

基于稀疏自编码器技术的电网气象灾害预测预警 在新型电力系统中的研究

方圆圻¹, 任茂鑫¹, 葛乃成¹, 李昊雨², 杨秀²

(1. 国家电网有限公司华东分部, 上海 200120; 2. 上海电力大学 电气工程学院, 上海 200090)

摘要: 自然灾害和气候因素是造成新型电力系统电网非计划停运的主要责任原因。随着高比例可再生能源接入和电网数字化升级, 新型电力系统对气象扰动的敏感性显著增强, 电网防灾减灾更需重点关注气象致灾。针对气象因素与电网故障的关联关系和规律, 文中提出了一种基于气象稀疏自编码器 (sparse autoencoder, SAE) 和支持向量机 (support vector machine, SVM) 的电网故障预警方法。通过稀疏自编码器和 SVM 的结合, 显著提高了含高比例电力电子设备 (power electronic devices, PED) 的电网故障预警的灵敏度和抗干扰能力。基于新型电力系统典型场景下的气象历史数据和电网运维检修数据, 通过应用合成少数类样本过采样技术 (synthetic minority over-sampling technique, SMOTE) 缓解数据集的不平衡问题, 并利用最小信息熵原理确定气象因子的初始权重。通过反向传播算法微调 SAE 提取气象特征, 预测气象灾害类型, 结合 SVM 建立适应新型电力系统柔性运行需求的电网故障预警模型, 完成气象场景与新型电网架构故障类型之间的关联预测。算例分析表明, 该方法可准确实现气象灾害和故障类型的预测预警, 为新型电力系统韧性提升提供技术支撑。

关键词: 新型电力系统; 电网故障; 特征提取; 堆叠自动编码器; 支持向量机; 预测预警模型

DOI: 10.19753/j.issn1001-1390.2026.07.001

中图分类号: TM73

文献标识码: A

文章编号: 1001-1390(2026)07-0002-13

Research on meteorological disaster prediction and early warning model based on sparse autoencoder technology in novel power system

FANG Yuanqi¹, REN Maoxin¹, GE Naicheng¹, LI Haoyu², YANG Xiu²

(1. East China Branch, State Grid Corporation of China, Shanghai 200120, China.

2. School of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: Natural disasters and climatic factors are the main reasons for the unplanned outages of the novel power system. With the high proportion of renewable energy access and the digital upgrade of power grids, the sensitivity of novel power system to meteorological disturbances has increased. Greater attention should be paid to meteorological disasters disaster of prevention and mitigation in power grid. In view of the correlation and patterns between meteorological factors and power grid faults, this study introduces a power grid fault early warning approach utilizing a meteorological sparse autoencoder (SAE) combined with support vector machine (SVM) technology. The method is developed by analyzing the relationship and patterns between meteorological conditions and power grid failures through the combination of sparse autoencoder and SVM, the sensitivity and anti-interference ability of power grid fault warning with a high proportion of power electronic devices (PED) are significantly improved. To address the dataset imbalance in historical meteorological and grid operation data under typical scenarios of modern power systems, this study employs the synthetic minority over-sampling technique (SMOTE) for data balancing. The initial weights of meteorological factors are optimized based on minimum information entropy principles. A stacked SAE, fine-tuned via backpropagation, is utilized to extract critical meteorological features and predict disaster types. By integrating SVM, an adaptive fault early warning model is developed to align with the flexible operational demands

基金项目: 国家自然科学基金资助项目 (52177098); 国家电网有限公司华东分部科技项目 (529924240017)

of contemporary power grids, enabling accurate correlation analysis between meteorological conditions and fault patterns in advanced grid architectures. Case studies demonstrate the effectiveness of the proposed model in disaster prediction and fault-type identification, offering actionable insights for enhancing the resilience of novel power systems.

Keywords: novel power system, power grid fault, feature extraction, stacked autoencoder, support vector machine, predicting and warning model

0 引言

伴随电力基础设施覆盖面的增长,线路的跨越范围进一步扩展,新型电力系统内众多分布式新能源发电装置及柔性输电设备长期处于户外环境,易受自然灾害等外界条件干扰,诱发故障^[1-2],电网运行故障往往与气象因素相关,呈现出空间跨度大、经济损失重的特性,在可再生能源主导发电结构的新型电力系统发展阶段,天气波动加剧了电网运行的不稳定风险^[3-4]。我国电网规模庞大且面临多样化的地理气候环境,面临自然气候灾害的持续威胁,现代电力系统中普遍安装的电力电子设备,面对极端气候时稳定性明显降低,引发设备失效,极端气象条件下的覆冰与风暴往往造成线路断线及设备损毁事故,鉴于现代电力系统强电力电子化特性,此类问题易造成电网连续脱网,对电网的安全稳定运行造成威胁,造成电力供应质量下滑及用户不便,为强化电网应对灾害的韧性,现代电力系统应建立“源网荷储”联动的灾害防御机制,着重于削减故障发生的风险与频次,从而保证电网的可靠安全供电^[5-7]。

气象灾害分属不同类别,作用范围辽阔,且常衍生出次生灾害,随机分布明显且延续周期长,由于布局分散和受自然环境制约,新型电力系统的风光发电单元,更容易受到区域气象灾害的集中冲击,该类型极端气候会对电力基础设施造成重大损害,尤其会降低新能源发电功率的预测精确度,对新型电力系统的供需平衡造成更大干扰,干扰电网可靠运行^[8-9]。2008 年南方爆发的特大冰冻雨雪灾害,引发多地区电网基础设施重大破坏,若处于当前新型电网架构中,新能源机组发生群体性脱网的概率将明显上升^[10],2012 年前后,该国电网的三次重大崩溃,同样由极端气候灾害直接引发,此事件证实新型电力系统可通过储能与需求管理提升极端天气应对能力^[11],即便设备制造工艺和运维水准不断进步,在推进新型电力系统建设阶段,气象条件已上升为电网故障的首要诱因,宜采用数字孪生技术配合广域气象监测等智能方式加强灾害预警。

研究者们通过雷电^[12]、覆冰^[13]、台风^[14]以及污闪^[15]等气象危害类型,进行了电网故障预测分析,文献[16]借助电网地理信息系统,研究了电力设备与山火之间的关联性,结合气象数据预测山火发展路径,以此实现电网火情预警。文献[17]报道了融合电场监测、雷电位置追踪和风险量化的预警策略,结合雷电至线路的间隔距离与电场强度测算预警等级,文献[18]基于线路覆冰演变过程的监测数据,运用层次分析法筛选出风速、风向及温度等核心影响因素,构建了动态双维度的输电线路覆冰预警体系。文献[19]通过建立经纬网格实现区域划分,结合气象资料及小尺度地形,采用台风预报数据分析线路脆弱区域,进而构建台风灾害预警模型。文献[20]定量分析了天气条件对绝缘子积污过程的贡献,借助灰色聚类-反向传播神经网络组合模型,预判绝缘子表面盐密的空间分布,由此建立线路污秽预警机制。学界普遍通过融合不同气象参数来实现电网设施的综合预警^[21],文献[22]给出多条件约束的输电线路风险量化策略,结合 8 个气象变量,采用三角隶属函数刻画气象因子与风险级别间的模糊关联,再通过点灰度函数解析模糊关系的可靠性缺口,进而生成风险分析结果,最终整合气象预报数据形成输电线路风险等级的预测预警方案。

已有研究将气象观测数据与电网 GIS 技术相结合,构建出电网灾害预警及故障预测框架,文献[23]提出的电网气象灾害监测预警系统,具备气象数据监测、分析预测及灾害动态仿真的功能,适配应急调度要求;文献[24]运用电网 GIS 工具整合气象观测结果,实现了气象要素实时驱动的灾情预警;文献[25]开发出融合时空特征的输电线气象风险量化方法,采用支持向量机(support vector machine, SVM)优化了预警准确度。

部分研究虽引入实时气象参数,然而面对规模庞大的电网及多变天气状况,或伴有一定时滞,造成应急反应延迟,因而必须实施更细致的数据加工及模型改进,保证预警和预测机制既可靠又实用。

本研究探索了堆叠自编码器在电网设备故障

预测中的运用,基于电网故障资料组建气象灾害故障对应样本集,采用优化后的深度自编码网络提取样本中致灾因子的特征,依托电网故障记录,整合网络挖掘的潜在特征,采用支持向量机技术训练电网故障预测模型,实现气象数据与电网故障的匹配关联,实现定向场景的电网故障预判。

1 基于稀疏自编码器的气象致灾特征提取模型

1.1 自编码器

自编码器 (autoencoder, AE) 是一种基于浅层神经网络的对称结构模型,其核心思想是通过无监督学习实现数据的特征提取与重构。该模型采用输入-隐藏-输出的层级设计,通过编码和解码两个阶段的协同处理,将输入数据映射到潜在特征空间后再重构还原。在训练过程中,系统通过最小化重构误差来优化网络参数,从而获得最具代表性的中间层特征表达。如图 1 所示,这种对称的网络结构能够有效捕捉输入数据的本质特征,并为后续处理提供优化的特征表示。




图 1 自编码器结构

Fig. 1 Architecture of autoencoder

自编码器的任务执行分为两个主要阶段:编码阶段 (Encoding) 与解码阶段 (Decoding), 在特征编码阶段, Encoder 网络实现了输入数据到式 (1) 所示潜在特征的转换:

$$\mathbf{h} = \sigma(\mathbf{W}\mathbf{x} + \mathbf{b}) \quad (1)$$

式中: $\mathbf{h}$ 对应输出层产生的向量, 与 $\mathbf{W}$ 的行数维度一致; 采用 Sigmoid 函数作为激活函数; 输入特征向量 $\mathbf{x}$ 作为模型输入端, 普遍以 $(\times 1)$ 作为维度规格, d 定义为特征维度大小; 权重矩阵 $\mathbf{W}$ 与偏置向量 $\mathbf{b}$ 构成了输入层 (原始数据) 至隐含层 (特征数据) 的连接参数。

在信号还原阶段, 输出数据由 Decoder 网络根据潜在特征重构生成, 详见:

$$\hat{\mathbf{x}} = \sigma(\mathbf{W}'\mathbf{h} + \mathbf{b}') \quad (2)$$

式中: $\mathbf{W}$ 和 $\mathbf{b}$ 分别表示输入层 (原始数据) 与隐含层 (特征表示) 之间的权重矩阵和偏置项; 相应地, $\mathbf{W}'$ 和 $\mathbf{b}'$ 代表隐含层到输出层 (重构数据) 的权重矩阵和偏置项。网络采用 Sigmoid 函数 σ 作为激活函数, 该函数的数学表达式及其导数特性详见式 (3) 和式 (4):

$$\sigma'(z) = \sigma(z)(1 - \sigma(z)) \quad (3)$$

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (4)$$

式中: z 代表神经元的加权输入总和。该激活函数将输入值非线性地压缩至 $(0, 1)$ 区间, 其输出 $\sigma(z)$ 可解释为概率分布或神经元激活强度。函数的一阶导数 $\sigma'(z)$ 则表征了输出值相对于输入变化的敏感度, 反映了激活状态的梯度变化特征。

自编码器的核心设计目标是通过编码-解码机制实现输出数据对输入数据的高精度重构。从理论层面分析, 理想状态下网络输出应能完全复现原始输入。该模型通过定义重构误差函数 $L(x, y)$ 来量化输入与输出之间的差异程度, 其中常用的误差函数由平方误差和交叉熵损失函数复合构成。值得注意的是, 当编码层采用 Sigmoid 激活函数时, 交叉熵损失函数因其数学特性成为更适配的误差度量方式, 这主要是由于该函数与 Sigmoid 激活在梯度计算方面具有良好的协同效应。

交叉熵损失函数的定义为:

$$L(x, y) = -\frac{1}{n} \sum_{i=1}^n [x_i \ln y_i + (1 - x_i) \ln(1 - y_i)] +$$

$$\frac{\lambda}{2} \sum_{l=1}^{n_l+1} \sum_{j=1}^{s^l} \sum_{i=1}^{s^{l+1}} (\mathbf{W}_{ij}^l)^2 \quad (5)$$

式中: λ 表示权重衰减, 用于控制模型复杂度; 网络架构包含 n_l 个隐藏层, 其中第 l 层的神经元数量由 s^l 确定; 各层间的连接权重采用矩阵表示, $\mathbf{W}_{ij}^l$ 特指第 l 层中第 i 个神经元与第 j 个神经元之间的连接权重。

基于 Sigmoid 激活函数的神经细胞, 该值逼近 1 或逼近 0, 分别反映神经元的“激活态”与“静息态”, 为引入稀疏性约束, 采取约束隐藏层神经元激活数量的方式, 限定活跃神经元的数量范围, 以使网络提取的特征既稀疏又高效。

稀疏自编码器借助稀疏惩罚项调节隐层神经元的激活程度, 以实现稀疏激活, 稀疏性约束一般采用如下定义方法: 测量隐藏层神经元的平均激活

水平,即:

$$\rho_j = \frac{1}{n} \sum_{i=1}^n [a_j(x(i))] \quad (6)$$

式中:神经元激活统计量 ρ_j 表示第 j 个神经元在整个训练集上的平均激活水平; n 代表训练批次大小,即每次参数更新时使用的样本数量;激活函数输出 $a_j(x(i))$ 为第 i 个训练样本 $x(i)$ 输入时第 j 个神经元的响应强度。

为实现编码的稀疏性,一般采用 (kullback-leibler, KL) 散度实现稀疏惩罚,以约束隐藏层神经元的放电水平,稀疏自编码器的抽象模型详见图 2。




图 2 稀疏自编码器抽象模型

Fig. 2 Abstract model of sparse autoencoder

结合重构误差及稀疏惩罚项,提出稀疏约束条件下的损失函数:

$$J(\mathbf{W}, \theta) = L(x, y) + \beta \sum_{j=1}^m KL(\rho \| \rho_j) \quad (7)$$

式中: β 为稀疏因子的控制权重; θ 为对网络进行参数初始化过程中采用的随机数。再设置完成目标函数后,利用逐层贪婪算法对目标函数进行迭代计算,使损失函数最小化:

$$W_{ij} = W_{ij} - \alpha \frac{\partial}{\partial W_{ij}} J(\mathbf{W}, \mathbf{b}) \quad (8)$$

$$b_i = b_i - \alpha \frac{\partial}{\partial b_i} J(\mathbf{W}, \mathbf{b}) \quad (9)$$

式中: α 表示学习率参数,控制着权重更新的步长幅度。当目标函数值收敛至预设阈值时,编码阶段的优化过程终止。

1.2 堆叠自动编码器

堆叠自编码器 (stacked autoencoder, SAE)^[26] 采用多层自编码器堆叠形成深度神经网络,以实现数据的高层特征学习,自编码器本质上属于无监督学习的范畴,采用编码器-解码器的双模块架构,编码器实现数据维度压缩,输出低维编码,解码器利

用此压缩表示实现输入数据的还原,其训练原理在于最小化数据重构前后的偏差值,以此实现数据的压缩优化和特征挖掘,自编码器的网络组成见图 3。




图 3 堆叠自编码器网络架构

Fig. 3 Network architecture of stacked autoencoder

2 基于 SVM 的电网气象致灾故障预警的模型

从统计学习理论出发,SVM 实现了机器学习建模,基于核函数转换和结构风险平衡理论,完成小样本集的分类目标,SVM 实施风险最小化机制,借助高维空间最优划分超平面来分离训练样本 (x_i, y_i) ($i = 1, 2, \dots, n$) 实现类别划分,这里 x_i 对应样本的输入属性,作为样本标签,该超平面定义为:

$$\mathbf{W} \cdot \psi(x_i) + \mathbf{b} = 0 \quad (10)$$

式中: $\mathbf{W}$ 为样本权重; $\mathbf{b}$ 为阈值; ψ 为目标函数。

SVM 通过对目标函数最小来寻找最优平面,如式(11)所示:

$$\begin{cases} \min \psi(\mathbf{W}, \zeta_i) = \frac{1}{2} \|\mathbf{W}\|^2 + C\zeta_i \\ \text{s. t. } (\mathbf{W} \cdot \psi(x_i) + \mathbf{b}) - 1 + \zeta_i \geq 0, \quad \zeta_i \geq 0 \end{cases} \quad (11)$$

式中: C 为惩罚参数; ζ_i 为非松弛因子。

之后便可以得到样本的最优分类决策函数为:

$$f(x) = \text{sgn} \left(\sum_{i=1}^n \alpha_i y_i K(x_i, x_j) + b^* \right) \quad (12)$$

式中: α_i 为最优拉格朗日乘子; b^* 为分类阈值; $\text{sgn}(\cdot)$ 为返回整数型变量函数; $K(x_i, x_j)$ 为核函数,选择 RBF 核函数,表达式为:

$$\exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|_2), \quad \gamma > 0 \quad (13)$$

式中: γ 为核函数; $\mathbf{x}$ 为样本向量; $\mathbf{x}'$ 为选取的地标向量,通常直接选取样本集中的所有样本作为地标向量。

3 电网气象故障预警步骤

借助最小信息熵准则对气象因子权重进行初始配置,采用无监督训练方式后,初步建立网络权重及偏置的初始值,依托场景分类器实施特征抽取训练,运用带灾害标签的训练集对网络做监督微调,改进特征抽取效能,采用反向传播算法优化堆叠自编码器,从气象资料中筛选核心特征,判定气象灾害类别,采用 SVM 方法搭建电网故障预警系统,结合 SVM 建立故障特征(短路、断线、杆塔倒塌、闪络)与历史气象因之间的关联性,构建气象参数与电网故障种类的映射预测,预测方法的实施步骤见图 4。




图 4 电网气象故障预警流程图

Fig. 4 Flowchart of power grid meteorological fault early warning system

3.1 数据归一化

各气象参数的量纲及单位具有差异性,量值区间可能大相径庭,极端差异可达到百倍级甚至千倍级水平,为简化模型运算复杂度,须对所有因子的初始数据作归一化调整,对数据进行量纲统一化。

选择离差标准化对数据样本进行归一化。其归一化公式如下:

$$x_i^* = \frac{x_i - \min\{x\}}{\max\{x\} - \min\{x\}}, \quad 1 \leq i \leq n \quad (14)$$

式中: x 为每一类气象因子的原始数据样本; x^* 为该因子经过归一化后的新输入样本; x_i 、 x_i^* 分别对

应气象数据集当中的 x 和 x^* 中第 i 个样本数据 $\max\{x\}$ 和 $\min\{x\}$ 分别为原始数据样本中的最大值和最小值。基于离差标准化处理后的数据具有良好的数值稳定性,可以显著提高自动编码器的收敛性和学习能力。

3.2 基于 SMOTE-SDAE 网络的电网气象防灾方法

电网气象防灾的 SMOTE-SDAE 网络方法主要分为两个阶段:采用历史数据耦合深度自学习机制,实现气象变量与电网故障的关联分析,本模块采用深度自编码器分析气象条件与电网故障事件间的非线性相关性,以强化气象参数与电网响应的建模关联性。依托第一步形成的匹配关系,加载给定气象条件,实施电网故障预判,借助真实故障记录对预测值进行误差校正,针对性修正对应连接逻辑,从而优化预测系统的准确率与鲁棒性,主要技术手段采用合成少数类过采样技术(synthetic minority over-sampling technique, SMOTE)样本合成技术,合成过采样 SMOTE 结合深度自编码神经网络,堆叠降噪自编码器(stacked denoising autoencoder, SDAE)的混合,既改善了样本类别不平衡现象,又提升了深度网络对非线性关系的建模效果,由此增强电网气象灾害预报的准确度及可靠性。

基于 SMOTE 算法完成原始数据的样本增强,扩充故障样本集,SMOTE 算法根据欧几里得距离选择少数类的邻近样本点,借助式(15)在特征空间随机创建新样本,实现故障类样本的增量扩充,扩增样本维持了原始样本的类别划分,同时未扰动原有样本的分布结构,从而维持故障与正常样本的比例平衡,采用这一方法,初始样本的类别失衡得到缓解,有效抑制了因故障样本不足产生的预测误差,新数据集按比例分配至训练和测试两个子集,服务于分类任务建模。

研究提出的 SMOTE-SDAE 电网气象灾害预警方法采用两阶段建模框架:第一阶段基于深度特征学习建立气象-故障关联模型,通过 SDAE 挖掘气象参数与电网故障间的深层非线性关联,显著提升气象因素对电网影响的表征能力;第二阶段实现动态预测优化,在输入实时气象数据生成故障预测后,采用实际运行数据驱动的反馈校正机制持续更新模型参数。该方法创新性地融合了 SMOTE 与深度自编码网络,有效克服了传统方法在样本不平衡条件下的建模局限,同时通过深度神经网络强大的

特征提取能力,显著提升了极端气象条件下电网故障预警的精确度与稳定性。

$$z_i = \mathbf{x} + (\mathbf{y}(i) - \mathbf{x}) \text{rand}(0,1) \quad (15)$$

式中: $\mathbf{x}$ 为起点向量(固定)。 $\mathbf{y}(i)$ 为第 i 个终点向量(可能有多组 y 样本)。 $\text{rand}(0,1)$ 为在 $[0,1]$ 区间均匀分布的随机数。 z_i 为插值结果,落在 $\mathbf{x}$ 和 $\mathbf{y}(i)$ 之间的随机点。

3.3 气象致灾因子动态初始权重确定

首先运用 G1 法对灾害因子实施主观权重赋值,采用该方式,基于因子重要程度排列其先后次序,把专家评审意见量化为具体数值,由此获取各因子的主观权重数值,借助加权法(如熵权法)实现致灾因子客观权重的测算,基于该阶段成果,生成初步分析矩阵,运用初始矩阵进行熵值推导,从而得到各因子的客观权重,结合主客观赋权结果,可对各致灾因子的整体作用进行综合分析,用以辅助后续的决策制定与相关分析。

1) G1 主观赋权法

设 $x_1, x_2, \dots, x_n$ 是多指标体系中的 n 个指标,即为气象因子,首先选出最重要的因子记为 x_1 ,如果 x_i 的重要程度比 x_j 要高,记作 $x_i \geq x_j$ 。当气象因子具备如下的关系 $x_1 \geq x_2 \geq \dots \geq x_n$,则称其建立序关系,确定序关系之后便可以对各个指标进行定量分析,分析方法如式(16)所示:

$$\omega_{k-1}/\omega_k = r_k \quad (k = n, n-1, n-2, \dots, 3, 2) \quad (16)$$

式中: ω_k 为第 k 个因子的主观权重; r_k 表示 x_{k-1} 与 x_k 的重要程度之比。基于专家给出的 r_k 理性赋值,则 ω_n 为:

$$\omega_{k-1}/\omega_k = r_k \quad (k = n, n-1, n-2, \dots, 3, 2) \quad (17)$$

$$\omega_n = \left(1 + \sum_{k=2}^n \prod_{i=k}^n r_i\right)^{-1} \quad (18)$$

$$\omega_{k-1} = r_k \omega_k \quad (k = n, n-1, \dots, 3, 2) \quad (19)$$

ω_n 为根据专家决策所决定的因子主观权重的计算公式,计算出 ω_n 后根据公式求出其他因子的主观权重。

2) 熵权法

通过信息熵计算指标离散程度,熵权法是决策分析的重要赋权手段,尤其擅长解决复合型评价难题,该方法以熵值计算为基础,分析各指标的重要性,依此获得各指标的权重配置,开展熵权法研究需先完成初始评价矩阵的建立,假定实验样本量为 m 个对象,基于 n 个评价指标的样本对象可形成矩阵 $\mathbf{R}$ 。

$$\mathbf{R} = (r_{ij})_{m \times n} \quad (20)$$

式中: r_{ij} 表示第 i 个评价对象的第 j 个指标的得分。

由式(21)计算 r_{ij} 的特征比重 p_{ij} :

$$p_{ij} = \frac{r_{ij}}{\sum_{i=1}^m r_{ij}} \quad (21)$$

式中: r_{ij} 为原始矩阵或向量中的第 i 行、第 j 列元素(非负实数)。 p_{ij} 为归一化后的结果, m 为行数(或需要归一化的维度大小)。

由式(22)和式(23)可以求得 j 指标的信息熵 H_j 和熵权 ω_j :

$$H_j = -\frac{1}{\ln m} \sum_{i=1}^m p_{ij} \ln p_{ij} \quad (22)$$

式中: p_{ij} 为第 i 行、第 j 列的概率值 m 为行数(或可能的状态数)。 H_j 为第 j 列的熵,衡量该列概率分布的不确定性。 $\ln m$ 为归一化因子,确保 $H_j \in [0, 1]$ (最大熵为 1)。

$$\omega_j = \frac{1 - H_j}{\sum_{j=1}^n (1 - H_j)} \quad (23)$$

式中: H_j 为第 j 列的熵(不确定性),取值范围 $[0, 1]$ (由之前的公式计算)。 $1 - H_j$ 为第 j 列的确定性(熵的补数)。熵越小,确定性越高。 ω_j 为第 j 列的权重。

当同一因子的数值差异越大,说明该因子能够提供的有效信息就越多,则所得到的该因子的熵值越小,权重越大,反之亦然。

3) 组合赋权法

通过拉格朗日乘子算法计算得到主客观组合权重:

$$\omega_k = \frac{(\omega_{ik} \omega_{jk})^{1/2}}{\sum_{k=1}^n (\omega_{ik} \omega_{jk})^{1/2}} \quad k = 1, 2, \dots, n \quad (24)$$

式中: ω_k 为由组合赋权得到的致灾因子组合权重; ω_i 为由主观赋权得到的致灾因子主观权重; ω_j 为通过熵权法得到的致灾因子客观权重。

通过组合赋权法确定各气象因子的初始权重,随后将这些经过初始加权的气象因子输入降噪自编码器进行特征提取。在特征提取过程中,34 维气象因子的权重会随着模型迭代次数增加而进行动态调整优化,从而实现对不同气象因子重要性的自适应学习。

3.4 特征提取训练

采用场景分类技术提取致灾因子特征时需执

行两个核心过程:第一阶段采用分层贪婪方式预训练深度收缩自编码网络,即依次对各收缩自编码器实施单独训练,各层自编码器基于损失最小化准则实现参数初始化,前级收缩自编码器训练完成后,输出作为后级编码器的训练输入,当所有收缩自编码器参数训练收敛后,生成致灾因子的初步特征集,无监督预训练的实施过程如图 5 所示。




图 5 无监督预训练基本流程

Fig. 5 Fundamental workflow of unsupervised pre-training

堆叠自动编码器预训练过程全部结束后,深层隐层输出结果被重新定义为特征集,作为输出层输入,经逐层传递运算后输出各隐藏层的激活值 h ,输出层的误差残差,采用如下计算式:

$$\delta^{(n)} = -(\nabla_{a^{(n)}} J) \cdot f'(h^{(n)}) \quad (25)$$

式中: $\delta^{(n)}$ 为输出层的误差项(误差信号); $\nabla_{a^{(n)}} J$ 为损失函数 J 对输出层激活值 $a^{(n)}$ 的梯度; $f'(h^{(n)})$ 为输出层激活函数 f 对其输入 $h^{(n)}$ 的导数。

由此可以得出各层网络的残差值,计算式如(26)所示:

$$\delta^l = (\mathbf{W}^l)^T \delta^{l+1} \cdot f'(h^l) \quad (26)$$

式中: δ^l 为第 l 层的误差项,衡量该层每个神经元对网络总误差的“责任”。用于后续计算权重的梯度(即如何调整权重以减少误差)。 $\mathbf{W}^l$ 为连接第 l 层和第 $l+1$ 层的权重矩阵。其转置 $(\mathbf{W}^l)^T$ 将误差

从第 $l+1$ 层反向传播到第 l 层(类似于“沿着网络反向传递错误”)。 δ^{l+1} 为第 $l+1$ 层的误差项,从更高层传递而来。可以理解为“后面层告诉前面层:你的输出导致了多少误差”。 $f'(h^l)$ 为激活函数 f 在加权输入 h^l (即前向传播时的净输入)处的导数。它表示该层神经元的激活值对输入的敏感度(例如, Sigmoid 函数在饱和区导数接近 0)。

计算得到残差之后,求出各层的偏导数,计算式如下所示:

$$\nabla_{\mathbf{W}^l} J(\mathbf{W}, \mathbf{b}) = \delta^{l+1} (\mathbf{h}^l)^T \quad (27)$$

$$\nabla_{\mathbf{b}^{(l)}} J(\mathbf{W}, \mathbf{b}) = \delta^{l+1} \quad (28)$$

式中: δ^{l+1} 为第 $l+1$ 层的误差项(反向传播的误差信号); $(\mathbf{h}^l)^T$ 为第 l 层的激活值(前向传播的输出)的转置。

其次是在深度收缩自编码器末端添加场景识别分类模块,运用电网气象灾害案例对深度收缩自编码架构执行针对性监督微调,提高深度自编码网络在电网灾害下提取关键特征的有效性,利用式(29)即可求得网络所有参数,经过末层隐藏层后,添加输出层结构,此层输出与样本类别标签绑定,输出层运用顶层特征进行决策输出,给出类别判定,输出端采用 Softmax 结构,实现输出值到概率的映射,以此实现多类别分类功能,各类概率的计算过程详见式(29)。

$$\mathbf{h}_\theta(x^i) = \begin{bmatrix} p(y^i = 1 | x^i) \\ \vdots \\ p(y^i = k | x^i; \theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T x^i}} \quad (29)$$

式中: $\mathbf{h}_\theta(x^i)$ 为模型对输入 x^i 的预测输出,是一个 $k \times 1$ 的概率向量。 $p(y^i)$ 为在给定参数 θ 和输入 x^i 时,样本属于类别 k 的概率。 θ_j 为第 j 个类别的参数向量(权重),维度与 x_i 相同。 $\theta_j^T x(i)$ 为线性模型的加权得分(logit)。

3.5 基于特征提取的预测预警模型

在神经网络进行故障特征提取时,结合 SVM 建立故障特征与历史气象因素、运维数据之间的关联性,可以通过以下步骤实现。这种方法利用了神经网络的特征提取能力和 SVM 的分类/回归优势,同时融合多源数据以提高故障诊断的准确性。流程如下:

步骤 1: 对数值型数据进行归一化 (Min-Max), 避免量纲差异影响模型;

步骤 2: 使用神经网络的中间层输出(如全连接

层的激活值)作为低维故障特征,通过 SDAE + Softmax 进一步降维;

步骤 3:判断故障类型输入:融合后的特征向量(故障特征 + 气象 + 运维数据)。输出:故障类别标签。SVM 通过核函数(如 RBF)处理非线性关系,适合小样本数据;

本故障诊断模型以融合后的多维特征向量作为输入,包括气象环境参数和运维记录数据,通过 SVM 进行故障类型分类,输出具体的故障类别标签;该方法的优势在于利用 SVM 的核函数有效捕捉特征间的复杂非线性关系,同时在小样本条件下仍能保持稳定的分类性能。

4 算例分析

总结了华东某地区自然灾害引起的电网事件,涵盖了 2013—2020 年的电网 500 kV 以上设备的电网及设备事件,共计 414 起事件。根据电网故障信息当中的故障时刻和故障位置,采集对应的 34 维气象原始数据,经统计分析,影响该地区电网的自然灾害主要有雷害、风害、台风、暴雨、雪灾、覆冰、污闪共计 7 类自然灾害场景。由自然灾害场景导致的电网故障类型主要包括:短路故障、断线故障、杆塔倒塌、闪络共计 4 类故障场景。采用 SAE 对高维气象数据进行降维处理,提取具有物理意义的低维特征表示。在神经网络进行故障特征提取时,根据图 4 中的分析流程,构建基于自编码器与 SVM 相结合的预警模型,建立故障特征与历史气象因素、运维数据之间的关联性,实现对气象灾害和故障类型进行预测与预警。

4.1 数据预处理

从电网故障日志提取故障时刻及点位,将 34 维气象原始数据进行标准化归一处理,相关归一化结果可参见图 6。




图 6 高层云量归一化

Fig. 6 Normalization of high-level cloud cover

该地区由自然灾害引起的故障主要以雷害为

主,占比如图 7 所示。




图 7 自然灾害类型统计分析

Fig. 7 Statistical analysis of natural disaster types

结合图 7 可见,电网故障中非雷电相关案例占少数,少数类样本的预测结果欠佳,通过 SMOTE 技术对电网气象故障的初始数据集进行了样本增强,生成了匹配的气象数据样本如图 8 所示,气象数据经处理后如图 9 所示。




图 8 数据处理前

Fig. 8 Raw data before preprocessing




图 9 数据处理后

Fig. 9 Processed data

4.2 气象因子权重初始化

基于 G1——熵值集成方法,实现了致灾因子的量化赋权,通过 G1 法结合专家打分完成致灾因子的主观加权,确定要素相对重要性并量化权重值,结合主观权重得分对各指标进行层次化排序,厘清各因子间的优先等级,基于熵值法求得因子的客观权重值,基于数据集散程度分配各因子权重,将专家主观赋权与数据客观赋权相结合,生成各因子的最终复合权重,初始化气象因子的权重参数,见表 1。

表 1 气象因子权重
Tab. 1 Relative weights of weather predictors

指标层	G1	熵值法	组合权重
海平面气压/hPa	0.032 8	0.006 0	0.007 47
地面气压/hPa	0.042 7	0.021 5	0.034 51
气温 2m/℃	0.132 5	0.013 9	0.069 18
降水量/mm	0.172 2	0.001 7	0.011 31
降雪量/mm	0.003 1	0.000 6	0.000 07
积雪深度 (mm of water equivalent)	0.000 4	0.000 6	0.000 01
积雪密度/(kg/m ³)	0.000 3	0.002 7	0.000 03
地表温度/℃	0.120 4	0.010 4	0.047 21
露点温度/℃	0.000 2	0.073 1	0.000 53
相对湿度/%	0.086 0	0.047 8	0.154 98
蒸发量/mm	0.017 1	0.067 7	0.043 62
潜在蒸发量/mm	0.002 2	0.121 3	0.010 06
经向风速/(V,m/s)	0.000 8	0.002 9	0.000 08
纬向风速/(U,m/s)	0.000 5	0.007 3	0.000 14
最大阵风(上一 小时内,m/s)	0.000 4	0.003 4	0.000 05
云底高度/m	0.061 4	0.001 4	0.003 33
低层云量/(lcc)	0.011 1	0.048 7	0.020 38
中层云量/(mcc)	0.010 1	0.029 4	0.011 17
高层云量/(hcc)	0.007 2	0.177 6	0.048 27
总云量/(tcc)	0.015 5	0.230 9	0.135 29
总太阳辐射度/ (down,J/m ²)	0.027 4	0.013 9	0.014 30
净太阳辐射度/ (net,J/m ²)	0.001 6	0.014 6	0.000 86
直接辐射/(J/m ²)	0.001 0	0.007 7	0.000 28
紫外强度/(J/m ²)	0.051 2	0.010 2	0.019 67
径流/mm	0.004 8	0.000 7	0.000 13
地表径流/mm	0.003 7	0.000 6	0.000 08
地下径流/mm	0.003 7	0.000 5	0.000 06
雷暴概率(TT,K)	0.000 2	0.023 9	0.000 16
K 指数/K	0.189 4	0.051 3	0.366 71
对流可用位能/(J/kg)	0.000 1	0.007 9	0.000 04

4.3 特征提取可视化分析

依托 Matla 仿真框架,基于 DeepLearn 工具箱与 Neural Network Toolbox,结合 drtoolbox 工具,完成了气象因子特征提取模型的仿真性能分析,经过若干次实验,渐进式调整模型参数,从而确定特征提取模型的理想参数组合,实验结果详见表 2。

表 2 参数确定
Tab. 2 Optimized parameter settings

参数类型	气象子网络
网络层数	3
各层神经元数	14-12-10
稀疏性参数	0.05
学习率	1
最大迭代次数	500
batchsize	32

根据电网事故(事件)的真实数据,不同自然灾害场景之间具有独立性,每次只对应一个事件(如雷害发生时不会伴随风害),且各类气象灾害场景不存在并发情况,因此以上气象灾害之间不存在交集。

该分类体系将气象场景归为雷害、风害、台风、暴雨、雪灾、覆冰以及污闪的七种灾害类型,各场景标签及其编码参见表 3。

表 3 气象场景分类
Tab. 3 Categorical taxonomy of weather patterns

气象灾害场景	场景标签	场景代码
雷害	1	1000000
风害	2	0100000
台风	3	0010000
暴雨	4	0001000
雪灾	5	0000100
覆冰	6	0000010
污闪	7	0000001

直接采集的数据往往具有高维属性,若未经过降维或特征提取处理,数据容易形成杂乱分布,SDAE 作为自编码器变体,采用深度堆叠架构,实现特征的无监督表示,初步训练过程已顺利实施,数据经历神经网络的编码及解码阶段,作为分类工具,Softmax 层具有普适性,生成各类别对应的概率分布,完成 Softmax 场景判定后,经过 SDAE 处理的特征分布可能更契合目标类别,特征边界呈现更高的可区分性,数据点可能展现出更强的聚集性,样本的类间分离性明显增强,可视化结果在图 10 和图 11 中给出。




图 10 SDAE 提取特征分布

Fig. 10 T-SNE projection of SDAE-encoded features distribution




图 11 SDAE + Softmax 提取特征分布

Fig. 11 T-SNE visualization of SDAE-encoded features with Softmax decision boundaries

在模型构建过程中,通过上述组合赋权法确定各气象因子的初始权重,随后将这些经过初始加权的气象因子输入降噪自编码器进行特征提取。在特征提取过程中,34 维气象因子的权重会随着模型迭代次数增加而进行动态调整优化,从而实现对不同气象因子重要性的自适应学习。利用降噪自编码器进行特征提取的结果表明,不同类型气象灾害的主导影响因子存在显著差异。

4.4 基于气象场景特征的预警模型

借助 Matlab 的仿真功能,对研究中电网气象灾害预警模型的可靠性加以验证,构建了一个采用堆叠自编码器深度学习架构的气象灾害分类预警模型,将数据集的 80% 随机采样作为训练集,网络测试采用 20% 数据量,训练阶段结束后,可对输入数据完成灾害种类判定,得出各气象灾害类型的概率估值,返回概率最大的气象灾害判定,输入对应算

例的气象初始输入,分析结果详见表 4。

表 4 训练集预测结果

Tab. 4 Performance metrics of training set predictions

气象灾害类型	训练集各气象灾害 预测正确率/%	训练集预测 正确率/%
雷害	85.1	97.9
风害	93.1	
台风	100	
暴雨	93.1	
雪灾	100	
覆冰	100	
污闪	100	

表 5 测试集预测结果

Tab. 5 Prediction result of independent test set

气象灾害类型	测试集各气象灾害 预测正确率/%	测试集预测 正确率/%
雷害	93.8	99.1
风害	94.1	
台风	100	
暴雨	100	
雪灾	100	
覆冰	100	
污闪	100	

从表 4 和表 5 看出,训练集预测精度达到 97.87%,测试集上的预测精度为 99.11%,仿真结果与实证结果高度相符,该方法可实现对高维度、强耦合的气象因子特征提取,实现对灾害性天气的预警。

该网络架构已实现气象数据的特征抽取及预测分析,把网络提取的特征组合成新的特征向量,采用 SVM 支持向量机建模,采用 SVM 建立气象因子与电网故障的数学模型,完成电网气象灾害故障的预测预警建模,由于故障模式种类繁多,需处理多类别划分,但原始 SVM 算法仅能实现二类判别,原生不支持多分类需求,为此本研究采用二叉树方案,采用三组支持向量机处理四种故障分类,进而实现预警模型的构建,模型架构详见图 12。




图 12 SVM 预警模型

Fig. 12 Support vector machine-based early warning model

文章主要针对由自然灾害引发的典型电网故障场景展开分析。根据某地区电网公司提供的运行数据,虽然实际中还存在着鸟害、施工破坏、山火、车辆撞击杆塔、设备自身质量问题等其他故障类型,但由于这些非自然灾害发生机理与自然灾害导致的故障存在本质差异,因此未纳入文章研究范畴。根据电网事故(事件)的真实数据,不同故障场景之间具有独立性,各类电网故障不存在并发情况(如发生短路故障时不会同时出现绝缘闪络),故障之间不存在交集。

该分类体系将电网故障划分为断线、杆塔倒塌、短路与闪络四个主要类别,各场景类型对应的代码信息参见表 6。

表 6 故障类型场景分类

Tab. 6 Scenario classification for power grid failure modes

故障场景	场景标签	场景代码
断线	1	1000
杆塔倒塌	2	0100
短路	3	0010
闪络	4	0001

采用预处理完成的各类致灾因子数据作为输入,利用网络架构进行因子特征挖掘,进而挖掘场景特征与电网故障的潜在联系,并统计各类故障的潜在发生频率,系统最终呈现电网故障的判别结果,预测因气象灾害产生的电网故障,预测结果的量化分析见表 7。

表 7 故障集预测结果

Tab. 7 Performance evaluation for contingency prediction

故障类型	各故障预测正确率/%	故障集预测正确率/%
断线	95.7	93.02
杆塔倒塌	96.7	
短路	87.7	
闪络	100	

电网故障预测的正确性为 93.02%,仿真结果与真实数据基本吻合,此处展示测试集事件样本的实例,论述 Matlab 仿真测试结果。采用该电网地区 4 起典型故障案例,基于概率比较的故障类型仿真分析,判定最高频次的故障模式,统计输出见表 8~表 11。可见,预测输出与实际情况高度契合。

表 8 典型事件预测结果(事件 1)

Tab. 8 Typical event forecasting result (Event 1)

场景类型	故障标签	灾害概率/%	预测结果	实际事件
断线	1000	83.65	断线	雪灾引起的断线故障
杆塔倒塌	0100	2.73		
短路	0010	12.07		
闪络	0001	1.54		

表 9 典型事件预测结果(事件 2)

Tab. 9 Typical event forecasting result (Event 2)

场景类型	故障标签	灾害概率/%	预测结果	实际事件
断线	1000	1.99	杆塔倒塌	利奇马台风引起的杆塔倒塌
杆塔倒塌	0100	93.32		
短路	0010	4.04		
闪络	0001	1.65		

表 10 典型事件预测结果(事件 3)

Tab. 10 Typical event forecasting result (Event 3)

场景类型	故障标签	灾害概率/%	预测结果	实际事件
断线	1000	2.38	短路	雷害引起的 A 相短路
杆塔倒塌	0100	8.47		
短路	0010	87.71		
闪络	0001	1.45		

表 11 典型事件预测结果(事件 4)

Tab. 11 Typical event forecasting RESULT (Event 4)

场景类型	故障标签	灾害概率/%	预测结果	实际事件
断线	1000	2.75	闪络	污闪引起的绝缘子闪络
杆塔倒塌	0100	3.54		
短路	0010	5.45		
闪络	0001	88.27		

5 结论

提出一种稀疏自编码器结合支持向量机的电网气象故障预警方案,运用稀疏自编码器对气象灾害数据进行特征挖掘,采用 BP 神经网络进行气象灾害预测,采用 SVM 技术建立致灾因子-电网故障耦合关系模型,进而实现对不同气象灾害背景下电网故障的预测,由此得出如下推断:

- 1) 为解决样本分布不均现象,采用 SMOTE 过采样技术改善数据集不平衡状况,以此增强故障判定的可靠性;
- 2) 利用最小信息熵准则确定气象因子的初始权重,可明显改善模型的收敛效率;
- 3) 稀疏自编码器可对气象因子特征实现有效

提取,结合 BP 算法可实现对自然灾害的精确预测;

4)应用 SVM 方法可系统分析气象特征与电网故障的关联机制及规律,实现电网故障类型的精准预判。

参 考 文 献

- [1] 余宏晖,林声宏,朱建全,等. 基于深度强化学习的微电网在线优化[J]. 电测与仪表, 2024, 61(4): 9-14.
YU Honghui, LIN Shenghong, ZHU Jianquan, et al. On-line optimization of micro-grid based on deep reinforcement learning[J]. Electrical Measurement & Instrumentation, 2024, 61(4): 9-14.
- [2] 欧阳金鑫,张澳归,蒋航,等. 基于深度置信网络的电网安全稳定控制系统故障诊断方法[J]. 电测与仪表, 2024, 61(7): 1-6.
OUYANG Jinxin, ZHANG Aogui, JIANG Hang, et al. Fault diagnosis method for power grid security and stability control system based on deep belief network[J]. Electrical Measurement & Instrumentation, 2024, 61(7): 1-6.
- [3] 谢强,李杰. 电力系统自然灾害的现状与对策[J]. 自然灾害学报, 2006, 15(4): 126-131.
XIE Qiang, LI Jie. Current situation and countermeasures of natural disasters in power systems[J]. Journal of Natural Disasters, 2006, 15(4): 126-131.
- [4] 魏韬,刘锐,沈平,等. 基于电力大数据的输电线路防灾减灾分析系统设计——以贵州电网为例[J]. 灾害学, 2016, 31(1): 135-138.
GUO Tao, LIU Rui, SHEN Ping, et al. Design of disaster prevention and mitigation analysis system for transmission lines based on power big data: A case study of Guizhou power grid[J]. Journal of Catastrophology, 2016, 31(1): 135-138.
- [5] 张大海,张晓炜,孙浩,等. 基于卷积神经网络的交直流输电系统故障诊断[J]. 电力系统自动化, 2022, 46(5): 132-145.
ZHANG Dahai, ZHANG Xiaowei, SUN Hao, et al. Fault diagnosis of AC/DC transmission system based on convolutional neural network[J]. Automation of Electric Power Systems, 2022, 46(5): 132-145.
- [6] 李峰,陈皖皖,李晓华,等. 基于 SVM-DCMSE 与 GSA-SVM 的新型电力系统变压器故障状态智能诊断方法[J]. 电测与仪表, 2024, 61(12): 17-25.
LI Feng, CHEN Wanwan, LI Xiaohua, et al. Intelligent fault diagnosis method for transformer in new power system based on SVM-DCMSE and GSA-SVM[J]. Electrical Measurement & Instrumentation, 2024, 61(12): 17-25.
- [7] 王洋,李江,张婧,等. 基于气象因素的 Stacking 回归模型的短期负荷预测方法[J]. 电工技术, 2024(17): 67-70.
WANG Yang, LI Jiang, ZHANG Jing, et al. Short-term load forecasting method based on meteorological factors using Stacking regression model[J]. Electrical Engineering, 2024(17): 67-70.
- [8] 李瀚儒,刘智健,来立永,等. 考虑气象参数预测误差条件分布的架空输电线路载流量概率预测方法[J]. 中国电力, 2024, 57(2): 103-114.
LI Hanru, LIU Zhijian, LAI Liyong, et al. Current-carrying capacity probability prediction of overhead transmission line considering conditional distribution prediction errors of meteorological parameters[J]. Electric Power, 2024, 57(2): 103-114.
- [9] 杨秋玉,旷树森,郑小刚,等. 基于 NPMA-LSSVM 算法的不平衡小类样本情况下中短期负荷预测[J]. 电测与仪表, 2025, 62(5): 158-168.
YANG Qiuyu, KUANG Shusen, ZHENG Xiaogang, et al. Medium and short-term load forecasting under imbalanced small-class samples based on NPMA-LSSVM algorithm[J]. Electrical Measurement & Instrumentation, 2025, 62(5): 158-168.
- [10] 李立生,刘洋,卢文华,等. 基于稀疏自编码的故障数据聚类清洗方法[J]. 科学技术与工程, 2021, 21(15): 6330-6336.
LI Lisheng, LIU Yang, LU Wenhua, et al. Fault data clustering and cleaning method based on sparse autoencoder[J]. Science Technology and Engineering, 2021, 21(15): 6330-6336.
- [11] 董彦军,王晓甜,马红明,等. 基于随机森林与长短期记忆网络的电力负荷预测方法[J]. 全球能源互联网, 2022, 5(2): 147-156.
DONG Yanjun, WANG Xiaotian, MA Hongming, et al. Power load forecasting method based on random forest and long short-term memory[J]. Journal of Global Energy-Interconnection, 2022, 5(2): 147-156.
- [12] 朱晔,王海涛,吴念,等. 输电线路覆冰在线监测动态预警模型[J]. 高电压技术, 2014, 40(5): 1374-1381.
ZHU Ye, WANG Haitao, WU Nian, et al. Dynamic early-warning model for transmission line icing on-line monitoring[J]. High Voltage Engineering, 2014, 40(5): 1374-1381.
- [13] 翁世杰. 架空输电线路大风灾害预警方法研究[D]. 重庆:重庆大学, 2015.
WENG Shijie. Research on early warning methods for wind disaster of overhead transmission lines[D]. Chongqing: Chongqing University, 2015.
- [14] 张慕婕. 基于气象关联分析的绝缘子污闪风险评估[D]. 武汉:华中科技大学, 2017.
ZHANG Mujie. Risk assessment of insulator pollution

- flashover based on meteorological correlation analysis[D]. Wuhan: Huazhong University of Science and Technology, 2017.
- [15] 任明, 李乾宇, 夏昌杰, 等. 基于稀疏光谱成像的线路复合绝缘子积污状态可视化评估[J]. 中国电力, 2025, 58(2): 203-215.
- REN Ming, LI Qianyu, XIA Changjie, et al. Visualized estimation of composite insulator pollution status of transmission line based on reflective Multi-spectral imaging[J]. Electric Power, 2025, 58(2): 203-215.
- [16] 熊小伏, 王尉军, 于洋, 等. 多气象因素组合的输电线路风险分析[J]. 电力系统及其自动化学报, 2011, 23(6): 11-15, 28.
- XIONG Xiaofu, WANG Weijun, YU Yang, et al. Risk analysis of transmission lines based on combined meteorological factors[J]. Proceedings of the CSU-EPSA, 2011, 23(6): 11-15, 28.
- [17] 汪颖, 雷蕾, 胡文曦, 等. 基于自适应关联规则挖掘的雷击-电压暂降严重程度预估[J]. 电测与仪表, 2025, 62(7): 190-199.
- WANG Ying, LEI Lei, HU Wenxi, et al. An estimation method of lightning-voltage sag severity based on adaptive association rule mining[J]. Electrical Measurement & Instrumentation, 2025, 62(7): 190-199.
- [18] 马富齐, 李佳乐, 贾嵘, 等. 基于双边特征融合语义分割的输电线路覆冰类型精细辨识方法[J]. 智慧电力, 2025, 53(10): 17-25.
- MA Fuqi, LI Jiale, JIA Rong, et al. A fine identification method for transmission line ice coating types based on bilateral feature-fused semantic segmentation[J]. Smart Power, 2025, 53(10): 17-25.
- [19] 王建. 输电线路气象灾害风险分析与预警方法研究[D]. 重庆: 重庆大学, 2016.
- WANG Jian. Research on risk analysis and early-warning methods for meteorological disasters of transmission lines[D]. Chongqing: Chongqing University, 2016.
- [20] 李明君. 电网灾害风险预警分析系统设计与实现[D]. 成都: 电子科技大学, 2020.
- LI Mingjun. Design and implementation of power grid disaster risk early-warning analysis system[D]. Chengdu: University of Electronic Science and Technology of China, 2020.
- [21] 徐安馨. 基于场景分类识别的电网气象灾害预警方法[D]. 济南: 山东大学, 2021.
- XU Anxin. Meteorological disaster early-warning method for power grids based on scenario classification and recognition[D]. Jinan: Shandong University, 2021.
- [22] 麻宁杰, 王华昕, 汤波, 等. 新型电力系统下架空输电线路受极端天气影响的风险评估与运维决策[J]. 电测与仪表, 2025, 62(11): 95-102.
- MA Ningjie, WANG Huaxin, TANG Bo, et al. Risk assessment and operation and maintenance decision of overhead transmission lines affected by extreme weather in novel power system[J]. Electrical Measurement & Instrumentation, 2025, 62(11): 95-102.
- [23] 黄俊杰, 谭波, 陈孝明, 等. 用Apriori关联规则挖掘算法发现湖北电网雷击灾害的时空分布规律[J]. 应用科学学报, 2017, 35(1): 31-41.
- HUANG Junjie, TAN Bo, CHEN Xiaoming, et al. Discovering spatiotemporal distribution patterns of lightning disasters in Hubei power grid using Apriori association rule mining algorithm[J]. Journal of Applied Sciences, 2017, 35(1): 31-41.
- [24] MA G Y, YUE X F, GAO X L, et al. Application of an improved sparrow search algorithm in BP network classification of strip steel surface defect images[J]. Multimedia Tools and Applications, 2022, 82(10): 14403-14439.
- [25] RAO C J, LIU Y, GOH M. Credit risk assessment mechanism of personal auto loan based on PSO-XG boost model[J]. Complex & Intelligent Systems, 2022, 9(2): 1391-1414.
- [26] 周峰, 赵敏, 郑毅. 基于SAE和迁移学习的电能表异常用电检测[J]. 电子测量与仪器学报, 2024, 38(1): 112-120.
- ZHOU Feng, ZHAO Min, ZHENG Yi. Abnormal electricity consumption detection for energy meters based on SAE and transfer learning[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(1): 112-120.

收稿日期: 2025-06-04; 修回日期: 2026-02-01

作者简介:

方圆圻(1989—),女,硕士,高级工程师,研究方向为电力安全管理。E-mail:739113279@qq.com

任茂鑫(1992—),男,硕士,工程师,研究方向为高电压技术、电网安全监督。E-mail:rmx92825@163.com

葛乃成(1980—),男,硕士,高级工程师,研究方向为电网安全监督、电力系统。E-mail:739113279@qq.com

李昊雨(2000—),男,通信作者,硕士研究生,研究方向为基于气象因素的电网事故分析及预警。
E-mail:854264723@qq.com

杨秀(1972—),男,博士,教授,博士生导师,研究方向为分布式发电与微电网技术。
E-mail:yangxiu721102@126.com

(编辑 田春雨)