第 52 卷 第 4 期：1675-1687 高电压技术 Vol.52, No.4: 1675-1687
2026 年 4 月 30 日 High Voltage Engineering April 30, 2026
DOI: 10.13336/j.1003-6520.hve.20250610

考虑气象干旱指数的多源数据融合输电线路山火预测

朱陈政翰，冯子姣，包秀明，黄津钜，高嘉辰，孙英云
（新能源电力系统全国重点实验室(华北电力大学)，北京 102206）

摘　要：输电线路山火预测可为调控资源优化、灭火装备提前部署提供参考。针对输电线路山火预测中建模困难等问题，提出了一种基于残差-时间卷积网络的多源数据融合输电线路山火预测新方法。基于重采样技术搭建涵盖气象要素、植被状况、干旱指数、人类活动、地形特征、输电线路六大类共计 14 种影响因子的多源数据集；依据时序匹配与空间对齐，设计多源数据时空五维张量输入结构；利用二维分组卷积设计多层残差单元与膨胀因果卷积以捕捉变量的时空相关性，拟合输入特征与输出标签的高维非线性关系。最后，将美国加州作为研究区域进行算例分析，通过方法对比并绘制输电线路山火风险等级分布图，表明所提算法在输电线路山火预测的有效性，可指导相关部门开展电网山火防治工作。

关键词：输电线路山火预测；干旱指数；多源数据；残差-时间卷积网络；时-空相关性；深度学习

Wildfire Prediction for Transmission Lines with Multi-source Data Integration Considering Meteorological Drought Index

ZHU Chenzhenghan, FENG Zijiao, BAO Xiuming, HUANG Jinju, GAO Jiachen, SUN Yingyun
(State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources
(North China Electric Power University), Beijing 102206, China)

Abstract: Wildfire prediction for transmission lines provides references for optimizing dispatching resources and pre-deploying firefighting equipment. To address the issues of modeling challenges in wildfire prediction for transmission lines, we put forward a novel approach for wildfire prediction for transmission lines based on residual-temporal convolutional network with multi-source data integration. A multi-source dataset was constructed by using resampling techniques and integrating six categories and fourteen influencing factors, including meteorological elements, vegetation conditions, drought index, human activities, topographical features and transmission lines. Through temporal sequence matching and spatial alignment, a spatio-temporal five-dimensional tensor structure was designed for multi-source data input. Multi-layer residual units designed with two-dimensional group convolution, together with dilated causal convolution, were used to capture spatio-temporal correlation among variables and to fit high-dimensional nonlinear relationships between input features and output labels. Finally, California in the United States was selected as the study area for case analysis. Moreover, the method comparison is conducted and wildfire risk level distribution maps for transmission lines are visualized, validating the effectiveness of the proposed method for wildfire prediction for transmission lines and providing guidance for relevant authorities in conducting wildfire prevention and control efforts for power grids.

Key words: wildfire prediction for transmission lines; drought index; multi-source data; residual-temporal convolutional network; spatio-temporal correlation; deep learning

0　引言

全球气候变化异常导致包括极端干旱在内的极端天气事件日益频发[1]。受气象干旱的持续性高温、干燥等影响，山火等极端灾害事件发生可能性、强度将进一步增大，从而破坏自然生态系统[2-3]。由于输电线路广泛分布于山区、林区等火险高发区域，其对电力设施同样构成严重威胁[4]。例如，2022 年我国辽宁多条输电线路因山火导致跳闸[5]；美国加利福尼亚州(以下简称加州)每年因山火导致大面积停电事件屡屡发生[6]；2024 年美国德克萨斯州最大规模山火由电网故障引起，致使至少 11 000 人断电。频发的山火灾害使电力系统的规划与安全运行面临严峻挑战，严重扰乱人民正常生产活动，同时电网故障本身也可能引发一定规模山火[7]。因此，如何

基金资助项目：国家重点研发计划(2024YFB2409100)。
Project supported by National Key R&D Program of China (2024YFB2409100).

实现对输电线路山火的准确预测，对电网调控资源优化、灭火装备提前部署以及电网韧性提高、电网抵御山火能力增强具有重要意义[8-10]。

山火灾害预测可大致分为火险天气预报、山火发生预测及火势蔓延预测[8,11]。火险天气预报主要关注多种天气条件引发山火的可能性；山火发生预测是综合考虑气象、植被分布、地形等多源数据以预测山火发生的可能性；火势蔓延预报则是预测山火发生后的火势蔓延速度、方向等。为准确量化输电线路山火灾害发生的可能性并提前预警高发风险区域，本文研究对象为考虑多源数据融合的输电线路山火发生预测。

目前国内外已有学者针对山火发生预测开展相关研究，可将其主要归类成基于显式建模的统计学法[11]与数据驱动的人工智能法[12-13]。统计学法发展起步较早，在输电线路山火预测方面应用较为成熟，无需大量历史数据，其依据公式推导及概率理论，模型结构较为清晰[14]。文献[15]选用符合山火发生数据结构的泊松回归模型(poisson regression, PR)与零膨胀模型(zero-inflation, ZI)，建模山火发生次数与气象因素的关系。文献[16]采用移动平均模型(moving average, MA)，结合气象、工农业用火、卫星检测热点等要素，实现架空输电线路山火预警。文献[17]选用森林火险气象指数、地表燃烧因子、历史火情因子，提出基于图理论模型(graph theory, GT)的电网山火风险等级预测方法。文献[18]通过收集人为、地理、气象等指标，构建主观赋值与客观权重计算的物元可拓输电线路山火风险评估模型。上述方法虽具有较高可解释性，但在进一步刻画多元变量与山火火点位置分布的映射关系上较为乏力，且在建模过程中常依赖于固定参数，同时受专家主观评分影响，导致模型泛化能力不强，预测精度仍有待提高。

近年来，随着计算机算力提高及卫星遥感、气象等数据积累，人工智能法因其数据表达能力出色、多元变量的高维分布求解能力较强，已逐步应用于山火预测研究[19]。文献[20]利用气象、植被等数据，建立融合随机森林算法(random forest, RF)与动态贝叶斯网络(dynamic bayesian network, DBN)的输电走廊山火风险评估模型。文献[21]基于多层感知机(multi-layer perceptron, MLP)并将遥感数据作为输入以预测山火，但受限于 MLP 的简单结构，模型的泛化能力存在一定局限性。文献[22-23]构建目标区域的 GIS 多源数据集，提出基于卷积神经网络(convolutional neural network, CNN)的预测模型，绘制未来山火燃烧概率的每日地图，为山火预测提供新的视角。文献[24]以广域山火火点预测为目标，采用 U 型卷积长短期记忆网络(U-convolutional long short-term memory, ULSTM)实现逐个空间网格的山火预测。现有人工智能法虽已提高预测未来山火发生的能力，但大多忽略了气象干旱以及输电线路等因素的影响[25]，难以表达其与山火发生的内在联系，仅针对温度、风速、湿度等气象因素以及植被、地形等数据进行建模，且大多采用当日或前一日数据作为变量输入，并未考虑山火发生前的多日变量累积效应以及相邻空间区域多元变量对山火发生的影响，可能无法深入挖掘多源数据间的时空相关性，进而影响输电线路山火预测准确度。

基于前述问题，综合考虑多元变量间的时空相关性，本文提出一种基于残差-时间卷积网络(residual-temporal convolutional network, Res-TCN)[26-27]的多源数据融合输电线路山火预测方法。创新方面主要如下：1）直接引入气象干旱指数以及输电线路分布、电压等级等特征，基于重采样等预处理技术搭建涵盖卫星遥感、气象再分析等数据集；2）依照时序匹配与空间对齐，设计融合静态、动态变量的多源数据时空五维张量输入结构；3）利用二维分组卷积设计多层残差单元提取空间相关性、TCN 捕捉多日时间相关性，加强模型可解释性并提高对山火时空特征的感知能力，最终拟合海量输入变量与输出标签的高维非线性关系，实现从局部域特征到目标域的日前输电线路山火预测。以美国加州地区作为研究区域，搭建了囊括干旱指数、温度、海拔、植被、人为、输电线路等 14 种影响因子数据集，将其作为算例输入验证本文方法预测输电线路山火的有效可行性。

1 问题描述与模型介绍

1.1 问题描述

假定输电线路山火预测区域为 Z，划分 Z 为若干个网格区域 $Z_s(s=1,2,\cdots,S)$，将 Z_s 看作二维平面的目标像素点，每个像素点的位置由 $H_j(j=1,2,\cdots,J)$与 $W_k(k=1,2,\cdots,K)$共同表示。若网格区域 Z_s 在未来某时间段 $T_i(i=1,2,\cdots,I)$内发生山火，可认为此处有火并标记为 1，无火则标记为 0。因此，利用卫星遥感与气象再分析、地理观测等数据进行输电线路山火

预测，本质上是由多种输入信息(高维)映射至对应样本标签(低维)的典型正负样本二分类问题，属有监督学习的范畴[27]。本文研究对象为日前输电线路山火预测，即预测 Z_s 在第二日是否发生山火。

在实际应用中，未来时段 T_i 的输电线路山火灾害不仅与对应区域 Z_s 当前时段的气象、环境等因素有关，还可能受邻域 $Z_{s'}(s'\neq s)$以及当前时段、前一甚至更长时段 $T_{i'}(i'<i)$因素的影响[20]，因此，本文目标为利用区域 Z_s 及邻域 $Z_{s'}$对应时间段 $T_{i'}$的输入变量以预测 Z_s 的标签，即：

$$y_{s,i}=f(C_v,T_{i'},H_{j(j')},W_{k(k')}) \tag{1}$$

式中：$y_{s,i}$ 为 Z_s 对应时段 T_i 的目标标签；$f(\cdot)$表示映射函数；$C_v(v=1,2,\cdots,V)$表示共有 v 种输入变量；Z_s 对应的空间位置为(H_j,W_k)；$Z_{s'}$对应的空间位置为($H_{j'}$,$W_{k'}$)。s 与 s'遵循$|s-s'|<\varepsilon$ 约束，其中$\varepsilon>0$。

因此，模型需具有刻画多源数据时空相关性、描述多元变量间非线性关系的能力，最终近似拟合 $f(\cdot)$实现区域输电线路山火预测。然而，传统基于显式建模的方法因参数受限，且依赖于固定函数形式与先验分布假设，已难以满足输电线路山火准确预测的需求。基于数据驱动的深度学习技术，搭建适配多源数据输入形式的网络框架，可有效捕捉其时空相关性，提高预测精度。

1.2 残差神经网络

在输电线路山火预测任务中，模型需处理海量多源数据，为准确拟合其复杂耦合的时空特性，应采取更深层的神经网络。残差神经网络(residual-network, Res-Net)是一种基于 CNN 的深层网络架构，其引入残差连接，增强网络提取不同层次特征的能力，稳定训练进程[26]，如下式所示：

$$h(x_{\mathrm{re}})=g(x_{\mathrm{re}})-x_{\mathrm{re}} \tag{2}$$

式中：x_{re}为单个残差单元的输入特征量；$g(x_{\mathrm{re}})$为对应输出特征量，故网络训练目标不再是直接学习 $g(x_{\mathrm{re}})$分布，而是转为拟合 x_{re} 与 $g(x_{\mathrm{re}})$间的差异 $h(x_{\mathrm{re}})$。传统残差单元如附录 A 图 A1(a)所示，其输入 x_{re} 与输出 $g(x_{\mathrm{re}})$维数形状相同。恒等映射为网络的梯度反向传播提供直接通道，解决了网络梯度易消失等问题，降低过拟合风险。

为贴合本文将目标区域及邻域的多维输入变量经模型最终映射至目标区域 0/1 标签的研究任务，应平滑逐步增大张量的通道特征数并减小特征图尺寸，使得模型学习变量间的空间相关性，同时此种平滑机制稳定了残差单元的训练架构。为此，设计改进残差单元如附录 A 图 A1(b)所示。

1.3 时间卷积网络

TCN 以非循环方式处理时序数据，核心在于结合膨胀与因果卷积作为卷积层，使模型在计算当前时段 T_i 时不利用未来时段信息，其在时序建模上表现优异[27]。利用上述特点，可实现对数据多时间尺度特性的提取。本文采用的膨胀因果卷积(dilated causal convolution, DConv)运算如式(3)所示：

$$f_{\mathrm{c}}(T)=(\delta * x_{\mathrm{c}})(T)=\sum_{m=0}^{k_{\mathrm{c}}-1}\delta_m x_{\mathrm{c},T-dm} \tag{3}$$

式中：$f_{\mathrm{c}}(T)$ 为当前时间段 T 所对应的卷积运算；$*$ 为卷积操作；$x_{\mathrm{c},T-dm}$ 为输入特征量 x_{c} 在时间段 T−dm 处的取值；δ_m 为膨胀因果卷积核第 m 个参数；k_{c} 为卷积核尺寸；d 为膨胀系数。

TCN 的膨胀因果卷积过程如图 1 所示。由图 1 与式(3)可知，d 为 1 时，网络能够感知输入层中时段 T_{i-1} 到 T_{i-7} 的数据特征，而在输出层仅能提取 T_{i-1} 特征。连续叠加多层可增大感受野，捕捉输电线路山火预测任务中多源数据的长时与短时依赖信息。

1.4 损失函数

二元交叉熵损失函数(binary cross-entropy loss function, BCELoss)[28]在大多分类问题中表现良好，但在正负样本不平衡时，将导致网络趋于占比更高的类别，影响预测结果。由于现实情况中输电线路山火为较小概率事件，即区域 Z_s 在时段 T_i 的 0 标签要多于 1 标签，是正负样本不平衡的二分类任务。为解决上述问题，Res-TCN 采用聚焦损失函数(focal loss function, FocalLoss)，其表达式如下：

$$\begin{aligned}L_{\mathrm{FL}}=-\frac{1}{N}\sum_{n=1}^{N}&(\alpha(1-y_n)^{\gamma}\hat{y}_n\ln(y_n)+\\&(1-\alpha)y_n{}^{\gamma}(1-\hat{y}_n)\ln(1-y_n))\end{aligned} \tag{4}$$

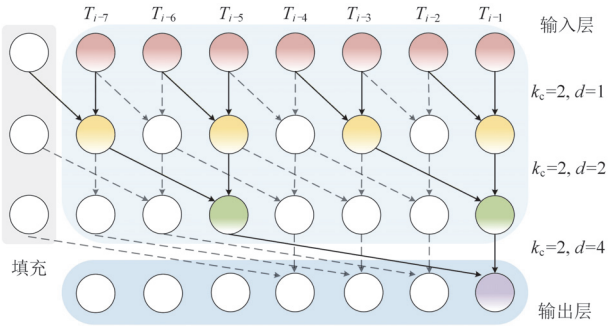


图 1 膨胀因果卷积过程

Fig.1 Dilated causal convolution process

式中：$\hat{y}_n \in \{0,1\}$ 为样本 n 的真实标签；y_n 为网络预测样本 n 为正类的概率；N 为样本个数；α 为正样本权重因子，其值越大模型越关注正样本；γ 为调制因子。L_{FL} 可通过 γ 将易混淆样本的损失放大，不仅使网络聚焦少类正样本，还降低易分类样本的损失贡献，加强对边缘样本特征信息的学习程度，提高 Res-TCN 整体预测能力与泛化性能。

2 基于 Res-TCN 的多源数据融合输电线路山火预测

2.1 多源数据集

2.1.1 数据准备

1）历史山火火点。火点数据来自开源数据集 WildfireDB[24]，记录山火发生日期与经纬度坐标。

2）气象要素。包括 2 m 温度、2 m 露点、降水量、10 m 纬向(10 m u)风速、10 m 经向(10 m v)风速，来自欧洲中期天气预报中心第五代再分析数据(european centre for medium-range weather forecasts reanalysis 5th generation, ERA5)[29]。气象要素是影响山火发生的重要因素[11]。例如，露点为空气中气态水达饱和状态而凝结成液态水所需降至的温度，当露点越接近温度，表明相对湿度越高；风速将影响空气中水分蒸发，进而影响可燃物的干湿度；降水量越大时山火发生可能性越小，反之可能因缺水导致可燃物干燥易燃。

3）植被状况。归一化植被指数(normalized difference vegetation index, NDVI)来自 NASA 地球观测系统陆地过程数据分发归档中心(NASA LP DAAC)MOD13A1 卫星遥感产品[30]。NDVI 可反映地表植被长势与植物光合作用强度，其值越高表明植被覆盖程度越高，为输电线路山火提供可燃物。

4）干旱指数。标准化降水蒸散指数(standardized precipitation evapotranspiration index, SPEI)在气象学领域常用于衡量干旱程度[22]，其能综合反映月时间尺度下降水亏缺情况，可与日时间尺度下气象要素互为补充，更为全面刻画干旱对山火的潜在影响以提升预测精度。选用 SPEI-GD[31]作为本文的气象干旱指数，其分级与对应天气状况如附录 A 表 A1 所示。连续高温少雨天气时 SPEI 值较低，土壤含水量少导致植被干枯，输电线路山火风险将增加。

5）人类活动。人为用火提供火源，提高了山火发生的可能性，是诱发大多数输电线路山火的直接原因之一[20]。选取来自覆盖全球范围的公开数据 WorldPop[32]中的人口密度、距道路距离、距水路距离作为与人类活动相关的输电线路山火影响因子。

6）地形特征。选取 NASA LP DAAC 的 ASTGTM 与 MCD12Q1 卫星遥感产品分别作为高程与土地类型数据。高程数据可用于描述区域的海拔高度，高海拔地区温度低，输电线路山火可能性减小；不同土地类型发生输电线路山火概率差异较大，如草地、森林等区域可燃物丰富，易发生输电线路山火，而水体等区域水域覆盖大，不会发生输电线路山火或概率极低。

7）输电线路。由于输电线路广泛分布于自然地带，其沿线覆盖多种土地类型，有可能穿越灌丛、草地等高可燃性区域，结合高温干燥、大风等气象条件，因线路故障等引发山火的风险将进一步增加，同时，在输电线路附近区域的山火极有可能威胁电力设施，危及电网安全稳定运行。选用加州能源委员会(california energy commission, CEC)[33]公开的电压等级与线路类型数据作为影响因子。

综上，基于各开源平台收集历史山火火点与涵盖气象要素、植被状况、干旱指数、人类活动、地形特征以及输电线路 6 方面的 14 种输电线路山火影响因子，数据集属性如表 1 所示。其中存储格式为开源平台数据的原始文件类型，时间分辨率是每日或每时为动态变量，其余为静态变量。

2.1.2 数据处理

由于各类原始数据在数据分布与存储格式上存在明显差异，首先，在空间尺度方面，本文选用双线性插值法、平均池化与最频值法，上采样空间分辨率较低、下采样空间分辨率较高的原始数据，

表 1 数据集属性

Table 1 Dataset properties

类型	因子	分辨率	单位	存储格式
历史火点	—	每日	—	CSV
气象要素	2 m 温度	每时/0.1°	K	GRIB2
	2 m 露点	每时/0.1°	K	GRIB2
	降水量	每时/0.1°	mm	GRIB2
	10 m u 风速	每时/0.1°	$m \cdot s^{-1}$	GRIB2
	10 m v 风速	每时/0.1°	$m \cdot s^{-1}$	GRIB2
植被状况	NDVI	16 日/0.5 km	—	TIF
干旱指数	SPEI	每日/0.25°	—	NC
人类活动	人口密度	每年/1 km	$人 \cdot km^{-2}$	TIF
	距道路距离	每年/0.1 km	km	TIF
	距水路距离	每年/0.1 km	km	TIF
地形特征	高程	0.03 km	m	TIF
	土地类型	每年/0.5 km	—	TIF
输电线路	电压等级	—	kV	SHP
	线路类型	—	回	SHP

通过重采样不同分辨率数据，将其映射至包含目标研究区域的 500×500 标准化网格，重采样表达式如式(5)—(6)所示：

$$Q^{\mathrm{up}}(j,k)=f_{\mathrm{bil}}(\tilde{Q}(\tilde{j},\tilde{k})) \tag{5}$$

$$Q^{\mathrm{down}}(j,k)=f_{\mathrm{af(mf)}}(\tilde{Q}(\tilde{j},\tilde{k});\tau_{j,k}) \tag{6}$$

式中：$\tilde{Q}(\tilde{j},\tilde{k})$ 与 $Q^{\mathrm{up}}(j,k)$、$Q^{\mathrm{down}}(j,k)$ 分别表示原始数据在 $(\tilde{j},\tilde{k})$ 位置的值与上、下采样后数据在 (j,k) 位置的值；$f_{\mathrm{bil}}(\cdot)$ 表示双线性插值函数；$f_{\mathrm{af(mf)}}(\cdot)$ 表示平均池化或最频值函数；$\tau_{j,k}$ 表示原始数据中对应下采样后数据在位置 (j,k) 的值。多源数据选用的重采样方法如附录 A 表 A2 所示。

其次，在时间尺度方面，将时间分辨率为每时的气象要素数据进行加权平均以得到日均值、每年的土地类型、人为等数据以日为单位进行复制扩充，保持各变量在时间分辨率的一致性，确保各数据的时间分辨率均为每日。最后，根据不同数据所对应的开源平台，获取各数据的实际有效值范围，对重采样后的异常值与缺失值数据进行清洗填充处理，确保各栅格数据具有物理现实意义。因此，通过数据重采样与数据清洗等技术，将实现各变量时空尺度与分辨率的统一与对齐，为后续模型输入张量的构建奠定基础。

2.2 网络结构设计

根据 1.1 节所述，考虑到输电线路山火灾害受多源数据的时空相关性影响，将区域 Z_s 及邻域 $Z_{s'}$ 的当日 T_{i-1} 共 14 种输入变量 C_n 以空间位置对齐为拼接条件，可设计得到当日数据立方体 $\boldsymbol{U}_{s,i-1}\in\mathbf{R}^{C\times H\times W}$，将 T_{i-1} 至 T_{i-7} 共 7 日数据立方体按时序匹配纵向拼接，整合成该样本的四维结构 $\boldsymbol{X}_{s,i}\in\mathbf{R}^{T\times C\times H\times W}$，结合训练时需将多个样本按批次进行组合后送入给网络的特点，最终可得多源数据时空五维张量输入结构 $\boldsymbol{X}\in\mathbf{R}^{B\times T\times C\times H\times W}$。如何使模型根据当日及前 6 日的多源数据 $\boldsymbol{X}_{s,i}\in\mathbf{R}^{T\times C\times H\times W}$，准确预测第二日区域 Z_s 的样本标签 $y_{s,i}$ 是本文方法的关键。

由于输入的 14 种动态、静态变量在特征分布与物理意义上存在明显差异，若直接采用传统卷积(convolution, Conv)可能导致不同通道信息交叉干扰，降低模型对不同类型特征的拟合能力。而分组卷积(group convolution, GConv)将输入的多源数据特征图按变量类型分组后再进行卷积操作，使得模型能同步学习不同类型的特征，降低网络参数量与计算量，减小过拟合风险。Conv 与 GConv 对比图如附录 A 图 A2 所示。考虑到反向传播中梯度消失以及数据死区等问题，本文采用 GeLU 作为隐藏层的激活函数，提升对负输入的处理能力。在每个残差单元中，输入张量都与对应 GConv 进行卷积等操作，提取局部特征后经残差连接得到输出张量，运算如式(7)所示。

$$\begin{aligned}Y_a^{\mathrm{R}}=f_{\mathrm{GeLU}}(B_{\mathrm{N}}(f_{\mathrm{GeLU}}(B_{\mathrm{N}}(Y_{a-1}^{\mathrm{R}}*K_{\mathrm{GC}_2,a}^{\mathrm{R}}))*K_{\mathrm{GC}_3,a}^{\mathrm{R}})+\\ Y_{a-1}^{\mathrm{R}}*K_{\mathrm{GC}_1,a}^{\mathrm{R}})\end{aligned} \tag{7}$$

式中：Y_a^{R} 为第 a 个残差单元的输出；$f_{\mathrm{GeLU}}(\cdot)$ 为 GeLU 激活函数；$K_{\mathrm{GC}_1,a}^{\mathrm{R}}$ 为第 a 个残差单元中对应的 GConv 1×1 卷积核；$K_{\mathrm{GC}_2,a}^{\mathrm{R}}$、$K_{\mathrm{GC}_3,a}^{\mathrm{R}}$ 分别为第 a 个残差单元中对应的第 1、2 个 GConv 3×3 卷积核；B_{N} 为批归一化层。

在 TCN 的每层膨胀因果卷积层中，运算如式(8)所示：

$$Y_{a'}^{\mathrm{D}}=S_{\mathrm{F}}(D_{\mathrm{N}}(f_{\mathrm{GeLU}}(B_{\mathrm{N}}(Y_{a'-1}^{\mathrm{D}}*K_{\mathrm{DC},a'}^{\mathrm{D}})))+Y_{a'-1}^{\mathrm{D}}) \tag{8}$$

式中：$Y_{a'}^{\mathrm{D}}$ 为第 a'层膨胀因果卷积层的输出；$K_{\mathrm{DC},a'}^{\mathrm{D}}$ 为第 a'层膨胀因果卷积层的卷积核；S_{F} 为缩放因子，将输出除以 $\sqrt{2}$ 以保持数值稳定性，避免梯度爆炸；D_{N} 为随机失活层。

经线性层输出后得到最后层，为确保最终输出范围限制在[0,1]，最后层输出选用 Sigmoid 作为激活函数。结合 1.2 节内容，本文设计多层改进残差单元与 TCN 分别处理多源输入数据的空间相关性与时间相关性，有效提取海量数据丰富的特征信息。Res-TCN 输电线路山火预测模型架构如图 2 所示。图 2 的 C_{in}、C_{out} 表示输入张量、输出张量的通道数。

2.3 预测验证指标

输电线路山火预测是一种正负样本二分类问题，在深度学习领域中，常采用混淆矩阵的准确率(accuracy, AC)、精确率(precision, PR)、召回率(recall, RE)与 F1 分数(F1 score, F1)、接收者操作特性曲线的下面积(area under the receiver operating characteristic curve, AUC)大小 F_{auc} 以评估模型预测效果[12]，混淆矩阵如附录 A 表 A3 所示，其中 E_{tp}、E_{fn}、E_{fp}、E_{tn} 分别为实际有火且预测有火、实际有火但预测无火、实际无火但预测有火、实际无火且预测无火的样本数量。AC、PR、RE、F1 计算式如式(9)—(12)所示：

$$F_{\mathrm{ac}}=\frac{E_{\mathrm{tp}}+E_{\mathrm{tn}}}{E_{\mathrm{tp}}+E_{\mathrm{fn}}+E_{\mathrm{fp}}+E_{\mathrm{tn}}} \tag{9}$$

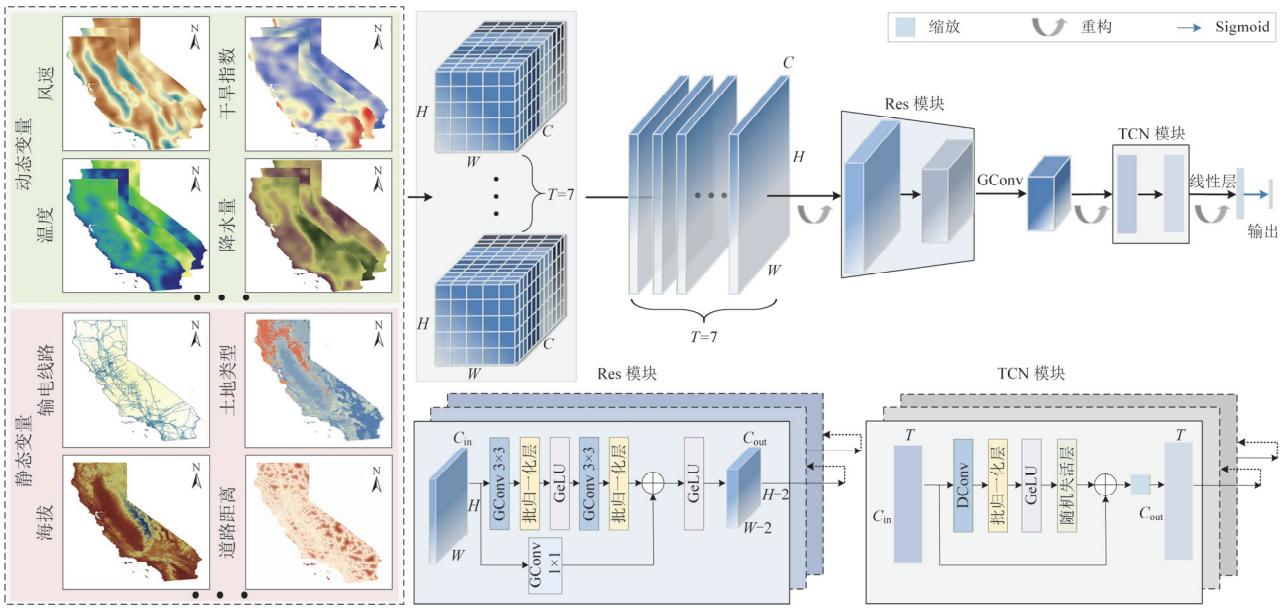


图 2 Res-TCN 输电线路山火预测模型架构

Fig.2 Framework of Res-TCN model for wildfire prediction for transmission lines

$$F_{\mathrm{pr}}=\frac{E_{\mathrm{tp}}}{E_{\mathrm{tp}}+E_{\mathrm{fp}}} \tag{10}$$

$$F_{\mathrm{re}}=\frac{E_{\mathrm{tp}}}{E_{\mathrm{tp}}+E_{\mathrm{fn}}} \tag{11}$$

$$F_{\mathrm{fl}}=\frac{2F_{\mathrm{pr}}F_{\mathrm{re}}}{F_{\mathrm{pr}}+F_{\mathrm{re}}} \tag{12}$$

式中：F_{ac}、F_{pr}、F_{re} 为 AC、PR、RE 在某一正负样本分类阈值条件下(通常为 0.5)的值，分别表示总体预测结果正确、预测有火且实际有火、实际有火且预测有火、实际无火但预测有火的比例；F_{fl} 为 F1 的值，综合考虑 PR 与 RE；F_{auc} 为模型随机抽取一对正负样本后将正样本排序靠前的概率，不依赖于分类阈值。F_{fl} 和 F_{auc} 综合反映模型的预测准度与泛化能力，适用于类不平衡的情况。F_{ac}、F_{pr}、F_{re}、F_{fl} 与 F_{auc} 越大表示模型预测性能越强。

3 算例分析

3.1 算例概要

为验证本文算法的有效性，选取美国加州((32.53°N~42.01°N)，(114.13°W~124.41°W))2012—2017 年山火事件为研究对象。加州包括丘陵、山地等复杂地形结构，其植被类型丰富、夏季多为高温干燥天气，易引发山火，是山火发生较多的区域。

实验选用 Python3.12.0 与 Pytorch2.7.1 深度学习框架，Intel i9-10920X CPU、128 GB RAM、NVIDIA GeForce RTX 3080Ti 等作为计算机硬件环境。

3.2 网络模型训练

本算例的总体训练流程如下。

1）根据 2.1.1 节与经纬度范围，收集 2012—2017 年的 14 种多源数据并利用 ArcGIS 软件对其进行空间掩码操作，保留加州区域内数值而区域外置为 0。

2）对掩码后的 14 种影响因子数据经 2.1.2 方法的数据处理后得到 14×500×500 的三维矩阵，并各自依据 Min-Max 标准化法归一化至 0~1 区间内。

3）选取火点中心周围 9×9 区域的前 7 日数据作为有火样本，为贴合有火小于无火样本的实际情况并同时保证模型识别对少数类，根据土地类型变量划分，以中心区域非水体为筛选条件，随机选取 4 倍有火样本数量的无火样本。划分 2012—2016 年样本为训练集、2017 年样本为测试集。

4）将测试集的预测验证指标最优作为目标条件，选用 Optuna 框架中的贝叶斯优化方法[34]进行网络学习率 l、每轮训练批次数 b、随机失活层比例 d_{r} 以及 L_{FL} 中 α、γ 的超参调优。

5）设置最佳超参 l、b、d_{r}、α、γ 与训练轮次 e，采用 Adam 优化算法分别更新 Res-TCN 各模块的权重与偏置矩阵，如式(7)—(8)所示。

6）计算式(4)所示的损失函数，当其稳定且逐步收敛于 0 时，保存 Res-TCN 的网络参数，用于测试集实现输电线路山火预测。

基于此可得 Res-TCN 伪代码算法如图 3 所示。

记录每轮训练对应的损失函数值直至训练结

束，如附录 A 图 A3 所示。训练伊始时损失函数值与波动幅度均较大，Res-TCN 各模块参数尚未学习到数据之间的特征。随训练深入，损失函数值逐步减小并趋于稳定，表明此时网络已逐渐捕捉多源数据的时空相关性，最终拟合输入变量到输出标签的高维非线性关系。

3.3 输电线路山火预测与对比分析

为探究不同连续型输电线路山火影响因子变量在有火、无火样本中的差异情况，选取数据集中一定数量样本绘制概率密度分布(probability density distribution, PDF)对比图，如附录 B 图 B1 所示。不同影响因子在有火、无火样本中的分布存在差异，既表示不同变量大小的变化与输电线路山火存在一定关联，也表明其并非由单一因素驱动，而是多因素相互作用影响的结果。部分有火样本集中于高温、低湿、低海拔、高植被覆盖率以及较干旱等区域，而人为活动等因素对山火发生的影响较为复杂，其部分集中于近道路与水路区域，说明存在人为点火的可能性。有火与无火样本 PDF 的重叠部分反映输电线路山火的发生存在一定随机不确定性，即使单个或多个类似的输入变量也可能导致不同的结果，若仅依赖于某一确定性规律或专家经验可能难以捕捉其复杂时空耦合特征。

为验证本文算法在输电线路山火预测方面的准确性与有效性，结合 5 个仿真方案进行对比：1）采用 Res-TCN 实现输电线路山火预测；2）只剔除 SPEI，用于说明气象干旱信息在输电线路山火预测中的重要性；3）采用文献[15]的 PR 统计模型，对比说明深度学习法在建模海量数据高维非线性特征的优越性；4）借助文献[21]的 MLP 直接进行输电线路山火预测，以说明 Res-TCN 在提取多源数据时空相关性的优势；5）选用文献[22]的 CNN 模型，以说明 Res-TCN 在深层网络中拟合不同层次特征的能力。基于训练后的网络模型参数，将 2017 年样本进行测试并取分类阈值为 0.5，图 4 给出上述 5 种方法对应的 F_{ac}、F_{pr}、F_{re}、F_{fl} 与 F_{auc} 指标计算结果对比。由于山火灾害可能引起输电线路跳闸等，严重时将导致大规模停电事故，所以有关部门宁“误判”也不“漏判”，即付出更大运维监控成本也要防止山火威胁电网，因此需额外关注 F_{re}、F_{fl} 与 F_{auc}。由图 4 可知，所提方法相较于其他对比方法在各项指标中均占优，通过定量分析表明 Res-TCN 能够学习多元变量的时空相关特征，对于样本拟合程度更高、预测结果更为准确，有效量化输电线路山火风险。

输入：有火样本与无火样本x_n；输电线路山火预测目标$\hat{y}_n$；l；b；d_r；e；α；γ；空间特征表示F_{zone}；时序特征表示F_{time}；损失函数值O_{loss}；梯度∇

while 模型训练参数θ_{res}, θ_{tcn}, θ_{linear} 不收敛 **do**

每轮训练批次数为b

  for 每轮训练$(1\rightarrow e)$ **do**

  # 前向传播

    # 空间相关性提取

    $F_{zone}\leftarrow G_{res}(x_n, \theta_{res})$

    # 时间相关性提取

    $F_{time}\leftarrow G_{tcn}(F_{zone}, \theta_{tcn}, d_r)$

    # 特征回归

    $y\leftarrow G_{linear}(F_{time}, \theta_{linear})$

    # 计算损失函数

    $O_{loss}\leftarrow L_{FL}(\alpha, \gamma)$

  # 反向传播

  $\theta_{res}, \theta_{tcn}, \theta_{linear}\leftarrow \mathrm{Adam}(l\cdot\nabla O_{loss})$

  end for

end while

return 模型训练最优参数θ_{res}', θ_{tcn}', θ_{linear}'

图 3 Res-TCN 训练步骤伪代码

Fig.3 Pseudocode of Res-TCN training steps

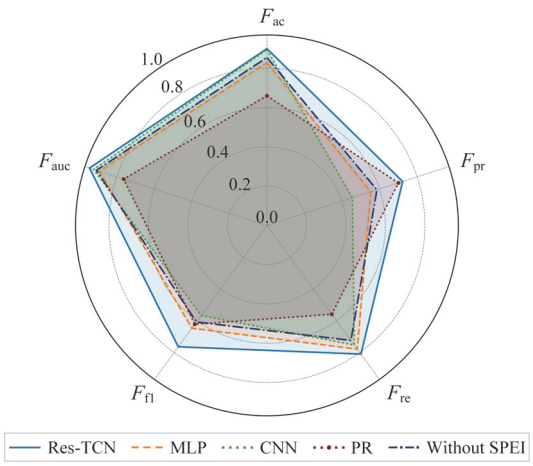


图 4 输电线路山火预测验证指标对比

Fig.4 Comparison of validation metrics for wildfire prediction for transmission lines

选取测试集中若干天样本进行可视化分析，以 20%、40%、60%、80%为分隔点，将山火发生概率划分为低风险、较低风险、中风险、较高风险和高风险 5 个风险等级，得到网格分辨率约为 2.53 km×2.53 km 的加州区域山火发生风险概率，并计算部分区域局部放大图中的干旱指数 SPEI 平均值，如附录 C 图 C1 所示，其中附录 C 图 C1(a)、(b)、(d)、(e)、(g)、(h)由仿真方案 1 得到。附录 C 图 C1(a)、(d)、(g)中的局部放大图展示了火点集中高发区域的

风险等级预测结果，该区域火点附近的预测等级为高风险、较高风险等级，其余区域风险等级较低，说明模型能有效拟合各影响因子与实际火点间的映射关系，同时该区域的 SPEI 较低，表明其受干旱影响，山火发生次数明显增多。附录 C 图 C1(b)、(e)、(h)中的局部放大图为相同区域但 SPEI 较高时的火点分布及预测结果，其值较高表明该区域为潮湿天气，此时该区域几乎没有火点分布，风险等级预测结果较低。根据仿真方案 2 设置，将气象干旱指数 SPEI 从 Res-TCN 的输入变量中剔除，选取与附录 C 图 C1(a)、(d)、(g)相同日期的样本进行对比消融实验的可视化展示，评估 SPEI 对预测性能的影响，结果如附录 C 图 C1(c)、(f)、(i)所示。在缺失 SPEI 的情况下，网络模型在火点集中高发区域的风险等级预测结果与实际火点情况存在明显偏差，对高风险区域识别能力下降，整体预测结果趋于保守。同时，结合图 4 的预测验证指标对比结果可知，气象干旱指数与火点之间呈现一定相关性，其与短期气象要素形成互补，有助于模型更全面地感知山火风险的潜在可能，将其作为输入能在一定程度上提高预测准确率。

以测试集中某日加州部分区域的输电线路为例，如附录 A 图 A4 所示，其中背景地形来自开源地图网站[35]。根据仿真方案 1 对该区域进行日前山火风险等级预测，将次日火点、输电线路空间分布与模型预测的风险等级结果通过二维平面图叠加，根据可视化展示发现火点附近的输电线路山火风险预测等级较高，而水源附近和远离火点的预测等级较低，表明本文方法能较为有效预测线路走廊附近区域的山火发生风险，所生成的输电线路山火风险等级分布图可运用于输电线路等电力设施风险预警等实际场景，指导有关部门开展电网山火防治工作，降低山火导致线路跳闸的概率。

为进一步加强本文方法的可解释性，选用基于博弈论构建的沙普利加性解释算法(shapley additive explanations, SHAP)[36]衡量测试集中旱季样本的输入变量 14 种影响因子对网络模型预测结果的边际贡献度，如附录 B 图 B2 所示。由于输电线路山火预测为二分类任务，模型输出表示山火发生概率，故 SHAP 值为正值时表示当前输入变量的取值推动该样本的预测结果向标签 1 靠近，即更倾向于山火发生，负值则反之。SHAP 值绝对值越大，表示此变量对该样本预测结果的影响程度越显著，图例则表示各影响因子经归一化后的标幺值大小。从图中可直观发现，不同变量的 SHAP 值分布具有一定差异，反映各变量在模型预测任务中的相对重要性。其中，SPEI、NDVI、土地类型、风速、露点等变量对预测结果影响较大。当露点、SPEI 较小而温度较高时，普遍对应 SHAP 值正向，表明当前变量取值促使预测结果接近山火发生，与天气较为干燥、相对湿度较低易引发山火的实际情况吻合；NDVI 值较大时大部分分布在 SHAP 值大于 0 的区间，意味植被状况越佳，为山火发生提供可燃物，同时也有少部分分布于小于 0 区间，可能对应区域为水体或林地附近使得植被及土壤具备一定含水量，反而减弱山火发生的可能；高程较大值主要位于 SHAP 值小于 0 部分，说明对应区域的海拔较高，常伴随温度降低的情况，从而影响山火发生；土地类型变量的较小值多处于 SHAP 值大于 0 部分，对应常绿针叶林、阔叶林等森林区域，其易在相应条件下点燃，导致山火风险增加；人口密度高值可能对应城镇中心，对用火行为管控更为严格，减少火源暴露；因选取为旱季的样本，降水量贡献程度较小；结合输电线路所在区域的天气、土地类型与植被管理程度，不同输电线路电压等级对山火的发生具有一定影响。此外，每个变量的纵向形状具有一定宽度，表明多源数据集中分布较为广泛，涵盖多种不同变量的组合情况，有利于增强模型泛化性。因此 SHAP 算法能够增加预测结果的透明度，一定程度上量化输入与山火的相关性，为电网安全运行管理提供更直观的决策辅助，同时也需结合当地实际情况与天气状况进行具体分析，不能仅依赖于单一因素。

4 结论

本文提出一种基于 Res-TCN 的输电线路山火预测方法，通过仿真得到以下结论：

1）引入气象干旱指数与输电线路空间分布特征等变量，基于重采样技术搭建涵盖卫星遥感、气象再分析等类型的开源数据集框架，具有较强的拓展性，便于后续研究进一步添加其余潜在影响因子。

2）Res-TCN 深度学习算法能够实现日前输电线路山火预测，为电力系统的安全调度优化与灭火装备提前部署等灾害预防措施提供参考依据。

3）根据时序匹配与空间对齐，设计包括气象要素、植被状况、干旱指数、人类活动、地形特征、输电线路等数据的五维张量输入结构，利用二维分

组卷积设计多层残差单元与 TCN 处理多源数据的时空相关性，加强模型可解释性的同时，提高对山火时空特征的感知能力，拟合输入特征与输出标签的高维非线性关系，通过多项指标对比说明所提方法具有一定优势性，为输电线路山火预测建模提供新思路。

综上，本文所提出的输电线路山火预测方法具有较高的准确度，能够一定程度上满足电网提前预警山火的需求，具备工程应用前景。

附录见本刊网络版(http://hve.epri.sgcc.com.cn)。

参考文献 References

[1] 叶 林，裴 铭，杨建宾，等. 极端天气下的新能源电力系统电力电量平衡体系[J]. 电力系统自动化，2025，49(4)：2-18.
YE Lin, PEI Ming, YANG Jianbin, et al. Electric power and energy balancing system for power system with renewable energy in extreme weather[J]. Automation of Electric Power Systems, 2025, 49(4): 2-18.

[2] VITOLO C, DI GIUSEPPE F, BARNARD C, et al. ERA5-based global meteorological wildfire danger maps[J]. Scientific Data, 2020, 7(1): 216.

[3] WANG Z C, WARA M, MAJUMDAR A, et al. Local and utility-wide cost allocations for a more equitable wildfire-resilient distribution grid[J]. Nature Energy, 2023, 8(10): 1097-1108.

[4] 殷浩洋，刘 东. 山火灾害下电网安全形态的事件驱动模型与动态推演方法[J]. 中国电机工程学报，2024，44(20)：7911-7924.
YIN Haoyang, LIU Dong. Event-driven model and dynamic deduction method of security morphological of power system under wildfires[J]. Proceedings of the CSEE, 2024, 44(20): 7911-7924.

[5] 国家能源局. 国家能源局综合司关于做好电力设施森林草原火灾防范应对工作的通知[EB/OL].[2025-04-14]. https://www. nea. gov. cn/2024-02/28/c_1310765730. htm.
National Energy Administration. Notice of the comprehensive department of the National Energy Administration on doing a good job in preventing and responding to forest and grassland fires in electric power facilities[EB/OL]. [2025-04-14]. https://www.nea.gov. cn/2024-02/28/c_1310765730. htm.

[6] 周特军，吴传平，陈海翔，等. 湖南电网输电线路山火跳闸时空分布规律[J]. 消防科学与技术，2019，38(3)：417-420.
ZHOU Tejun, WU Chuanping, CHEN Haixiang, et al. Temporal and spatial distribution laws of transmission line trips caused by wildfire for Hunan power grid[J]. Fire Science and Technology, 2019, 38(3): 417-420.

[7] VAZQUEZ D A Z, QIU F, FAN N, et al. Wildfire mitigation plans in power systems: a literature review[J]. IEEE Transactions on Power Systems, 2022, 37(5): 3540-3551.

[8] 杨淳岚，宁 鑫，徐会凯，等. 电网山火监测及风险预警技术研究综述[J]. 电网技术，2023，47(11)：4765-4777.
YANG Chunlan, NING Xin, XU Huikai, et al. Overview of mountain fire monitoring and early warning for power grid demand[J]. Power System Technology, 2023, 47(11): 4765-4777.

[9] 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)：2561-2569.
ZHOU You, SUI Sanyi, CHEN Jie, et al. Monitor and alarm technology of wildfire occurrences in transmission lines corridors based on Himawari-8 geostationary meteorological satellite[J]. High Voltage Engineering, 2020, 46(7): 2561-2569.

[10] 陆佳政，周特军，吴传平，等. 某省级电网 220 kV 及以上输电线路故障统计与分析[J]. 高电压技术，2016，42(1)：200-207.
LU Jiazheng, ZHOU Tejun, WU Chuanping, et al. Fault statistics and analysis of 220 kV and above power transmission line in province-level power grid[J]. High Voltage Engineering, 2016, 42(1): 200-207.

[11] 高 超，林红蕾，胡海清，等. 我国林火发生预测模型研究进展[J]. 应用生态学报，2020，31(9)：3227-3240.
GAO Chao, LIN Honglei, HU Haiqing, et al. A review of models of forest fire occurrence prediction in China[J]. Chinese Journal of Applied Ecology, 2020, 31(9): 3227-3240.

[12] JAIN P, COOGAN S C P, SUBRAMANIAN S G, et al. A review of machine learning applications in wildfire science and management[J]. Environmental Reviews, 2020, 28(4): 478-505.

[13] BRYS C, LA RED MARTÍNEZ D L, MARINELLI M, et al. Machine learning methods for wildfire risk assessment[J]. Earth Science Informatics, 2025, 18(1): 148.

[14] 岳 超，罗彩访，舒立福，等. 全球变化背景下野火研究进展[J]. 生态学报，2020，40(2)：385-401.
YUE Chao, LUO Caifang, SHU Lifu, et al. A review on wildfire studies in the context of global change[J]. Acta Ecologica Sinica, 2020, 40(2): 385-401.

[15] 郭福涛，胡海清，马志海，等. 不同模型对拟合大兴安岭林火发生与气象因素关系的适用性[J]. 应用生态学报，2010，21(1)：159-164.
GUO Futao, HU Haiqing, MA Zhihai, et al. Applicability of different models in simulating the relationships between forest fire occurrence and weather factors in Daxing'an Mountains[J]. Chinese Journal of Applied Ecology, 2010, 21(1): 159-164.

[16] 陆佳政，刘 毓，徐勋建，等. 架空输电线路山火预测预警技术[J]. 高电压技术，2017，43(1)：314-320.
LU Jiazheng, LIU Yu, XU Xunjian, et al. Prediction and early warning technology of wildfire nearby overhead transmission lines[J]. High Voltage Engineering, 2017, 43(1): 314-320.

[17] 周恩泽，黄 勇，陈 洁，等. 基于图模型的架空输电线路山火风险等级预测模型[J]. 南方电网技术，2020，14(4)：8-16.
ZHOU Enze, HUANG Yong, CHEN Jie, et al. Graph theory based fire risk prediction level model of overhead transmission lines[J]. Southern Power System Technology, 2020, 14(4): 8-16.

[18] 周恩泽，黄 勇，向 谆，等. 基于物元可拓的输电线路山火风险评估模型[J]. 南方电网技术，2022，16(1)：145-154.
ZHOU Enze, HUANG Yong, XIANG Zhun, et al. Evaluation model of wildfire risk in transmission lines based on matter-element extension[J]. Southern Power System Technology, 2022, 16(1): 145-154.

[19] DI GIUSEPPE F, MCNORTON J, LOMBARDI A, et al. Global data-driven prediction of fire activity[J]. Nature Communications, 2025, 16(1): 2918.

[20] 刘 晖，向 谆，周恩泽，等. 基于动态贝叶斯网络的输电走廊山火风险时空评估[J]. 南方电网技术，2023，17(11)：148-158.
LIU Hui, XIANG Zhun, ZHOU Enze, et al. Temporal and spatial assessment of wildfire risk in transmission line corridors based on dynamic Bayesian networks[J]. Southern Power System Technology, 2023, 17(11): 148-158.

[21] LE H V, HOANG D A, TRAN C T, et al. A new approach of deep neural computing for spatial prediction of wildfire danger at tropical climate areas[J]. Ecological Informatics, 2021, 63: 101300.

[22] ZHANG G L, WANG M, LIU K. Deep neural networks for global wildfire susceptibility modelling[J]. Ecological Indicators, 2021, 127:

107735.

[23] BERGADO J R, PERSELLO C, REINKE K, et al. Predicting wildfire burns from big geodata using deep learning[J]. Safety Science, 2021, 140: 105276.

[24] BHOWMIK R T, JUNG Y S, AGUILERA J A, et al. A multi-modal wildfire prediction and early-warning system based on a novel machine learning framework[J]. Journal of Environmental Management, 2023, 341: 117908.

[25] 黎 博，杜尔顺，蔡兆丰，等. 计及电力气象的“源-网-荷”影响评估与电力系统规划方法综述[J/OL]. 中国电机工程学报，2025：1-23[2025-06-24]. http://kns.cnki.net/kcms/detail/11.2107.tm. 20250517.1634.004. html.
LI Bo, DU Ershun, CAI Zhaofeng, et al. A review of power system planning method and impact assessment of ‘source-grid-load’ integrating electric meteorology[J/OL]. Proceedings of the CSEE, 2025: 1-23[2025-06-24]. http: //kns. cnki. net/kcms/detail/11.2107. tm. 20250517.1634.004. html.

[26] WU Z F, SHEN C H, VAN DEN HENGEL A. Wider or deeper: revisiting the ResNet model for visual recognition[J]. Pattern Recognition, 2019, 90: 119-133.

[27] LIMOUNI T, YAAGOUBI R, BOUZIANE K, et al. Accurate one step and multistep forecasting of very short-term PV power using LSTM-TCN model[J]. Renewable Energy, 2023, 205: 1010-1024.

[28] EDDIN M H S, ROSCHER R, GALL J. Location-aware adaptive normalization: a deep learning approach for wildfire danger forecasting[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 4703018.

[29] ECMWF. ECMWF reanalysis v5 (ERA5)[EB/OL].[2025-04-14]. https://www.ecmwf. int/en/forecasts/dataset/ecmwf-reanalysis-v5.

[30] NASA. LP DAAC[EB/OL].[2025-04-14]. https://lpdaac.usgs.gov/data/get-started-data/.

[31] LIU X B, YU S Y, YANG Z W, et al. The first global multi-timescale daily SPEI dataset from 1982 to 2021[J]. Scientific Data, 2024, 11(1): 223.

[32] WorldPop. Open spatial demographic data and research[EB/OL]. [2025-04-14]. https://hub.worldpop. org/.

[33] CEC. California electric transmission lines[EB/OL].[2025-04-14]. https://cecgis-caenergy. opendata. arcgis. com/datasets/CAEnergy::california-electric-transmission-lines-1/about.

[34] AKIBA T, SANO S, YANASE T, et al. Optuna: a next-generation hyperparameter optimization framework[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage, USA: Association for Computing Machinery, 2019: 2623-2631.

[35] OSMF. OpenStreetMap[EB/OL]. [2025-07-21]. https://www.openstreetmap. org.

[36] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc., 2017: 4768-4777.



朱陈政翰
2001—，男，博士生
主要从事人工智能在电力系统的应用等研究工作
E-mail: yzlz0102@163.com

ZHU Chenzhenghan
Ph.D. candidate



孙英云(通信作者)
1975—，男，博士，教授，博导
主要从事人工智能在电力系统的应用等研究工作
E-mail: sunyy@ncepu.edu.cn

SUN Yingyun
Ph.D., Professor
Corresponding author

收稿日期 2025-04-28 在线出版日期 2025-08-22 编辑 陈 蔓

附录 A

表 A1　SPEI 分级与对应天气状况

Table A1　SPEI classification and corresponding weather conditions

取值范围	天气状况
SPEI≥2.0	极端潮湿
1.5≤SPEI<2.0	重度潮湿
1.0≤SPEI<1.5	中度潮湿
0.5<SPEI<1.0	轻度潮湿
−0.5≤SPEI≤0.5	正常
−1.0<SPEI<−0.5	轻度干旱
−1.5<SPEI≤−1.0	中度干旱
−2.0<SPEI≤−1.5	重度干旱
SPEI≤−2.0	极端干旱

表 A2　多源数据对应的重采样方法

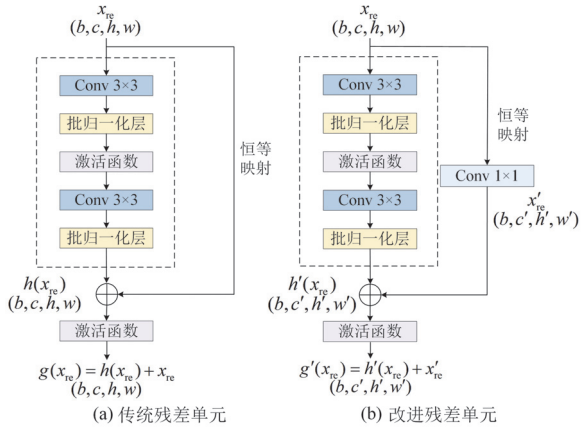
Table A2　Resampling methods corresponding to multi-source data

类型	因子	重采样策略	重采样方法
气象要素	2 m 温度 2 m 露点 降水量 10 m u 风速 10 m v 风速	上采样	双线性插值
植被状况	NDVI	下采样	平均池化
干旱指数	SPEI	上采样	双线性插值
人类活动	人口密度 距道路距离 距水路距离	下采样	平均池化
地形特征	高程	下采样	平均池化
	土地类型	下采样	最频值

表 A3　混淆矩阵

Table A3　Confusion matrix

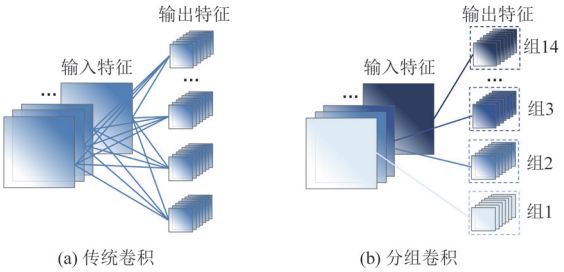
真实情况\模型预测	预测有火(正类)	预测无火(负类)
实际有火(正类)	真有火(E_{tp})	假无火(E_{fn})
实际无火(负类)	假有火(E_{fp})	真无火(E_{tn})



(a) 传统残差单元　(b) 改进残差单元

图 A1　传统残差单元与改进残差单元对比

Fig.A1　Comparison between conventional residual units and improved residual units



(a) 传统卷积　(b) 分组卷积

图 A2　传统卷积与分组卷积对比

Fig.A2　Comparison between conventional convolution and group convolution

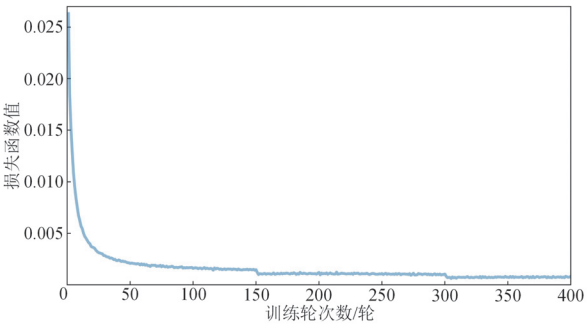


图 A3　模型损失函数

Fig.A3　Loss function of the model



图 A4　输电线路山火预测风险等级分布图

Fig.A4　Risk level distribution map of wildfire prediction for transmission lines

附录 B

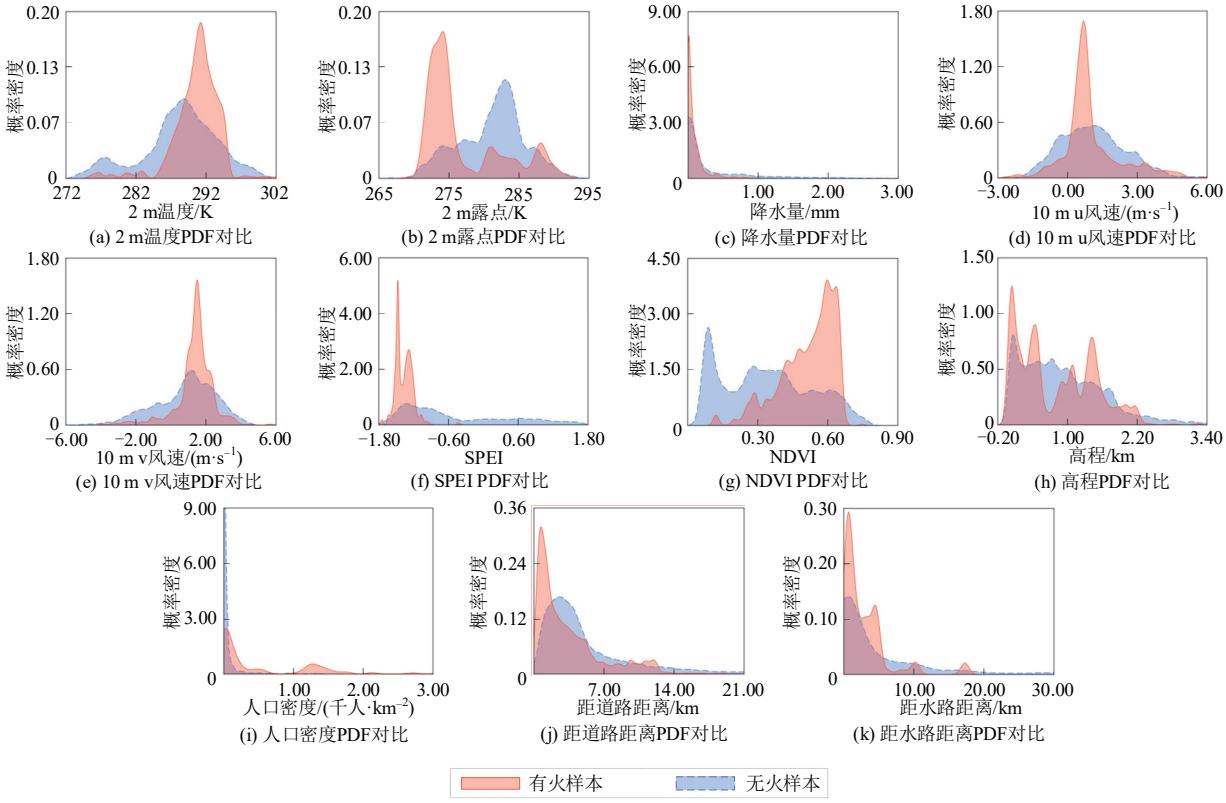


图 B1　影响因子 PDF 对比图

Fig.B1　Comparison plots of PDF for influence factors

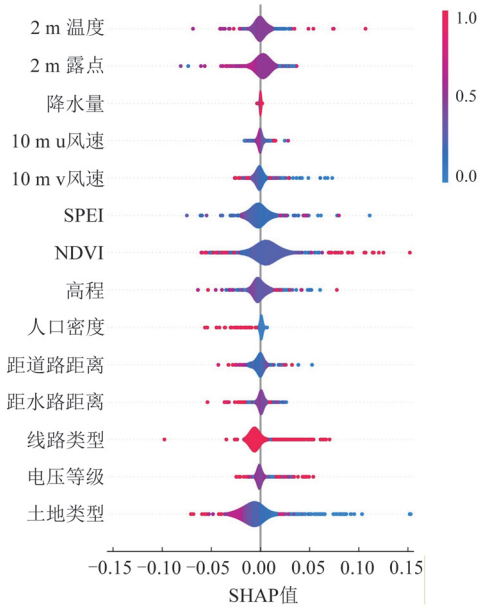


图 B2　影响因子 SHAP 值分布图

Fig.B2　Distribution plot of SHAP values for influence factors

附录 C

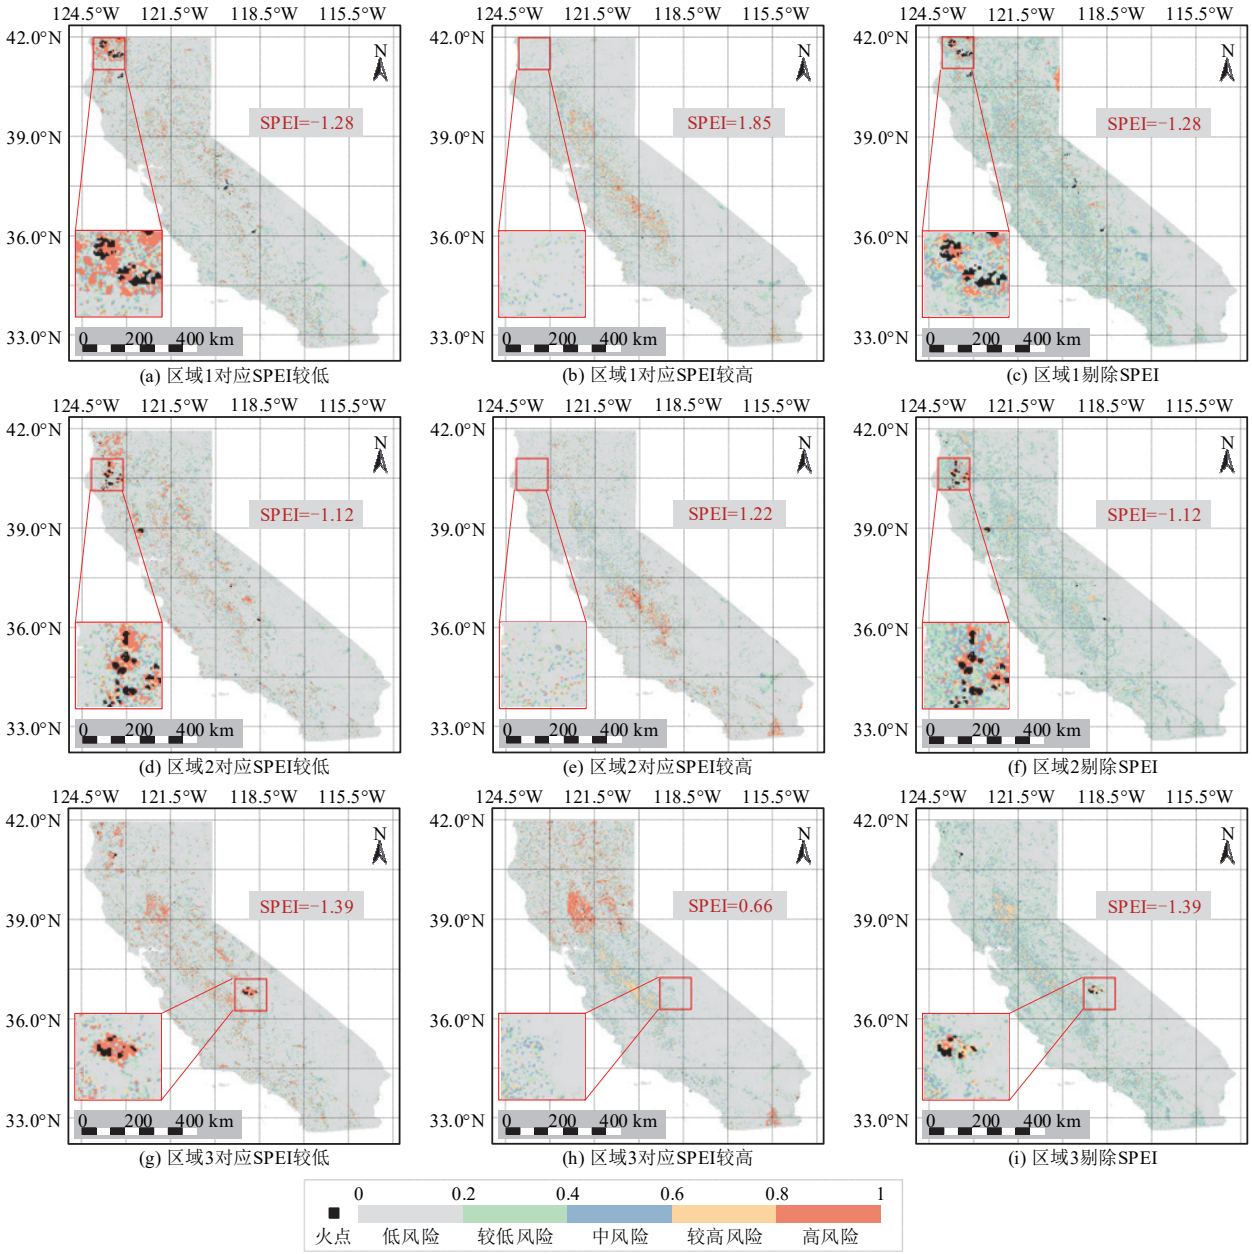


图 C1　不同 SPEI 下的山火预测风险等级分布图与消融对比结果

Fig.C1　Risk level distribution maps of wildfire prediction under different SPEI conditions and ablation comparison results