

DOI:10.19651/j.cnki.emt.2211418

基于改进 VMD 与特征选择的路灯故障检测方法^{*}

覃尚昊¹ 胡迎春¹ 周明² 曾思勇¹

(1. 广西师范大学电子与信息工程学院 桂林 541004; 2. 桂林海威科技股份有限公司 桂林 541004)

摘要: 路灯正常运行对于城市照明具有重要意义。当前路灯故障检测局限于初步的故障现象,无法辨识具体的故障类别。为实现路灯具体故障类别的检测,本文以路灯监控和数据采集系统的路灯运行数据为对象,提出了一种基于改进 VMD 与特征选择的路灯故障检测模型。首先,利用主成分分析法筛选路灯运行数据的主要变量参数,并用变分模态分解对筛选参数进行分解。同时,引入鲸鱼优化算法改进变分模态分解的自适应性。在特征选择方面,通过 Pearson 系数选择相关 IMF 分量结合样本熵构建故障特征向量。最后,结合广西崇左市 2019~2022 年路灯故障数据,建立基于 XGBoost 的故障诊断模型,从而辨别路灯的正常、电源故障、线路故障、保险故障 4 种状态。实验结果表明,该方法能有效实现路灯具体故障类别的诊断,故障辨识率为 93.75%,为路灯故障检测研究提供了新途径。

关键词: 路灯故障检测;VMD;鲸鱼优化算法;Pearson 系数;XGBoost

中图分类号: TM75;TU113.666 文献标识码: A 国家标准学科分类代码: 510.99

Streetlight fault detection method based on improved VMD and feature selection

Qin Shanghao¹ Hu Yingchun¹ Zhou Ming² Zeng Siyong¹

(1. College of Electrical and Information Engineering, Guangxi Normal University, Guilin 541004, China;

2. Guilin HiVison Technology Co., Ltd., Guilin 541004, China)

Abstract: As the core equipment of the urban lighting system, the regular operation of streetlights is of great significance to urban lighting. Currently, streetlight fault detection is limited to preliminary fault phenomenon. To detect the streetlight's specific fault category, this paper takes the streetlight operation data of the streetlight monitoring and data acquisition system as the object. A streetlight fault detection model based on improved VMD and feature selection is proposed combining the traditional method, the data-driven method and the signal processing method. First, principal component analysis filters the main variable parameters of streetlight operation data, and variational mode decomposition is used to decompose the screened parameters. Similarly, the whale optimization algorithm is introduced to improve the adaptability of the variational mode decomposition. Secondly, the Pearson coefficient selects the relevant IMF components, and the sample entropy is used to construct the fault feature vector. Through the experimental verification of the streetlight fault statistical data of the urban lighting monitoring system in Chongzuo City, Guangxi, the results show that the proposed fault diagnosis method can effectively extract the fault feature information of different fault states of streetlights. The correct rate of fault diagnosis is 93.75%, which provides a new way for streetlight fault diagnosis.

Keywords: streetlight fault detection;VMD;whale optimization algorithm;Pearson coefficient;XGBoost

0 引言

路灯是城市中分布最为广泛的基础设施,路灯故障的日常维护与检修是城市照明能否正常运作的关键。路灯设施大规模应用,也使得城市照明的维护与检修工作面临着

更加严苛的状况。

传统的路灯故障诊断方法主要依靠人工排查检修,存在排查效率低和耗费时间成本不足。目前在实际应用中主要采用物联网技术搭建路灯监控与数据采集系统^[1],并构建阈值规则、故障树等进行初步的故障诊断。何欣^[2]通过

收稿日期:2022-09-16

^{*} 基金项目:国家自然科学基金(51565007)、桂林市重点研发计划项目(2019021113)资助

系统监控各路灯节点电压、电流等运行参数是否超过设定阈值进行故障预警。文献[3-4]通过预设路灯不同运行参数的可变动范围进行故障诊断。Fabio^[5]基于 Zigbee 无线传感器对路灯节点的运行参数进行逐点采集以检查路灯的状态并在出现故障时采取适当措施。以上诊断方法侧重于路灯发生故障后的第一时间警报反馈,但诊断结果局限于路灯负载过低、负载过高、终端离线等初步的故障现象,无法与具体的故障类别相联系,对路灯故障的排查检修存在一定局限性。因此,在初步故障现象识别的基础上实现更为具体的故障诊断是亟待解决的问题^[6]。

由于路灯运行数据的保密要求,目前结合路灯运行数据的故障诊断相关研究未广泛开展。章建涛对四川宜宾市路灯故障运行数据的研究分析^[7],提出了基于 ELM 极限学习的路灯节点故障诊断方法。该方法通过构造 ELM 快速学习模型以学习路灯具体故障与相应运行数据之间的关系实现故障诊断。该方法基于纯数据驱动的方式实现了具体类别的故障诊断,然而基于纯数据驱动的故障诊断会忽略路灯运行时部分电气参数的周期性、长期趋势特性,在时间维度上的可解释性弱。路灯监控与数据采集系统的路灯运行数据属于时间序列数据,故障的发生在当前与历史时间窗口中运行数据会表现出相关性。如运行期间,电流、电压等变量参数表现出周期特性与趋势性^[8]。因此,可对大量路灯的历史运行数据进行分析,研究路灯运行数据与具体故障间的深层次关系实现具体故障的辨识。

变分模式分解 (variational mode decomposition, VMD) 是一种处理非平稳时间序列信号方法^[9],原理是将信号分解成包含原信号各时间尺度部分特征的有限个模态分量 (intrinsic mode functions, IMF)。具有良好的抑制模态混叠与端点效应能力,在故障检测领域已广泛应用。文献[10]分析了在 VMD 分解信号过程中分解参数选择不规律会影响分解效果,由于 VMD 在现阶段用于路灯运行信号的分解研究较少。因此,预设 VMD 分解参数可能会导致路灯运行信号故障特征不充分,无法最大程度保留故障特征。

综上所述,在路灯故障检测相关的研究工作中,均侧重于单一的传统方法或者纯数据驱动方法。因此,本文在总结现有工作的研究基础上,将传统方法、数据驱动方法、信号处理方法相结合提出了一种基于改进 VMD 与特征选择的路灯故障检测模型,进而辨别路灯运行的正常、保险故障、线路故障、电源故障 4 种状态。实验结果表明,该方法能有效揭示路灯不同故障运行数据与故障之间的相关性,实现具体故障类别的检测,对路灯故障检修具有一定的工程应用价值和现实意义。

1 诊断思路与方法

1.1 路灯监控与数据采集系统分析

路灯监控和数据采集系统主要功能是对路灯节点进行监控管理,通过传感器收集相关运行参数,由集中控制器定

时传输记录每个路灯节点的数据到监控系统,为本文路灯故障诊断提供数据来源和支持。路灯运行数据采集过程如图 1 所示,路灯运行数据采集设备如图 2 所示。

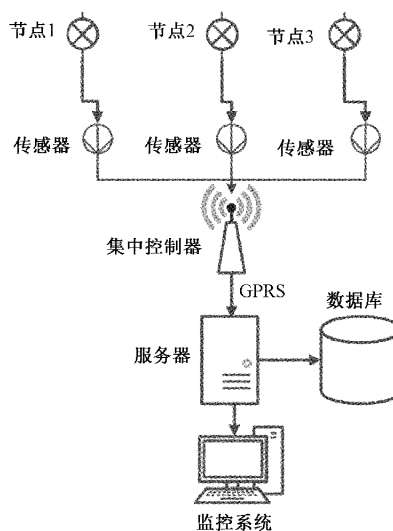


图 1 路灯运行数据采集过程



图 2 路灯运行数据采集设备与集中控制器

1.2 路灯故障检测方法

图 3 为路灯监控与数据采集系统的路灯故障报警信息记录。当路灯发生故障时,路灯监控和数据采集系统按照阈值规则及故障树分类进行初步的路灯故障类型识别,如终端离线、终端负载过低等。表 1 为检修工作人员记录的部分路灯故障检修实例,本文依据专业领域相关知识将路灯运行过程中可能发生的故障整体划分为 3 类,分别为电源故障、线路故障、保险故障。

序号	设备名称	故障名称	故障信息	发生时间
1	AL29 花山南桥	新城西XC17-3	终端离线报警	2022-03-27 01:50:46
2	AL42 立交桥	LJQA01	终端离线报警	2022-04-13 08:37:02
3	AL42 立交桥	LJQA03-2	终端离线报警	2022-04-13 04:38:53
4	AL42 立交桥	LJQA18-2	终端离线报警	2022-03-20 04:08:51
5	AL42 立交桥	LJQA19-1	终端离线报警	2022-03-26 04:05:56
6	AL42 立交桥	LJQA21-1	终端离线报警	2022-03-26 04:07:27
7	AL42 立交桥	LJQA22-1	终端离线报警	2022-03-23 04:05:10
8	AL42 立交桥	LJBT09	灯真故障	2022-03-24 11:50:40
9	AL09 碧山花山	LXS149-2	终端离线报警	2022-04-15 04:19:28
10	AL09 碧山花山	LXS150-2	终端离线报警	2022-04-15 04:26:30

图 3 路灯监控与数据采集系统故障报警信息

表 1 部分路灯故障检修记录实例

时间	故障现象	故障类型
2021 年 6 月 20 日	友谊路 067 号杆保险烧坏	保险故障
2021 年 3 月 23 日	龙峡山路 040 号杆灯杆 火线断开,无电压上杆	线路故障
2021 年 4 月 2 日	佛子路 076 号杆电源烧坏	电源故障
2021 年 10 月 29 日	建设路 037 杆内跳闸	线路故障

基于上述描述,本文将相应的路灯运行数据、人工现场维护检修记录及路灯监控与数据采集系统的路灯故障报警信息相结合为分析对象,提出一种基于改进 VMD 与特征选择路灯故障检测模型。首先,运用主成分分析法(principal component analysis,PCA)^[11]对路灯运行数据的多维度变量参数进行降维,筛选主要变量参数作为 VMD 输入信号进行分解。VMD 能够对发生故障的路灯运行数据进行时频域建模,按照故障时间序列找到对应的时间区间分析故障数据变化的趋势性和周期性,提取路灯运行数据的故障特征信息。同时,为改进 VMD 分解的自适应能力和分解效果,引入鲸鱼优化算法^[12](whale optimization algorithm,WOA)结合包络熵的方式对 VMD 分解参数的选择进行了改进优化。其次,通过计算皮尔逊相关系数(Pearson correlation coefficient,PCC)^[13]选取信号分解后具有表征意义的模态分量,并计算样本熵值构建故障特征向量,最后基于分类算法建立故障辨别模型,从而进行路灯的电源故障、保险故障、线路故障、正常 4 类状态的识别。路灯故障具体步骤如图 4 所示。

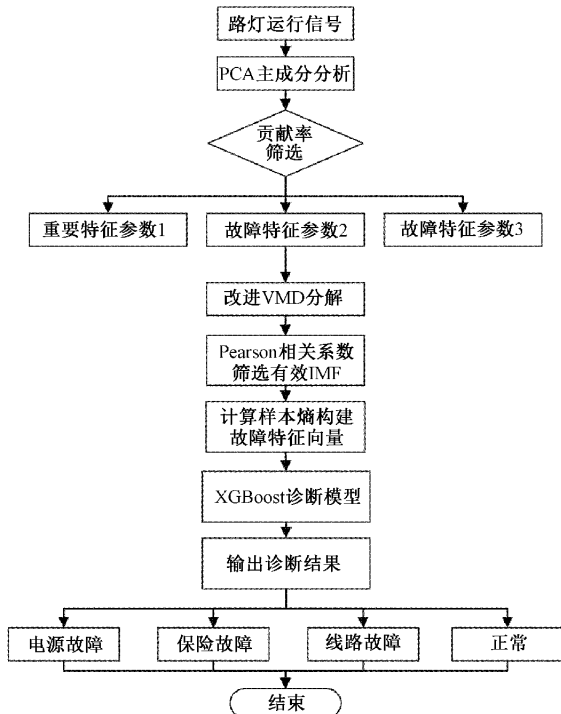


图 4 路灯故障检测流程

2 算法理论

2.1 数据预处理

路灯运行数据包含多种变量参数,多维度变量参数之间可能存在相关性与独立性。为避免受到噪声干扰等因素的影响,本文利用主成分分析法对路灯运行数据进行降维,分别计算多种变量参数的主成分贡献率和累积贡献率。在降低数据维度的同时,尽量减少原始数据包含信息的损失,通常以累积贡献率在 85% 以上作为主成分提取阈值筛选信号的重要特征参数作为后续 VMD 分解的输入信号。路灯运行数据降维过程如图 5 所示。

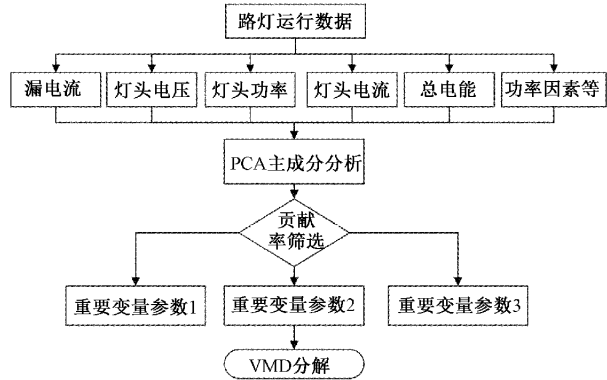


图 5 降维过程

主成分分析法是一种高维度特征数据降维、特征提取的无监督学习算法,采用特征分解方式,提取原始数据主要成分,实现高维度特征数据降维。主要步骤包括:以设定步长采集的路灯故障前正常运行时 m 个时刻的时间序列状态数据作为训练数据,每个训练数据包括 n 维特征变量,将路灯原始运行数据分成 $[m, n]$ 大小的矩阵 X ,依据式(1)对矩阵 X 去均值 \bar{X} ;依据式(2)对矩阵 X 进行标准化后计算其协方差矩阵 R ;对协方差矩阵 R 进行特征分解求特征值和特征向量;依据式(3)选择贡献率最大的特征值对应的特征向量作为子空间的基,构造新的低维空间矩阵,用较少的数据维度表征原数据的大部分信息量,实现数据从高维空间到低维空间的转变。

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \tag{1}$$

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2} \tag{2}$$

$$C = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(y_i - y) \tag{3}$$

其中, \bar{X} 为去均值矩阵公式, s 为标准化公式, C 为贡献率计算公式。

2.2 基于 WOA 改进 VMD

由于 VMD 分解时参数 k 和 α 的选择不当会影响 VMD 的分解效果,出现故障特征信息不充分问题。因此,本文引入鲸鱼优化算法改进 VMD 分解参数。以包络熵极

小值为适应度函数,即优化效果评价指标,对 VMD 分解参数 k 、 α 进行自适应参数寻优,改进 VMD 分解的自适应性。包络熵 E_p 的计算过程如式(4)所示。

$$\begin{cases} E_p = - \sum_{j=1}^N P_j \lg P_j \\ P_j = a(j) / \sum_{j=1}^N a(j) \end{cases} \quad (4)$$

式中: P_j 为 $a(j)$ 的概率分布序列; $a(j)$ 是由 VMD 分解的 k 个模态分量经希尔伯特解调后的包络信号。包络熵代表原始信号的稀疏特性,当经 VMD 算法分解后的 IMF 分量包含的故障特征信息较多时,则包络熵值较小;反之则包络熵值较大。因此,采用包络熵值作为鲸鱼优化算法的优化效果评价指标。

鲸鱼优化算法是一种模仿自然界中鲸鱼捕食行为的新群体智能优化算法,其优化过程模拟了鲸鱼的捕食行为:包围猎物、气泡网攻击及收缩包围捕食。其中包围猎物的行为用数学公式表示为:

$$\vec{X}(t+1) = \vec{X}^*(t) - A \cdot \vec{D} \quad (5)$$

$$\vec{D} = |C \cdot \vec{X}^* - \vec{X}(t)| \quad (6)$$

$$A = 2 \cdot a \cdot r - a \quad (7)$$

$$C = 2 \cdot r \quad (8)$$

其中, \vec{X} 是鲸鱼的位置, \vec{X}^* 是当前的最佳位置, t 是迭代次数, a 在迭代过程中从 2 逐渐减少到 0, r 是在 $[0, 1]$ 范围内均匀分布的随机数。算法利用螺旋方程模拟鲸鱼通过螺旋运动包围猎物,依据式(9)完成包围猎物发动气泡网攻击,收缩包围捕食的行为如式(10)所示。

$$\vec{X}(t+1) = e^{bl} \cdot \cos(2\pi l) \cdot \vec{D}' + \vec{X}^*(t) \quad (9)$$

$$\vec{D}' = |\vec{X}^*(t) - \vec{X}(t)| \quad (10)$$

以上表达式中, b 为螺旋形状常数, l 是均匀分布在 $[-1, 1]$ 的随机数。由于鲸鱼在包围猎物时有可能同时进行螺旋运动,假设包围猎物及发动气泡网攻击两种行为的概率为 50%。引入随机数 $P \in [0, 1]$, 若 $P < 0.5$, 则依据式(5)、(6)更新位置,反之依据式(9)、(10)更新位置。

为了具备全局优化能力,避免陷入局部最优解,算法模拟了鲸鱼根据同伴位置进行随机搜索,如下:

$$D = |C \cdot \mathbf{X}_{rand}(t) - \mathbf{X}| \quad (11)$$

$$\vec{X}(t+1) = \mathbf{X}_{rand} - A \cdot D \quad (12)$$

式中: \mathbf{X}_{rand} 为随机选择的鲸鱼位置,若 A 的绝对值大于 1 时,鲸鱼将离开当前包围猎物去寻找新猎物,位置依据式(11)、(12)进行更新,避免陷入局部最优解。鲸鱼优化算法流程如图 6 所示。

2.3 特征选择

信号基于改进 VMD 的分解得到一系列 IMF 分量,考虑到故障特征信息分布在不同频率的 IMF 分量上。为实现筛选包含较多原始信号特征信息和能有效表征故障信息

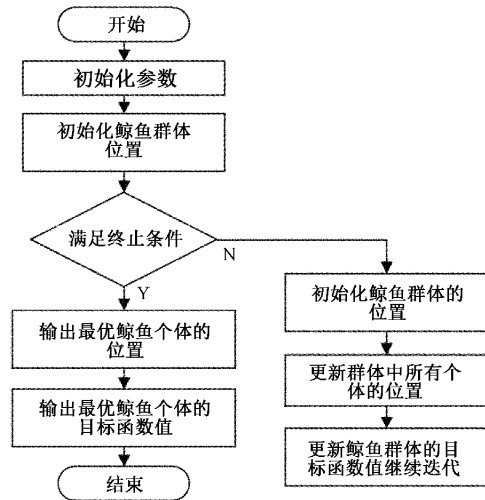


图 6 鲸鱼优化算法流程

的 IMF 分量,本文通过计算每个 IMF 分量与原始信号的 Pearson 相关系数进行筛选。

Pearson 相关系数可以反映原始信号与 IMF 分量之间的相关程度,当相关系数高于规定的阈值 0.2 时^[13],则认为相关程度较高。则原始信号 $x(t)$ 与各 IMF 分量 $x_n(t)$ 之间的 Pearson 相关系数 ξ 可表示为:

$$\xi = \frac{\sum_{t=0}^{T-1} x(t)x_n(t)}{\sqrt{\sum_{t=0}^{T-1} x^2(t) \sum_{t=0}^{T-1} x_n^2(t)}} \quad (13)$$

样本熵以一个非负数表示时间信号序列的复杂性和不规则度,样本熵值越大,表明该信号时间序列成分越复杂,反之,则序列越规律。与模糊熵^[14]、排列熵^[15-16]等相比,样本熵具有所需数据短、抗噪声性和抗干扰能力强、在参数的大取值范围内一致性好等优点。因此,本文基于 Pearson 相关系数筛选 IMF 分量,并计算样本熵值作为特征向量,划分路灯不同状态的样本熵区段。

2.4 基于集成学习的故障辨别

集成学习算法(eXtreme gradient boosting, XGBoost)是在梯度提升树相关算法和工程基础上改进开发的分类模型,在故障诊断和风险预测领域被广泛应用^[17-18]。XGBoost 基于决策树为子模型,通过梯度提升树实现多棵树的集成学习,得到最终模型。

本文采用 XGBoost 作为路灯 4 种状态的辨别模型,分别为正常,电源故障、线路故障、保险故障,并标记对应的数字标签。模型的辨别结果标准为模型输出为分类器 4 类状态的辨别准确率,选择辨别准确率占比最大的类别作为输出结果。

3 实验验证与分析

3.1 实验数据处理

本文实验数据来源于广西壮族自治区崇左市 2019 年~

2022 年路灯故障信息记录。路灯监控与数据采集系统所采集的路灯运行数据如图 7 所示。在保证丰富的故障特征信息的情况下,将路灯故障发生当前与历史时间窗内 1 000 个数据采样点作为一组样本,每种状态的样本 40 组,4 种状态共 160 组。按照 8 : 2 划分训练集与测试集,其中训练数据 128 组,测试数据 32 组。

序号	故障类型	发生时间	电压/V	电流/A	功率/W	频率/Hz	相位角/°	功率因数
1	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
2	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
3	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
4	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
5	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
6	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
7	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
8	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
9	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
10	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
11	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
12	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
13	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
14	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
15	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0
16	路灯故障	2022-09-01 10:00:00	220.0	0.5	110.0	50.0	0.0	0.0

图 7 监控与数据采集系统路灯运行数据信息

本文采用主成分分析法对相关路灯运行数据进行降维,通过计算数据中变量参数的主成分贡献率作为筛选指标。图 8 为路灯原始数据经 PCA 处理后各主成分的贡献率及累计贡献率情况。可知,当主成分个数为 3 时,累计贡献率为 93.63%,当选取 5 个主成分时,累计贡献率超过了 95%。合理选择主成分个数既可以代表路灯原始运行信号的大部分特征信息量,并且在一定程度上减少参数冗余和噪声干扰。因此,依据设定的主成分提取阈值 85% 选取电压、电流、功率 3 种主成分作为后续的 VMD 分解的输入信号。




图 8 贡献率及累计贡献率分析图

3.2 VMD 参数优化

针对 VMD 分解参数选择不当,导致故障特征信息不丰富等问题,采用鲸鱼优化算法结合包络熵为适应度函数,对 VMD 的分解参数进行优化改进。为体现鲸鱼算法对 VMD 分解参数的优化效果,本文以粒子群优化算法^[19](particle swarm optimization, PSO)和遗传优化算法(genetic algorithm, GA)对路灯保险故障状态电压信号的优化效果进行比对。在参数优化过程中,设定参数搜索范围为 $k: [1, 10], \alpha: [100, 5\ 000]$,种群均设置为 50,最大迭代次数为 20,均以最小包络熵为优化目标确定 VMD 参数的最佳适应度,即优化效果评价指标。

不同优化算法的 VMD 分解参数自适应曲线如图 9 所

示。由图可知,基于粒子群算法和遗传算法的优化在迭代过程中收敛速度慢,优化效果未达到 VMD 分解参数的最佳适应点。基于鲸鱼算法优化的自适应曲线在第 6 轮迭代过程后达到了稳定收敛,且最小包络熵值更低,优化效果达到了 VMD 分解参数的最佳适应点。因此,鲸鱼优化算法的参数优化效果更佳,其自适应能力,收敛速度要优于粒子群算法和遗传算法。




图 9 不同优化算法下的优化结果

以保险故障状态电压参数为例,基于 WOA 改进 VMD 分解参数的包络熵,分解模态数 k 及惩罚因子 α 优化过程如图 10~12 所示。




图 10 包络熵优化过程




图 11 分解模态数优化过程

采用鲸鱼优化算法分别对路灯 4 种不同状态下电压、




图 12 惩罚因子优化过程

电流、功率参数进行 VMD 分解参数组合 $[k, \alpha]$ 参数寻优, 参数寻优结果如表 2 所示。

表 2 4 种状态分解参数组合

路灯状态	电压信号	电流信号	功率信号
电源故障	[7,3 100]	[8,3 300]	[6,2 800]
保险故障	[8,3 000]	[9,3 500]	[8,3 900]
线缆故障	[10,2 250]	[9,2 400]	[8,2 860]
正常状态	[7,2 100]	[7,2 330]	[9,4 000]

根据表 2 的参数优化结果,将路灯运行数据中电压、电流、功率参数作为输入信号进行 WOA 改进 VMD 参数优化分解,分析路灯在故障时间窗中不同故障的运行参数所表现出的周期性与趋势性,提取故障特征信息。以电压参数为例,路灯 3 种故障状态的分解结果如图 13~15 所示。




图 13 电源故障电压信号分解结果

以上分解结果表明,在路灯故障发生的当前与历史时间窗内,不同频率的 IMF 分量中信号波动存在明显的周期性和趋势性。由图可知,电源故障由于电源线路接触不严密导致电源电压逐渐降低。在故障时间窗前期产生了征兆




图 14 保险故障电压信号分解结果




图 15 线路故障电压信号分解结果

性的信号波动,符合路灯电源故障特性。保险故障由于前期线路电压过载,导致电压在过载一段时间后出现明显波动,在故障时间窗内电压信号波动较为明显,符合保险故障特性。线路故障的主要原因为电源开关跳闸短路,发生跳闸后无电压流经。电压参数 VMD 分解图中,在故障时间窗内存在明显趋势,符合线路故障特性。

3.3 故障特征选择

考虑故障特征信息分布在不同频率成分的 IMF 分量中,本文对所分解得到的各 IMF 分量计算与原始信号的 Pearson 相关系数,依据阈值筛选与原始信号高度相关且能表征故障特征的 IMF 分量。各 IMF 分量与原始信号的 Pearson 相关系数数值结果如表 3 所示。

表 3 中加粗数值为超过设定阈值,由表 3 和设定阈值可知,电源故障和正常状态的主要特征信息分布在 IMF2-IMF5,保险故障、线路故障的主要特征信息分布在 IMF3-

表 3 Pearson 相关系数表

路灯状态	电源故障	保险故障	线路故障	正常状态
IMF1	0.095	0.079	0.026	0.058
IMF2	0.565	0.153	0.023	0.214
IMF3	0.742	0.916	0.268	0.872
IMF4	0.821	0.759	0.812	0.826
IMF5	0.283	0.317	0.864	0.272
IMF6	0.193	0.156	0.161	0.097
IMF7	0.138	0.092	0.115	0.073
IMF8	0.062	0.051	0.089	0.032
IMF9	0.055	0.038	0.085	0.006
IMF10	0.002	0.015	0.004	0.001

IMF5;由于所有路灯状态 IMF5 分量的相关系数均大于阈值,且仅有保险故障、线路故障的 IMF2 分量相关系数小于阈值。因此,为尽可能保留有效故障特征信息实现故障诊断,本文选择 IMF2-IM5 计算样本熵值构造故障特征向量集。

表 4 为路灯不同状态下电压、电流、功率参数 IMF2-IMF5 分量的样本熵均值。由图 16 可知,采用本文故障特征提取方法能有效地提取路灯各状态运行信号蕴含的丰富特征信息。IMF 分量计算的样本熵值范围划分明显,且构造的特征向量具有较好的区分性,很好地反映了路灯运行信号与不同状态之间的相关特性,证明了本文故障特征提取方法可以有效提取路灯不同状态下运行参数的特征信息。

表 4 WOA 参数优化 IMF 分量样本熵

路灯状态	IMF2	IMF3	IMF4	IMF5
电源故障	0.119	0.437	0.458	0.301
保险故障	0.167	0.472	0.495	0.318
线路故障	0.149	0.411	0.396	0.284
正常状态	0.235	0.501	0.526	0.452

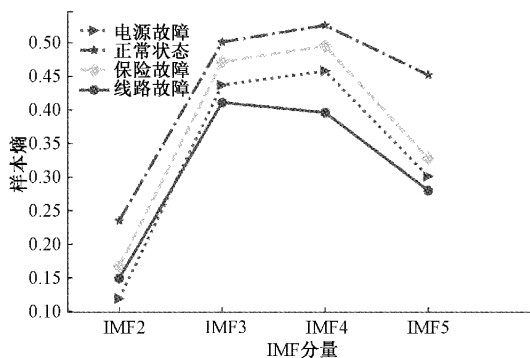


图 16 不同故障类别样本熵划分

3.4 实验结果分析

对 160 组路灯数据的电压、电流、功率参数进行故障特

征提取,制作故障特征向量 $(x_1, x_2, x_3, x_4, \dots, x_{11}, x_{12})$ 形成故障样本集。按照比例 8 : 2 划分故障特性向量集,选取训练集样本 128 组,测试集样本 32 组。用数字标签代替路灯运行状态,其中测试样本的顺序为:1~8 为正常状态(标签 0);9~16 为保险故障状态(标签 1);17~24 为线路故障状态(标签 2);25~32 为电源故障状态(标签 3)。以制作好的故障样本集与对应标签作为输入量,输入 XGBoost 模型进行故障检测。模型参数设置选取 gblinear 为基学习器,学习器数量为 100,学习率为 0.1,树的最大深度为 50。路灯 4 种状态下的测试样本诊断结果如图 17 所示。




图 17 测试样本结果

测试结果表明,测试集 32 组样本中正常状态、保险故障状态和线路故障状态的故障识别率达 100%,电源故障状态有 2 个样本被错分为保险故障状态,考虑两种故障的 IMF 样本熵值范围近似。因此,本文方法基于 XGBoost 模型的故障识别率为 93.75%。

为进一步验证本文方法的合理性和可靠性,本文将 EEMD、LMD、VMD、GA 优化 VMD 参数结合样本熵重构故障特征向量集的特征提取方法进行比对。其中,160 组路灯节点数据制作的故障样本集按照比例 8 : 2 划分,通过计算 IMF2-IMF5 阶样本熵制作故障样本集,与对应标签作为输入量分别输入 XGBoost 判别模型进行诊断。遗传算法种群设置为 50,最大迭代次数为 20。表 5 为不同方法的测试集识别结果。

表 5 不同方法测试集结果比较

序号	特征提取方法	识别率/%
1	EEMD+SampEn	70.2
2	LMD+SampEn	78.5
3	VMD+SampEn	80.1
4	GA-VMD+SampEn	85.3
5	WOA-VMD+SampEn	93.7

比较结果表明,由于 EEMD、LMD 分解存在模态重叠,端点效应等问题,该方法的故障识别正确率偏低。VMD 分解方法能有效地克服端点问题,因此,采用 VMD

方法的故障辨别率得到了提升。基于鲸鱼优化算法改进的 VMD 分解比基于遗传算法改进 VMD 识别率高,验证了引入鲸鱼优化算法在 VMD 分解参数优化方面具有更好的优化效果,提高了模型的故障辨别率。

综上,基于本文方法建立的路灯故障诊断模型在实际应用中,当路灯监控与数据采集系统上报路灯警报信息时,选取故障路灯对应时间区间内的历史运行数据的电压、电流、功率参数,并对 3 种参数进行 WOA 改进 VMD 分解。其次,计算 IMF2-IMF5 的样本熵值,构造故障特征向量 $(x_1, x_2, x_3, x_4, \dots, x_{11}, x_{12})$ 。最后将该故障特征向量输入建立好的模型进行诊断,依据模型输出的数字标签对应相关的故障。至此,路灯故障诊断过程结束。

根据路灯监控与数据采集系统的数据采集情况,模型可用于后续崇左市的路灯故障离线分析或在线分析中,随着路灯故障样本逐渐增多,可对已训练好的路灯故障检测模型进行定期增量训练,增强模型的泛化能力,提高模型的故障辨别率。

4 结 论

本文提出了一种基于改进 VMD 与特征选择的路灯故障检测模型。从而辨别路灯实际运行过程中的具体故障类别。实验结果表明:

根据主成分分析法计算贡献率对路灯运行数据降维,有效地筛选了运行数据中的主要变量参数,减少了参数冗余。

在 VMD 分解算法中引入 WOA 算法优化分解参数 $[k, \alpha]$,实现了对分解参数的寻优,有效避免了经验观察法 VMD 分解造成的不足。基于改进 VMD 对路灯不同故障的分解结果表明,故障当前与历史时间窗内相关参数存在明显的周期性和趋势性,从多角度揭示了路灯不同故障的内在特性。

在构造故障特征向量过程中,引入 Pearson 相关系数筛选相关性高的 IMF 分量,相对完整地保留了有效故障特征信息,从而提高故障辨识度。

参考文献

- [1] 秦洪海. 智慧城市背景下的智慧路灯合理性设计[J]. 智能城市, 2021, 7(14): 36-37.
- [2] 何欣. 市政工程自动化领域中通讯网络的应用及优化[D]. 南京: 南京邮电大学, 2015.
- [3] 程婷婷, 胡炜薇, 崔佳冬. 智慧路灯远程监控平台的设计与实现[J]. 计算机应用与软件, 2018, 35(3): 93-97.
- [4] 孟志强, 刘小可, 周华安, 等. NB-IoT 无线路灯控制器研究[J]. 湖南大学学报(自然科学版), 2021, 48(12): 146-152.
- [5] FABIO L. Remote-control system of high efficiency

and intelligent street lighting using a ZigBee network of devices and sensors[J]. IEEE Transactions on Power Delivery, 2013, 28(1): 21-28.

- [6] 王广宁. 智慧路灯控制模块研发及其应用[D]. 深圳: 中国科学院大学(中国科学院深圳先进技术研究院), 2020.
- [7] 章建涛. 面向城市照明系统的智能故障诊断与预测方法研究[D]. 成都: 电子科技大学, 2017.
- [8] 李祥和. 基于物联网技术的智慧路灯管理系统设计[J]. 自动化与仪器仪表, 2018(7): 113-116.
- [9] DRAGOMIRETSKIY K, ZOISSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [10] 刘建昌, 权贺, 于霞, 等. 基于参数优化 VMD 和样本熵的滚动轴承故障诊断[J]. 自动化学报, 2022, 48(3): 808-819.
- [11] 郑甲宏, 赵敬超. 一种基于 PCA-BP 的直升机起落架着舰载荷评估方法[J]. 中国测试, 2021, 47(5): 156-161.
- [12] 王鹏翔, 沈娟, 王菁咏, 等. 基于 PCA-LMD-WOA-ELM 的短期光伏功率预测[J]. 智慧电力, 2022, 50(6): 72-78.
- [13] 刘若男, 辛义忠, 李岩. 基于皮尔逊相关系数的动态签名验证方法[J]. 仪器仪表学报, 2022, 43(7): 279-287.
- [14] 张勇, 刘洁, 路敬祎, 等. 基于 VMD 去噪及多尺度模糊熵的管道小泄漏研究[J]. 电子测量技术, 2021, 44(22): 37-43.
- [15] 姚德臣, 杨建伟, 程晓卿, 等. 基于多尺度本征模态排列熵和 SA-SVM 的轴承故障诊断研究[J]. 机械工程学报, 2018, 54(9): 168-176.
- [16] 王菲, 冯早, 朱雪峰. 基于 FOA 优化的 CSSVM 管道堵塞状态识别研究[J]. 电子测量与仪器学报, 2020, 34(7): 168-176.
- [17] 马良玉, 程善珍. 基于支持向量数据描述和 XGBoost 的风电机组异常工况预警研究[J]. 电工技术学报, 2022, 37(13): 3241-3249.
- [18] 徐伟, 夏志祥, 行鸿彦. 基于集成经验模态分解和极端梯度提升的雷电预警方法[J]. 仪器仪表学报, 2020, 41(8): 235-243.
- [19] 居明宇. 基于 PSO 算法的 DBN 模型参数优化[J]. 国外电子测量技术, 2020, 39(3): 12-16.

作者简介

覃尚昊, 硕士研究生, 主要研究方向为故障诊断。

胡迎春(通信作者), 博士, 教授, 主要研究方向为人工智能与智能制造技术。

E-mail: gxnuhyc@mailbox.gxnu.edu.cn