

DOI: 10. 19650/j. cnki. cjsi. J2412881

基于 LCPSO 与异构集成学习模型的输电线路覆冰等级预警方法*

尚秋峰^{1,2,3}, 谷元宇¹, 樊小凯¹, 王健健^{1,2,3}, 姚国珍^{1,2,3}

(1. 华北电力大学电子与通信工程系 保定 071003; 2. 华北电力大学河北省电力物联网技术重点实验室 保定 071003; 3. 华北电力大学保定市光纤传感与光通信技术重点实验室 保定 071003)

摘要: 基于 Φ -OTDR 的分布式光纤传感技术, 通过分析 OPGW 中光纤的振动特征, 可以实现输电线路全线路、全天候的在线健康监测。采用 Φ -OTDR 采集了无覆冰、1 级覆冰和 2 级覆冰 3 种工况下的振动信号, 充分挖掘了相位和幅值信号的时域、频域、时频域特征及其对应的统计学特性。为提升覆冰工况的识别准确率, 提出基于 LCPSO-AdaBoost-MCG 的最优特征子集选择算法, 以 AdaBoost-MCG 的分类错误率为适应度函数, 采用 LCPSO 算法迭代计算最优特征子集。采用 AdaBoost 集成 SCN、KNN、PNN、SVM 4 种弱分类器, 构成了异构强分类器, 利用每种弱分类器的优势, 提高了模型泛化性能和识别准确率。经现场数据集验证, 本文方法对覆冰等级的识别准确率达到 98.7%。根据本文确定的最优特征子集, 可以构建覆冰等级预警特征库, 为输电线路智能巡检提供有益参考。

关键词: 输电线路覆冰; 光纤传感; 特征选择; 集成学习; 优化算法

中图分类号: TM75 TH744 **文献标识码:** A **国家标准学科分类代码:** 510.40

A transmission line icing level warning method based on LCPSO and heterogeneous ensemble learning model

Shang Qiufeng^{1,2,3}, Guyuanyu¹, Fan Xiaokai¹, Wang Jianjian^{1,2,3}, Yao Guozhen^{1,2,3}

(1. Department of Electronic and Communication Engineering, North China Electric Power University, Baoding 071003, China; 2. Key Laboratory of Power Internet of Things Technology, Hebei Province, North China Electric Power University, Baoding 071003, China; 3. Key Laboratory of Fiber Optic Sensing and Optical Communication Technology, Baoding City, North China Electric Power University, Baoding 071003, China)

Abstract: Based on Φ -OTDR, distributed fiber optic sensing technology can be utilized to achieve online, real-time health monitoring of power transmission lines by analyzing the vibration characteristics of optical fibers within OPGW. By utilizing Φ -OTDR, vibration signals under three operating conditions—no icing, level 1 icing, and level 2 icing—were collected, and the temporal, frequency, and time-frequency domain features, along with their corresponding statistical properties, of both phase and amplitude signals were thoroughly explored. To enhance the accuracy of icing condition identification, this paper proposes an optimal feature subset selection algorithm based on LCPSO-AdaBoost-MCG. This algorithm employs the classification error rate of the AdaBoost-MCG as the fitness function and iterates with the LCPSO to calculate the optimal feature subset. The AdaBoost ensemble incorporates four weak classifiers: Simple Cartesian Network (SCN), K-Nearest Neighbors (KNN), Probabilistic Neural Network (PNN), and Support Vector Machine (SVM), forming a heterogeneous strong classifier. By leveraging the strengths of each weak classifier, the model's generalization performance and recognition accuracy are improved. Field data validation demonstrates that the proposed method achieves a 98.7% accuracy in identifying icing levels. Using the optimal feature subset identified in this study, an icing level warning feature library can be established, offering a valuable reference for intelligent transmission line inspection.

Keywords: transmission line icing; fiber optic sensing; feature selection; ensemble learning; optimization algorithm

收稿日期: 2024-05-24 Received Date: 2024-05-24

* 基金项目: 国家自然科学基金(62205105)、河北省自然科学基金(E2019502179)、河北省省级科技计划(SZX2020034)项目资助

0 引言

输电线路覆冰作为一种频发的输电线路灾害,严重威胁着电力系统的安全运行^[1-3]。覆冰后会增加输电导线的重量荷载和风荷载,当覆冰超过线路最大荷载时可能会导致绝缘子闪络、导线断裂、杆塔倒塌,严重时甚至会导致电网瘫痪^[4-5]。相位敏感光时域反射计(Φ -OTDR)作为一种应用广泛的分布式光传感技术,具有抗电磁干扰、灵敏度高等优势,能借助输电线路中的光纤复合架空地线(optical ground wire, OPGW)实现全线路、全天候在线监测,克服了传统监测方法的局限性。近年来, Φ -OTDR在输电线路故障监测领域取得了进展。张旭莘等^[6]提出将 Φ -OTDR应用于输电线路、水下线缆、地震波监测和周界安防,对 Φ -OTDR发展趋势进行了展望。郝伟博等^[7]发现 Φ -OTDR振动信号与导线激振频率相符,实现了输电线路舞动状态监测。Ding等^[8]利用 Φ -OTDR测得了覆冰与悬垂线固有频率之间的关系,为输电线路覆冰监测提供了新的解决方案。以上文献,对输电线路故障监测的研究多使用解析法,但是由于现场环境复杂多变,以及覆冰形状的不规则性,导致实验室条件下获得的解析式难以匹配现场应用。因此本文基于 Φ -OTDR振动信号特征挖掘,给出覆冰等级预警方案。

由于 Φ -OTDR系统存在相干衰落,将影响某些空间点相位解调的准确性,可能导致事件误报,而相干衰落在幅值信号上表现为明显的极小值点^[9]。同时,不同的扰动强度也会引起后向瑞利散射光振幅波动,幅值信号也能反映振动特性,因此幅值信号可以辅助相位信号识别外界振动。相位与幅值信号的同时引入导致特征维度的急剧增加,而特征维数增大,会导致实时性降低,也可能影响模式识别的准确率。特征选择方法能够有效去除冗余特征,挑选出最优特征子集。典型的特征选择方法包括过滤式(Filter)和包裹式(Wrapper)。过滤式方法利用特征本身特性以及特征之间的相互作用挑选特征,常用的方法有relief^[10]、最大相关最小冗余(max-relevance and min-redundancy, MRMR)^[11]和T-检验^[12]等。包裹式方法将分类器的识别准确率作为挑选子集的评价指标,在整个特征空间中搜索使分类器识别准确率最高的特征子集。张可颖等^[13]提出一种基于特征工程和集成学习的实时山火风险评估模型,用Wrapper方法迭代获取了100维特征子集作为模型输入,构建了基于集成学习的实时山火风险评估模型,预测精度达到96.4%。高慧敏等^[14]提出一种融合教与学优化算法与局部搜索方法的混合Wrapper算法模型,以KNN的分类错误率为适应度函数,搜索最优子集,实验结果表明,该算法识别准确率相比其他算法显著提高。王军等^[15]提出一种参数动态调整的粒子群优化算法,成功挑选出有意义的特

征子集,在构建机器学习模型时,使用了堆叠的集成学习框架对多个模型结果进行泛化,提升了整体预测精度,实验结果表明,该方法识别准确率达到95%。潘礼正等^[16]提出了基于融合信息的数据处理策略,使用了特征选择方法筛选了特征,并通过ELM-AdaBoost方法构建强分类器实现了情绪状态识别,识别准确率达到83.06%。为提升覆冰等级预警的识别准确率,本文采用Wrapper方法筛选最优特征子集,同时结合异构集成学习模型提升泛化性能与识别准确率。

本文利用正交解调获得监测数据的相位与幅值信号,构建相位与幅值信号融合特征集。采用最大相关最小冗余法剔除特征集中的冗余特征,在此基础上,使用变长粒子群算法(length change particle swarm optimization, LCPSO)以AdaBoost多分类器组(AdaBoost-multi classifier group, AdaBoost-MCG)的分类错误率为适应度函数筛选最优特征子集,将最优子集作为模型输入,构建了基于AdaBoost-MCG的覆冰等级预警模型。

1 特征体系

本文对 Φ -OTDR相位信号和幅值信号进行特征提取,其特征体系包含时域、频域、时频域的多域特征及其方差与均值。

1.1 时域-频域-时频域特征

特征提取的目的是挖掘不同振动信号的特性。本文提取了时域、频域、时频域信号的特征作为基特征向量,将多域特征融合构建特征集,如图1所示。



图1 时域-频域-时频域特征体系

Fig. 1 Time domain-frequency domain-time frequency domain feature system

针对时域波形提取了最大值、峰峰值、平均值、方根幅值、标准差、有效值、偏度指标、峰值指标、脉冲指标、裕度指标、波形指标、峭度、能量、重心频率 14 种常用特征;针对频域波形,在上述 14 种特征的基础上增加了频率均方根、频率标准差、主频带位置、频率能量集中度 4 种特征;时频域部分,提取了熵特征与小波包分解特征:排列熵、样本熵、奇异谱熵、小波能量占比(8 层)、小波特征尺度熵(8 层)。

1.2 特征统计学特性

由于实际输电线路环境复杂,振动信号容易受到风速、风向等外界因素的影响,即使在同一工况下也可能导致振动信号的特征值发生剧烈波动,严重影响识别准确率。通过分析现场采集的覆冰时间段与非覆冰时间段信号特征可知,在覆冰时间段内,同一特征随时间的变化量小且数值分布与非覆冰时间段不同。因此可以引入各特征量的均值与方差参与表征无覆冰、1 级覆冰、2 级覆冰 3 种工况。本文以 1 天为 1 个时窗,引入了特征在 1 个时窗内变化的方差与均值作为新的特征加入到特征集中,辅助时域、频域、时频域特征识别不同覆冰工况。

2 特征选择与覆冰等级分类识别

本文提出的基于特征选择的覆冰等级预警模型构建流程为:首先使用最大相关最小冗余算法初选特征,降低特征的冗余度;其次使用 LCPSO-AdaBoost-MCG 算法寻找最优特征子集;最后将最优特征子集作为输入构建基于 AdaBoost-MCG 的覆冰等级预警模型。

2.1 MRMR 算法

最大相关性用于选择与类别标签相关性最高的特征,相关性用 R 表示, R 值越大,表明该特征与类别标签的相关性越强。冗余度用 T 表示, T 值越小表明特征之间的冗余度越小,最大相关性 with 最小冗余度表示为^[17],

$$\max R(S, y), R = \frac{1}{|S|} \sum_{x_i \in S} w_M(X_i; y) \quad (1)$$

$$\min T(S), T = \frac{1}{|S|^2} \sum_{x_i, x_j \in S} w_M(X_i; X_j) \quad (2)$$

式中: S 为特征子集; $|S|$ 为特征子集的大小; $w_M(X_i; y)$ 为特征 X_i 与类别标签 y 之间的互信息; $w_M(X_i; X_j)$ 为特征 X_i 与 X_j 之间的互信息。

2.2 LCPSO 算法

粒子群优化算法(particle swarm optimization, PSO)模拟了自然界鸟群捕食和鱼群捕食的过程,通过群体协作找到问题的最优解。PSO 实现简单,全局搜索能力强,适用于多维、非线性优化问题^[18],但该算法易于陷入局部最优。针对特征选择问题,本文提出一种变长粒子群

优化算法,在初始化阶段将每个个体设置为不同长度,即将整个搜索空间分割成多个子空间,提高了搜索空间的多样性,可以避免算法陷入局部最优^[19]。在 LCPSO 算法中,每个粒子都代表筛选出的一个特征子集。初始化不同长度的粒子长度,代表每个粒子搜索的特征空间大小不同,其中每个粒子都转化为二进制向量表示,每个二进制向量代表一个特征,0 表示未选择该特征,1 表示选择该特征,如图 2 所示。将每个粒子选中的特征子集送入分类器进行训练,计算分类准确率。LCPSO 算法流程分为 5 个阶段:初始化种群、更新每个粒子的速度与位置、评估每个粒子的适应值、更新每个粒子最优位置、更新群体全局最优位置。该算法以初始变长种群为起点,经过不断迭代更新粒子位置与速度,找到全局最优的特征子集。




图 2 变长个体及特征的二进制向量表示

Fig. 2 Binary vector representation of variable length individuals and features

初始化种群时,需要将每个粒子的长度设置为不同大小,个体大小更新公式为:

$$L(x_i) = i \times \frac{n}{p} \quad (3)$$

式中: x_i 为个体编号索引; n 为特征集维度; p 为种群大小。

粒子群算法中所有粒子按照每个粒子极值和全局极值来更新每个粒子的速度与位置。更新公式为:

$$v_{i,k+1} = v_{i,k} + c_1 \times r_1 \times (x_{i,pbest} - x_{i,k}) + c_2 \times r_2 \times (x_{i,gbest} - x_{i,k}) \quad (4)$$

$$x_{i,k+1} = x_{i,k} + v_{i,k+1} \quad (5)$$

式中: $v_{i,k}$ 代表第 i 个粒子第 k 次迭代的速度; c_1 和 c_2 为学习因子,通常取 $c_1 = c_2$; r_1 和 r_2 为 $(0,1)$ 内的随机数; $x_{i,k}$ 为第 i 个粒子第 k 次迭代的位置; $x_{i,pbest}$ 为第 i 个粒子搜索到的历史最佳位置; $x_{i,gbest}$ 为全局历史最佳位置。

2.3 AdaBoost 集成多弱分类器组模型

AdaBoost 能通过集成多个弱分类器构成预测精度更高的强分类器。算法思想:前一个弱分类器的错误分类样本对应的权重增加,正确分类样本对应的权重减小;每训练一个弱分类器更新一次样本权重,更新权重后的样本用来训练下一个弱分类器;根据每个弱分类器分类误

差,更新每个弱分类器权重,增大误差率小的弱分类器权重。本文使用 AdaBoost 集成多弱分类器组,构成异构强分类器,充分利用各个弱分类器的优势,提高模型的适用性和泛化能力,同时减少过拟合的风险并提高模型的鲁棒性,适用于现场环境下数据集波动较大的场景。本文选取了 4 种经典的分类器模型:随机配置网络(stochastic configuration network, SCN)、K 最近邻算法(K-nearest neighbors, KNN)、概率神经网络(probabilistic neural network, PNN)以及支持向量机(support vector machine, SVM)。SCN 泛化能力强,学习效率高,可以泛化应用于数十公里范围内不同距离点的振动信号识别;KNN 计算的时间复杂度低,而且对异常值不敏感,适用于异常值较多的现场数据。PNN 结构简单,无需训练,实时性好,而且 PNN 网络在实际应用中适用于解决分类问题;由于现场长期为正常运行,覆冰工况样本集较少,而 SVM 适用于小样本学习,对于小样本学习极具优势。AdaBoost 集成算法实现步骤如下^[20]:

1) 首先初始化训练样本权重,按照式(1)为每个训练样本更新权重:

$$D_0(w) = \frac{1}{W} \quad (6)$$

式中: w 为训练样本; W 为训练样本总数。

2) 第 t 个弱分类器,其误差 ε_t 与权重 A_t 分别为:

$$\varepsilon_t = \sum_{w=1}^W D_t(h_t(w)), h_t(w) \neq y(w) \quad (7)$$

$$A_t = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_t}{\varepsilon_t} \right) \quad (8)$$

式中: $h_t(w)$ 为预测输出标签; $y(w)$ 为实际标签; D_t 为样本权重。

3) 通过每个弱分类器权重更新样本权重,计算公式为:

$$D_{t+1}(w) = \frac{D_t(w)}{Z_t} \exp(-A_t \cdot y(w) \cdot h_t(w)) \quad (9)$$

式中: Z_t 为样本权重归一化系数, $Z_t = 2\sqrt{e_t(1 - e_t)}$ 。

4) 重复步骤 2~3 直至达到最大迭代次数,最后按照弱分类权重 A_t 组合各个弱分类器,即

$$f(w) = \sum_{t=1}^T A_t H_t(w) \quad (10)$$

5) 通过符号函数 $sign$ 作用,得到异构强分类器为:

$$H_{final} = sign(f(w)) = sign \left(\sum_{t=1}^T A_t H_t(w) \right) \quad (11)$$

2.4 LCPSO-AdaBoost-MCG 算法

由于引入了相位信号与幅值信号两类信号,导致特征集维度成倍增加,使用机器学习模型进行训练时不仅会增加训练时间成本而且可能会出现过拟合,致使识别准确率下降。因此本文提出使用 Filter 和 Wrapper 串行

的特征选择方法,通过 MRMR 筛选与类别标签相关性最高的特征,同时去除其中的冗余特征。随后,按图 3 所示将 AdaBoost-MCG 模型分类错误率作为 LCPSO 优化算法的适应度函数,挑选识别准确率最高的特征子集。算法流程如下:

1) 初始化粒子群,将每个粒子设定为不同长度;初始化学习因子、迭代次数。

2) 更新每个粒子的速度与位置,得到粒子当前位置即该粒子选择的特征子集。

3) 计算当前特征子集的适应度函数,将该特征子集作为训练集与测试集导入到 AdaBoost-MCG 算法中计算分类错误率。

4) 评估适应度函数,更新当前粒子最优解。

5) 重复步骤 2)~4) 直至达到最大迭代次数,得到全局最优解,即最优特征子集。

3 现场数据分析

3.1 覆冰监测系统与数据集

用于输电线路覆冰监测的 Φ -OTDR 系统结构如图 4 所示。图中所示激光器(laser)采用输出功率 13 dBm,中心波长为 1 550 nm 的窄线宽光源。脉冲采样频率为 1.25 kHz,激光器的出射光通过保偏耦合器分为两路,90% 的一路作为探测光,10% 的一路作为本地光。探测光经声光调制器(acousto-optic modulator, AOM)调制后产生移频,移频量为 50 MHz。脉冲发生器(pulse generator, PG)用于驱动 AOM,探测光脉冲宽度为 100 ns,探测光脉冲经掺铒光纤放大器(erbium doped fiber amplifier, EDFA)进行光强度放大后,再由光纤环形器(circulator)进入 OPGW 内的传感光纤。OPGW 中产生的后向瑞利散射光(RBS)经环形器后在 3 dB 耦合器中与本地光进行拍频,拍频信号进入平衡光电探测器(balanced photodetector, BPD)后实现光电转换。转换后的电信号经过数据采集卡(data acquisition card, DAQ)后转换为数字信号,DAQ 采样率为 250 MSa/s,计算机(PC)用于信号解调与处理。

本文将该系统应用于输电线路监测场景中,将 Φ -OTDR 设备安装在某超高压变电站内,通过 OPGW 内的光纤,实现输电线路的分布式监测,线路全长 50 km,其中站内光缆长度为 10 km,站外输电线长 40 km。本文共采集了 2023 年 12 月 13~31 日的的数据,根据现场观测结果可知,12 月 13~14 日输电线出现轻微覆冰,覆冰厚度为 0~5 mm;12 月 15~21 日由于持续降雪冰厚不断增加,覆冰厚度为 5~10 mm;12 月 26~29 日线路无覆冰。为提高本文数据集的泛化性能,选取了输电线路沿线 5 个

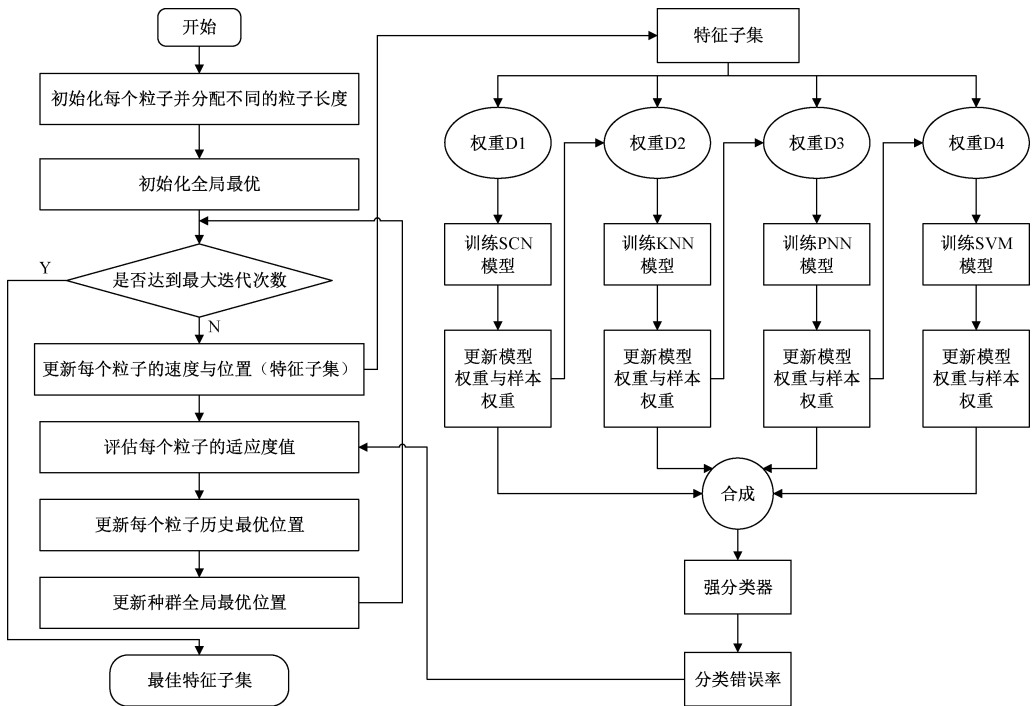


图 3 LCPSO-AdaBoost-MCG 集成模型流程

Fig. 3 LCPSO-AdaBoost-MCG integrated model flowchart

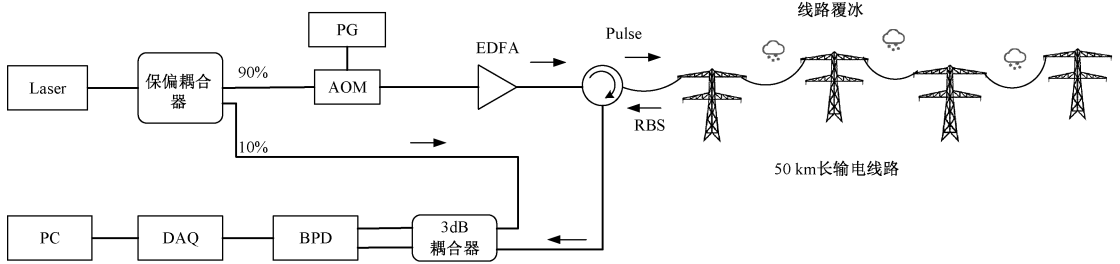


图 4 输电线路覆冰监测系统结构

Fig. 4 Structure diagram of transmission line icing monitoring system

不同距离点的数据,依次是 10.5、15、20、25、30 km (30 km 之后输电线路所在区域的天气状况不同,未出现覆冰)。根据现场观测,依次提取了 1 级覆冰(0~5 mm)、2 级覆冰(5~10 mm)、无覆冰 3 种工况不同距离点数据特征,经过特征分析,选择了 89 维能够反映 3 种覆冰工况的特征,包括相位时域(10 维)、相位频域(10 维)、相位时频域(10 维)、幅值时域(6 维)、幅值频域(15 维)、幅值时频域(12 维)、相位信号特征量均值与方差(26 维)。每种工况提取了 300 组样本,共计 900 组,其中每种工况挑选 200 组样本用于训练,100 组样本用于测试。指定无覆冰信号标签为 1,1 级覆冰信号标签为 2,2 级覆冰信号标签为 3。如图 5 所示为无覆冰、1 级覆冰和 2 级覆冰 3 种工况下的典型时域波形。

3.2 AdaBoost-MCG 模型性能评估

本文基于混淆矩阵,引入准确率 P_a 、精确率 P_p 和召回率 P_r 作为评价指标,表示如下:

$$P_a = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \quad (12)$$

$$P_p = \frac{T_p}{T_p + F_p} \quad (13)$$

$$P_r = \frac{T_p}{T_p + F_N} \quad (14)$$

式中: T_p 表征正样本预测为正; T_N 表征负样本预测为负; F_p 表征负样本预测为正; F_N 表征正样本预测为负。准确率 P_a 反映了预测正确的样本占所有样本的比例;精确率 P_p 反映了反映预测结果为正例的样本占真实为正例的比例。召回率 P_r 反映真实为正例的样本中预测结果为正


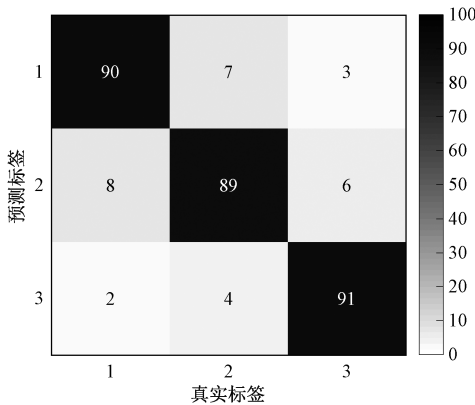


图 5 3 种覆冰工况典型时域波形

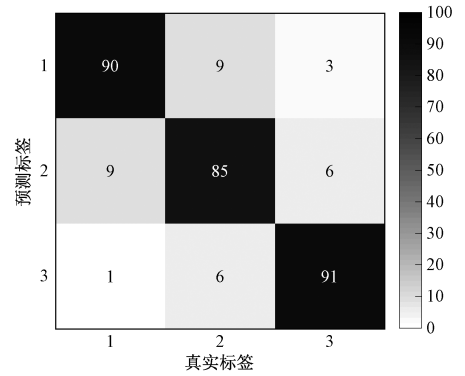
Fig. 5 Typical time-domain waveforms of three icing conditions

例的比例。

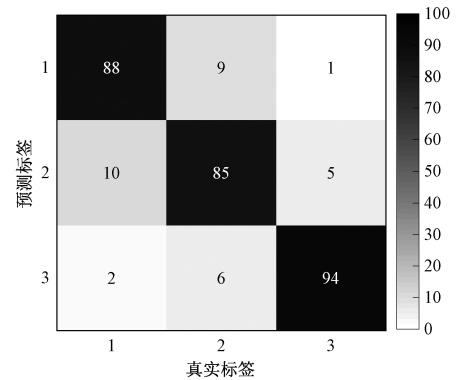
本文使用的 AdaBoost-MCG 模型结构如图 3 所示,使用遍历法选择 SCN 最佳的隐藏层节点数 $L=25$;KNN 模型的最近邻居数量 $K=4$;SVM 核函数使用 RBF,使用网格搜索法搜索出最佳乘法因子 $c=10$ 和核函数参数 $g=0.01$;PNN 使用模型默认参数。使用 MRMR 初选后的特征子集测试本文方法与 AdaBoost-SCN、AdaBoost-KNN、AdaBoost-PNN 和 AdaBoost-SVM 相比的优越性(上述 AdaBoost 集成的弱分类器个数均为 4 个)。如图 6 所示,混淆矩阵的横轴和纵轴分别代表真实标签和预测标签,每类覆冰工况有 100 组测试样本,左对角线上的值为每种覆冰工况被正确预测的样本数量,通过混淆矩阵可以计算出各模型分类的准确率、精确率和召回率。由表 1 可知,AdaBoost-MCG 模型不仅在准确率上优于其他 4 种模型,而且该模型在 3 种工况下分类的精确率和召回率相比其他 4 种模型都有提升。可见 AdaBoost-MCG 模型分类性能优于 AdaBoost 集成同一分类器模型。




(a) AdaBoost-SCN混淆矩阵
(a) AdaBoost-SCN confusion matrix




(b) AdaBoost-KNN混淆矩阵
(b) AdaBoost-KNN confusion matrix



(c) AdaBoost-PNN混淆矩阵
(c) AdaBoost-PNN confusion matrix



(d) AdaBoost-SVM混淆矩阵
(d) AdaBoost-SVM confusion matrix



(e) AdaBoost-MCG混淆矩阵
(e) AdaBoost-MCG confusion matrix

图 6 各分类器混淆矩阵

Fig. 6 Confusion matrix of various classifiers

表 1 各分类器评价指标

Table 1 Evaluation metrics for each classifier

分类器	准确率/%	类别	精确率/%	召回率/%
AdaBoost-SCN	90	无覆冰	90	90
		1 级覆冰	89	86.4
		2 级覆冰	91	93.8
AdaBoost-KNN	88.7	无覆冰	90	88.2
		1 级覆冰	85	85
		2 级覆冰	91	92.9
AdaBoost-PNN	89	无覆冰	88	89.8
		1 级覆冰	85	85
		2 级覆冰	94	92.2
AdaBoost-SVM	92.3	无覆冰	93	92.1
		1 级覆冰	90	90.9
		2 级覆冰	94	94
AdaBoost-MCG	93.7	无覆冰	93	93
		1 级覆冰	92	91.1
		2 级覆冰	96	97

注:每个模型的准确率唯一,而每个模型的精确率和召回率对应于 3 种工况。

3.3 包裹式算法对比

表 1 中模型的准确率为未进行 LCPSO-AdaBoost-MCG 特征选择的结果,本节为验证 LCPSO 算法的优越性与实时性,将包裹式算法中常用的 3 种优化算法与本文方法进行对比,包括粒子群算法(PSO)、灰狼算法(GWO)、果蝇算法(FOA),特征集使用 MRMR 初选后的特征子集,分类器均使用 AdaBoost-MCG。由表 2 可知,通过对上述 4 种算法在特征子集维数、准确率和寻优时长方面进行对比可知:1) PSO 算法与 GWO 和 FOA 相比在准确率方面有优势,且寻优用时和特征子集维度相差较小。2) LCPSO 算法相比于 PSO 算法在准确率方面得到了提升,从算法寻优效率来看,LCPSO 算法寻优时长为 591 s,而 PSO 算法的寻优时长为 658 s,可见在准确率和寻优效率上 LCPSO 算法均优于 PSO 算法。因此本文提出的 LCPSO 算法相比其他 3 种算法综合性能最好,挑选

表 2 各寻优算法评价指标对比

Table 2 Comparison of evaluation indicators for various optimization algorithms

优化算法	准确率/%	特征子集维数/个	寻优时长/s
GWO	95.5	33	657
FOA	94.7	28	668
PSO	96.33	32	658
LCPSO	98.7	30	591

出的特征子集效果最佳。

3.4 特征选择方法有效性评估

原始特征集经过两个阶段(MRMR+LCPSO)的特征选择后,保留了 30 维对识别准确率贡献最大的特征,如表 3 所示,可以发现 30 维特征中特征的方差与均值有 15 维,说明引入相位特征的方差与均值对分类的贡献度很大(其中 CD 代表小波分量)。为说明本文方法挑选特征子集方法的优越性,对未降维特征集、仅使用 MRMR 算法初选后特征集和使用 MRMR+LCPSO 算法筛选的特征集进行性能评估,如表 4 所示,本文方法选择的特征子集在线计算时间仅需 1.01 s,经过两个阶段特征选择后,特征维度显著降低而且准确率达到了 98.7%,相比未降维与仅使用 MRMR 算法,准确率显著提升。本文所提特征选择体系挑选的特征子集,兼顾了准确率与实时性,满足实际工程中覆冰等级实时准确预警的要求。

表 3 LCPSO-AdaBoost-MCG 挑选的特征子集

Table 3 Feature subsets selected by LCPSO-AdaBoost-MCG

编号	特征	编号	特征
T1	波形指标方差	T16	波形指标均值
T2	有效值均值	T17	CD8 特征尺度熵(相位)
T3	峰峰值均值	T18	重心频率(幅值)
T4	样本熵方差	T19	方根幅值
T5	排列熵(相位)	T20	CD2 能量占比(幅值)
T6	标准差方差	T21	CD4 能量占比(幅值)
T7	标准差均值	T22	频率方差(相位)
T8	峭度方差	T23	峰值指标(幅值)
T9	奇异谱熵方差	T24	主频带位置(幅值)
T10	能量均值	T25	CD5 特征尺度熵(相位)
T11	排列熵方差	T26	CD7 特征尺度熵(幅值)
T12	平均幅值均值	T27	奇异谱熵(相位)
T13	裕度指标均值	T28	峭度(幅值)
T14	脉冲指标方差	T29	峰峰值(相位)
T15	脉冲指标均值	T30	波形指标(相位)

表 4 特征选择评价指标对比

Table 4 Comparison of feature selection evaluation indicators

特征选择阶段	特征维数/个	准确率/%	在线计算用时/s
未降维	89	90.3	2.90
仅 MRMR	60	93.7	2.79
MRMR+LCPSO	30	98.7	1.01

4 结 论

本文通过联合相位信号与幅值信号充分挖掘了不同覆冰工况下的特征,提出了适用于覆冰等级预警的特征选择算法(MRMR+LCPSO)与 AdaBoost-MCG 模型,挑选出的特征子集在现场数据集上验证,准确率能达到 98.7%。结论如下:

1) LCPSO 算法将粒子群中每个个体初始化为不同长度,该方法对于特征选择来说,提高了特征子集的多样性。其次,由于每个个体长度不同,LCPSO 算法缩短了搜索的时长节约了计算成本。

2) 由于 AdaBoost 采用加权投票的方式组合多种弱分类器,因此可以减少模型的过拟合问题,而且使用不同的弱分类器可以提高模型的泛化性能,测试结果表明,AdaBoost-MCG 算法相比于 AdaBoost 集成同一分类器的模型准确率提升了 1.4%~5%。

3) 将 MRMR+LCPSO 算法应用于覆冰等级分类任务中挑选出的特征子集,在 AdaBoost-MCG 模型上的准确率能达到 98.7%,使用该子集中的特征构建特征库,能实现覆冰等级的高效准确预警。

参考文献

- [1] 郝艳捧,魏发生,王斌,等.特殊地形下输电线路等值覆冰厚度计算模型有效性分析和改进研究[J].电网技术,2022,46(7):2786-2793.
HAO Y P, WEI F SH, WANG B, et al. Effectiveness analysis and improvement research of equivalent icing thickness calculation model for transmission lines in special terrains [J]. Power Grid Technology, 2022, 46 (7): 2786-2793.
- [2] YANG L, CHEN Y F, HAO Y P, et al. Detection method for equivalent ice thickness of 500 kV overhead lines based on axial tension measurement and its application [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-11.
- [3] 胡建林,刘杰,蒋兴良,等.基于弧垂测量的综合荷载下导线等值覆冰厚度监测方法[J].高电压技术,2022,48(2):584-593.
HU J L, LIU J, JIANG X L, et al. Monitoring method for equivalent ice thickness of conductors under comprehensive loads based on sag measurement [J]. High Voltage Technology, 2022, 48 (2): 584-593.
- [4] 邹红波,宋家乐,刘媛,等.基于 PSO-SVM 算法的输电线路覆冰舞动预测模型[J].振动与冲击,2023,42(3):280-286.
ZOU H B, SONG J L, LIU Y, et al. A prediction model for ice dancing on transmission lines based on PSO-SVM

algorithm [J]. Vibration and Shock, 2023, 42 (3): 280-286.

- [5] PALANGAR M F, AMIN U, BAKHSHAYESH H, et al. Identification of composite insulator criticality based on a new leakage current diagnostic index [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 9004110, 1-10.
- [6] 张旭莘,丁哲文,洪瑞,等.相位敏感光时域反射分布式光纤传感技术[J].光学学报,2021,41(1):93-107.
ZHANG X P, DING ZH W, HONG R, et al. Phase sensitive time-domain reflection distributed fiber optic sensing technology [J]. Acta Optica Sinica, 2021, 41(1): 93-107.
- [7] 郝伟博,赵衍双,李卓枢,等.基于相位敏感光时域反射技术的导线舞动状态监测[J].应用科学学报,2019,37(4):437-446.
HAO W B, ZHAO Y SH, LI ZH SH, et al. Monitoring of wire dancing status based on phase sensitive time-domain reflection technology [J]. Journal of Applied Science, 2019, 37 (4): 437-446.
- [8] DING ZH W, ZHANG X P, ZOU N M, et al. Phi-OTDR based on-line monitoring of overhead power transmission line [J]. Journal of Lightwave Technology 2021, 39(15): 5163-5169.
- [9] 李笑,高毅,吴昊,等.基于混合输入神经网络的 Phi-OTDR 系统模式识别方法[J].中国激光,2023,50(11):265-271.
LI X, GAO Y, WU H, et al. A hybrid input neural network based approach Phi-OTDR system pattern recognition method [J]. China Laser, 2023, 50 (11): 265-271.
- [10] ROBNIK-ŠIKONJA M, KONONENKO I. Theoretical and empirical analysis of Relief and RRelief [J]. Machine Learning, 2003, 53(1/2): 23-69.
- [11] DING C, PENG H CH. Minimum redundancy feature selection from microarray gene expression data [J]. Journal of Bioinformatics and Computational Biology 2005, 3(2): 185-205.
- [12] TIBSHIRANI R, HASTIE T, NARASIMHAN B, et al. Diagnosis of multiple cancer types by shrunken centroids of gene expression [J]. Proceedings of the National Academy of Sciences 2002, 99(10): 6567-6572.
- [13] 张可颖,吴新桥,赵继光,等.基于特征工程和集成学习与模型融合的输电走廊实时山火风险评估模型[J].电网技术,2023,47(11):4727-4736.
ZHANG K Y, WU X Q, ZHAO J G, et al. Real time mountain fire risk assessment model for transmission corridors based on feature engineering and ensemble

- learning and model fusion[J]. Power Grid Technology, 2023, 47 (11): 4727-4736.
- [14] 高慧敏,王云鹤,卞闯,等. 基于混合进化算法的特征选择方法研究[J]. 电子学报, 2023, 51(6): 1619-1636.
- GAO H M, WANG Y H, BIAN CH, et al. Research on feature selection methods based on hybrid evolutionary algorithms[J]. Journal of Electronics, 2023, 51(6): 1619-1636.
- [15] 王军,司昌馥,王凯鹏,等. 基于集成学习和改进的PSO-GA算法特征选择的入侵检测方法[J/OL]. 吉林大学学报(工学版), 1-9 [2024-08-19]. <https://doi.org/10.13229/j.cnki.jdxboxb.20230751>.
- WANG J, SI CH F, WANG K P, et al. Intrusion detection method based on ensemble learning and improved PSO-GA algorithm feature selection [J/OL]. Journal of Jilin University (Engineering Edition), 1-9 [2024-08-19]. <https://doi.org/10.13229/j.cnki.jdxboxb.20230751>.
- [16] 潘礼正,王顺超,丁忆,等. 基于全视域特征表征与ELM-Adaboost方法的情绪辨识研究[J]. 仪器仪表学报, 2022, 43(11): 162-171.
- PAN L ZH, WANG SH CH, DING Y, et al. Research on emotion recognition based on full field feature representation and ELM Adaboost method[J]. Chinese Journal of Scientific Instrument, 2022, 43(11): 162-171.
- [17] 詹文法,张鲁萍,江健生. 基于联合分类的有效测试模式重选方法[J]. 仪器仪表学报, 2023, 44(3): 155-162.
- ZHAN W F, ZHANG L P, JIANG J SH. An effective test pattern reselection method based on joint classification [J]. Chinese Journal of Scientific Instrument, 2023, 44(3): 155-162.
- [18] 戴虎,郑睿,马小陆,等. 基于粒子群的多毫米波安防机器人环境感知方法[J]. 仪器仪表学报, 2024, 45(1): 90-100.
- DAI H, ZHENG R, MA X L, et al. Environmental perception method for multi millimeter wave security robots based on particle swarm optimization[J]. Chinese Journal of Scientific Instrument, 2024, 45(1): 90-100.
- [19] 周俊海. 基于长度自适应遗传算法的高维数据特征选择研究[D]. 重庆大学, 2022.
- ZHOU J H. Research on high-dimensional data feature selection based on length adaptive genetic algorithm[D]. Chongqing University, 2022.
- [20] 司江宽,吐松江·卡日,范想,等. 基于SO-PAA-GAF和AdaBoost集成学习的高压断路器故障诊断[J]. 电力

系统保护与控制, 2024, 52(3): 152-160.

SI J K, TUSONGJIANG K R, FAN X, et al. Fault diagnosis of high-voltage circuit breakers based on SO-PAA-GAF and AdaBoost ensemble learning[J]. Power System Protection and Control, 2024, 52(3): 152-160.

作者简介



尚秋峰, 1990年于电子科技大学获得学士学位, 1999年于华北电力大学获得硕士学位, 2005年于华北电力大学获得博士学位, 现为华北电力大学电子与通信工程系教授, 主要研究方向为光通信与光传感、模式识别与人工智能。

E-mail: lindashqf@126.com


Shang Qiufeng received her B. Sc. degree from the University of Electronic Science and Technology of China in 1990, and received her M. Sc. degree from North China Electric Power University in 1999, and received her Ph. D. degree from North China Electric Power University in 2005. She is currently a professor in the Department of Electronic and Communication Engineering at North China Electric Power University, with main research directions in optical communication and sensing, pattern recognition, and artificial intelligence.



谷元宇, 2022年于河北农业大学获得学士学位, 现为华北电力大学在读硕士研究生, 主要研究方向为光纤传感与模式识别。

E-mail: 1315019394@qq.com

Gu Yuanyu received his B. Sc. degree from Hebei Agricultural University in 2022, He is currently a master's student at North China Electric Power University. His main research direction is fiber optic sensing and pattern recognition.



王健健(通信作者), 2005年于华北电力大学获得学士学位, 2008年于北京交通大学获得硕士学位, 2021年于华北电力大学获得博士学位, 现为华北电力大学电子与通信工程系讲师, 主要研究方向为光纤传感技术及智能信息处理。

E-mail: ncepuwangjj@163.com

Wang Jianjian (Corresponding author) received her B. Sc. degree from North China Electric Power University in 2005, and received her M. Sc. degree from Beijing Jiaotong University in 2008, and received her Ph. D. degree from North China Electric Power University in 2021. Currently, She is a lecturer in the Department of Electronic and Communication Engineering at North China Electric Power University, with a main research focus on fiber optic sensing technology and intelligent information processing.