概率预测模型具备较高的稳健性与泛化能力;总降水量(PRE)、平均气温(TMP)、相对湿度(RHU)及归一化植被指数(NDVI)是影响WUI火灾发生的核心因素,反映了干旱气象条件与可燃物积累的协同驱动效应;西部与北部地区为高风险集中区,其中XGBoost模型识别的高风险及以上区域面积显著高于东部与南部沿海地区。研究揭示了多因子耦合作用下WUI火灾的形成机制,预测模型与风险图谱可为福建省WUI火灾的精细化监测、可燃物管理与应急资源布局提供科学依据。

关键词: 森林-城镇交界域; WUI火灾; 驱动因素; 机器学习; 风险评估

中图分类号: S 762; X 954

文献标志码: A

文章编号: 1672-9315(2026)02-0455-10

DOI: 10.13800/j.cnki.xakjdx.2026.0220

Driving factors and risk assessment of wildland-urban interface fires in Fujian Province

WANG Jianwei¹, GONG Dapeng¹, WANG Pei¹, ZHANG Yilong²

(1. China Fire and Rescue Institute, Beijing 102202, China;

2. National Fire and Rescue Administration Mobile Division, Beijing 100023, China)

Abstract: The wildland-urban interface (WUI) is a critical zone where wildfires threaten transitional areas between forests and urban settlements. Consequently, assessing and mitigating fire risks within this region has become a core focus of regional disaster prevention and mitigation. Based on the 2007—

收稿日期: 2025-09-10

基金项目: 国家重点研发计划项目(2023YFC3011704-2); 中国消防救援学院重点科研项目(XFKZD202502)

第一作者: 王建伟, 男, 山东威海人, 博士, 讲师, E-mail: wang.jw@126.com

通信作者: 宫大鹏, 男, 吉林吉林人, 博士, 讲师, E-mail: gdp@cfri.edu.cn

2024 WUI fire point observation of Fujian Province, by integrating such multi-source variables as meteorology, topography, vegetation and human activities, four machine learning methods including Support Vector Machine(SVM), Random Forest(RF), Extreme Gradient Boosting(XGBoost), and Light Gradient Boosting Machine(LGBM) were employed to construct a predictive model for the wildfire occurrence probability in the WUI of Fujian Province, and the DALEX framework was used to analyze the key driving factors and their contribution degrees. The results show that: The annual WUI fire frequency in Fujian province exhibits a significant downward trend($p < 0.01$), with seasonal concentration in winter and spring, accounting for 71.49% of annual occurrences, while spatial distribution displays pronounced clustering, with high kernel density values predominantly in western and northern mountainous regions. The XGBoost model demonstrates optimal performance in both the area under the ROC curve (AUC = 0.870 1) and Brier score(0.143 5). The RF, LGBM and SVM models also exhibit strong discrimination capabilities (AUC > 0.85), indicating that machine learning-based WUI fire probability models possess high predictive robustness and generalization ability. Total precipitation(PRE), mean temperature(TMP), relative humidity(RHU), and normalized difference vegetation index(NDVI) are the primary factors influencing WUI fire occurrence, reflecting the synergistic effects of the arid meteorological conditions and fuel accumulation. The western and northern regions constitute high-risk clusters. Among them, the total areas classified as high risk or above by the XGBoost model are significantly higher than that in the eastern and southern coastal regions. This study elucidates the formation mechanisms of WUI fires under multi-factor coupling interactions. The prediction model and risk maps can provide scientific basis for refined monitoring, fuel management, and emergency resource deployment for WUI fires in Fujian Province.

Key words: wildland-urban interface; WUI fire; driving factor; machine learning; risk assessment

0 引言

随着全球气候变化加剧和城市化进程的加速推进,森林-城镇交界域(Wildland-Urban Interface, WUI)作为生态系统与人类社会高度交织的特殊地带,其火灾发生频率与危害程度持续攀升,已成为国内外防灾减灾领域的研究热点^[1-3]。WUI兼具森林可燃物连续分布与城镇人口资产密集的双重特征,一旦发生火灾,极易造成重大生态损失,并引发严重的社会经济后果^[4-5]。国际上,WUI研究已形成较为系统的理论框架,涵盖WUI的空间识别与分类、火灾驱动机制、风险评估方法及防控策略等多个维度。例如,RADELOFF等基于住房密度与植被覆盖度,提出了WUI的标准化制图方法,首次完成美国全域WUI空间评估,为全球WUI识别提供了重要参考^[6];LAMPIN-MAILLET等进一步整合建筑空间格局与植被连续性,通过二者交叉组合构建了适用于欧洲的WUI分类体系,强调了空间异质性在火灾风险评估中的关键作用^[7]。

现有研究普遍认为WUI火灾成因复杂,是气

象、植被、地形与人类活动等多维度因素交互作用的结果。气象条件尤其是干旱相关指标(如气温、降水、相对湿度)被广泛证实为WUI火灾发生的主导自然因子。例如,WILLIAMS等针对美国加利福尼亚州的研究发现,气候变暖导致的饱和水汽压差上升显著提高了该区域林火风险,并量化了人为气候变化与人类活动对林火的贡献差异^[8];GUO等针对中国不同森林生态系统,验证了气象要素对火险季节性特征的控制作用,并明确其为火险季节变化的主导因子^[9]。与此同时,人类活动因素(如人口密度、道路距离、土地利用变化)通过改变火源格局与可燃物分布,加剧了WUI火灾的复杂性与不确定性^[10-11]。VILAR等以西班牙为研究区,发现人为火源与居民点距离存在密切关联^[10];YING等针对云南省的研究发现农业活动是中国西南地区WUI火灾的重要诱因^[11]。

传统统计学模型(如Logistic回归)虽已在各个领域被广泛应用,但在评估WUI火灾风险时,难以充分捕捉该系统中复杂的非线性关系与变量交互效应^[12]。近年来,如随机森林(Random Forest,

RF)、支持向量机(Support Vector Machine, SVM)等机器学习方法凭借其强大的特征学习与预测能力,逐渐成为 WUI 火灾建模的主流工具^[13-14]。SHARMA 等针对印度森林火险易发性,对比 6 种机器学习方法的预测表现,发现集成学习方法(如随机森林)具有最优的预测精度^[15];GONG 等在中国 WUI 火灾研究中引入极端梯度提升(eXtreme Gradient Boosting, XGBoost)和轻量梯度提升(Light Gradient Boosting Machine, LGBM)等模型,显著提升了火险评估的空间分辨能力^[12]。此外,模型可解释性框架(如 DALEX)能够在不依赖模型内部结构的前提下,一致性地量化各变量对预测结果的贡献,便于在多模型环境下进行交叉验证与结果对比^[16]。

中国作为全球 WUI 面积增长最快的国家之一,其 WUI 火灾相关研究尚处于起步阶段,尤其在福建等高火险省份,系统性的 WUI 火灾风险评估仍较为缺乏。作为森林资源大省,福建省森林覆盖率连续多年位居全国首位,生态资源丰富,但火灾风险亦特别突出,其中 84 个县级行政区中有 55 个被列为国家森林火灾高风险区^[17-19]。据统计,福建省近年发生的多起重大森林火灾(如 2017 年宁德福鼎火灾、2018 年福州福清火灾、2020 年三明大田火灾、2021 年泉州南安火灾、2024 年三明宁化火灾)均位于 WUI 区域,造成了重大人员伤亡与财产损失,这凸显了该区域火灾风险的严峻性与火灾防治研究的紧迫性。为此,文中以福建省为研究区,集成气象、地形、植被、人类活动等多源数据,采用支持向量机、随机森林、极端梯度提升与轻量梯度提升 4 种机器学习方法,构建 WUI 火灾预测模型,并结合 DALEX 可解释性框架揭示关键驱动因子,绘制火险等级空间分布图。研究旨在系统揭示福建省 WUI 火灾的时空分异规律与形成机制,明确多因子协同作用对火险的增强效应,以期为该区域 WUI 火灾精准防控、应急资源优化配置与国土空间安全规划提供科学支撑。

1 研究区域、数据来源与研究方法

1.1 研究区概述

福建省地处中国东南沿海,位于 23°33'~28°19'N、115°50'E~120°43'E,属于亚热带海洋性季风气候,雨量充沛,四季常绿;北、西、南三面分别与浙江省、江西省、广东省陆地接壤,东部与台湾

省隔海相望。福建省森林资源丰富,是中国南方的重点林区之一。据《2024 年福建省生态环境状况公报》显示,2024 年福建省森林面积达 807.72 万公顷,森林覆盖率为 65.12%,森林蓄积量达 8.07 亿 m³。根据地理位置和气候植被等条件特征,将福建省划分为东部(福州市和宁德市)、南部(莆田市、泉州市、厦门市和漳州市)、西部(三明市和龙岩市)、北部(南平市)。

采用联合国粮食及农业组织(FAO)提出的 WUI 空间区划标准^[20],将“城市和荒野缓冲重叠区”作为 WUI 的定义。该定义涉及了城市、荒野和缓冲距离 3 个变量,其中缓冲距离是 WUI 识别的关键要素,城市与荒野空间位置可通过欧洲哥白尼气候数据中心土地利用/覆被数据(<https://cds.climate.co-pernitus.eu>)获取。根据历史 WUI 火灾案例,通过量化分析可确定适用于中国 WUI 特征的有效缓冲距离,其覆盖范围可达 90%。基于上述改进的 WUI 空间区划方法,绘制了福建省 WUI 区域分布图,如图 1 所示。福建省 WUI 区域分布较为平均,实际面积约为 26 075.11 km²,占全省总面积的 21.03%,其中东部和南部沿海地区 WUI 区域分布相对集中。

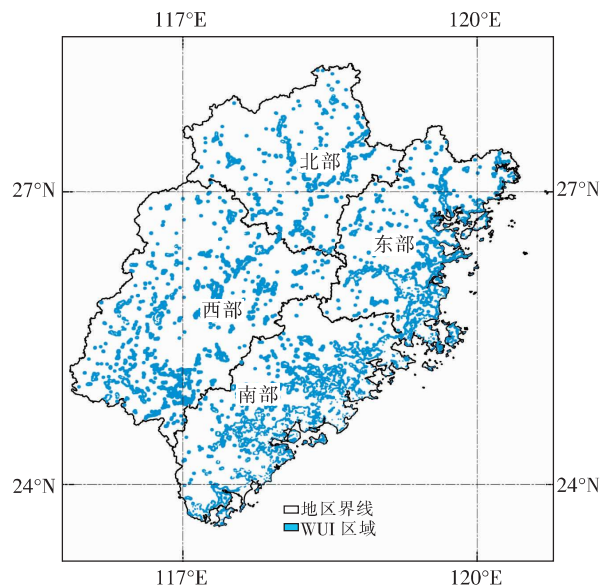


图1 福建省 WUI 区域分布

Fig. 1 Distribution of WUI areas in Fujian Province

1.2 数据来源与处理

2007—2024 年林火卫星监测数据来源于国家森林草原防火信息共享平台(<https://slcygxp.slcyfh.mem.gov.cn>)。该数据集包含火点的日期、

时间、位置、经纬度、像素数量、连续性、土地类型及反馈信息,且已通过地面核查,并在其他相关研究中得到验证^[21]。在参考已有研究指标选取的基础上^[22],选取气象、地形、植被、人为因素作为预测因子,4类预测因子共13个变量,见表1,所选变量不仅覆盖了火灾发生“可燃物-火源-气象”3要素理论框架,更结合WUI区域人-地交互特点,纳入社会经济维度,形成多系统、多过程的综合驱动表征。

表1 模型的预测变量

Table 1 Predictor variables of the model

类型	变量	代码	分辨率/单位	数据来源
气象	平均气温	TMP	日/°C	国家级地面气象观测站 (http://www.nmic.cn/)
	平均风速	WIN	日/(m·s ⁻¹)	
	相对湿度	RHU	日/%	
	总降水量	PRE	日/mm	
	饱和水汽压差	VPD	日/kPa	
地形	海拔	ELE	90 m/m	资源环境科学数据平台 (https://www.resdc.cn)
	坡度	Slope	90 m/(°)	
	西南指数	Aspect	90 m/—	基于坡向计算获取
植被	归一化植被指数	NDVI	250 m/—	国家青藏高原科学数据中心 (http://data.tpdc.ac.cn)
人为活动	道路距离	Road	1:1 000 000/m	全国地理信息资源目录服务系统 (http://www.webmap.cn)
	房屋距离	House	1:1 000 000/m	
	人口密度	POP	30%/ (人·km ⁻¹)	WorldPop 研究项目 (https://hub.worldpop.org)
	国内生产总值	GDP	1 km/美元	Zenodo 数据平台 (https://www.zenodo.org)

1.2.1 气象

气象数据来源于国家级地面气象观测站。在研究时段内,筛选出要素缺失比例不超过5%的站点,采用多元线性回归分析法进行插值^[23],修正有效站点的异常值及缺失值,得到平均气温TMP、平均风速WIN、相对湿度RHU以及总降水量PRE。饱和水汽压差VPD表示空气距离水汽饱和状态的程度,是衡量大气干旱程度的重要指标,可采用经验公式直接由温度计算得到^[24]。

1.2.2 地形

海拔ELE、坡度Slope、坡向Aspect等变量被认为与火灾发生相关,通常会影响到植被类型、小气候及火行为。其中,海拔高度的数字高程模型(Digit-

al Elevation Model, DEM)空间分布数据来源于中国科学院资源环境科学数据平台。借助ArcGIS 10.8软件,从DEM数据集中获取高程、坡度及坡向数值。基于三角函数可将坡向转化为西南指数,该指数表示斜坡朝向西南的程度^[25-26],即接受最大潜在日照的程度,其取值范围为[-1,1]。

1.2.3 植被

归一化植被指数(Normalized Difference Vegetation Index, NDVI)是植被覆盖度遥感估算中最常见的指数之一,常用于衡量地表植被状况。植被数据来源于国家青藏高原科学数据中心,这些数据源自Aqua/Terra-MODIS卫星传感器获取的MOD13Q1数据集,时间跨度为2000—2022年,空间分辨率250 m,数据合成方式采用月最大值合成法。

1.2.4 人类活动

人为活动与WUI火灾的发生关联更为密切。人为活动因素包括2类:一是人为基础设施,即道路距离Road和房屋距离House;二是社会经济因素,即人口密度POP和国内生产总值GDP。其中,道路和房屋数据来源于全国地理信息资源目录服务网站的《全国1:100万公众版基础地理信息数据(2021)》;人口密度数据来源于美国能源部橡树岭国家实验室(ORNL)开发的LandScan人口数据集,该数据集通过空间数据、图像分析及多变量建模法,对行政边界内的人口普查数据进行空间分解,进而获得人口在24 h内活动的空间范围;GDP数据来源于Zenodo数据分享平台,该平台数据包括2000—2020年全球年度国内生产总值。为确保数据时空一致性,采用双线性插值算法,将所有预测变量统一重新采样至1 km分辨率。

1.3 驱动因素分析

为揭示WUI火灾发生的主导作用力及其形成机制,首先需明确各类驱动因素。为确保样本的时空代表性,遵循“时空双随机”原则,按1:1比例创建WUI火点样本(赋值1)与随机点样本(赋值0)。经剔除重复数据后,最终获得有效样本3 358个。将有效样本按7:3比例划分为训练集与测试集,采用随机搜索结合5折交叉验证的方法训练模型,以确定最佳超参数。

选取支持向量机、随机森林、极端梯度提升、轻量梯度提升4种机器学习方法,构建WUI火灾发生概率预测模型。从区分能力和校准度2个方

面,评估所构建预测模型的准确度。采用 ROC 曲线下面积(Area Under the Curve, AUC)表征模型对不同结果的区分度, AUC 值越大,模型的区分能力越好,通常认为 $AUC > 0.8$ 时模型区分能力良好^[10]。通过 Hosmer-Lemeshow 拟合优度检验量化不同分位数上的预测概率与真实概率的吻合程度^[27],并以校准曲线形式在校准图中可视化拟合结果。

为系统比较不同机器学习模型在识别 WUI 火灾驱动因素方面的一致性,并提升模型结果的可比性与可解释性,引入 DALEX (moDel Agnostic Language for Exploration and eXplanation) 框架,对 4 种模型的变量重要性进行统一评估。DALEX 是 R 语言中专门用于解释机器学习模型行为的工具包,其提供统一分析框架,可帮助用户理解模型预测结果及整体行为^[16],特别是对随机森林等复杂模型,能提供性能评估、变量重要性等关键信息。基于 R 4.2.2 环境,使用 DALEX 工具包,通过计算损失函数(1-AUC)确定变量重要性^[28],得到各变量对模型预测结果的贡献度,并完成特征重要性的排序与可视化,从而揭示模型决策机制。

2 结果与分析


2.1 WUI 火点时空特征

2007—2024 年,福建省共有 2023 场火点发生在 WUI 区域,年均 112.39 场。其中 2016—2024 年年均发生频次为 58.56 场,显著低于整个研究时段的平均值。总体看来,2007—2024 年 WUI 火灾发生次数呈现显著下降趋势($p < 0.01$),下降速率为 11.06 场/年,如图 2(a)所示,这与福建省近年来加强森林火源管控、推进防火基础设施建设的政策成效一致。


在月尺度上,福建省 WUI 火灾呈现明显的季节性分布特征,如图 2(b)所示。2007—2024 年,每年 12 月至次年 3 月为火灾高发期,累计发生 1446 场,占比 71.49%;4~5 月和 10~11 月为次高发期,累计发生 530 场,占比 26.21%;6~9 月火灾最少,累计发生 47 场,仅占 2.30%。这种季节分布特征与福建省森林防火期(每年 9 月 15 日至次年的 4 月 30 日)基本一致,需要在冬季和春季加强火源监测和应急响应。

在空间分布上,2007—2024 年福建省发生的 WUI 火点分布于省内多个区域,如图 3 中红色散

点所示。高核密度区域(火灾发生密度 > 0.058 次/ $\text{km}^2/18\text{ a}$)主要分布在福建西部、北部等局部区域,例如南平市南部、龙岩市东部、三明市东南部等地区。这一时空格局提示,未来福建省防火工作应继续强化季节性管控与区域差异化策略。



(a) WUI 火灾发生年际变化



(b) WUI 火灾发生月份走势

图 2 福建省 WUI 火灾时间分布特征

Fig. 2 Temporal distribution characteristics of WUI fires in Fujian Province

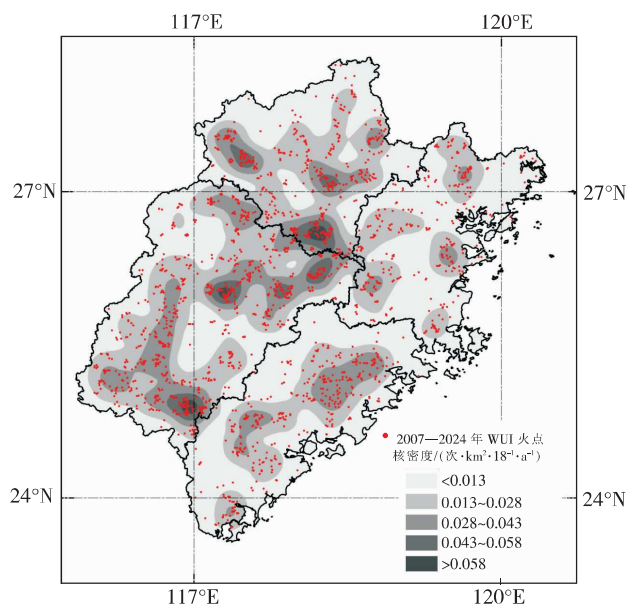


图 3 福建省 WUI 火灾空间分布特征

Fig. 3 Spatial distribution characteristics of WUI fires in Fujian Province

2.2 模型评价

采用上述4种机器学习方法,分别构建了福建省WUI火灾预测模型,明确了气象、植被、地形、人类活动等13个相关因素对WUI火灾发生概率影响的重要性。不同机器学习模型的ROC曲线,如图4所示。4种模型的AUC值相近且均大于0.85,表明这4种机器学习模型对福建省WUI火灾均具备较好预测区分能力。其中,XGBoost模型的AUC值最高,为0.8701;其次是RF、LGBM和SVM模型,AUC值分别为0.8646、0.8627和0.8546。综上,XGBoost模型在预测福建省WUI火灾发生概率中表现出更优的区分能力。

不同机器学习模型的校准曲线,如图5所示。4种机器学习模型预测的概率与实际的WUI火灾发生概率一致性较好,4种机器学习模型在预测WUI火灾发生概率的区分度与校准度上,均表现出良好的泛化能力。其中,XGBoost模型最好,Brier评分为0.1435;其次是RF和LGBM模型,Brier评分为0.1497和0.1460;SVM模型Brier评分为0.1510。这说明XGBoost模型校准效果相对

更优,其预测概率与实际发生概率贴合度更高,RF、LGBM、SVM模型也保持了较好的校准表现,整体来看各模型在福建省WUI火灾概率预测任务中均具备可靠性。相较于传统统计模型,使用的机器学习方法在处理多源、非线性、高维数据方面具有显著优势,能够有效捕捉WUI火灾系统中复杂的因子交互作用^[28]。




图4 不同机器学习模型的ROC曲线

Fig. 4 ROC curves of different machine learning models

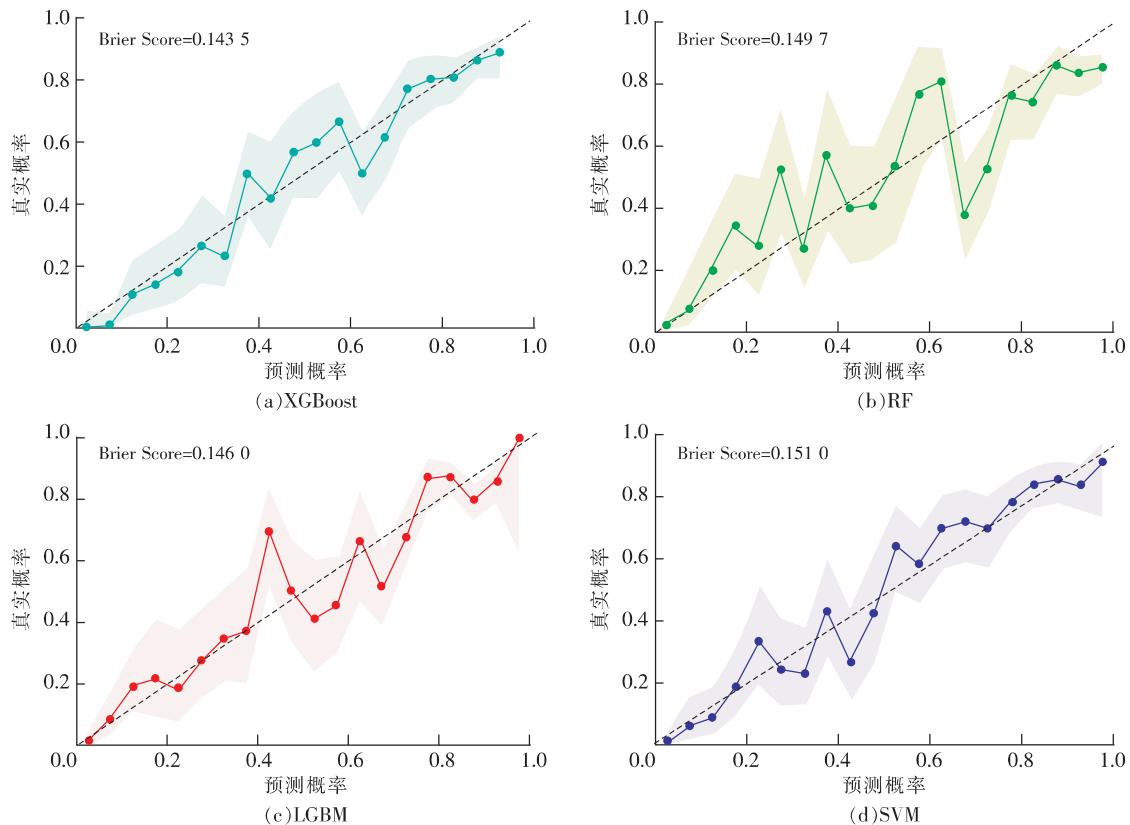


图5 不同机器学习模型的校准曲线

Fig. 5 Calibration curves of different machine learning models

2.3 驱动因素

基于 DALEX 的统一解释框架,对比了 4 种模型中各变量的重要性排序,如图 6 所示。不同颜色

带状连接对应各模型(XGBoost、RF、LGBM、SVM)驱动因素差异过程,特征下的损失函数(1-AUC)反映了对模型影响的重要性程度。




图 6 基于 DALEX 的不同机器学习模型变量重要性桑基图

Fig. 6 DALEX-based Sankey diagram of variable importance for different machine learning models

4 个模型均一致识别出总降水量(PRE)、平均气温(TMP)和相对湿度(RHU)等气象因子为 WUI 火灾发生的关键驱动因素,进一步突显了干旱条件在火灾发生中的重要作用。归一化植被指数(NDVI)作为可燃物载量的表征指标,其重要性次之,反映了可燃物积累对火灾风险的关键作用。社会经济因素中,人口密度(POP)和国内生产总值(GDP)在部分模型中表现突出,表明人类活动对火灾的潜在影响。值得注意的是,饱和水汽压差(VPD)和风速(WIN)的重要性在不同模型间波动较大,可能与其非线性作用机制有关,但二者均表现出中等重要性,反映了大气干旱和风速扩散的协同作用。总体而言,WUI 火灾风险是气象-植被-人类活动多因素耦合的结果,但气象条件(尤其是 PRE、TMP 和 RHU)和可燃物积累(NDVI)是跨模型一致的核心驱动力,而社会经济因素的空间异质性可能导致其贡献度在不同模型中出现波动。这一发现为 WUI 火灾精准防控提供了理论依据,即需优先监测气象干旱和植被动态,同时结合局部地形与社会经济特征制定差异化策略。然而,由于部分数据(如防火设施分布、火源类型细

分)在省级尺度上难以系统获取,因此未将其纳入模型。了解野火发生的驱动因素对 WUI 火灾的预防和管理具有重要价值^[29-30]。未来研究可结合更高分辨率的遥感数据与社会调查数据,进一步量化这些变量对 WUI 火灾的贡献。

2.4 风险评估

基于上述 4 种机器学习方法构建的 WUI 火灾发生模型,获取研究区域 WUI 火灾发生概率。该概率取值范围为 0~1,网格概率值越大,表示对应区域火灾发生的概率越高。结合火灾发生概率绘制火险等级图,如图 7 所示。将研究区域火险等级划分为 5 个等级,其中[0~0.2)为极低风险(绿色),[0.2~0.4)为低风险(浅绿色),[0.4~0.6)为中风险(黄色),[0.6~0.8)为高风险(橙色),[0.8~1.0]为极高风险(红色)。

对比 XGBoost、RF、LGBM 和 SVM 这 4 种模型的评估结果可以看出,福建省 WUI 火灾风险呈现明显的空间异质性,且不同模型识别的火灾风险空间格局具有高度一致性。西部和北部地区表现出更高的火灾风险等级,尤其西部地区高风险与极高风险面积比例显著突出(如 XGBoost 模型中

高风险占11.29%、极高风险占2.99%),这与该区域地形复杂、植被密集及季节性干旱的气候特征密切相关。北部地区虽然极高风险面积占比较低(如RF模型中为4.23%),但高风险及以上等级占比仍明显高于东部和南部地区,可能受山区地形和局部气象条件影响。相比之下,东部和南部地区以低风险和中风险为主(如LGBM模型中南

部低风险占11.08%、中风险占7.77%),这与其相对湿润的气候、该区域防火管理体系较完善以及较低的植被可燃物负荷有关。值得注意的是,所有模型均显示西部地区高风险区面积比例远超其他地区,尤其是在SVM模型中西部地区高风险区面积达到11.59%,进一步验证了该区域为火灾防控的核心重点区域。

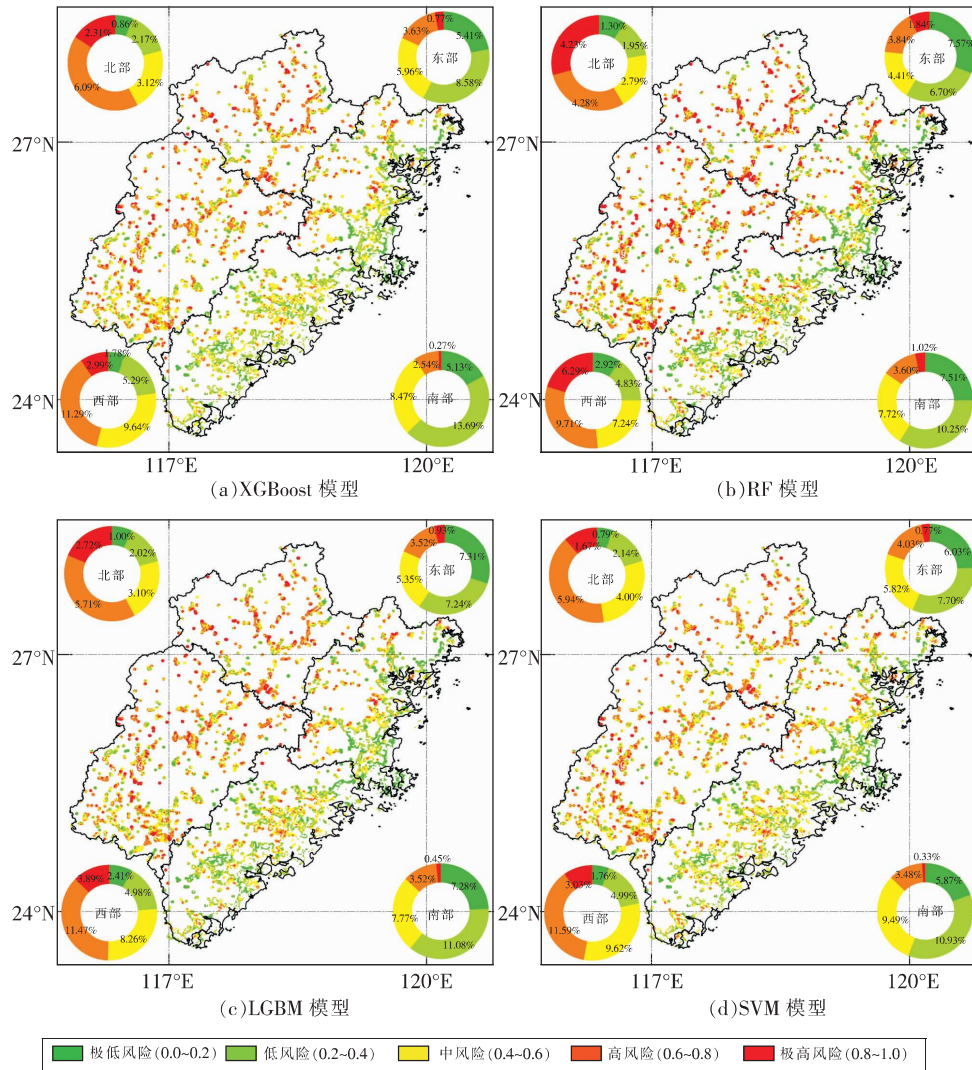


图7 基于不同机器学习模型的风险等级

Fig. 7 Risk levels based on different machine learning models

3 结论

1) WUI火灾呈现显著时空异质性。年际变化上,2007—2024年火灾次数以11.06次/年的速率显著下降($p < 0.01$);季节分布上,冬季(12~次年2月)与春季(3月)为火灾高发期,占全年71.49%;空间上,火点呈现高密度聚集特征,主要分布于西部(三明、龙岩)与北部(南平)山区,与其

地形复杂、植被覆盖度高及局部气候干旱特征相吻合。这一时空格局提示,未来福建省防火工作应强化季节性管控与区域差异化策略的完善。

2) SVM、RF、XGBoost、LGBM这4种方法构建模型的AUC均大于0.85,校准度良好。其中,XGBoost模型AUC值最高,且Brier评分最低,校准效果最优,表明XGBoost模型区分与预测能力更好。相较于传统模型,机器学习方法在处理多源、非线

性、高维数据方面具有显著优势,能够有效捕捉WUI火灾系统中复杂的因子交互作用,特别是集成学习方法(如XGBoost、RF)具有较高的学习泛化能力,避免过拟合,适用于具有时空异质性的WUI火灾风险评估。

3)总降水量(PRE)、平均气温(TMP)、相对湿度(RHU)和可燃物(NDVI)是跨模型一致的关键驱动因素,反映出干旱气候与丰富可燃物对火灾的促进作用。WUI火灾还受火源类型、土地利用结构、防火设施分布、政策管理强度等因素的影响,未来应持续加强森林火源管控、推进防火基础设施建设。

4)福建省WUI火灾风险等级呈现显著的空间分异特征,但不同模型的WUI火灾风险格局高度一致,西部与北部为高风险聚集区域,而东部与南部沿海地区风险相对较低。风险等级图可为火源监测、可燃物管理与早期扑救资源的空间配置提供空间决策依据。未来应融合承灾体脆弱性等数据,进一步构建“概率-后果”双维度的综合风险评估体系,为应急疏散规划与国土空间布局提供更全面的决策依据。

参考文献(References):

- [1] 杨晓菡,韩峥,邓玲,等.森林-城镇交界域火灾安全问题国内外研究进展综述[C]//2023中国消防协会科学技术年会论文集.北京:中国消防协会,2023:81-86.
YANG Xiaohan, HAN Zheng, DENG Ling, et al. Review on research progress of fire safety in wildland-urban interface at home and abroad [C]//Proceedings of the 2023 Annual Conference on Science and Technology of China Fire Protection Association. Beijing: China Fire Protection Association, 2023: 81-86.
- [2] 王庆飞,郝泽周,吴泽鹏,等.森林和城镇交界域火灾现状、特点与防控综述[J].生态科学,2024,43(5):231-239.
WANG Qingfei, HAO Zezhou, WU Zepeng, et al. Review on status, characteristics and comprehensive principles of fire prevention and control in wildland-urban interface [J]. Ecological Science, 2024, 43(5): 231-239.
- [3] 王秋华,王劲,李晓娜,等.森林-城镇交界域火灾研究进展[J].南京林业大学学报(自然科学版),2024,48(5):1-10.
WANG Qiuhua, WANG Jin, LI Xiaona, et al. Advances in research of wildland-urban interface fires [J]. Journal of Nanjing Forestry University (Natural Sciences Edition), 2024, 48(5): 1-10.
- [4] 王琪,涂吾祺,吴泽群,等.森林-城镇交界域火灾多模型组合扩展预测方法[J].清华大学学报(自然科学版),2025,65(1):143-151.
WANG Qi, TU Wuqi, WU Zequn, et al. Extended multi-model combination prediction method for fire in wildland-urban interface [J]. Journal of Tsinghua University (Science and Technology), 2025, 65(1): 143-151.
- [5] 关如泓,焦珂伟,常禹,等.黑龙江省森林-城镇交界域火灾分布格局及高发区域时空动态辨识[J].生态学报,2025,45(13):1-11.
GUAN Ruhong, JIAO Kewei, CHANG Yu, et al. Spatio-temporal dynamics of wildland-urban interface distribution patterns and high fire occurrence areas in Heilongjiang Province [J]. Acta Ecologica Sinica, 2025, 45(13): 1-11.
- [6] RADELOFF V C, HAMMER R B, STEWART S I, et al. The wildland-urban interface in the United States [J]. Ecological Applications, 2005, 15(3): 799-805.
- [7] LAMPIN-MAILLET C, JAPPIOT M, LONG M, et al. Mapping wildland-urban interfaces at large scales integrating housing density and vegetation aggregation for fire prevention in the South of France [J]. Journal of Environmental Management, 2010, 91(3): 732-741.
- [8] WILLIAMS A P, ABATZOGLOU J T, GERSHUNOV A, et al. Observed impacts of anthropogenic climate change on wildfire in California [J]. Earth's Future, 2019, 7(8): 892-910.
- [9] GUO F, SU Z, WANG G, et al. Understanding fire drivers and relative impacts in different Chinese forest ecosystems [J]. The Science of the total environment, 2017, 605-606: 411-425.
- [10] VILAR DEL HOYO L, MARTÍN ISABEL M P, MARTÍNEZ VEGA F J. Logistic regression models for human-caused wildfire risk estimation: Analysing the effect of the spatial accuracy in fire occurrence data [J]. European Journal of Forest Research, 2011, 130(6): 983-996.
- [11] YING L, CHENG H, SHEN Z, et al. Relative humidity and agricultural activities dominate wildfire ignitions in Yunnan, Southwest China: Patterns, thresholds, and implications [J]. Agricultural and Forest Meteorology, 2021, 307: 108540.
- [12] GONG Dapeng. Higher emissions scenarios increase wildland-urban interface fire hazard in China [J]. Sustainability, 2025, 17: 7409.
- [13] 王苏健,贾澎涛,金声尧.基于随机森林回归的围岩

- 应力插值方法[J]. 西安科技大学学报, 2021, 41(2): 274-281.
- WANG Sujian, JIA Pengtao, JIN Shengyao. An interpolation method of surrounding rock stress based on random forest regression[J]. Journal of Xi'an University of Science and Technology, 2021, 41(2): 274-281.
- [14] 马砺, 黄霄, 高建勋, 等. 城市区域火灾事件分布规律及概率密度预测[J]. 西安科技大学学报, 2022, 42(2): 260-267.
- MA Li, HUANG Xiao, GAO Jianxun, et al. Distribution law and probability density prediction of urban area fire events[J]. Journal of Xi'an University of Science and Technology, 2022, 42(2): 260-267.
- [15] SHARMA L K, GUPTA R, FATIMA N. Assessing the predictive efficacy of six machine learning algorithms for the susceptibility of Indian forests to fire[J]. International Journal of Wildland Fire, 2022, 31(8): 735-758.
- [16] BIECEK P, BURZYKOWSKI T. Explanatory model analysis: Explore, explain, and examine predictive models[M]. New York: Chapman and Hall/CRC, 2021.
- [17] 苏漳文, 刘爱琴, 郭福涛, 等. 福建林火发生的驱动因子及空间格局分析[J]. 自然灾害学报, 2016, 25(2): 110-119.
- SU Zhangwen, LIU Aiqing, GUO Futao, et al. Driving factors and spatial distribution pattern of forest fire in Fujian Province[J]. Journal of Natural Disasters, 2016, 25(2): 110-119.
- [18] 黄奇晓. 福建省森林火灾对气候变化的响应及趋势预测[D]. 福州: 福建农林大学, 2020.
- HUANG Qixiao. The Response of forest fires to climate change and its trend prediction in Fujian Province[D]. Fuzhou: Fujian Agriculture and Forestry University, 2020.
- [19] 王玲萍, 郑裕永. 福建省林业局聚焦“十化”着力解决森林防火“两个普遍性突出问题”[EB/OL]. 人民网, 2024-12-17. <http://fj.people.com.cn/n2/2024/1217/c181466-41078409.htm>.
- WANG Lingping, ZHENG Yuyong. Fujian Provincial Forestry Bureau focuses on “Ten Modernizations” to solve the “Two Prominent Widespread Problems” in forest fire prevention[EB/OL]. People's Network, 2024-12-17. <http://fj.people.com.cn/n2/2024/1217/c181466-41078409.htm>.
- [20] Food and Agriculture Organization of the United Nations. Guidelines on fire management in temperate and boreal forests[EB/OL]. (2002-11) [2025-08-18] <https://www.fao.org/4/ag041e/AG041E00.htm>.
- [21] TIAN X R, ZHAO F J, SHU L F, et al. Distribution characteristics and the influence factors of forest fires in China[J]. Forest Ecology and Management, 2013, 310: 460-467.
- [22] 张晓. 森林及交界域火灾发生影响因素时空异质性分析研究[D]. 合肥: 中国科学技术大学, 2024.
- ZHANG Xiao. Spatiotemporal heterogeneity analysis of factors affecting fire occurrence in forest and wildland-urban interface[D]. Hefei: University of Science and Technology of China, 2024.
- [23] TSINKO Y, BAKHSHAI A, JOHNSON E A, et al. Comparisons of fire weather indices using Canadian raw and homogenized weather data[J]. Agricultural and Forest Meteorology, 2018, 262: 110-119.
- [24] ALLAN R, PEREIRA L, RAES D, et al. Crop Evapotranspiration-Guidelines for computing crop water requirements-FAO irrigation and drainage paper 56[M]. Rome: Food and Agriculture Organization of the United Nations (FAO), 1998.
- [25] KHATCHIKIAN C, SANGERMANO F, KENDELL D, et al. Evaluation of species distribution model algorithms for fine-scale container-breeding mosquito risk prediction[J]. Medical and Veterinary Entomology, 2011, 25(3): 268-275.
- [26] TRANG P T, ANDREW M E, CHU T, et al. Forest fire and its key drivers in the tropical forests of northern Vietnam[J]. International Journal of Wildland Fire, 2022, 31(3): 213-229.
- [27] STEYERBERG E W, VICKERS A J, COOK N R, et al. Assessing the performance of prediction models: A framework for traditional and novel measures[J]. Epidemiology, 2010, 21(1): 128-138.
- [28] GUNASEKARAN A, MISTRY P, CHEN M. Which explanation should be selected: A method agnostic model class reliance explanation for model and explanation multiplicity[J]. SN Computer Science, 2024, 5(5): 503.
- [29] GUO M, YAO Q C, SUO H Q, et al. The importance degree of weather elements in driving wildfire occurrence in mainland China[J]. Ecological Indicators, 2023, 148: 110152.
- [30] HUANG Y, WU S, KAPLAN J O. Sensitivity of global wildfire occurrences to various factors in the context of global change[J]. Atmospheric Environment, 2015, 121: 86-92.

(责任编辑: 刘洁)