

DOI: 10.19783/j.cnki.pspc.250046

基于先验知识与孪生网络监督的输电线路山火跳闸预测模型

谢从珍, 周晓静, 余松, 莫子扬, 黄梦成, 蓝子毅

(华南理工大学电力学院, 广东 广州 510641)

摘要: 准确有效地预测输电线路山火跳闸事件对电网安全运行至关重要。但历史跳闸数据存在小样本不平衡问题, 使得机器学习模型易将跳闸事件误分类为正常, 影响预测准确性。为缓解传统样本不平衡方法中信息噪声引发的模型坍塌风险, 提出了一种基于先验知识与孪生网络监督的山火跳闸预测模型。首先, 在原始跳闸数据集的基础上, 基于多元概率统计方法确定生成虚拟样本的数量, 缓解小样本不平衡问题。其次, 基于先验知识约束的生成式过采样法生成虚拟正样本, 以修正数据集正样本分布。然后, 采用孪生网络模型筛选虚拟样本, 使虚拟正样本具备与真实数据相匹配的特征。最后, 将支持向量机(support vector machine, SVM)作为二分类模型对山火条件下线路跳闸进行预测。通过高质量、低需求的数据生成, 预测模型召回率相比于常规方法最大可提升 31.94%, 有效提高了实际工程环境下山火跳闸事件的预测效果。

关键词: 山火; 跳闸; 样本生成; 不平衡数据; 数据驱动

Wildfire-induced transmission line trip prediction model based on prior knowledge and Siamese network supervision

XIE Congzhen, ZHOU Xiaojing, YU Song, MO Ziyang, HUANG Mengcheng, LAN Ziyi

(School of Electrical Power, South China University of Technology, Guangzhou 510641, China)

Abstract: Accurately and effectively predicting wildfire-induced transmission line trip events is crucial for the safe operation of power grids. However, historical tripping data suffer from small sample imbalance, which makes machine learning models prone to misclassifying trip events as normal, thereby reducing prediction accuracy. To mitigate the risk of model collapse caused by informational noise in traditional sample imbalance handling methods, this paper proposes a wildfire-induced transmission line trip prediction model based on prior knowledge and Siamese network supervision. First, based on the original trip dataset, a multivariate probability statistical method is used to determine the number of virtual samples to be generated, thereby alleviating the small sample imbalance issue. Second, a generative oversampling method constrained by prior knowledge is applied to generate virtual positive samples and correct the distribution of positive samples in the dataset. Then, a Siamese network model filters the virtual samples, ensuring that generated positive samples match the characteristics of real data. Finally, a support vector machine (SVM) is employed as a binary classifier to predict line trips under wildfire conditions. Through high-quality and low-demand data generation, the proposed model improves the recall rate by up to 31.94% compared to conventional methods, effectively enhancing the prediction performance of wildfire-induced trip events in practical engineering environments.

This work is supported by the National Natural Science Foundation of China (No. 51977084).

Key words: wildfire; trip; sample generation; imbalanced data; data-driven

0 引言

输电线路常跨越崎岖山区, 复杂的地理环境使

得附近地区火灾风险显著提升。山火通过产生高温气体、烟雾颗粒物等^[1-3]致使空气绝缘性能下降而引发跳闸。精准预测山火跳闸对电网安全运行意义重大。

现阶段已建立起算法先进、装备完善的山火监测预警技术体系^[4-6], 便于山火发生后应急响应。文

基金项目: 国家自然科学基金项目资助(51977084); 国家电网有限责任公司科技项目资助(SGNC0000DKJS2210093)

献[7]提出一种基于 mesh 网络的输电线路山火预警监视系统, 经挂网测试, 该系统可准确探测并传输火灾信息。输电线路在山火发生后可能出现跳闸故障, 进而引发大规模停电, 甚至可能对公共安全和经济活动造成长远影响。因此, 亟需进一步研究如何有效预测和防范山火后诱发的线路跳闸事件, 以避免带来严重后果。

现阶段对于山火跳闸的研究主要从机理层面展开。文献[8]量化计算了 4 种因子对山火跳闸综合概率的贡献。文献[9]考虑不同火焰燃烧情况下间隙绝缘的下降程度评估山火跳闸风险。文献[10]开发了组合线路中断概率(combined line outage probability, CLOP)模型。山火诱发输电线路跳闸是一个复杂的过程, 基于机理分析的模型大部分是在理想状况之下或者对某些复杂条件进行简化构建而成, 难免存在一定的局限性。近年来, 人工智能技术成为故障诊断领域的研究热点^[11], 电网在线监测技术的发展为山火跳闸概率智能模型研究工作提供丰富、可靠的数据来源^[12], 解决传统研究方法的复杂性与主观性问题。

然而, 山火跳闸等电力故障属于小概率事件, 在历史数据库中占比较低^[11], 导致数据集正负样本极不平衡, 分类器往往倾向于将样本划分为高概率的正常类别。同时, 传统机器学习与深度学习均对样本数量要求较高^[13-14], 在实际小样本条件下对故障风险计算时常常受限。部分学者采用迁移学习策略以缓解小样本及数据不平衡问题, 但该方法仍依赖于大规模源域样本数据^[15], 实际工程中往往无法满足。文献[16]基于孪生神经网络对柱塞泵小样本进行故障诊断, 通过相似度对比的方法扩大训练样本数量, 使不同状态数据具有较好的可分性; 因其在小样本条件下的优势, 孪生网络模型亦可用于对生成样本的质量筛选^[17]。文献[18]分析输电线路在山火条件下间隙电场畸变特性, 所得气象因子与跳闸风险的相关性规律可作为先验知识, 提高小样本条件下的模型泛化能力。现有虚拟样本生成方法包括合成少数类过采样技术(synthetic minority over-sampling technique, SMOTE)^[19-20]、生成对抗网络(generative adversarial network, GAN)^[21-22]、自适应合成采样方法(adaptive synthetic sampling approach, ADASYN)^[23]等, 通常使正样本增加至与负样本数量相同, 在改善数据集不平衡问题的同时不可避免地引入了噪声样本, 这些样本的特征可能与真实情况不符, 从而干扰模型的判断, 影响其准确识别能力。而目前确定虚拟样本数量的研究较少, 文献[24]基于信息熵理论与概率统计模型确定虚拟样本最优

生成数量, 但其仅考虑了样本的一维特征, 数学推导路径值得进一步探讨。

因此, 本文为降低上述样本生成方法中因无效数据信息而导致模型坍塌的风险, 提出了一种先验知识约束与孪生网络监督的输电线路山火跳闸预测模型。首先基于多元概率统计方法确定噪声容许限额下的最大样本数量, 构建次平衡训练集。在该数据集上考虑山火诱发特征因子存在的先验单调信息, 提出一种约束型生成式过采样算法, 将特征的排序不一致率差值作为损失函数优化对象, 促使模型符合单调性约束, 减小无效样本对预测模型性能的影响。此外, 利用嵌入原始样本信息的孪生网络进一步筛选上述生成样本, 从而获取与原始样本信息相匹配的生成样本空间。为论证本文方法的有效性与普适性, 分别在不同不平衡率、不同二分类模型下对山火致线路跳闸的预测效果进行对比分析。

1 模型建立

1.1 山火诱发线路跳闸关键因素提取

山火燃烧过程伴随的高温、烟雾和高浓度离子会降低空气击穿电压, 影响输电线路周围空气的绝缘性能, 可能导致线路对地发生击穿。为探究山火与线路跳闸的关联性, 须提取山火致线路跳闸的关键因素。

气象与植被作为客观的自然地理条件, 对山火爆发与蔓延、线路间隙粒子运动规律有较大影响^[25-26]。对山火致线路跳闸相关气象因子与植被因子进行数据提取, 气象因子包括实时降雨量、风速、气温、相对湿度等, 植被因子包括植被覆盖度、叶面积指数、植被类型等。线路参数和人类活动分别作为主要的物理因素和社会因素^[27-28], 同样对山火引发线路跳闸起重要作用。线路参数包括导线高度和电压等级, 人类活动因素则用区域人口密度表征。具体选取的指标信息见表 1。本节所述气象因子和植被因子数据来源于 WheatA 农业大数据系统, 人口数据来源于中国统计年鉴, 线路参数与输电线路山火跳闸历史数据来自某区域电网公司。在山火高发区域, 短时多次跳闸风险相应增高, 统计灾害情况如图 1 所示。

1.2 虚拟山火跳闸样本生成

1.2.1 虚拟样本生成数量确定

在生成虚拟样本前, 需首先确定用于模型训练的虚拟样本生成数量。多元概率统计(multivariate probability statistical, MPS)方法研究多个变量之间的统计规律性, 可用于确定虚拟样本生成数量。记原始少数类样本个数为 n_1 , 虚拟样本生成个数为 n_2 。

表 1 山火致线路跳闸影响因子

Table 1 Wildfire-induced line tripping impact factors

气象因子		植被因子	
温度	高层植被覆盖度	不同深度的土壤	温度(四层)
相对湿度	低层植被覆盖度	不同深度的土壤	水分量(四层)
风速	高层植被覆盖叶面积指数	高植被类型	
降水	低层植被覆盖叶面积指数	低植被类型	
地表温度	线路参数	人类活动	
日照辐射	导线高度	人口密度	
土壤湿度	电压等级	—	

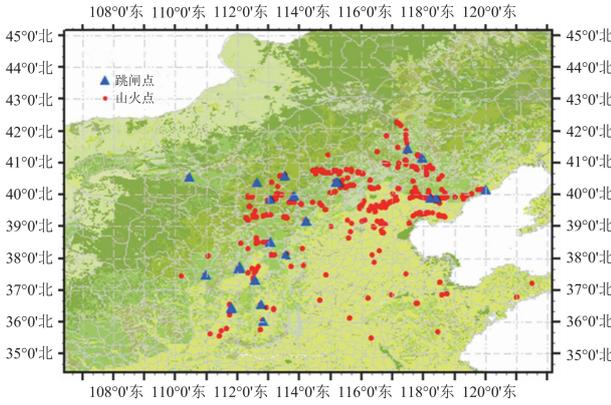


图 1 某区域输电线路山火发生情况统计

Fig. 1 Statistics on the occurrence of wildfires on transmission lines in a certain region

假设所有虚拟样本是相互独立的随机变量，且服从均值为 μ 、方差为 σ 的同一分布。要求新生成的虚拟样本分布与原始样本尽可能一致，故将第 p 维特征的均值 μ_0^p 、方差 σ_0^p 取为原始少数类样本的均值、方差估计值。对于样本特征空间中的第 p 维特征，若要求 n_2 个虚拟样本带来的噪声小于原始样本噪声置信水平的95%，即虚拟样本第 p 维产生总噪声小于 $n_1\mu_0^p$ 的概率 P 大于95%，即

$$P\left\{\sum_{i=1}^{n_2} X_i^p < n_1\mu_0^p\right\} > 0.95 \quad (1)$$

式中： X_i^p 为第 i 个虚拟样本的第 p 维特征。以上讨论了在第 p 维特征下噪声对虚拟样本数量的约束。除此之外，样本其他特征维度下需满足形如式(1)的约束。由中心极限定理及相关推导^[27]，虚拟样本 n_2 生成个数需满足式(2)。

$$n_2 = \left\lceil \min_{i=1,2,\dots,t} \left(\frac{-1.645\sigma_0^i + \sqrt{2.706(\sigma_0^i)^2 + 4\mu_0^i \cdot n_1\mu_0^i}}{2\mu_0^i} \right)^2 \right\rceil \quad (2)$$

式中： t 表示样本特征维度总个数； $\lfloor \cdot \rfloor$ 为向下取整符号，表示小于或等于该数字的最大整数。

1.2.2 基于过采样技术的初始虚拟样本生成

在确定虚拟样本生成数量后，采用过采样技术生成虚拟样本。本文研究区域原始数据集共有1132条山火记录，其中有54条引发输电线路跳闸。故障发生为小概率事件，故“山火不跳闸”与“山火致跳闸”存在较严重的小样本不平衡问题。山火跳闸与否的预测是个二分类问题，若采取传统机器学习模型进行二分类任务，即使模型将所有样本均预测为负样本，仍可达到约95.4%的准确率，但此时查全率为0，故须采取策略解决数据不平衡问题。

在有关生成对抗网络的研究中，Wasserstein生成对抗网络(Wasserstein generative adversarial network, WGAN)^[29-31]作为一种重要的改进方法，旨在通过引入Wasserstein距离来提高生成模型的训练稳定性和样本质量。尽管WGAN在样本生成的多样性和质量方面有所提升，但在特定特征的生成能力上仍存在改进空间。文献[19]表明，降水量、相对湿度和风速的大小均与山火诱发输电线路跳闸风险呈负相关的单调性关系，可考虑在模型的设计阶段嵌入含先验规则的数值约束。

为量化特征 q 与标签值 Y 的单调性，文献[32]提出计算排序不一致率(rank inequality ratio, RIR)的差值 v_q 确定特征对标签正负值的单调性关系。首先计算向上的排序不一致率 S_{URIR} ，然后计算向下的排序不一致率 S_{DRIR} ，以二者差值 v_q 量化特征 q 与标签值 Y 单调性关联程度。当 $v_q \in (\delta, \infty)$ 时， q 与标签值是单调递减的； $v_q \in (-\infty, -\delta)$ 时， q 与标签值是单调递增的。

$$S_{URIR}(q, Y) = -\frac{1}{|U|} \sum_{u=1}^{|U|} \log_2 \frac{|[X_u^q]^{\geq}] \cdot |[Y_u]^{\leq}|}{|U| \cdot |[X_u^q]^{\geq} \cap [Y_u]^{\leq}|} \quad (3)$$

$$S_{DRIR}(q, Y) = -\frac{1}{|U|} \sum_{u=1}^{|U|} \log_2 \frac{|[X_u^q]^{\leq}] \cdot |[Y_u]^{\geq}|}{|U| \cdot |[X_u^q]^{\leq} \cap [Y_u]^{\geq}|} \quad (4)$$

$$v_q = S_{URIR}(q, Y) - S_{DRIR}(q, Y) \quad (5)$$

式中：“ $|\cdot|$ ”为集合的元素数量； U 为对象集； $[X_u^q]^{\geq}$ 为 U 中 q 的特征值大于等于 X_u^q 的元素集合； $[X_u^q]^{\leq}$ 为 U 中 q 的特征值小于等于 X_u^q 的元素集合； $[Y_u]^{\leq}$ 为 U 中标签值 Y 小于等于 Y_u 的元素集合。

为加入先验单调信息约束的同时综合WGAN的优点，本文提出了一种新的生成对抗网络变体——约束型生成式过采样(constrained Wasserstein GAN,

CWGAN)法, 该模型在 WGAN 的基础上, 增加了对生成样本的特征单调性约束, 即通过引入惩罚项使得生成正样本在第 q 维特征的数值尽量小, 从而最大化 v_q 。具体地, CWGAN 的生成器、判别器损失函数 L 分别被修正为

$$L_G = -E_{x \sim \zeta_z} [D(z)] + \sum_{i=1, q_i \in \Omega}^4 (\lambda_{q_i} E_{x \sim \zeta_z} [(z^{q_i})^2]) \quad (6)$$

$$L_D = -E_{x \sim \zeta_{\text{data}}} [D(x)] + E_{x \sim \zeta_z} [D(z)] \quad (7)$$

式中: z 为生成器生成的虚拟样本; Ω 为降水量、相对湿度、经向风速与纬向风速 4 个特征的维度空间; $D(x)$ 表示判别器对真实样本 x 的评分; z^{q_i} 表示生成的虚拟样本在 q_i 特征维度上的数值; λ_{q_i} 为调节系数, 取值为正, 用于平衡 Wasserstein 距离与生成样本在 Ω 的单调性数值约束; ζ_{data} 和 ζ_z 分别为真实数据分布和潜在空间分布; $E_{x \sim \zeta_{\text{data}}}$ 与 $E_{x \sim \zeta_z}$ 分别为 ζ_{data} 与 ζ_z 的数学期望。CWGAN 引入特征约束, 不仅增强了生成样本在特定特征维度上的表现能力, 还可兼顾生成样本的多样性与标签类别判定功能。

1.2.3 基于孪生网络模型的虚拟样本真实性检验

为在保持样本真实性的前提下改善小样本不平衡条件的模型泛化性能, 生成虚拟样本之后, 令山火跳闸正、负样本以样本对的方式训练孪生网络模型 (siamese networks, SN), 以校核虚拟样本的有效性。将样本两两组合为样本对 (如图 2), “相同” 标签的样本对组合为正样本对, “不同” 标签的样本组合为负样本对, 可使得数据集样本数量由 N 扩展为 N^2 。若定义含 N_{pos} 个少数类正样本、 N_{neg} 个多数类负样本的不平衡率 R 为

$$R = \frac{N_{\text{pos}}}{N_{\text{neg}}} < 1 \quad (8)$$

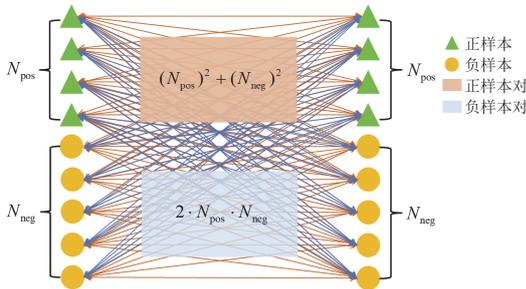


图 2 组成一次样本对后正负样本数量变化

Fig. 2 Change in the number of positive and negative samples after the composition of a sample pair

样本对形成前后, 不平衡率的数值变大, 更加接近于 1 (见式(9)), 可见样本对的方式能改善正负样本不平衡性。本文将对原始数据集样本进行一次样

本对构建, 训练孪生网络模型。

$$\frac{N_{\text{pos}}}{N_{\text{neg}}} < \frac{2 \cdot N_{\text{pos}} \cdot N_{\text{neg}}}{(N_{\text{pos}})^2 + (N_{\text{neg}})^2} < 1 \quad (9)$$

数据类不平衡情况在构建一次样本对后得到了缓解, 但仍然存在。为在不增加模型运算复杂度的同时, 减少因多数类别淹没少数类别造成的损失^[33], 采用焦点对比损失函数 L_f , 如式(10)所示。

$$L_f = \frac{1}{2n_{\text{pair}}} \sum_{j=1}^{n_{\text{pair}}} \beta \cdot y_j \cdot d_j^2 + (1 - \beta) \cdot (1 - y_j) \max(m - d_j^2, 0)^2 \quad (10)$$

式中: n_{pair} 为样本对数量; β 为样本规模系数 ($0 < \beta < 1$), 用以调制正负样本对在不同规模下的损失比例 (其取值将在后文讨论); y_j 为第 j 个样本对的真实标签; m 为边界值 (此处取值为 1); d_j 为第 j 个样本对经过孪生网络后输出值的欧氏距离, 计算公式为

$$d_j = \|\mathbf{o}_{j,1} - \mathbf{o}_{j,2}\| = \sqrt{\sum_{i=1}^t (\mathbf{o}_{j,1}^i - \mathbf{o}_{j,2}^i)^2} \quad (11)$$

式中: $\mathbf{o}_{j,1}$ 与 $\mathbf{o}_{j,2}$ 分别为第 j 个样本对中的两个样本经过孪生网络后的两个输出值。孪生网络通过损失函数使同类样本的欧氏距离小、异类样本的欧氏距离大。为判定虚拟正样本的实际标签值, 采用式(12)、式(13)分别计算其与训练集中正、负样本的孪生网络欧氏距离平均值。

$$\bar{d}_{\text{pos}} = \frac{1}{N_{\text{pos}}} \sum_{i=1}^{N_{\text{pos}}} \|\mathbf{o}_{\text{pos}}^{(i)} - \mathbf{o}_{\phi}\| \quad (12)$$

$$\bar{d}_{\text{neg}} = \frac{1}{N_{\text{neg}}} \sum_{i=1}^{N_{\text{neg}}} \|\mathbf{o}_{\text{neg}}^{(i)} - \mathbf{o}_{\phi}\| \quad (13)$$

式中: \mathbf{o}_{ϕ} 为虚拟正样本 ϕ 的特征值 X_{ϕ} 经过孪生网络后的输出值; $\mathbf{o}_{\text{pos}}^{(i)}$ 、 $\mathbf{o}_{\text{neg}}^{(i)}$ 分别为第 i 个正样本、第 i 个负样本经过孪生网络后的输出值。

若某一虚拟正样本 ϕ 与负样本的欧氏距离平均值 \bar{d}_{neg} 小于与正样本的欧氏距离平均值 \bar{d}_{pos} , 则认为该虚拟正样本是无效的。图 3 中, 样本分布位置在虚拟正样本筛选后发生改变; 部分边界类虚拟正样本被 SN 筛选剔除, 转而被新的虚拟正样本替代。

1.3 基于虚拟样本的山火跳闸预测模型

基于 1.2 节方法生成虚拟样本, 得到次平衡数据集, 用以训练山火跳闸预测模型。为探究模型在不同样本规模与类不平衡率下的性能, 以数据集中的 70% 作为训练集、30% 作为测试集, 用于评判模型效果。

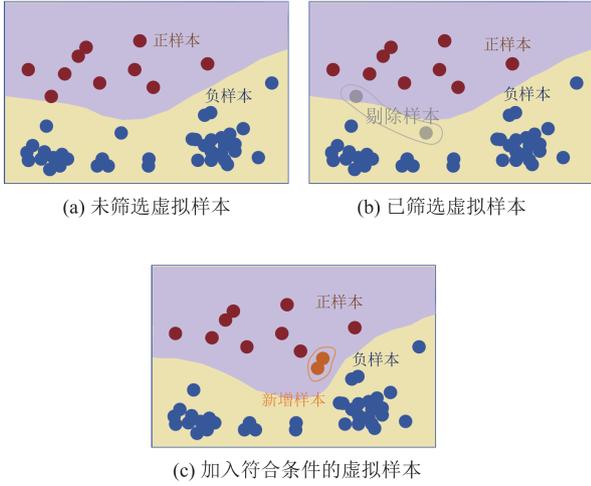


图3 样本筛选前后样本分布情况

Fig. 3 Sample distribution before and after filtering

二分类问题的常用分类指标是准确率、召回率、精确率和 F1-score。为更全面地考量不平衡小样本条件下的模型性能,模型评价时综合考虑 7 个指标,具体计算公式为

$$V_{acc} = \frac{T_p + F_N}{T_p + T_N + F_p + F_N} \quad (14)$$

$$V_{tpr} = \frac{T_p}{T_p + F_N} \quad (15)$$

$$V_{tnr} = \frac{T_N}{T_N + F_p} \quad (16)$$

$$V_{prec} = \frac{T_p}{T_p + F_p} \quad (17)$$

$$V_{Gmean} = \sqrt{V_{tpr} \cdot V_{tnr}} \quad (18)$$

$$V_{F1} = \frac{2 \cdot V_{tpr} \cdot V_{prec}}{V_{tpr} + V_{prec}} \quad (19)$$

$$V_{iba} = (1 + V_{tpr} - V_{tnr}) \cdot V_{tpr} \cdot V_{tnr} \quad (20)$$

式中: V_{acc} 表示模型正样本准确率; V_{tpr} 表示模型正样本召回率; V_{tnr} 表示模型负样本召回率; V_{prec} 表示模型正样本精确率; V_{Gmean} 表示模型正样本召回率与负样本召回率的几何平均; V_{F1} 表示模型正样本精确率与正样本召回率的调和平均; V_{iba} 表示模型正样本召回率与负样本召回率的综合指标; T_p (真正例) 表示模型正确预测为正例的样本数量; T_N (真负例) 表示模型正确预测为负例的样本数量; F_p (假正例) 表示模型错误预测为正例,但实际上是负例的样本数量; F_N (假负例) 表示模型错误预测为负例,但实际上是正例的样本数量。

采用 1.2 节所述方法生成虚拟样本、构建次平衡数据集后,进一步采取机器学习模型进行样本二分类。生成的 n_2 个虚拟样本能在减少噪声影响的前提下,通过有效增加样本数量改善模型的泛化性能。然而实际上可能无法获取足够多满足要求的虚拟样本。设置最大运行次数为 100, 预测模型总体流程图如图 4。

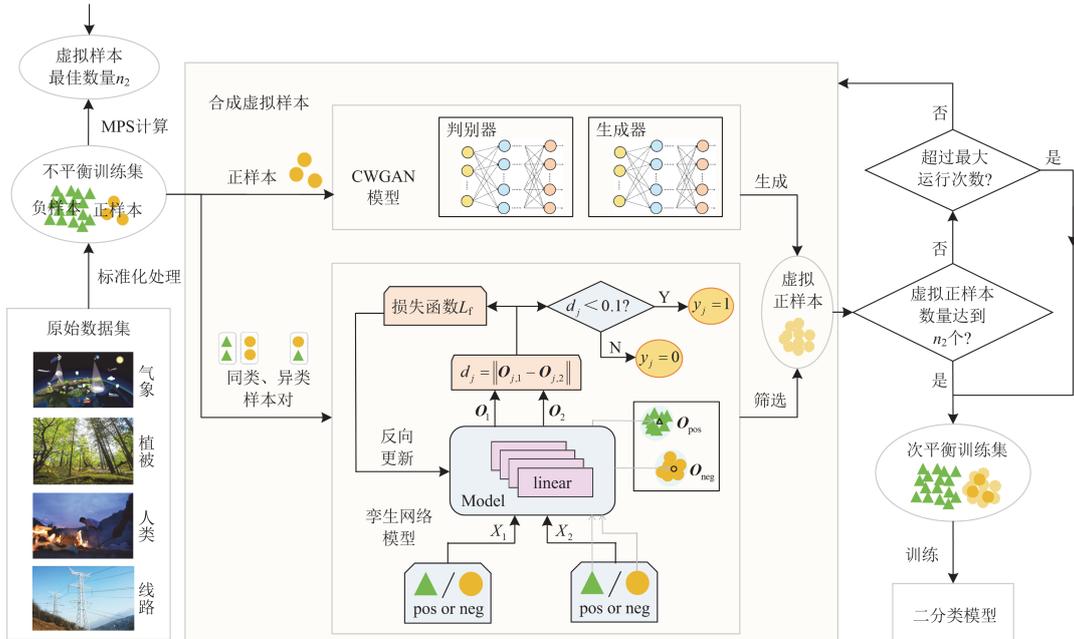


图4 山火致线路跳闸预测模型流程

Fig. 4 Flow of wildfire-induced transmission line trip prediction model

本文研究通过生成虚拟样本解决小样本类别不平衡问题, 因此分类器的选择对研究结果并不具有显著影响。后文将以 SVM 作为山火跳闸预测模型的基准分类器, 通过消融实验研究预测模型各部分对整体性能的贡献。此外, 为展现本文虚拟样本方法对各二分类模型的普适性, 将补充运用常见二分类模型: 逻辑回归(logistic regression, LR)、k 近邻(k-nearest neighbors, KNN)、梯度提升树(gradient boosting, GB)对结果进行分析讨论。

2 结果与讨论

本节首先确定孪生网络模型损失函数最佳权重因子, 以获得虚拟样本筛选的最优效果。然后分析虚拟样本生成质量与山火致跳闸预测模型性能。

2.1 模型参数选取

构建孪生网络模型须对参数进行寻优, 使其获得优良的筛选性能。真实正样本数据数量小于真实负样本数量, 故虚拟正样本与真实样本输入孪生网络模型后, 正样本对数量将小于负样本对数量。由于孪生网络模型用于少数类虚拟正样本检验, 旨在关注少数类虚拟正样本的真实性, 孪生网络模型评价须重点关注正样本对(少数类虚拟正样本与真实正样本形成的样本对)的召回率与精确率。

为了选择孪生网络模型中损失函数的样本规模系数 β , 在 0.1~0.35 之间对其数值进行测试, 并基于多种评价指标(召回率、精确率等)评估其性能。图 5 展示了不同 β 下各评价指标的变化曲线。观察可得, 在 β 为 0.24 时, 模型的整体性能最佳, 尤其

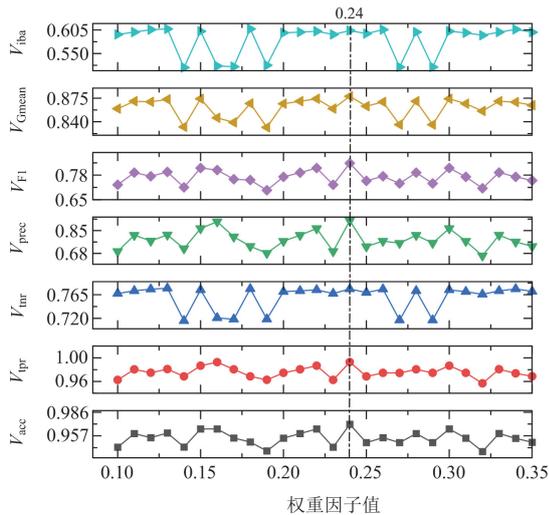


图 5 孪生网络损失函数最佳样本规模系数 β 选取

Fig. 5 Optimal sample size coefficient β selection of the loss function for the Siamese network

是在召回率和精确率之间达到了较好的平衡。因此, 最终确定将 β 设置为 0.24。在 β 为 0.24 的条件下训练孪生网络模型后, 性能评估结果如表 2 所示。具体而言, 模型正样本对的召回率达到了 99.29%, 负样本对的召回率为 77.61%, 而正样本对的精确率则为 92.34%。

表 2 孪生网络最佳样本规模系数 β 模型性能

Table 2 Siamese network model performance under optimal sample size coefficient β

V_{acc}	V_{tpr}	V_{tnr}	V_{prec}
0.9712	0.9929	0.7761	0.9234
V_{F1}	V_{Gmean}	V_{iba}	—
0.8433	0.8778	0.6035	—

2.2 虚拟样本生成效果

2.2.1 虚拟样本数量设置方法对比

本文基于 1.2 节所述 MPS 确定虚拟样本数量, 采取 CWGAN 算法获取虚拟样本, 建立次平衡数据集(sub-balanced datasets, SBD)。设置对比实验, 比较基于本文方法与原始不平衡数据集(imbalanced datasets, IBD)、绝对平衡数据集(absolute balanced datasets, ABD)、过平衡数据集(overfit balanced datasets, OBD)的分类模型效果。

其中, IBD 表示不采用虚拟样本生成方法, 直接采用原始不平衡数据集, 不平衡率 R 约为 19.96; ABD 表示生成虚拟少数类样本后, 正负样本数量 N_{pos} 、 N_{neg} 绝对均衡; OBD 表示生成虚拟少数类样本后, 原本为少数类的正样本数量 N_{pos} 大于负样本数量 N_{neg} 。本文 MPS 法生成的虚拟样本数量 n_2 见式(2), 各不平衡率下 n_2 取值见表 3, IBD、ABD、OBD 方法生成的虚拟样本数量分别设置为

$$n_2^{IBD} = 0 \quad (21)$$

$$n_2^{ABD} = N_{neg} - N_{pos} \quad (22)$$

$$n_2^{OBD} = 2(N_{neg} - N_{pos}) \quad (23)$$

表 3 本文方法在不同原始不平衡率下虚拟样本生成数量

Table 3 Number of virtual samples generated at different initial imbalance rates under the method proposed

负样本数量	原始不平衡率	n_2	扩充后不平衡率
54	1	12	0.8169
216	4	97	1.4282
432	8	243	1.4501
648	12	405	1.4103
864	16	575	1.3733
1080	20	750	1.3431

图 6 展现了模型在不同虚拟样本数量下的性能对比。观察到 SVM 分类器基于原始数据集难以学习到两类样本间的差异，且少数类正样本召回率较低，仅为 43.75%；ABD 与 OBD 加入虚拟样本改善了模型的查全性能，但同时引入了噪声，精确率仅为 54.17%与 56.52%， V_{F1} 相比基于本文 SBD 分别相差 10.75%与 12.42%。ABD 与 OBD 误分类样本数量接近，但 OBD 误分类样本更远离分类边界，原因在于 OBD 引入更多噪声致使正负类样本混淆。后续将综合采用更高质量的虚拟样本，以展现 SBD 在处理二分类问题上的优越性。

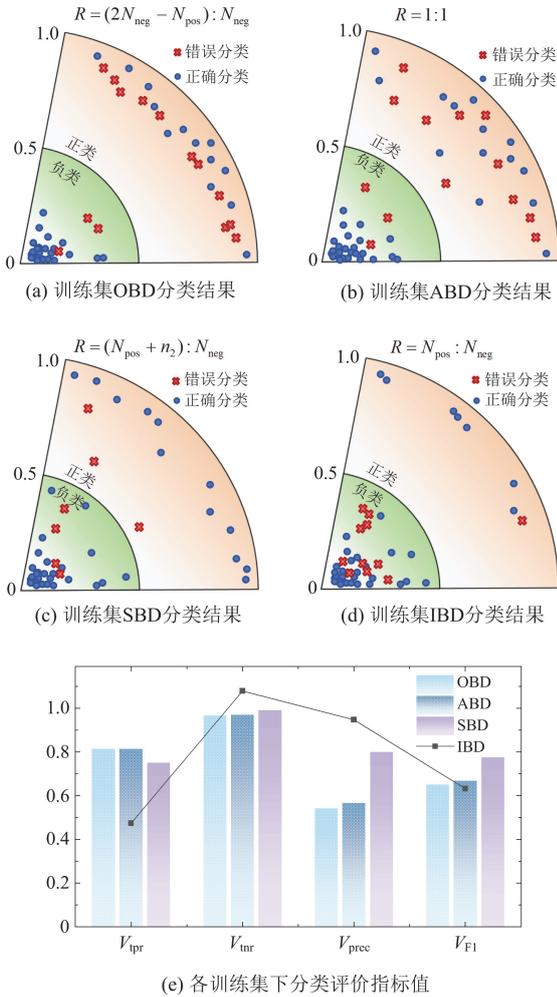


图 6 不同虚拟样本生成数量下 SVM 模型二分类效果
Fig. 6 Binary classification effect of SVM model under different generated numbers of virtual samples

2.2.2 常用虚拟样本生成算法对比

计算原始数据集(baseline)与采取各虚拟样本生成算法后数据集中正、负样本关于降水量、经向风速、纬向风速、相对湿度的上下排序不一致率差值，结果见表 4。其中，原始数据集正、负样本的上下

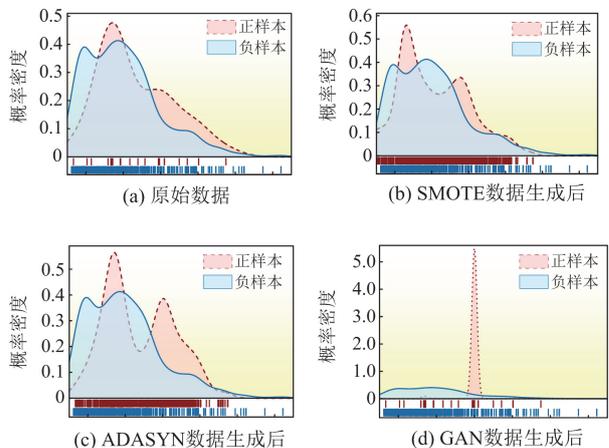
排序不一致率差值绝对值较小，特征样本分布情况与单调性先验知识存在略微差异，其原因在于正样本数据过少。可加入虚拟正样本使得正负样本分布情况满足先验单调性约束。

表 4 各数据分布情况下排序不一致率差值

Table 4 Sorting inconsistency rate interpolation in the case of each data distribution

数据生成算法	排序不一致率差值			
	降水量	经向风速	纬向风速	相对湿度
baseline	0.015 33	0.0410	-0.0397	0.0079
SMOTE	0.1074	0.4758	-0.4603	0.0968
ADASYN	0.0642	0.2082	-0.5197	0.2703
GAN	1.3914	-1.0726	-1.1813	-1.0764
WGAN	0.5213	0.4749	-0.4946	0.1573
CGAN	1.3914	-1.0726	0.8597	-1.0764
CWGAN	0.9882	0.4648	0.0329	0.1686
CWGAN-SN	0.9881	0.4650	0.0328	0.1680

以纬向风速为典型特征进行分析，数据概率密度分布情况如图 7。其原始数据排序不一致率差值为-0.0397，倾向于正相关，与先验信息相悖；但其绝对值较小，正负样本单调性特征较弱。SMOTE、ADASYN 算法在保持数据原本正、负样本单调性分布特征的前提下增加正样本，导致数据排序不一致率差值的绝对值增大，但单调性特征未发生改善；GAN、CGAN 训练所得的样本集中于特定区域，这是由于训练过程中发生了模式崩溃，生成器只学会生成少数几种样本；WGAN、CWGAN 引入 Wasserstein 距离，解决了传统 GAN 训练不稳定的问题，增加了生成样本的多样性；CGAN 与 CWGAN 加入先验损失使得正样本分布靠数轴左侧。此外，采用 SN 进行筛选后，虚拟正样本集合中的部分错误样本被剔除，虚拟正样本集合的修正信息熵均值 T 由 0.3287 增加到 0.6249 (计算公式见式(24))，表明虚拟正样本集合被更新为更有价值的正样本集合。CWGAN-SN 的正负样本分布曲线与 CWGAN 接近。



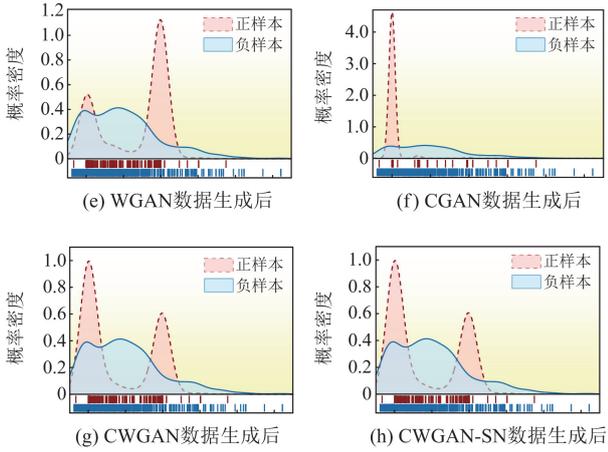


图 7 正负样本概率密度分布图

Fig. 7 Distribution of positive and negative samples probability density

$$T = -\frac{1}{n_2} \sum_{i=1}^{n_2} \sum_{j=0}^1 r_i (P(Y = j|X_i) \ln P(Y = j|X_i)) \quad (24)$$

式中: r_i 为样本鉴定因子; $P(Y = 0|X_i)$ 和 $P(Y = 1|X_i)$ 分别为虚拟样本 X_i 属于负样本和正样本的概率。当 $P(Y = 1|X_i) < 0.5$ 时, 即虚拟样本 X_i 概率标签为负样本时, r_i 为 0, 以排除错误样本对信息熵的增益作用。

$$r_i = \begin{cases} 0, & P(Y = 1|X_i) < 0.5 \\ 1, & P(Y = 1|X_i) \geq 0.5 \end{cases} \quad (25)$$

2.3 山火致跳闸模型预测效果

2.3.1 各不平衡率尺度下模型预测效果

本节比较了 MPS-CWGAN-SN 方法与原始数据集(baseline)、ACGAN、ADASYN、CWGAN、MPS-CWGAN、CWGAN-SN 这 6 种方法在不同不平衡率 R 下 SVM 的性能, 如图 8 所示。

由于各不平衡率下数据集正样本数量固定, 在不平衡率较小时, 训练集样本数量亦较小, MPS-CWGAN-SN 不具备优势。随着不平衡率的增大, 虚拟正样本生成需求增大, 本文算法可为二分类模型提供优质虚拟正样本, 在提高正样本召回率的同时保持优良的精确率。分别比较 MPS-CWGAN-SN 与原始数据集 baseline、CWGAN、MPS-CWGAN、CWGAN-SN, 由结果可知 CWGAN、MPS、SN 这 3 个部分对整体模型均有增益作用, 其中, CWGAN 算法可提高正样本召回率, 但损失了精确率; MPS 算法可在 CWGAN 的基础上提高精确率, 却同时损失了召回率; SN 算法可改善虚拟正样本质量, 同时对正样本召回率与精确度的值均有增益。本文模型 MPS-CWGAN-SN 结合了 3 种算法的优势, 效果叠加, 在极不平衡条件下性能最佳, 有利于改善预测模型的整体效果。

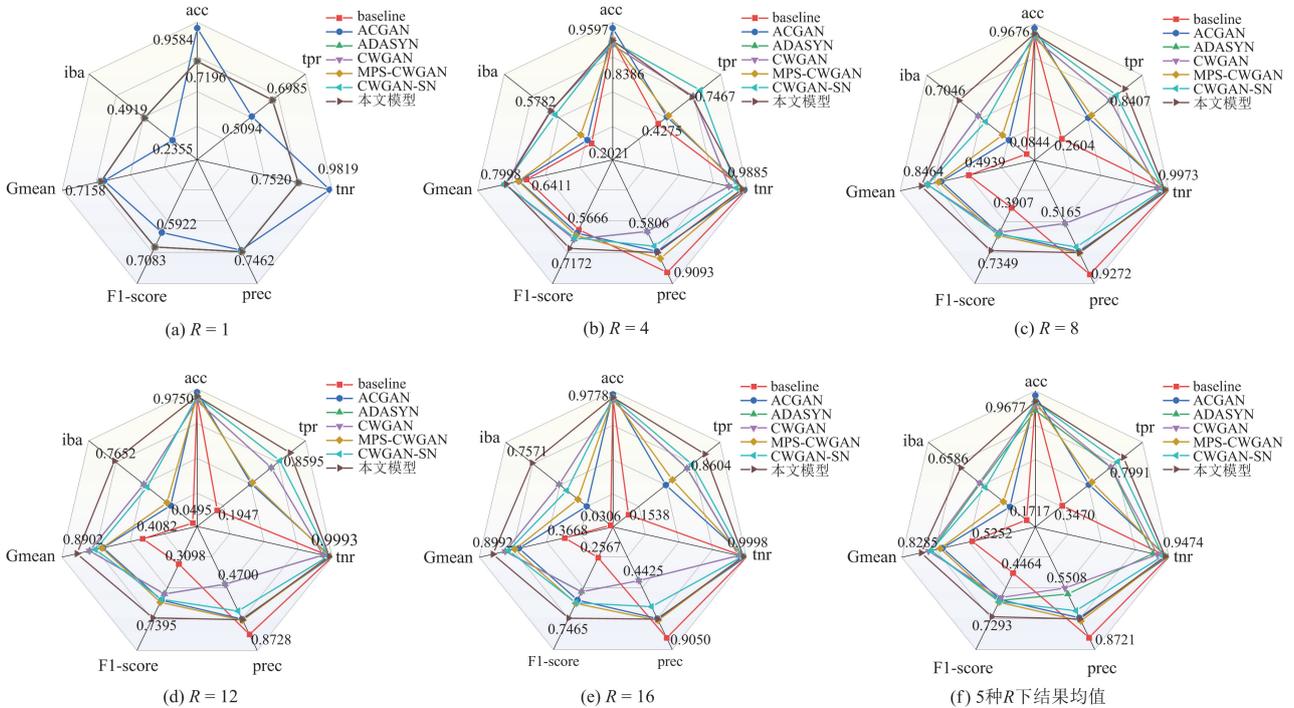


图 8 不同不平衡率下各算法性能

Fig. 8 Performance of each algorithm under different imbalanced ratios

2.3.2 虚拟样本生成方法对二分类模型的普适性

前文展示了 MPS-CWGAN-SN 使用 SVM 作为分类器时在不平衡小样本条件下预测山火跳闸事件的优越性。为验证本文提出的虚拟样本生成方法在其他机器学习算法中的普适性，选取 LR、KNN、GB 这 3 种常见的机器学习算法进行进一步研究。

绘制 V_{F1} 与 V_{Gmean} 数值的图像，如图 9、图 10 所示，分别采用 3 种数据增强方法后，分类器平均 F1-score 相较于原始数据集提升效果为：CWGAN 提升了 0.2831，MPS-CWGAN 提升了 0.3942，CWGAN-SN

提升了 0.2531；分类器平均 V_{Gmean} 相较于原始数据集提升效果为：CWGAN 提升了 0.2831，MPS-CWGAN 提升了 0.3942，CWGAN-SN 提升了 0.2531，可知在不平衡小样本条件下本文采用的虚拟样本生成方法对其他二分类模型亦有增益作用，具有应用普适性。在各不平衡率下采用 MPS-CWGAN-SN 数据生成方法后，各性能指标平均值如表 5 所示，其中 SVM 整体效果最佳，适用于本文数据集中山火致线路跳闸的预测。

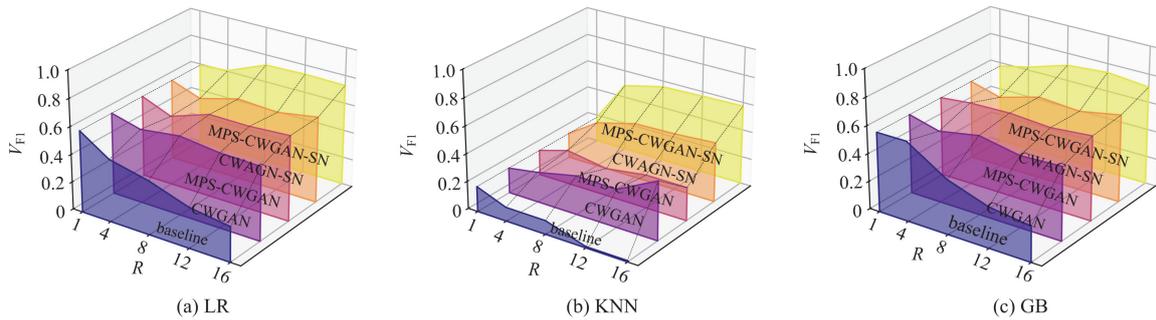


图 9 基于不同智能算法的山火跳闸预测模型不平衡学习 V_{F1} 值对比

Fig. 9 Comparison of V_{F1} values in imbalanced learning for wildfire trip prediction models based on different intelligent algorithms

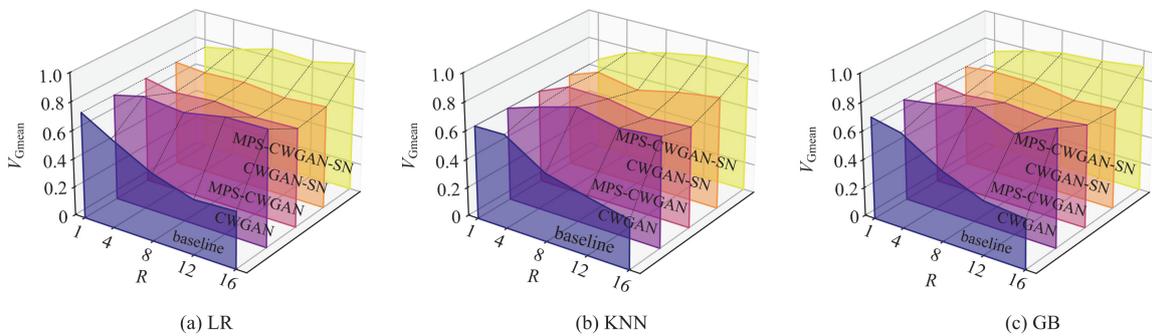


图 10 基于不同智能算法的山火跳闸预测模型不平衡学习 V_{Gmean} 值对比

Fig. 10 Comparison of V_{Gmean} values in imbalanced learning for wildfire trip prediction models based on different intelligent algorithms

2.4 模型应用分析

本节以一起于 2022 年 3 月 15 日 13:59 由山火引发的跳闸故障为具体算例，分析如何将本文提出的算法模型应用于输电线路的山火跳闸预防控制中。为体现模型的有效性，本节中该算例仅作为测试数据，未应用于算法模型前期训练过程。

本文研究区域的电网调度部门已配备山火基础告警信息接口，可实时返回最新线路山火信息，包括线路名称、杆塔编号及所在位置等，每 10 min 刷

新一次。获得山火告警信息后，根据该位置的经纬度，检索对应时空条件下的植被、气象、线路及人口数据，作为本文输电线路山火跳闸预测模型的输入变量。其中，植被、线路及人口数据在短期相对恒定，可定期将数据整理为离线数据，便于山火告警后的快速查阅；气象数据则需要实时在线获取，可于中国气象数据网及电网公司配备的相关气象接口获取。在该线路 2022 年 3 月 15 日 13:40 山火告警后，将特征数据输入本文山火跳闸预测模型。经预

测分析, 该线路后续将发生跳闸, 与实际情况相符。

表 5 各二分类模型基于生成样本的预测性能平均值

Table 5 Average predictive performance based on generated samples of each binary classification model

	V_{acc}	V_{tpr}	V_{tfr}	V_{prec}
SVM	0.8833	0.7991	0.9275	0.7517
LR	0.8942	0.7063	0.9674	0.7456
KNN	0.8981	0.5851	0.9912	0.7842
GB	0.8816	0.7117	0.9317	0.7058
	V_{F1}	V_{Gmean}	V_{iba}	—
SVM	0.7293	0.8285	0.6586	—
LR	0.6764	0.8259	0.5074	—
KNN	0.4739	0.8053	0.3068	—
GB	0.6702	0.8142	0.5146	—

值得指出的是, 山火引发的输电线路跳闸过程与电网保护控制策略密切相关。当山火导致空气绝缘击穿形成放电通道时, 线路过流保护装置将触发断路器动作; 而重合闸策略的执行可能因山火持续时间长、引发二次跳闸而失效。本文模型研究案例中重合闸成功率仅为 1.85%, 故暂未将重合闸成功率纳入预测模型计算中。跳闸预警的最终目标是为调度决策提供前瞻支撑——通过预判保护装置动作结果, 可提前启动备用线路或完成倒闸操作准备, 从而将系统停电时间缩短至保护装置动作时延量级。

3 结论

为应对山火跳闸样本稀缺的现实挑战, 本文提出一种基于先验知识与孪生网络监督的输电线路山火跳闸预测模型, 以实现对于山火致线路跳闸事件的提前感知, 结论如下。

1) 本文基于 MPS 方法确定虚拟样本数量, 能在增强模型分类能力的同时减少虚拟样本带来的噪声影响。相比于绝对平衡数据集和过平衡数据集, F1-score 分别提高 10.75%与 12.42%。

2) CWGAN-SN 有助于生成更符合先验单调性知识的虚拟正样本。孪生网络算法筛选虚拟样本前后样本信息熵由 0.3971 增加到 0.6109, 使预测模型 V_{Gmean} 在各不平衡率下的平均值提升至 85.66%。

3) 相比于传统数据不平衡方法, 本文方法在召回率上最大可提升 31.94%, 表明基于先验知识和孪生网络监督的方法可通过增强特征一致性改善虚拟样本的质量, 提升山火跳闸这类“高风险小概率”事件的预测效果, 适用于实际工程背景。

参考文献

[1] 吴田, 阮江军, 胡毅, 等. 500 kV 输电线路的山火击穿特性及机制研究[J]. 中国电机工程学报, 2011, 31(34):

163-170.

WU Tian, RUAN Jiangjun, HU Yi, et al. Study on forest fire induced breakdown of 500 kV transmission line in terms of characteristics and mechanism[J]. Proceedings of the CSEE, 2011, 31(34): 163-170.

[2] 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.

[3] 周恩泽, 饶章权, 刘琦, 等. 典型高风险植被火条件下导线——板间隙击穿特性[J]. 高压电器, 2024, 60(3): 179-185.

ZHOU Enze, RAO Zhangquan, LIU Qi, et al. Breakdown characteristics of conductor-plane gap under typical high risk vegetation fire condition[J]. High Voltage Apparatus, 2024, 60(3): 179-185.

[4] 王开正, 付一桐, 钱国超, 等. 基于时空上下文的输电线路山火自动识别算法[J]. 电力系统保护与控制, 2022, 50(18): 83-91.

WANG Kaizheng, FU Yitong, QIAN Guochao, et al. An automatic identification algorithm for wildfire occurrences near transmission line corridors based on spatio-temporal context[J]. Power System Protection and Control, 2022, 50(18): 83-91.

[5] 叶丽梅, 黄俊杰, 高正旭, 等. 基于湖北输电线路灾情的山火分布特征分析[J]. 南方能源建设, 2024, 11(1): 196-204.

YE Limei, HUANG Junjie, GAO Zhengxu, et al. Analysis of the distribution characteristics of mountain fires based on the disaster data of Hubei transmission lines[J]. Southern Energy Construction, 2024, 11(1): 196-204.

[6] 郭伯森, 李天友, 王连辉, 等. 基于层次分析法的中压配电线路森林火灾故障预警辨识模型[J]. 供用电, 2023, 40(3): 55-62.

GUO Bosen, LI Tianyou, WANG Lianhui, et al. An early warning evaluation model for forest fire faults in medium-voltage distribution lines based on analytic hierarchy process[J]. Distribution & Utilization, 2023, 40(3): 55-62.

[7] 林铭瀚, 胡永洪, 薛毓强, 等. 基于 Mesh 网络的输电线路山火预警监视系统研制[J]. 电力系统保护与控制, 2016, 44(1): 134-138.

LIN Minghan, HU Yonghong, XUE Yuqiang, et al. Research and application of forest fire early-warning and monitor system based on wireless Mesh network for transmission

- line[J]. *Power System Protection and Control*, 2016, 44(1): 134-138.
- [8] 周志宇, 艾欣, 陆佳政, 等. 山火灾害引发的输电线路跳闸风险实时分析方法及应用[J]. *中国电机工程学报*, 2017, 37(18): 5321-5330, 5531.
ZHOU Zhiyu, AI Xin, LU Jiazheng, et al. A real-time analysis approach and its application for transmission-line trip risk due to wildfire disaster[J]. *Proceedings of the CSEE*, 2017, 37(18): 5321-5330, 5531.
- [9] 周恩泽, 樊灵孟, 黄勇, 等. 基于火焰燃烧模型的输电线路山火跳闸风险分布评估[J]. *电网技术*, 2022, 46(7): 2778-2785.
ZHOU Enze, FAN Lingmeng, HUANG Yong, et al. Risk distribution assessment of wildfire-induced trips in transmission line based on flame combustion model[J]. *Power System Technology*, 2022, 46(7): 2778-2785.
- [10] KHAN I, GHASSEMI M. A probabilistic approach for analysis of line outage risk caused by wildfires[J]. *International Journal of Electrical Power & Energy Systems*, 2022, 139.
- [11] 贺兴, 潘美琪, 艾芊. 小样本学习技术在新型电力系统中的应用与挑战[J]. *电力系统自动化*, 2024, 48(6): 74-82.
HE Xing, PAN Meiqi, AI Qian. Applications and challenges of few-shot learning technologies in new power system[J]. *Automation of Electric Power Systems*, 2024, 48(6): 74-82.
- [12] YI Zhenxiao, CHEN Zhaoliang, YIN Kai, et al. Sensing as the key to the safety and sustainability of new energy storage devices[J]. *Protection and Control of Modern Power Systems*, 2023, 8(2): 431-452.
- [13] 魏书荣, 殷世杰, 闫梦飞, 等. 基于改进生成对抗网络的海上风电机组故障数据增强及诊断[J]. *电力系统保护与控制*, 2025, 53(1): 114-124.
WEI Shurong, YIN Shijie, YAN Mengfei, et al. Offshore wind turbine fault data enhancement and diagnosis based on an improved generative adversarial network[J]. *Power System Protection and Control*, 2025, 53(1): 114-124.
- [14] 孙文成, 李健, 彭宇辉, 等. 基于样本不平衡和特征优选多源融合的输电线路故障类型辨识[J]. *电测与仪表*, 2024, 61(12): 79-89.
SUN Wencheng, LI Jian, PENG Yuhui, et al. Transmission line fault type identification based on the sample imbalance and feature preferred multi-source fusion[J]. *Electrical Measurement & Instrumentation*, 2024, 61(12): 79-89.
- [15] 郭红霞, 陈凌轩, 张启, 等. 电力电量平衡视角下新型电力系统极端场景研究及应对综述[J]. *电网技术*, 2024, 48(10): 3975-3994.
GUO Hongxia, CHEN Lingxuan, ZHANG Qi, et al. Research and response to extreme scenarios in new power system: a review from perspective of electricity and power balance[J]. *Power System Technology*, 2024, 48(10): 3975-3994.
- [16] 高浩寒, 潮群, 徐孜, 等. 小样本下基于孪生神经网络的柱塞泵故障诊断[J]. *北京航空航天大学学报*, 2023, 49(1): 155-164.
GAO Haohan, CHAO Qun, XU Zi, et al. Piston pump fault diagnosis based on Siamese neural network with small samples[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2023, 49(1): 155-164.
- [17] LIN L S, LIN Y S, LI D C, et al. Mega trend diffusion-siamese network oversampling for imbalanced datasets's SVM classification[J]. *Applied Soft Computing*, 2023, 143.
- [18] 李磊, 张雷, 富梦迪, 等. 基于模拟实验和真实场景参数的山火输电线路间隙电场畸变特性分析[J]. *南方电网技术*: 1-9[2024-12-07]. <https://link.cnki.net/urlid/44.1643.TK.20240718.1521.005>
LI Lei, ZHANG Lei, FU Mengdi, et al. Analysis of gap electric field distortion characteristics of mountain fire transmission lines based on simulation experiment and real scene parameters[J]. *Southern Power System Technology*: 1-9[2024-12-07]. <https://link.cnki.net/urlid/44.1643.TK.20240718.1521.005>
- [19] 周萱, 吴伟丽. 基于改进 SMOTE 不均衡样本处理和 IHPO-DBN 的变压器故障诊断方法研究[J]. *电力系统保护与控制*, 2024, 52(11): 21-30.
ZHOU Xuan, WU Weili. Transformer fault diagnosis method based on improved SMOTE unbalanced sample processing and IHPO-DBN[J]. *Power System Protection and Control*, 2024, 52(11): 21-30.
- [20] 刘颂凯, 党喜, 崔梓琪, 等. 针对样本类不平衡的深度残差网络电力系统暂态稳定评估方法[J]. *智慧电力*, 2024, 52(1): 116-123.
LIU Songkai, DANG Xi, CUI Ziqi, et al. Transient stability evaluation method for power systems with deep residual network considering class imbalance of samples[J]. *Smart Power*, 2024, 52(1): 116-123.
- [21] 兰健, 郭庆来, 周艳真, 等. 基于生成对抗网络和模型迁移的电力系统典型运行方式样本生成[J]. *中国电机工程学报*, 2022, 42(8): 2889-2900.
LAN Jian, GUO Qinglai, ZHOU Yanzhen, et al. Generation of power system typical operation mode samples: a generation adversarial network and model-based transfer learning approach[J]. *Proceedings of the CSEE*, 2022, 42(8): 2889-2900.

- [22] 薛展豪, 陈力, 林志颖, 等. 基于双向长短期记忆生成对抗网络的电力系统次同步振荡数据生成方法[J]. 智慧电力, 2024, 52(5): 60-66.
XUE Zhanhao, CHEN Li, LIN Zhiying, et al. Subsynchronous oscillation data generation method of power system based on bidirectional long shortterm memory generative adversarial network[J]. Smart Power, 2024, 52(5): 60-66.
- [23] 余松, 胡东, 唐超, 等. 基于 TLR-ADASYN 平衡化数据集的 MSSA-SVM 变压器故障诊断[J]. 高电压技术, 2021, 47(11): 3845-3853.
YU Song, HU Dong, TANG Chao, et al. MSSA-SVM transformer fault diagnosis method based on TLR-ADASYN balanced data set[J]. High Voltage Engineering, 2021, 47(11): 3845-3853.
- [24] 林越, 刘廷章, 王哲河. 具有两类上限条件的虚拟样本生成数量优化[J]. 广西师范大学学报(自然科学版), 2019, 37(1): 142-148.
LIN Yue, LIU Tingzhang, WANG Zhehe. Quantity optimization of virtual sample generation with two kinds of upper bound conditions[J]. Journal of Guangxi Normal University (Natural Science Edition), 2019, 37(1): 142-148.
- [25] 欧阳帆, 余笑龙, 徐彪, 等. 基于多指标综合评价的配电网接地故障山火风险等级划分[J]. 电力系统保护与控制, 2024, 52(8): 10-19.
OUYANG Fan, SHE Xiaolong, XU Biao, et al. A method for dividing the forest fire risk levels caused by a ground fault risk levels on distribution lines based on multiple index comprehensive evaluation[J]. Power System Protection and Control, 2024, 52(8): 10-19.
- [26] 刘晖, 向淳, 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.
- [27] 周恩泽, 龚博, 刘淑琴, 等. 南方电网架空线路因山火跳闸故障统计分析[J]. 广东电力, 2022, 35(4): 80-86.
ZHOU Enze, GONG Bo, LIU Shuqin, et al. Statistics and analysis on tripping fault of overhead transmission lines caused by mountain fires in China southern power grids[J]. Guangdong Electric Power, 2022, 35(4): 80-86.
- [28] 张雷. 华北电网输电线路受山火影响特征分析[J]. 山东电力技术, 2019, 46(9): 18-22.
ZHANG Lei. Feature analysis of transmission line affected by mountain fire in North China power grid[J]. Shandong Electric Power, 2019, 46(9): 18-22.
- [29] 芦肇基, 沈艳霞, 谭永强. 基于多结构融合 WGAN 的模糊绝缘子图像复原方法研究[J]. 电力系统保护与控制, 2024, 52(22): 166-175.
LU Zhaoji, SHEN Yanxia, TAN Yongqiang. A WGAN blur insulator image restoration method based on multi-structure fusion[J]. Power System Protection and Control, 2024, 52(22): 166-175.
- [30] 王欢, 王昕, 张峰, 等. 基于改进生成对抗网络的变压器声纹故障诊断[J]. 智慧电力, 2024, 52(4): 24-31.
WANG Huan, WANG Xin, ZHANG Feng, et al. Transformer voiceprint fault diagnosis based on improved generative adversarial network[J]. Smart Power, 2024, 52(4): 24-31.
- [31] 李宽宏. 基于 Wasserstein 条件生成对抗网络的新能源出力场景生成方法[J]. 供用电, 2023, 40(3): 86-94.
LI Kuanhong. A method for renewable energy power generation based on Wasserstein conditional generative adversarial networks[J]. Distribution & Utilization, 2023, 40(3): 86-94.
- [32] 裴生雷. 面向复杂单调性分类任务的学习算法研究[D]. 天津: 天津大学, 2018.
PEI Shenglei. Research on learning algorithm for complex monotonicity classification tasks[D]. Tianjin: Tianjin University, 2018.
- [33] YU S, WANG J, GOU B, et al. A novel bilateral branching network with cost-sensitive Res2Net for diagnosis GIS insulation defects on imbalanced data[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-11.

收稿日期: 2025-01-14; 修回日期: 2025-03-26

作者简介:

谢从珍(1973—), 女, 通信作者, 教授, 博导, 主要从事输变电设备在线监测、人工智能及高电压试验技术等方面的研究工作; E-mail: xiecongzhen@scut.edu.cn

周晓静(2001—), 女, 硕士研究生, 研究方向为电网防灾减灾、人工智能技术。E-mail: cystem@foxmail.com

(编辑 周金梅)