

DOI: 10.19783/j.cnki.pspc.226423

基于深度稀疏自编码网络和场景分类器的 电网气象故障预警方法

胡凉平¹, 丛伟¹, 徐安馨², 魏振³, 邱吉福³, 陈明³

(1. 电网智能化调度与控制教育部重点实验室(山东大学), 山东 济南 250061; 2. 国网山东省电力公司日照供电公司, 山东 日照 276800; 3. 国网山东省电力公司青岛供电公司, 山东 青岛 266001)

摘要: 为保证电网安全稳定运行, 提高电网防灾减灾和弹性水平, 提出了一种基于深度稀疏自编码网络和场景分类器的电网气象故障预警方法。首先, 采用主客观权重相结合的动态赋权方法, 对气象因子进行初始赋权, 以合理表征不同气象因子对电网故障的影响程度。然后, 对传统的深度自编码网络增加稀疏性约束条件, 以提高网络训练的收敛性, 并在深度自编码网络的最后一层增加场景分类器, 以提高气象因子与电网故障场景间关联关系的合理性。最后, 将带权重的气象因子以及设备因子和环境因子作为深度稀疏自编码网络的输入, 利用支持向量机构建多因素耦合的电网气象灾害故障预警模型。采用实际电网故障算例验证了所提方法的有效性。

关键词: 电网气象故障; 预警方法; 动态组合权重; 场景分类器; 深度稀疏自编码网络

Early warning method for a power grid fault caused by meteorology based on a deep sparse auto-encoder network and scene classifier

HU Liangping¹, CONG Wei¹, XU Anxin², WEI Zhen³, QIU Jifu³, CHEN Ming³

(1. Key Laboratory for Power System Intelligent Dispatching and Control (Shandong University), Jinan 250061, China;

2. Rizhao Power Supply Company, State Grid Shandong Electric Power Company, Rizhao 276800, China;

3. Qingdao Power Supply Company, State Grid Shandong Electric Power Company, Qingdao 266001, China)

Abstract: In order to ensure the safe and stable operation of the power grid and improve the level of disaster prevention, mitigation and resilience of the grid, this paper proposes an early warning method for power grid meteorological faults based on a deep sparse self-encoding network and a scene classifier. First, this paper adopts a dynamic weighting method combining subjective and objective weights to initially weight meteorological factors to reasonably describe the influence of different meteorological factors on power grid faults. Then, a sparsity constraint is added to the traditional deep self-encoding network to improve the convergence of network training, and a scene classifier is added to the last layer of the deep self-encoding network to improve the rationality of the relationship between meteorological factors and power grid fault scenarios. Finally, the meteorological factors which are dynamic weighted, equipment factors and environmental factors are used as the input of a deep sparse self-encoding network, and a support vector machine is used to build a multi-factor coupled grid meteorological disaster fault early warning model. The effectiveness of the method is verified by an actual power grid fault example.

This work is supported by the Science and Technology of State Grid Corporation of China (No. 52060019001H).

Key words: power grid fault caused by meteorology; early warning method; dynamic combination of weights; scene classifier; deep sparse auto-encoder network

0 引言

电网覆盖面积越来越广, 输电线路跨度增大,

众多设备长期暴露在外界环境中, 非常容易遭受自然灾害和其他因素的影响而导致故障。气象因素是导致电网故障的主要诱因之一, 具有影响面广、故障损失大、对电网影响严重等特点。开展电网气象故障预警方法研究, 可提高电网故障发生时的应对

基金项目: 国家电网公司科技项目资助(52060019001H)

能力和处置能力,有助于提高电网的弹性水平。

电网气象故障具有影响因子类型多、数量多和因子间耦合关系复杂等特点,雷电、山火、台风等极端气象灾害给电网的正常运行带来了极大的威胁和挑战,极易造成电网大面积停电事故^[1-6]。文献[7]利用风速风向的联合分布和概率统计的方法计算电力断线倒塔的概率,对风灾条件下的断线倒塔进行预警;文献[8]提出了一种基于时间序列分析与卡尔曼滤波算法的线路覆冰短期预测模型,减少了微气象因素对预测精度的影响;文献[9]结合舞动运动方程、气象信息及故障信息,计算了覆冰导线舞动导致线路跳闸的概率;文献[10]基于实时雷电定位数据提出了输电线路防雷评估模型和高风险雷暴评估模型,进行紧密输电通道的连续雷击跳闸预警;文献[11]对导致输电走廊山火灾害的14类因子进行重要程度排序,并利用朴素贝叶斯网络搭建了山火风险评估模型;文献[12]构建了面向台风气象的电网运行风险态势指标体系,对台风灾害下的电网故障进行风险预测。

上述研究都是针对单一气象或灾害条件对电网的影响,但电网在运行中会受到多种气象因素的影响,单一因素不能全面反映气象与电网灾害的关联关系。

文献[13]针对电网故障的时空分布特性,采用BP神经网络,构建了基于季节气候、地形地貌及自然灾害等因素的电力系统安全状态预警系统;文献[14]通过分析恶劣天气下电网连锁故障的产生机理,提出了恶劣天气下复杂电网连锁故障在线预警模型;文献[15]基于大数据处理集群技术,以朴素贝叶斯算法结合时间序列相似性故障匹配的方法建立输电线路故障预警模型。文献[16]提出对电网资源和气象数据进行网格化表达,直观展示气象对电网影响的时空分布;文献[17]建立了基于区块链技术的电网自然灾害预警系统,实现了线路故障预警。以上方法考虑了多类因素的影响,但故障预测的准确性还需要进一步提升。

人工智能技术在电力系统负荷预测、设备异常诊断、系统态势感知等领域获得了广泛应用^[18-19]。深度学习作为人工智能的一个分支,可有效解决高维复杂数据挖掘以及特征提取等难题,同时还可弥补传统机器学习算法存在的训练数据不足、泛化能力差等问题^[20-21]。文献[22]利用条件生成对抗网络进行样本集扩充,建立Dense-YOLOv3网络对输电线路异物入侵进行识别;文献[23]提出了一种GRA和LSTM相结合的区域综合能源系统多元负荷短期预测模型,预测误差明显下降;文献[24]利用Faster

R-CNN网络进行绝缘子目标检测,检测准确率达到96%;文献[25]利用GA-DBN模型感知电网暂态安全状态,具有较高的准确率;文献[26]利用随机森林算法进行特征降维,然后利用LSTM网络进行风电功率预测,可提高预测准确率。文献[27]利用CycleGAN进行输电线路巡检图像数据集扩充,将MobileNet网络的模型进行迁移学习并进行有监督微调,提高了输电线路物体识别的匹配度。

本文将场景分类器和深度稀疏自编码网络(deep sparse auto-encoder, DSAE)相结合,提出了基于DSAE的电网气象故障预警方法。利用DSAE表征各因子间的复杂耦合关系,基于有标签的数据样本采用场景分类器对模型参数进行有监督微调,并根据指标权重动态变化的特点对气象因子进行组合赋权,突出高影响气象因子,加快网络训练收敛速度,提高预警方法的准确性。

1 气象因子权重的组合赋权法

导致电网气象故障的气象因子种类繁多,耦合关系复杂。若直接利用已有的自编码网络对气象因子进行处理,可能会出现收敛速度慢、数据过拟合、学习效果存在偏差等问题,因此需要基于历史数据对气象因子确定初始权重。

1.1 基于G1法的主观赋权

设 $x_1, x_2, x_3, \dots, x_n$ 是多指标体系中的 n 个指标。如果评价指标 x_i 的重要程度比 x_j 高,记作 $x_i \geq x_j$ 。当评价指标 $x_1, x_2, x_3, \dots, x_n (n \geq 2)$ 满足 $x_1 \geq x_2 \geq \dots \geq x_n$ 时,称 $x_1, x_2, x_3, \dots, x_n$ 建立了序关系,然后对各指标的重要程度进行定量分析,定量求取方法如式(1)所示。

$$w_{1k-1} / w_{1k} = r_k \quad (1)$$

$$(k = n, n-1, n-2, \dots, 3, 2)$$

式中: w_{1k} 为第 k 个指标的主观权重; w_{1k-1} 为第 $k-1$ 个指标的主观权重; r_k 表示相邻两个指标 x_{k-1} 与 x_k 之间的重要程度比。 r_k 的取值如表1所示。

表1 指标间相对重要程度 r_k 的说明

Table 1 Explanation of the relative importance r_k between indicators

r_k	说明
1.0	x_{k-1} 与 x_k 同样重要
1.1	x_{k-1} 比 x_k 介于同样重要和稍微重要之间
1.2	x_{k-1} 比 x_k 稍微重要
1.3	x_{k-1} 比 x_k 介于稍微重要和明显重要之间
1.4	x_{k-1} 比 x_k 明显重要
1.5	x_{k-1} 比 x_k 介于明显重要和强烈重要之间
1.6	x_{k-1} 比 x_k 强烈重要
1.7	x_{k-1} 比 x_k 介于强烈重要和极端重要之间
1.8	x_{k-1} 比 x_k 极端重要

基于专家给出的 r_k 主观赋值, 指标 x_n 的主观权重 w_{1n} 及其余指标的主观权重 $w_{11} \sim w_{1k-1}$ 求取方法如式(2)所示。

$$\begin{cases} w_{1n} = \left(1 + \sum_{k=2}^n \prod_{i=k}^n r_i\right)^{-1} \\ w_{1k-1} = r_k w_{1k} \\ (k = n, n-1, n-2, L, 3, 2) \end{cases} \quad (2)$$

1.2 基于熵权法的客观赋权

熵权法是一种客观赋权方法, 用熵来衡量数据或样本所包含的有用信息, 用熵权法构建一个初始评价矩阵。假设评价对象有 m 个样本对象, 每个评价对象有 n 个评价指标, 则可以构成 $m \times n$ 维初始评价矩阵 \mathbf{R} 。

$$\mathbf{R} = (r_{ij})_{m \times n} \quad (3)$$

式中, r_{ij} 为第 i 个评价对象的第 j 个指标的量值。根据式(4)计算 p_{ij} 。

$$p_{ij} = r_{ij} / \sum_{i=1}^m r_{ij} \quad (4)$$

式中, p_{ij} 代表 r_{ij} 在 m 个评价对象中第 i 个评价对象的第 j 个指标所占的特征比重。由 p_{ij} 即可根据式(5)、式(6)计算第 j 个指标的信息熵 H_j 和熵权 w_{2j} 。

$$H_j = - \left(\sum_{i=1}^m p_{ij} \ln p_{ij} \right) / \ln m \quad (5)$$

$$w_{2j} = (1 - H_j) / \sum_{i=1}^n (1 - H_j) \quad (6)$$

式中, 熵权 w_{2j} 即为第 j 个指标的客观权重。在同一样本中, 当指标的数值差距越大时, 说明提供的有效信息越多, 熵值越小, 熵权越大, 反之亦然。

1.3 主客观组合赋权及权重修正

主观赋权法受专家经验和人为意愿的影响而带有一定的主观随意性; 客观赋权法得到的权重没有将专家经验和决策者倾向纳入考虑范围内, 得出的权重值可能与实际情况不符。本文将主、客观权重进行综合得到气象因子组合权重, 最后根据气象因子的状态将其分为 4 个等级, 每个等级对应一个状态权重, 通过状态权重来对主、客观组合权重进行修正, 得到对气象因子即时状态进行修正后的动态组合权重。

首先运用最小信息熵原理对主观权重和客观权重进行组合。

$$\min F = \sum_{i=1}^n w_{zi} (\ln w_{zi} - \ln w_{1i}) + \sum_{i=1}^n w_{2i} (\ln w_{zi} - \ln w_{2i}) \quad (7)$$

用拉格朗日乘子算法计算组合权重为

$$w_{zi} = (w_{1i} w_{2i})^{1/2} / \sum_{i=1}^n (w_{1i} w_{2i})^{1/2}, \quad i = 1, 2, L, n \quad (8)$$

式中: w_{zi} 为由主、客观组合赋权得到的第 i 个气象因子的组合权重; w_{1i} 为由主观赋权得到的第 i 个气象因子的主观权重; w_{2i} 为由熵权法得到的第 i 个气象因子的客观权重。

根据气象评价标准(GB/T 33680-2017、GB/T 36542-2018 等), 将每个气象因子状态分为 4 个等级, 划分方法见表 A1。限于篇幅, 表 A1 仅展示部分常用的气象因子。每个等级对应一个状态权重, 该权重可由 G1 法获得, 如表 2 所示。当获取到各因子的实际值后, 即可确定相应的状态等级及对应的状态权重, 然后对组合权重进行修正, 得到该气象因子经动态修正后的权重。

表 2 因子状态权重确定

因子编号	状态等级	排序依据	重要性定量	k	状态权重
X_1	4	非常重要	—	—	0.506 94
X_2	3	比较重要	1.8	2	0.266 81
X_3	2	一般重要	1.8	3	0.148 23
X_4	1	不重要	1.1	4	0.078 02

对主客观组合权重进行修正, 如式(9)所示。

$$\begin{cases} w_i = F(w_{zi} + w_{pi}) = \\ (\alpha w_{zi} + (1 - \alpha) w_{pi}) / \sum_{i=1}^n (\alpha w_{zi} + (1 - \alpha) w_{pi}) \\ i = 1, 2, L, n \end{cases} \quad (9)$$

式中: w_i 为状态权重修正后第 i 个气象因子的动态组合权重; w_{pi} 为由状态等级表所确定的第 i 个气象因子的状态权重; α 为修正系数, 本文取 $\alpha = 0.5$ 。

动态组合赋权既可以保留专家经验, 又可以反映评价对象中客观数据对决策的贡献度, 并保存了罕见高影响性因子的重要状态属性, 有助于提高评价结论的合理性。

2 带场景分类的深度稀疏自编码网络

电网气象因子具有高维度、耦合情况复杂等特点, 与电网故障的关系难以采用数学模型解析表达。本文采用具有自学习能力的 DSAE, 结合具有气象灾害场景标签的分类器, 来表征气象因子与电网故障之间的映射关系, 实现电网气象灾害故障的准确预测。

2.1 稀疏自编码网络

稀疏自编码器(sparse auto-encoder, SAE)是对传

统自编码器(auto-encoder, AE)的隐藏层神经元增加稀疏性约束,使大多数隐藏层神经元被抑制,以此来控制隐藏层神经元激活的数量,减少学习过程中的冗余信息,通过稀疏的表达有效提取输入信号的特征,实现对输入信号特征的有效提取和准确表达^[28]。稀疏性约束通过在自编码器的损失函数中添加稀疏惩罚项的方式来实现。

对于输入信号为 $x = \{x_1, x_2, x_3, \dots, x_n\}$ 的样本,当样本数量为 N 时,用 $\alpha_j(x)$ 来表示隐藏层第 j 个神经元对于输入 x 的激活度,在整个训练过程中,隐藏层第 j 个神经元的平均激活度可以用式(10)计算。

$$\rho_j = \left(\sum_{i=1}^N \alpha_j(x^{(i)}) \right) / N \quad (10)$$

式中, $\sum_{i=1}^N \alpha_j(x^{(i)})$ 为第 i 个样本中隐藏层第 j 个神经元对输入 x 的激活度。通过设置稀疏性参数 ρ , 一般取 $\rho = 0.05$, 将隐藏层神经元 j 的平均激活度控制在一个接近于 0 的数值,以保证隐藏层神经元具有稀疏性。在网络的损失函数上添加一个稀疏惩罚项,对平均激活度 ρ_j 偏离稀疏性参数 ρ 较大的情况进行惩罚。本文选择基于 KL 散度的函数作为惩罚约束项^[29], 其表达式为

$$\text{KL}(\rho \mathbf{P} \rho_j) = \rho \ln(\rho / \rho_j) + (1 - \rho) \ln[(1 - \rho) / (1 - \rho_j)] \quad (11)$$

式中: ρ_j 为隐藏层神经元 j 的平均激活度; ρ 为可以设置的隐藏层神经元稀疏性参数。当 $\rho_j = \rho$ 时, KL 散度 $\text{KL}(\rho \mathbf{P} \rho_j) = 0$, 当 ρ_j 接近于 1, KL 散度的数值趋于 ∞ 。这样就可以控制隐藏层神经元的激活数量,实现隐藏层神经元的稀疏性约束。

SAE 的网络损失函数如式(12)所示。

$$J_{\text{SAE}}(\theta) = J_{\text{AE}}(\theta) + \beta \sum_{j=1}^s [\text{KL}(\rho \mathbf{P} \rho_j)] + \left[\gamma \cdot \sum_{l=1}^2 \sum_{i=1}^s \sum_{j=1}^{s+1} (w_{ij}^{(l)})^2 \right] / 2 \quad (12)$$

式中: $J_{\text{AE}}(\theta)$ 为 AE 的损失函数; θ 为网络参数的集合; β 为稀疏性惩罚约束项的权重; s 为整个隐藏层神经元的数量; l 为网络层数; γ 为该衰减项所占的比重; 最后一项是为了防止自编码器过拟合而加入的权重衰减项; $w_{ij}^{(l)}$ 表示第 l 层第 j 个神经元与第 $l+1$ 层第 i 个神经元之间的权重。

2.2 场景分类器构造

针对电网气象灾害场景较多这一特点,本文选择用于多元分类的 Softmax 分类器作为场景分类

器,进行电网气象灾害的场景识别。该分类器可以最大化提取数据特征,并对分类输出进行归一化处理,将其映射为每一个类别的概率取值。

设 $\{X_1, X_2, \dots, X_m\}$ 是输入的训练样本集, $\{y_1, y_2, \dots, y_m\}$ 为该样本集中每个样本所对应的类别标签,且 $y_i \in \{1, 2, \dots, r\}$, r 代表总的分类数。当给定输入 $X_i (1 \leq i \leq m)$ 时,可用假设函数 $h_\lambda(x)$ 计算每个类别的概率值,如式(13)所示。

$$h_\lambda(x) = \begin{bmatrix} p(y_i = 1 | X_i; \lambda) \\ p(y_i = 2 | X_i; \lambda) \\ \mathbf{M} \\ p(y_i = r | X_i; \lambda) \end{bmatrix} = \begin{bmatrix} e^{\lambda_1^T X_{(i)}} \\ e^{\lambda_2^T X_{(i)}} \\ \mathbf{M} \\ e^{\lambda_r^T X_{(i)}} \end{bmatrix} / \sum_{i=1}^r e^{\lambda_j^T X_{(i)}} \quad (13)$$

式中: $\lambda_1, \lambda_2, \dots, \lambda_r \in \mathbf{R}^n$ 是模型的基本参数; y_i 表示样本类别; $X_i (1 \leq i \leq m)$ 表示样本类别 y_i 对应的输入训练样本; $p(y_i = 1 | X_i; \lambda)$ 表示在给定输入 $X_i (1 \leq i \leq m)$ 的条件下 $y_i = 1$ 的概率,其中参数为 λ 。

X_i 属于第 k 类 $1 \leq k \leq r$ 样本类别的概率,可以通过式(14)计算。

$$p(y_i = k | X_i) = e^{\lambda_k^T X_{(i)}} / \sum_{j=1}^r e^{\lambda_j^T X_{(i)}} \quad (14)$$

由此便完成场景分类器的构造。

2.3 深度稀疏自编码网络的建立

DSAE 由多个 SAE 堆叠而成,除作为输入层的自编码器外,其他每一层的输入都是由其上一层的输出组成,确定网络损失函数后,可以通过网络训练来优化该目标函数,获得具有良好特征提取能力的深度网络模型。DSAE 网络模型如图 A1 所示。

DSAE 可通过逐层贪婪的无监督预训练,对输入气象因子的特征进行初步提取,但由于训练过程是无监督的,网络具有很大的自主性,此时提取的特征主要用来实现输出对输入的重构,难以与电网气象灾害有效关联。

本文在 DSAE 的最后一层构造场景分类器,通过有监督的学习方式,利用带有气象灾害场景标签的数据样本对网络参数进行针对性微调,以此来建立气象因子与电网气象灾害之间的关联关系,使网络对输入气象因子的知识学习更加符合电网气象灾害的各类场景特征。

3 电网气象故障预警方法

3.1 气象因子特征提取方法

DSAE 首先采用逐层贪婪无监督算法进行预训练,然后基于场景分类器结合反向传播算法,对深度稀疏自编码网络进行有监督微调,使各层提取的

数据特征符合电网气象灾害场景。

3.1.1 无监督预训练

利用经过组合赋权的气象因子来训练 DSAE, 对数据进行逐层降维, 并优化网络各层之间的权重和偏置向量, 使降维后的数据与输入尽可能一致。利用重构误差函数得到损失函数, 采用梯度下降算法对网络参数进行调整直至损失函数值越来越小。无监督预训练的流程如图 1 所示。

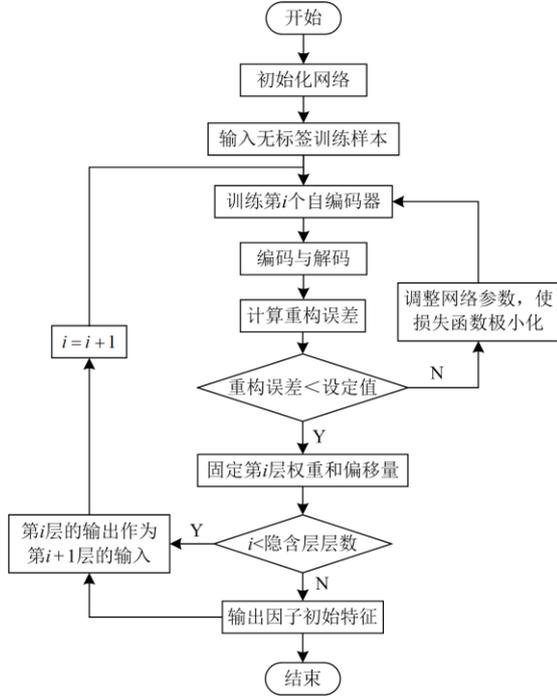


图 1 无监督预训练流程图

Fig. 1 Flowchart of unsupervised pre-training

DSAE 逐层贪婪预训练过程, 实际就是对输入因子进行特征学习的过程。首先用原始无标签数据训练第一层自编码器, 提取出比原始输入更稳定、抽象的特征表达, 然后依次类推, 用第 i 层的输出作为第 $i+1$ 层的输入来进行训练。通过多层自编码器不断堆叠学习, 最终实现对输入信号特征的提取。

3.1.2 场景分类器有监督的因子特征提取

无监督预训练只能初步建立气象因子间的关联关系, 要得到气象因子与电网灾害间的特定耦合关系还需要对网络进行微调。在网络最后一层添加场景分类器, 将最后一层自编码器的输出作为场景分类器的输入, 利用 BP 算法对网络各层连接权重和偏置量进行优化更新, 通过使损失函数值达到最小来实现相应场景下特征的有效提取, 得到与电网气象灾害相关联的深度特征提取网络, 过程如下:

1) 在预训练的基础上, 输入带有气象场景标签

的样本集, 对整个网络的权值进行调整, 得到各个隐含层上的激活值 h 。

2) 输出层的残差为

$$\delta^{(n)} = -(\nabla_{a^{(n)}} J) g f'(h^{(n)}) \quad (15)$$

式中: $h^{(n)}$ 是第 n 个隐藏层的激活值; $\nabla_{a^{(n)}} J = \theta^T(I - P)$, 其中 θ 为网络参数的集合, I 为输入样本对应的类别标签, P 为条件概率向量。

3) 对于 $l = n-1, n-2, \dots, 2$ 层, 各层的残差为

$$\delta^{(l)} = ((W^{(l)})^T \delta^{(l+1)}) g f'(h^{(l)}) \quad (16)$$

式中, $(W^{(l)})^T$ 是第 l 层网络数值矩阵的转置。

4) 计算得到各层对应的偏导数为

$$\begin{cases} \nabla_{W^{(l)}} J(W, b) = \delta^{(l+1)} (h^{(l)})^T \\ \nabla_{b^{(l)}} J(W, b) = \delta^{(l+1)} \end{cases} \quad (17)$$

利用式(17), 就可以微调得到整个网络的参数。通过场景分类器完成有监督微调的 DSAE 具备了良好的气象因子特征提取能力, 通过网络参数的非线性组合建立气象因子与电网灾害场景间的关联关系。

3.2 基于气象特征的电网故障预警

本文将 DSAE 提取的气象特征与设备因子、环境因子串联形成一个新的特征向量, 输入到支持向量机(support vector machine, SVM)中, 利用 SVM 建立 3 类致灾因子与电网故障间的关联关系, 构建一个多因素复合的电网气象灾害故障预警模型。SVM 通过在高维空间中找到一个最优平面来将训练样本 $(x_i, y_i) (i=1, 2, \dots, L, n)$ 区分开, 其中 x_i 为样本输入, y_i 为样本输出。该超平面表达式为

$$W \cdot \psi(x_i) + b = 0 \quad (18)$$

式中: W 为样本权重矩阵; b 为阈值; ψ 为目标函数。

SVM 通过对目标函数最小化来寻找最优超平面, 如式(19)所示。

$$\begin{cases} \min \psi(W, \zeta_i) = \|W\|^2 / 2 + C \zeta_i \\ \text{s.t. } (W \cdot \psi(x_i) + b) - 1 + \zeta_i \geq 0, \zeta_i \geq 0 \end{cases} \quad (19)$$

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

$$f(x) = \text{sgn} \left(\sum_{i=1}^n \alpha_i y_i K(x_i, x_j) + b^* \right) \quad (20)$$

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, 本文选择 RBF 核函数, 表达式为

$$\exp(-\gamma \|x - x'\|^2), \gamma > 0 \quad (21)$$

式中: γ 为核参数; x 为样本向量; 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。为了实现准确的电网故障预警, 本文以“二叉树”理论对传统SVM进行改进, 将仅限于故障和非故障预测的二分类模型扩充到多分类预测模型。利用常见的4类故障和正常运行情况共5种场景构建SVM分类器, 其中1为正常样本, 2为短路故障, 3为断线故障, 4为杆塔倾倒, 5为绝缘子闪络, 结构如图2所示。

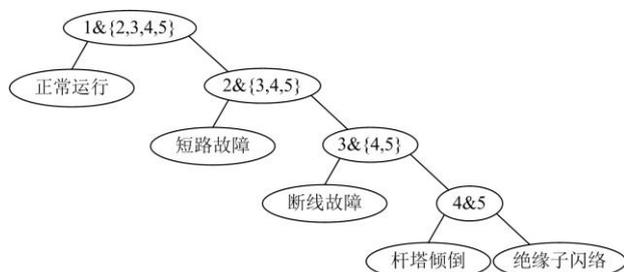


图 2 故障预测结构图

Fig. 2 Structure diagram of fault prediction

电网气象故障预警步骤如下所述:

1) 数据预处理。收集电网故障相对应的气象因子数据以及设备、环境因子相关数据, 建立电网气象灾害样本集, 采用离差标准化方法对样本数据进行归一化处理。

2) 气象因子组合权重确定。利用最小信息熵原理对主客观权重进行组合, 再根据因子状态权重对组合权重进行动态修正, 将修正后的组合权重赋值给预处理后的数据样本。

3) DSAE初始训练。将经过组合赋权的气象因子作为输入量, 对网络进行无监督训练, 初步确定各层网络的连接权重和偏置量。

4) 基于场景分类器的特征提取训练。根据气象灾害场景数量确定输出层神经元个数, 利用场景分类器和带有灾害场景标签的气象因子, 对网络进行有监督微调, 得到针对性更强的特征提取网络。

5) 构建电网气象故障预警模型。利用上述网络和 SVM 建立故障预测模型, 将气象特征因子与设备、环境因子串联, 综合电网故障信息来训练 SVM 模型, 实现多类别电网气象故障预测预警。

4 算例仿真

以山东某地市电网为对象, 根据电网故障信息中的故障时刻和故障位置对气象原始数据、电网设备数据和地理环境数据进行关联匹配, 并采用合成少数类过采样技术(synthetic minority oversampling technique, SMOTE)得到 500 组电网气象故障原始数据集。原始气象数据包括 26 个气象因子, 基于 G1

法建立序关系, 如表 3 第 2 列所示; 根据专家打分得到各因子的主观赋值, 如表 3 第 3 列所示。

表 3 气象因子权重确定

Table 3 Determination of the meteorological factors weight

编号	气象因子	重要性定量	r_k	组合权重	修正权重
X ₁	累计降水量	—	—	0.132 24	0.055 922
X ₂	降雨量	1	r_2	0.112 24	0.050 603
X ₃	降雪量	1.1	r_3	0.101 48	0.047 741
X ₄	雷电流幅值	1	r_4	0.038 96	0.049 787
X ₅	回击数	1.2	r_5	0.043 08	0.032 208
X ₆	风速	1	r_6	0.082 71	0.156 832
X ₇	风向	1.1	r_7	0.076 32	0.040 598
X ₈	相对湿度	1.3	r_8	0.046 00	0.051 66
X ₉	短波辐射 1	1.2	r_9	0.039 83	0.021 187
X ₁₀	短波辐射 2	1	r_{10}	0.038 04	0.020 235
X ₁₁	气温	1	r_{11}	0.044 69	0.032 636
X ₁₂	能见度	1.2	r_{12}	0.047 65	0.033 424
X ₁₃	PM10	1.1	r_{13}	0.045 64	0.146 972
X ₁₄	PM2.5	1	r_{14}	0.017 32	0.044 032
X ₁₅	蒸发量	1	r_{15}	0.012 98	0.006 905
X ₁₆	云量	1.3	r_{16}	0.016 56	0.008 809
X ₁₇	SO ₂	1.2	r_{17}	0.010 65	0.023 583
X ₁₈	云高	1.4	r_{18}	0.011 66	0.006 202
X ₁₉	长波辐射 1	1.2	r_{19}	0.004 17	0.002 218
X ₂₀	长波辐射 2	1	r_{20}	0.018 64	0.009 915
X ₂₁	NO ₂	1	r_{21}	0.014 13	0.024 508
X ₂₂	CO	1.6	r_{22}	0.009 42	0.023 255
X ₂₃	O ₃	1	r_{23}	0.009 65	0.041 992
X ₂₄	地面气压	1	r_{24}	0.010 80	0.042 297
X ₂₅	海平面气压	1.2	r_{25}	0.008 74	0.023 075
X ₂₆	比湿	1.1	r_{26}	0.006 40	0.003 404

以某次大风导致的线路短路故障为例, 由气象中心获取故障发生时段的气象数据, 通过式(8)和式(9)计算气象因子的组合权重和修正权重, 计算结果如表 3 第 5 列和第 6 列所示。

基于 Matlab 仿真软件中 DeepLearn Toolbox、Neural Network Toolbox 和 drtoolbox 工具箱, 对本文气象因子特征提取模型进行性能仿真验证, 通过多次实验确定特征提取模型的网络参数, 实验结果如表 4 所示。

表 4 网络参数确定

Table 4 Determination of network parameters

参数类型	气象子网络
网络层数	5
各层神经元数	26-50-25-10-8
稀疏性参数	0.05
学习率	1
最大迭代次数	500
batchsize	10

本文将气象场景划分为雷电、大风、洪涝、暴雨、雾霾、覆冰、山火 7 种灾害场景和正常场景，相应的场景类型及标签代码如表 5 所示。

表 5 气象灾害场景代码

气象灾害场景	场景标签	场景代码
雷电	1	1000000
大风	2	0100000
洪涝	3	0010000
暴雨	4	0001000
正常	5	0000100
覆冰	6	0000010
雾霾	7	0000001
山火	8	0000001

基于 t-SNE 技术的网络特征提取效果如图 3 所示，分别为有标签测试集的原始数据集、经主成分分析法(principal component analysis, PCA)提取的特征、经初始训练的 DSAE 网络提取的特征、经 Softmax 场景识别的 DSAE 网络提取的特征分布可视化显示结果。

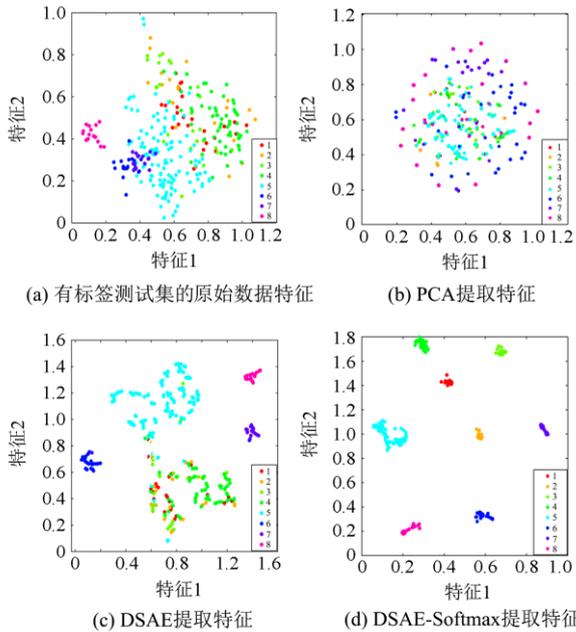


图 3 特征提取可视化效果图

Fig. 3 Visualization of feature extraction

t-SNE 算法主要原理是利用高维数据点和映射到低维空间的数据点之间的联合概率分布来表示二者之间的相似度，低维分布与高维分布之间的相似度用 KL 散度来表示。通过梯度下降算法求得 KL 散度的最小值并迭代获得最佳的低维空间数据点。本文利用 t-SNE 算法将高维原始数据降低到 2 维，

横纵坐标为降维后无量纲的特征 1、特征 2^[30]。

由图 3(a)可以看出，原始数据集中不同样本相互掺杂在一起，特征难以分辨。图 3(b)中经 PCA 提取后，特征的区分稍微明显，但大部分样本仍重叠在一起，而且不同场景下样本比较分散。图 3(c)为经 DSAE 初始训练提取的特征，部分场景已经有比较高的区分度，但是仍有几类场景叠加在一起。图 3(d)为本文方法提取的特征，可清晰分辨样本的每一类场景，且不同场景之间距离更加明显。可以看出本文方法具有优良的特征提取能力。

基于 Matlab 软件仿真平台对本文电网气象故障预警模型性能进行仿真验证。对于 SVM 模型采用 RBF 核函数，利用 K-层交叉验证确定模型超参数 C 和 γ ，本文取 $C=1.5$ ， $\gamma=0.07$ 。随机选取数据集的 80% 为网络训练集，20% 作为测试集，采用识别准确率 A (Accuracy)、 F_1 (F1-score) 和 G (G-mean) 作为评价指标来对网络效果进行综合性对比验证。

$$A = (T_p + T_n) / (T_p + T_n + F_n + R_p) \quad (22)$$

$$F_1 = (2 \times P \times R) / (P + R) \quad (23)$$

$$G = \sqrt{P \times R} \quad (24)$$

其中，

$$\begin{cases} P = T_p / (T_p + F_p) \\ R = T_p / (T_p + F_n) \\ S = T_n / (T_n + F_p) \end{cases} \quad (25)$$

式中： P 代表查准率； R 代表召回率； S 代表特效度； T_p 代表灾害场景识别正确的数量； T_n 代表正常样本识别正确的数量； F_p 代表灾害场景识别错误的数量； F_n 代表正常样本识别错误的数量。

模型经训练后，可对输入信号进行故障类型识别，并计算每个故障类型的发生概率，模型通过对不同故障类型发生的概率进行比较，输出最大概率值对应的故障类型。输入该算例对应的气象、设备和地理环境初始信息后，得到的输出结果如表 6 所示，预测发生概率最高的是短路故障。

本次事件实际情况为大风天气下，由于线路舞动，使 AB 两相间固定金具损坏，导致两相碰线短路。预测结果与实际情况相符。

故障预测概率是对于单一事件而言的，对于不同的事件输入，模型所输出的概率和预测结果也不同。本文以另一典型事件 2 为例，输入该事件对应的原始数据后，模型预测结果如表 7 所示，预测发生概率最高的是断线故障，概率为 64.57%。本次事件为台风暴雨导致的架空线路 C 相断线故障，预测输出正确。当模型输出与实际结果有所出入时，可以依据实际情况对模型进行反馈调整。

由事件 1、2 的预测结果可以看出, 事件 1、2 均包含了大风场景, 但不同事件在进行故障预测时模型输出的预测结果却有较大区别, 这是由于两次事件的原始输入数据除了风力信息有一定的相似性外, 其他气象信息、设备信息和地理环境信息均有一定差异导致, 而模型通过多次迭代训练已经学习到输入不同数据时预测结果的差异性。

表 6 事件 1 预测结果

Table 6 Prediction result of event 1

故障类型	故障标签	预测概率/%	预测结果	实际事件
正常运行	1	3.96		
短路故障	2	85.25		
断线故障	3	6.72	短路故障	两相短路
杆塔倾倒	4	3.23		
绝缘子闪络	5	0.84		

表 7 事件 2 预测结果

Table 7 Prediction result of event 2

故障类型	故障标签	预测概率/%	预测结果	实际事件
正常运行	1	3.19		
短路故障	2	4.2		
断线故障	3	64.57	断线故障	风吹断线
杆塔倾倒	4	25.23		
绝缘子闪络	5	2.81		

为了验证本文方法的有效性, 将本文方法与以下几种方法对故障预测效果进行对比, 其中 SVM 输入为未进行气象特征提取的原始样本集, AE-SVM、PCA-SVM 分别采用 AE、PCA 进行气象因子特征提取, DSAE-SVM 采用只经过初始训练的 DSAE 网络进行气象因子特征提取, 本文方法为 DSAE-S-SVM, 相比 DSAE-SVM 增加了场景分类器。同时, 以上模型均增加了未经组合赋权的数据对照组。以上实验的结果均为进行 3 次实验所得的均值, 其中, AE 网络层数为 1, 神经元结构为 26-8, 最大迭代次数、学习率等参数与本文模型相同; PCA 采用 Matlab 默认函数; DSAE-SVM 与本文 DSAE-S-SVM 方法中, DSAE 模块采用相同的模型参数与网络结构。对比结果如表 8 所示。

表 8 模型效果对比验证

Table 8 Comparison and verification of model effects

类别	正确率		F ₁ -score	G-mean
	组合赋权	无赋权		
SVM	0.8235	0.8130	0.7953	0.8069
AE-SVM	0.8633	0.8512	0.8731	0.8715
PCA-SVM	0.8776	0.8476	0.8628	0.8742
DSAE-SVM	0.9027	0.8603	0.8967	0.8869
DSAE-S-SVM	0.9475	0.8789	0.9102	0.9117

通过对比各项指标可以看出, 本文方法预测效果要好于其他模型, 预测正确率更高于其他方法, 且经组合赋权后, 故障结果判断正确率较无赋权时均有一定提升。因此本文方法可以对高维、耦合复杂的气象因子进行有效的特征提取, 并建立 3 类致灾因子与电网故障之间的关联映射关系, 更加准确地实现电网气象故障预测预警。

5 结论

本文提出一种基于组合赋权法赋予气象因子初始权重并融合场景分类器和深度稀疏自编码网络的电网气象故障预警方法。利用最小相对信息熵原理计算气象因子的主客观组合权重, 并基于气象因子的当时状态修正组合权重, 然后利用场景分类器和深度稀疏自编码网络建立气象因子间的关联关系, 提取气象因子有效特征, 提高电网气象故障预警的准确度, 主要结论如下:

- 1) 对于原始气象数据类型多样、耦合复杂的问题, 本文利用 G1 法和熵权法从主客观两个角度进行权重分析, 基于最小相对信息熵原理计算组合权重, 并基于气象因子的当时状态对组合权重进行修正, 提高网络收敛能力。
- 2) 利用深度稀疏自编码网络进行无监督预训练和场景分类器有监督微调, 通过网络参数的多重组合对气象因子内部的耦合关系进行表达, 有效提取气象因子数据内部特征。
- 3) 基于网络提取的气象特征与设备、环境因子相串联, 利用改进 SVM 模型对电网故障类型进行预测。与其他网络模型相比较, 本文提出的方法能够准确建立 3 类致灾因子间的关联关系, 对给定的因子条件下可能引发的电网故障类型进行准确预判, 更加准确地实现电网气象故障预警。

附录A

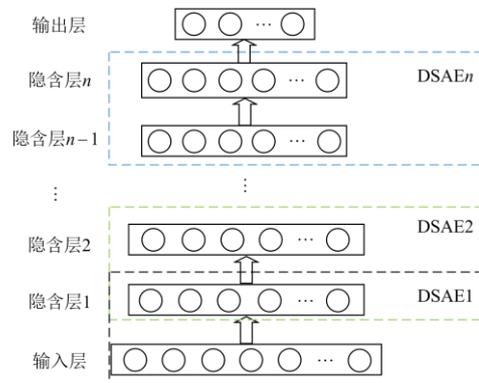


图 A1 深度稀疏自编码网络模型

Fig. A1 Network model of deep sparse autoencoder

表 A1 部分气象因子状态等级评级标准

Table A1 State grade rating standard of some meteorological factors

气象因子(部分)	状态等级 1	状态等级 2	状态等级 3	状态等级 4
降雨量/(mm/h)	<2.0	2.0~3.9	4.0~7.9	>8.0
累计降水量/(mm/d)	<10	10.0~24.9	25.0~50	>50.0
风速/(m/s)	<7.9	8.0~10.7	10.8~13.8	>13.8
地面气压/hPa	>1013	898~1013	794~898	<794
海平面气压/hPa	>1013	898~1013	794~898	<794
降雪量/(mm/h)	<2.0	2.0~2.9	3.0~5.9	>6.0
气温/°C	0~35	-20~0	>35	<-20
相对湿度/%	<49.9	50.0~59.9	60.0~69.9	>70.0
能见度	>6	4~5	2~3	<1
雷电流幅值-绝对值/kA	<36	36~68	68~151	>151
回击数(1)	<2	2~3	4~7	>7
PM2.5/($\mu\text{g}/\text{m}^3$)	<35	35~75	76~115	>115
PM10/($\mu\text{g}/\text{m}^3$)	<50	50~100	101~150	>151
SO ₂ /($\mu\text{g}/\text{m}^3$)	<23	23~46	47~69	>69
NO ₂ /($\mu\text{g}/\text{m}^3$)	<40	40~60	61~80	>81
CO/(mg/m^3)	<1.3	1.3~2.0	2.1~2.8	>2.8
O ₃ /($\mu\text{g}/\text{m}^3$)	<50	50~150	151~250	>251

参考文献

- [1] 徐伟, 路永玲, 唐梦颖, 等. 江苏电网近年雷电活动及输电线路雷击跳闸分析[J]. 电力工程技术, 2017, 36(6): 106-110.
XU Wei, LU Yongling, TANG Mengying, et al. Analysis of lightning activities and transmission line lightning strike tripping in Jiangsu power grid in recent years[J]. Electric Power Engineering Technology, 2017, 36(6): 106-110.
- [2] 吴勇军, 薛禹胜, 陆佳政, 等. 山火灾害对电网故障率的时空影响[J]. 电力系统自动化, 2016, 40(3): 14-20.
WU Yongjun, XUE Yusheng, LU Jiazheng, et al. Space-time impact of forest fire on power grid fault probability[J]. Automation of Electric Power Systems, 2016, 40(3): 14-20.
- [3] 陈嘉宁, 吴振杰, 王源涛, 等. 基于雷击灾害的输电网可靠性综合评估模型[J]. 高压电器, 2020, 56(2): 170-175, 182.
CHEN Jianing, WU Zhenjie, WANG Yuantao, et al. Lightning disaster-based comprehensive reliability assessment model for transmission grid[J]. High Voltage Apparatus, 2020, 56(2): 170-175, 182.
- [4] 江进波, 杨文, 马可, 等. 220 kV 输电线路跨江段防雷措施研究[J]. 高压电器, 2020, 56(1): 141-147.
JIANG Jinbo, YANG Wen, MA Ke, et al. Study on lightning protection measures of 220 kV transmission line section across river[J]. High Voltage Apparatus, 2020, 56(1): 141-147.
- [5] 田金虎, 刘渝根, 赵俊光. GIS 升压站雷电侵入波过电压计算及其影响因素分析[J]. 高压电器, 2021, 57(12): 74-82.
TIAN Jinhu, LIU Yugen, ZHAO Jinguang. Calculation and influence factors analysis of lightning intruding overvoltage in GIS step-up station[J]. High Voltage Apparatus, 2021, 57(12): 74-82.
- [6] 吴琛, 苏明昕, 谢云云, 等. 基于 BP 神经网络的输电线路雷击故障预测[J]. 电力工程技术, 2020, 39(5): 133-139.
WU Chen, SU Mingxin, XIE Yunyun, et al. BP neural network based lightning fault prediction of transmission lines[J]. Electric Power Engineering Technology, 2020, 39(5): 133-139.
- [7] 朱凌, 陈涛威, 周晨, 等. 考虑风速风向联合分布的大风灾害下电力断线倒塔概率预测[J]. 电力系统保护与控制, 2019, 47(2): 115-122.
ZHU Ling, CHEN Taowei, ZHOU Chen, et al. Probability prediction of transmission line breakage and tower topple over under wind disaster considering the joint distribution of

- wind speed and wind direction[J]. *Power System Protection and Control*, 2019, 47(2): 115-122.
- [8] 黄新波, 李弘博, 朱永灿, 等. 基于时间序列分析与卡尔曼滤波的输电线路覆冰短期预测[J]. *高电压技术*, 2017, 43(6): 1943-1949.
HUANG Xinbo, LI Hongbo, ZHU Yongcan, et al. Short-term forecast for transmission line icing by time series analysis and Kalman filtering[J]. *High Voltage Engineering*, 2017, 43(6): 1943-1949.
- [9] 刘辉, 马曾泰, 林济铿, 等. 覆冰架空导线舞动跳闸概率计算新方法[J]. *中国电力*, 2022, 55(3): 125-132.
LIU Hui, MA Zengtai, LIN Jikeng, et al. A new method for calculation of transmission line tripping probability caused by galloping of iced overhead conductor[J]. *Electric Power*, 2022, 55(3): 125-132.
- [10] 鲍捷, 王昕, 张峰, 等. 基于雷电定位数据驱动的紧密输电通道连续雷击跳闸预警方法[J]. *电网技术*, 2022, 46(3): 1194-1205.
BAO Jie, WANG Xin, ZHANG Feng, et al. Data-driven early warning for continuous lightning trip-out of compact power corridors based on lightning location data[J]. *Power System Technology*, 2022, 46(3): 1194-1205.
- [11] 周恩泽, 黄勇, 龚博, 等. 基于朴素贝叶斯网络的输电走廊山火风险评估模型[J]. *南方电网技术*, 2021, 15(8): 120-129.
ZHOU Enze, HUANG Yong, GONG Bo, et al. Wildfire risk assessment model of power transmission line corridors based on naive Bayes network[J]. *Southern Power System Technology*, 2021, 15(8): 120-129.
- [12] 李大虎, 袁志军, 何俊, 等. 面向台风气象的电网运行风险态势感知方法[J]. *高电压技术*, 2021, 47(7): 2301-2313.
LI Dahu, YUAN Zhijun, HE Jun, et al. Situation awareness method of power grid operation risk under typhoon weather[J]. *High Voltage Engineering*, 2021, 47(7): 2301-2313.
- [13] 史坤鹏, 范国英, 赵伟, 等. 基于 BP 神经网络的电网安全性预警系统研发[J]. *南方电网技术*, 2013, 7(6): 141-144.
SHI Kunpeng, FAN Guoying, ZHAO Wei, et al. Development of a BP-neural network based security-warning system for electric power grid[J]. *Southern Power System Technology*, 2013, 7(6): 141-144.
- [14] 王佳明, 刘文颖, 张建立. 恶劣天气下的复杂电网连锁故障在线预警[J]. *电网技术*, 2012, 36(5): 239-244.
WANG Jiaming, LIU Wenyong, ZHANG Jianli. Online early warning model for cascading failure in complex power grid under severe weather[J]. *Power System Technology*, 2012, 36(5): 239-244.
- [15] 郑茂然, 余江, 陈宏山, 等. 基于大数据的输电线路故障预警模型设计[J]. *南方电网技术*, 2017, 11(4): 30-37.
ZHENG Maoran, XU Jiang, CHEN Hongshan, et al. Design of fault warning model of transmission line based on big data[J]. *Southern Power System Technology*, 2017, 11(4): 30-37.
- [16] 田兵, 李冬, 邓昊, 等. 基于实时气象信息的电网灾害预警分析[J]. *山东电力技术*, 2015, 42(11): 40-42, 56.
TIAN Bing, LI Dong, DENG Hao, et al. Grid disaster warning based on real-time weather information[J]. *Shandong Electric Power*, 2015, 42(11): 40-42, 56.
- [17] 张中丹, 杨德州, 王洲, 等. 基于区块链技术的电网灾害预警决策系统[J]. *现代电力*, 2021, 38(3): 307-315.
ZHANG Zhongdan, YANG Dezhou, WANG Zhou, et al. A block chain technology based power grid disaster early warning and decision making system[J]. *Modern Electric Power*, 2021, 38(3): 307-315.
- [18] 杨挺, 赵黎媛, 王成山. 人工智能在电力系统及综合能源系统中的应用综述[J]. *电力系统自动化*, 2019, 43(1): 2-14.
YANG Ting, ZHAO Liyuan, WANG Chengshan. Review on application of artificial intelligence in power system and integrated energy system[J]. *Automation of Electric Power Systems*, 2019, 43(1): 2-14.
- [19] XU Jizhi, ZHANG Xinyan, LI Jianwei. Application of artificial intelligence in the field of power systems[J]. *Journal of Electrical and Electronic Engineering*, 2019, 7(1): 23-28.
- [20] 汤奕, 崔晗, 李峰, 等. 人工智能在电力系统暂态问题中的应用综述[J]. *中国电机工程学报*, 2019, 39(1): 2-13, 315.
TANG Yi, CUI Han, LI Feng, et al. Review on application of artificial intelligence in power system and integrated energy system[J]. *Proceedings of the CSEE*, 2019, 39(1): 2-13, 315.
- [21] 周念成, 廖建权, 王强钢, 等. 深度学习在智能电网中的应用现状分析与展望[J]. *电力系统自动化*, 2019, 43(4): 180-197.
ZHOU Niancheng, LIAO Jianquan, WANG Qianggang, et al. Analysis and prospect of deep learning application in smart grid[J]. *Automation of Electric Power Systems*, 2019, 43(4): 180-197.
- [22] 杨剑锋, 秦钟, 庞小龙, 等. 基于深度学习网络的输电

- 线路异物入侵监测和识别方法[J]. 电力系统保护与控制, 2021, 49(4): 37-44.
- YANG Jianfeng, QIN Zhong, PANG Xiaolong, et al. Foreign body intrusion monitoring and recognition method based on Dense-YOLOv3 deep learning network[J]. Power System Protection and Control, 2021, 49(4): 37-44.
- [23] 田浩含, 撒奥洋, 于立涛, 等. 基于 GRA-LSTM 神经网络的区域综合能源系统多元负荷短期预测模型[J]. 广东电力, 2020, 33(5): 44-51.
- TIAN Haohan, HAN Aoyang, YU Litao, et al. Research on multi-load short-term forecasting model of regional integrated energy system based on GRA-LSTM neural network[J]. Guangdong Electric Power, 2020, 33(5): 44-51.
- [24] 何宁辉, 王世杰, 刘军福, 等. 基于深度学习的航拍图像绝缘子缺失监测方法研究[J]. 电力系统保护与控制, 2021, 49(12): 132-140.
- HE Ninghui, WANG Shijie, LIU Junfu, et al. Research on infrared image missing insulator detection method based on deep learning[J]. Power System Protection and Control, 2021, 49(12): 132-140.
- [25] 李海英, 沈益涛, 罗雨航. 基于改进深度置信网络的智能电网暂态安全感知[J]. 电力系统保护与控制, 2022, 50(5): 171-177.
- LI Haiying, SHEN Yitao, LUO Yuhang. Transient security situational awareness of smart grids based on an improved deep belief network[J]. Power System Protection and Control, 2022, 50(5): 171-177.
- [26] 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.
- [27] 陆继翔, 李昊, 徐康, 等. 基于迁移学习的小样本输电线路巡检图像处理方法[J]. 全球能源互联网, 2019, 2(4): 409-415.
- LU Jixiang, LI Hao, XU Kang, et al. Defect recognition using few-shot learning and transfer learning for transmission line inspection images[J]. Journal of Global Energy Interconnection, 2019, 2(4): 409-415.
- [28] 丁石川, 厉雪衣, 杭俊, 等. 深度学习理论及其在电机故障诊断中的研究现状与展望[J]. 电力系统保护与控制, 2020, 48(8): 172-187.
- DING Shichuan, LI Xueyi, HANG Jun, et al. Deep learning theory and its application to fault diagnosis of an electric machine[J]. Power System Protection and Control, 2020, 48(8): 172-187.
- [29] 李俊卿, 王焕仲, 季刚, 等. 基于大数据分析的风机轴承故障预警[J]. 智慧电力, 2020, 48(2): 25-30.
- LI Junqing, WANG Huanzhong, JI Gang, et al. Fault early warning of wind turbine bearing based on big data analysis[J]. Smart Power, 2020, 48(2): 25-30.
- [30] 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 for AC/DC transmission system based on convolutional neural network[J]. Automation of Electric Power Systems, 2022, 46(5): 132-145.

收稿日期: 2022-01-06; 修回日期: 2022-06-22

作者简介:

胡凉平(1997—), 男, 通信作者, 硕士研究生, 研究方向为电力系统继电保护与控制; E-mail: 542715486@qq.com

丛伟(1978—), 男, 博士, 副教授, 研究方向为电力系统继电保护与控制; E-mail: weicong@sdu.edu.cn

徐安馨(1996—), 女, 硕士, 研究方向为电力系统继电保护与控制。E-mail: xuanxin0531@163.com

(编辑 魏小丽)