

多维特征优化提取的电力系统扰动辨识方法

刘灏, 廖梦竹, 毕天姝*

(新能源电力系统国家重点实验室(华北电力大学), 北京市 昌平区 102206)

Power System Disturbance Identification Method Based on Optimized Multi-dimensional Feature Extraction

LIU Hao, LIAO Mengzhu, BI Tianshu*

(State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources,
(North China Electric Power University), Changping District, Beijing 102206, China)

ABSTRACT: The large-scale integration of renewable energy has increased the penetration of power electronics in power systems. The weak support and low immunity of power systems have augmented the probability of cascading failures. The rapid identification of power system disturbances based on the phasor measurement unit can offer support for system security and stability control. Nevertheless, the complexity of the dynamic behavior of power systems has resulted in an increase in the intra-class variance and inter-class similarity of disturbances, making the extraction of data features for different disturbances increasingly arduous. To address the abovementioned issues, a power system disturbance identification method based on optimized multi-dimensional feature extraction is proposed in this paper. This method presents an optimized feature extraction approach based on variational mode decomposition, utilizes an improved sparrow search algorithm to optimize the number of modal components and the penalty factor, and extracts the most informative and stable multi-dimensional time-domain features from PMU phasor data, laying the foundation for enhancing classification accuracy. On this basis, a disturbance classification method based on a deep learning and neural network fusion model is proposed. By taking the classification accuracy as the objective function and optimizing hyper parameters such as the learning rate through the transit search algorithm, the optimal fitting effect of data training is achieved. The proposed method has undergone simulation tests on the IEEE-39 node and the western China power grid model and has been verified with actual disturbance data of the power system. The results indicate that the proposed method exhibits good accuracy and generalization.

KEY WORDS: disturbance identification; synchronous phasor measurement; feature extraction; fusion neural network; variational mode decomposition

摘要: 新能源的大规模接入使得电力系统的电力电子化趋势日益明显, 电力系统的弱支撑性及低抗扰性增加了其发生连锁故障的概率。基于相量测量单元(phasor measurement unit, PMU)的电力系统扰动快速辨识可为系统安全稳定控制提供支撑。然而, 电力系统动态行为的复杂性导致扰动的类内差异性和类间相似性增大, 不同扰动的数据特征提取愈发困难。针对上述问题, 该文提出一种多维特征优化提取的电力系统扰动辨识方法。提出优化变分模态分解的特征提取方法, 利用改进麻雀搜索算法优化模态分量数和惩罚因子, 提取PMU相量数据中信息最多、序列最平稳的多维时域特征, 为提高分类准确度奠定基础; 在此基础上, 提出基于深度学习融合神经网络模型的扰动分类方法, 将分类精度作为目标函数, 利用凌日搜索算法优化学习率等超参数, 实现数据训练的最优拟合效果。采用IEEE-39节点与中国西部电网模型的仿真测试, 并利用电力系统实际扰动数据进行验证, 结果表明, 所提方法具有较好的准确性和泛化性。

关键词: 扰动辨识; 同步相量测量; 特征提取; 融合神经网络; 变分模态分解

0 引言

在“双碳”目标的推动下, 中国致力于构建新型电力系统体系, 在此背景下, 风电和光伏等新能源、分布式储能及柔性负荷大规模接入电网, 由此配置的电力电子装备使得电网动态行为复杂化, 影响系统稳定性, 可能引发连锁故障: 2016年澳大利亚因恶劣天气导致新能源脱网^[1], 2017年印度电网崩溃影响数亿人^[2], 2019年英国霍恩风电场脱网致频率跌至49.5 Hz, 影响百万人用电^[3]。连锁故障可能导致系统崩溃, 及时识别扰动、预防连锁故障、

基金项目: 国家自然科学基金项目(52377098)。

Project Supported by National Natural Science Foundation of China (52377098).

保障系统稳定至关重要。

相量测量单元(phasor measurement unit, PMU)可以实现同步、快速的测量,基于PMU数据进行电力系统扰动快速辨识,可为保障电力系统安全稳定运行提供基础^[4]。然而,新能源的大规模接入增加了电力系统扰动的复杂性,加剧了扰动识别的难度^[5-6]。

电力系统扰动辨识的研究主要包含基于模型驱动和数据驱动的方法^[7]。模型驱动的方法依赖于精准的电网模型进行扰动识别,但该方法通常忽略系统的非线性和不确定性。文献[8-9]指出,随着电网的复杂性增加和规模扩大,仅基于拓扑结构和参数建立电网模型的难度增大,仿真模型的实时响应能力也较差,使得模型驱动的方法在复杂电网的环境下可靠性不足。

在人工智能技术的支撑下,基于数据驱动的扰动识别方法通过挖掘海量PMU数据,学习并分析历史数据,建立数据与标签的映射关系,有效地提升分类准确度并防范故障的发生^[10]。

基于数据驱动的方法主要分为特征提取和分类两个阶段^[11]。短时傅里叶变换(short-time Fourier transform, STFT)、小波变换(wavelet transform, WT)、奇异值分解(singular value decomposition, SVD)作为常用的信号处理方法,在特征提取和信号降噪等领域得到了广泛的应用^[12]。文献[13]基于频率切片小波变换(frequency slice wavelet transform, FSWT)在时频域中局部化分析振动响应信号,进行频率的特征提取。文献[14]提出自适应S变换(adaptive S transform, AST)简化窗函数结构的方法,提升时频分辨率,实现了对复合电能质量的特征提取。文献[15]基于对称化点模式和尺度不变特征变换(scale-invariant feature transform, SIFT)建立故障与图像的映射关系从而提升特征提取能力。文献[16]提出人类水平波形分解(human-level waveform decomposition, HLWD)方法,将波形分解为一般形状和残差结构再进行特征提取。上述研究大多通过设置固定参数进行特征提取,没有考虑各类扰动的类间相似性和类内差异性增大的情况,普适性较差,且未能有效地去除冗余信息。

基于上述方法提取得到的特征向量作为神经网络的输入,经过分类器训练以实现扰动辨识。文献[17]提取PMU信号的时空信息并编码为尖峰

序列,并使用基于尖峰神经网络(spiking neural network, SNN)的计算框架实现分类。文献[18]将时序信号转为二维图像,利用深度残差网络(depth residual network, ResNet)建立的二分类器进行特征提取与分类,进而识别未知标签的复合扰动。文献[19]利用变分模态分解(variational mode decomposition, VMD)和决策树(decision tree, DT)算法建立多分类模型,采用基于规则的决策逻辑实现事件辨识。文献[20]利用希尔伯特变换(Hilbert transform, HT)和极坐标变换将一维时序替换为二维轨迹圆图像,送入ResNet实现特征学习与分类。上述扰动分类的研究大多根据经验试凑法设置网络的超参数,未考虑在面临庞大的参数空间和复杂的依赖关系时,参数设置不当可能导致模型过拟合或欠拟合的情况。

针对上述问题,本文提出一种多维特征优化提取的电力系统扰动辨识方法,并提出优化VMD的特征提取方法,利用改进麻雀搜索算法搜寻VMD的最优参数组合,提取PMU相量数据中信息丰富、序列平稳的多维特征;提出封装式特征选择的方法,利用支持向量机(support vector machine, SVM)分类器,寻找反映扰动本质的特征子集,去除冗余信息,为分类奠定基础;在此基础上,提出融合神经网络分类模型的扰动识别方法,以分类准确率为目标函数,利用凌日搜索算法优化学习率等超参数,实现扰动的高精度辨识;最后,将通过仿真和实测算例分析进行特征提取的可视化和分类准确率的计算,同时进行模型鲁棒性和方法有效性的验证。

1 高渗透率新能源下扰动辨识问题分析

新能源大规模接入电力系统导致系统频率的动态过程发生显著性变化,由于电力系统转动惯量的降低,系统频率在经受故障扰动后会发生较大波动^[21];与电压和电流的局部性不同,频率具有整体性特征,它能反映电力系统全局的稳定性与运行状态,频率波动能更准确地揭示系统的功率平衡、能量交换状况,因此本文选用系统频率作为研究对象进行分析。基于改进的IEEE-39节点系统,将30、31和38节点的机组替换为同容量风电机组,风电渗透率为30%,在此场景下,分析8类与有功功率、无功功率相关的电力系统典型扰动事件^[22],包括与有功功率相关的发电机出力降低(generator load

reduction, GL)、三相短路(3- ϕ Flt)、线路跳闸(line trip, LT)、单相接地(ϕ -g Flt)、负荷投入(L-on)、负荷切除(L-off), 与无功功率相关的并联电容器投入(SC-on)和并联电容器切除(SC-off), 图1为电力系统典型的扰动事件。这些典型扰动在功率波动及频率调节等方面能够有效反映高比例新能源接入电网的动态行为, 同时这些单一扰动的发生可能引发连锁故障^[23]。




图1 典型扰动事件

Fig. 1 Typical disturbance event

由图1可知, 短路、线路跳闸和切除电容器事件具有瞬时性和冲击性, 短路事件的曲线尖锐程度和波动特性存在相似性, 事件发生的时间内包含丰富的扰动信息, 如图1(b)、(c)、(d)和(f)所示; 发电机出力降低和切负荷事件引起频率的骤降和骤升, 随后趋于稳定, 波动性和周期性在时间序列中展现相同的趋势, 如图1(a)和(e)所示。

由于不同扰动事件对应的频率 f 曲线存在相似性和不可区分性, 各类扰动的相量数据如果未经过特征提取而直接分类, 会因为缺乏关键统计特征而导致类间相似性重合度较高, 进而无法实现分类。图2为上述8类扰动未经特征增强的聚类图谱, 其中3- ϕ Flt和 ϕ -g Flt由于相似的波动趋势引起了类别混叠; GL和L-on存在时间依赖性, 事件的长时间扰动包含冗余信息, 且二者均会引起电力系统的频率下降, 故特征存在重合的相似性, 界线较为不清

晰。综上所述, 基于纯时序序列数据的特征相似性降低了显著区分度。




图2 基于数据序列的聚类

Fig. 2 Clustering based on data sequences

选用门控循环单元(gated recurrent unit, GRU)网络模型进行分类, 神经元个数设为64时, 分类准确度为48.44%。由此可知: 未经过特征提取的时间序列数据和未经过超参数优化的低层次、单一结构化的神经网络模型不能实现高精度的扰动辨识。

2 基于变分模态分解最优参数组合的特征提取方法

2.1 基于改进变分模态分解的特征提取方法

特征提取作为基于深度学习神经网络进行分类系统的不可或缺的步骤, 变分模态分解及其改进算法由于其自适应性和高效性在电力系统信号的特征提取方面有广泛的应用。本文拟采用VMD将非稳定性、非线性的原始信号分解成多个相对平稳的模态特征分量(intrinsic mode function, IMF)^[24]。

VMD的两个关键参数为分解的模态特征分量数量 K_V 和惩罚因子 α 。 K_V 取值偏小导致时间序列隐含特征无法充分提取; α 设置较大, 会造成局部信息丢失。图3为三相短路的频率相量数据在不同参数组合下的分解结果, K_V 设置为5, α 设置为10, 出现模态混叠现象, IMF₃和IMF₅出现了某些高频分量, 无法准确反映电气量的真实成分, 降低了分解的精度和可解释能力, 如图3(a)所示; K_V 设置为8, α 设置为100, 出现过分解现象, IMF₇和IMF₈包含细微噪声, 对此类不重要的特征建模会出现过拟合现象, 增加分析的复杂度, 如图3(b)所示。

针对上述分析, 需要确定最佳的参数组合 $[K_V, \alpha]$ 。在参数优化前, 首先确定适应度函数, 用以评估解(即 $[K_V, \alpha]$)的优劣并引导算法朝着更优解的方向行进。为了提取PMU相量数据中信息最多、





图3 频率数据的分解结果

Fig. 3 Decomposition results of frequency data

序列最平稳的时域特征,本文选用排列熵/互信息熵的最小值作为适应度函数。

互信息熵表示两个相量之间包含彼此信息的多少,熵值越大,分解出的模态分量所包含的原始序列的特征信息越丰富,计算公式为:

$$I(X, Y) = H_1(X) + H_1(Y) - H(X, Y) \quad (1)$$

$$H_1(X) = -\sum_{i=1}^{n_1} p(x_i) \lg p(x_i) \quad (2)$$

$$H(X, Y) = -\sum_{i=1}^{n_1} \sum_{j=1}^{n_2} p(x_i, y_j) \lg p(x_i, y_j) \quad (3)$$

式中: X 和 Y 为两个离散随机变量; x_i 为随机变量 X 的第 i 个取值; y_j 为随机变量 Y 的第 j 个取值; $p(x_i)$ 是事件 x_i 发生的概率; $p(x_i, y_j)$ 为事件 (x_i, y_j) 同时发生概率; n_1 和 n_2 为 X 和 Y 的取值个数; $H_1(X)$ 和 $H_1(Y)$ 为随机变量 X 和 Y 的信息熵; $H(X, Y)$ 为 X 和 Y 的联合信息熵。

排列熵反映了序列的复杂度和波动性,熵值越小,时间序列越平稳和规则,计算公式如下:

$$H_2(X) = \frac{-\sum_{i=1}^k P_i(x) \lg P_i(x)}{\lg(m!)} \quad (4)$$

式中: m 为嵌入维度; $P_i(x)$ 为随机变量 X 取值为 x 的概率; k 为变量 X 的取值个数。

本文构建了复合指标 H_1 为排列熵/互信息熵,表示为

$$H_1 = H_2(X) / I(X, Y) \quad (5)$$

复合指标 H_1 越小,说明特征模态分量 $I_{MF} = [IMF_1, IMF_2, \dots, IMF_i, \dots, IMF_K]$ 复杂度越低、特征信息越丰富。将 H_1 最小值作为适应度函数,表示为

$$\text{fitnessIndex} = \min_{1 \leq i \leq K} \{H_{1i}\} \quad (6)$$

式中 K 为模态特征分量 IMF 分解的个数。

针对每一种扰动类型,通过优化算法确立 VMD 的最佳参数组合 $[K_v, \alpha]$,使复合指标 H_1 取得最小值。

2.2 基于改进麻雀搜索算法的参数寻优方法

麻雀搜索算法(sparrow search algorithm, SSA)适用于解决具有多个局部极值、复杂目标函数、高维的非线性、非凸优化问题,已经在新能源电力系统的负荷态势感知^[25]和功率变换器系统性能劣化预测^[26]领域有相关的应用。在本文场景中,传统麻雀搜索算法依赖局部搜索方式进行解的更新,用于 VMD 参数优化时存在局部最优、收敛速度慢等局限性。

柯西分布通过产生较大幅度的变异,提升了算法搜索较远区域的能力。随着柯西变异算子的引入,考虑解的局部信息并扩大了搜索规模。变异更

新的计算公式为

$$\begin{cases} X'_i = X_i + \beta \cdot \Gamma(0,1) \cdot \Delta t \\ f(y) = \frac{1}{\pi(1+y^2)} \end{cases} \quad (7)$$

式中： X_i 和 X'_i 分别为变异前、后的粒子位置； β 为用以控制变异幅度的调节参数； Γ 为生成柯西分布特性的随机数； Δt 为时间步长； $f(y)$ 为柯西分布的概率密度函数。


混沌映射 Logistic 凭借复杂性和敏感性的优势，生成了分布均匀和丰富的搜索空间分布。在混沌动态的影响下，算法加速搜索进程，进行广泛的全局搜索，减少了陷入局部最优的时间，提升了收敛速度。

因此，本文将逻辑混沌序列和柯西变异操作加入麻雀搜索算法，得到混沌融合鱼鹰和柯西变异的麻雀搜索算法(logistic osprey cauchy sparrow search algorithm, LOCSSA)，该改进算法提高了算法的鲁棒性和稳定性，增加了全局搜索和局部优化能力^[27]。


LOCSSA 采用混合策略评估每个候选解(即 K_V 和 α)的优劣，计算其对应的适应度值；鱼鹰算法通过挑选适应度较好的个体来引导搜索，在适应度较差的个体上应用 Cauchy 分布变换，依靠随机性引导个体向最优解方向搜索，最终确立 fitnessIndex 对应的 $[K_V, \alpha]$ 。

采用 CEC2021 函数测试集，选用 F5、F7、F9 和 F10 4 种不同的测试函数，将所提算法与 SSA、冠豪猪优化器(crested porcupine optimizer, CPO)、小龙虾优化算法(crayfish optimization algorithm, COA)、灰狼优化算法(grey wolf optimizer, GWO)、鲸鱼优化算法(whale optimization algorithm, WOA)等进行比较，所提算法在迭代 100 次后达到收敛，收敛速度较快，收敛精度较高，不同测试函数下算法之间的比较结果如图 4 所示。


确立 VMD 的最佳参数组合 $[K_V, \alpha]$ 后，记录 HI_i 最小值对应的 IMF_K ，利用 VMD 对当前扰动信号的




(a) F5测试函数



(b) F7测试函数



(c) F9测试函数



(d) F10测试函数

图 4 不同测试函数下的算法收敛曲线

Fig. 4 Convergence curves of algorithms under different test functions

IMF_K 进行 9 种特征向量：均值、方差、峰值、峭度、有效值、峰值因子、脉冲因子、波形因子、裕度因子的特征提取。

2.3 基于封装式方法的特征选择框架

经过上述特征提取的 9 种特征向量在不同的扰动中存在共性，通过再选择将最能表征扰动个性的特征挑选出来输入分类器。本文采用封装式(Wrapper)特征选择方法，流程图如图 5 所示，以分类准确率为度量标准，通过训练 SVM 分类器评估特征子集的性能，最终确定特征子集由均值、峰值、峭度、有效值、峰值因子、波形因子 6 种特征向量构成。




图 5 Wrapper 特征选择流程图

Fig. 5 Wrapper flow chart of feature selection

特征提取和特征选择的流程如图 6 所示。




图6 特征提取和选择流程图

Fig. 6 Flow chart of feature extraction and selection

3 基于优化深度学习融合神经网络超参数的扰动分类方法

3.1 基于超参数优化融合神经网络框架的扰动分类模型

新能源高渗透率下的电力系统表现出高维非线性, 分类模型的第一层选用卷积神经网络(convolutional neural network, CNN), 卷积层提取频率信号中多维非线性数据的高维特征; 批标准化层(batch normalization, BN)对输入的特征向量归一化处理, 加速模型收敛并提高模型的泛化能力^[28]。

为了弥补CNN不能捕获长时间的特征和GRU单向传播的劣势, 分类模型的第二层选用双向GRU网络模型(bidirectional gated recurrent unit, BiGRU)^[29], 在前向和后向传播中均可捕捉数据特征信息, 充分利用时序信号数据特征。

设置融合神经网络的卷积核大小、学习率、隐藏层神经元个数3个超参数的不同取值, 输入经过特征提取后的相量数据, 分类结果如表1所示。由表1可知, 超参数设置的不同影响最终的分类准确度, 需借助优化算法设定超参数。

表1 不同超参数下的分类结果

Table 1 Classification results under different hyperparameters

超参数	数值设置	分类准确率/%
卷积核大小	2	97.83
	3	96.90
学习率	0.000 1	65.33
	0.001	98.14
隐藏层	64	70.12
神经元个数	100	67.37

本文利用凌日搜索优化算法(transit search optimization algorithm, TSOA)^[30]探索超参数空间、选择最优的参数组合, 算法以分类准确度为目标函数, 不断微调参数, 实现模型的最优性能, 算法的核心在于通过不断调整搜索空间内的位置, 利用目标函数来指导搜索, 将优化目标参数转换为所需超参数。

高比例新能源接入的电力系统的扰动分类任务通常涉及复杂的时序数据和多源扰动, 在此背景下, 本文根据实践验证设定学习率的有效区间为[0.001,0.01], 用以保证训练的稳定性; 神经元个数在[60,100]的范围内有助于模型捕捉多样的时序特征, 保证模型的训练效率和泛化能力; 卷积核大小在[2,5]的范围内可以有效地捕捉数据的局部变化模式, 避免计算复杂度过高^[31]。综上所述, 定义学习率、神经元个数和卷积核大小3个超参数的可能值的范围依次为式

$$\begin{cases} V_{\min} = [0.001, 60, 2] \\ V_{\max} = [0.01, 100, 5] \end{cases} \quad (8)$$

根据2.3节得到的均值、峰值、峭度、有效值、峰值因子、波形因子6个特征作为每一类扰动对应的特征向量输入参数优化后的神经网络模型之中, 为了让模型自动学习不同特征在不同扰动类别中的重要性, 本文在模型中加入多头注意力机制以实现多特征输入向量数据的特征增强, 该方法通过赋权重形式表示输入数据的重要信息, 由查询(query, Q)、键(key, K)和值(value, V)向量组成^[32]。多头注意力机制为每一类扰动分配6个头, 模型进而可以为6个特征分配不同的权重, 并动态地选择某个特征对该扰动分类最重要, 第*i*个头的注意力权重系数计算公式为

$$H_i = \text{Attention}(X_i W_i^Q, X_i W_i^K, X_i W_i^V) \quad (9)$$

式中: $X_i \in \mathbb{R}^6$ 为输入特征向量; W_i^Q 、 W_i^K 、 W_i^V 为学习的权重矩阵; H_i 为第*i*个输出。

每个头独立地计算注意力权重系数后, 模型再将所有头的输出拼接起来, 通过线性变换操作将组合的多头输出与随机矩阵相乘, 融合得到最终的加权表示矩阵, 线性变换公式为

$$W_{\text{att}} = \text{MultiHead}(Q, K, V) = \text{Concat}(H_1, H_2, \dots, H_n) W^R \quad (10)$$

式中: W_{att} 为特征向量最终的加权表示矩阵; W^R 为输出组合对应矩阵; *n* 为头的个数。

多头注意力机制提升权重分配过程的并行性，同时关注不同的特征子空间，模型利用权重系数评估不同扰动对应的特征向量对注意力矩阵数据的贡献差异性，使最终融合得到的加权表示矩阵对提升分类性能的特征有所侧重，最终实现特征增强。

多头注意力机制的输出作为 Softmax 分类器的输入，分类器利用这些加权后的特征进行最终的分

类决策，生成各扰动对应的概率分布，概率分布的计算公式为

$$y = \text{Softmax}(\mathbf{W}_{\text{att}} \mathbf{X}_t + b_t) = [p_1, p_2, \dots, p_i, \dots, p_k] \quad (11)$$

式中： $\mathbf{X}_t$ 为特征向量； $\mathbf{W}_{\text{att}}$ 为特征向量对应的权重矩阵； b_t 为偏置； p_i 为最终分类概率。

3.2 扰动识别模型结构与辨识方法

本文所提 VMD-CNN-BiGRU-Multiattention 模型结构图如图 7 所示。




图 7 分类模型结构框图

Fig. 7 Block diagram of classification model structure

具体实现步骤为：

第 1 步：获取 PMU 数据，输入电力系统不同扰动类型的频率电气量数据，并归一化处理。

第 2 步：利用 LOCSSA 算法优化 VMD 的 K_V 和 α ，记录每种扰动适应度函数最小值对应的 IMF，利用 VMD 对上述 IMF 进行九种特征向量的特征提取，保留局部特征。训练 SVM 以分类正确率为目标函数减少特征冗余，特征选择后确立均值、峰值、峭度、波形因子、峰值因子、有效值 6 种特征向量作为神经网络模型的输入。

第 3 步：利用 TSOA 算法优化模型的 3 个超参数：学习率、神经元个数和卷积核大小。序列折叠层对输入序列进行压缩或聚合，减少维度，保留关键信息；序列反折叠层将压缩后的信息展开，在后续的网络层中进行处理。

第 4 步：利用 CNN 处理多维非线性数据，提取高维特征，卷积层提取输入的非线性局部特征；池化层压缩提取的特征并生成更为重要的特征信息，进而降低模型的复杂度；BN 层加速训练过程，防止梯度消失或梯度爆炸。

第 5 步：利用 BiGRU 挖掘长时间序列特征，经正反两个方向提取特征向量，从而获得全局特征信息，在模型的末端加入 dropout 层防止过拟合现象。

第 6 步：计算多头注意力机制的特征权重分配

矩阵，关注关键序列，进行特征增强，Softmax 分类器对加权后的特征进行分类决策，输出最终的分类结果。本文采用的模型网络结构参数设置如表 2 所示。

表 2 模型网络层参数设置

Table 2 Parameter setting of model network layer	
网络层	参数
卷积层	卷积核大小=3，过滤器=32，步长=2
池化层	池大小=2，步长=2
隐藏神经元	60
学习率	0.001
批大小	16
迭代次数	20
Dropout 层	0.2
学习率下降因子	0.01
优化器	Adam
星体数量 ns	2
信噪比 SN	1

训练和测试的结果一般需要多轮交叉评估。本文采用分类准确率 Acc(accuracy)、精确率 Pre(precision)、召回率 Rec(recall)、F₁ 分数(F₁-Score)4 个指标进行模型评估^[33]。

4 仿真算例验证与分析

4.1 IEEE-39 节点仿真算例的数据集构成

为了验证所提模型对于扰动辨识的泛化性，利

用 PowerFactory 软件对 IEEE-39 节点进行仿真, PMU 上送频率为 50 Hz, 仿真步长为 0.02 s, 考虑新能源风电渗透率为 40%条件下对扰动识别的影响, 将 30、32、33、36 和 37 节点的火电机组替换为同容量的双馈风电机组^[34]。仿真生成了 3- ϕ Flt、 ϕ -g Flt、GL、L-on、L-off、LT、SC-on 和 SC-off 共 8 类扰动, 960 个扰动事件, 每类扰动各 120 个, 以 7:3 的比例构造训练集和测试集。

4.2 特征分布

经特征提取后 8 类扰动对应 α , K_V 和最小适应度值对应的 IMF 分量索引值如表 3 所示。

表 3 特征提取的优化参数

Table 3 Optimization parameters of feature extraction		
惩罚因子 α	模态特征	最小适应度值对应的 IMF
	分量数量 K_V	分量索引值
910	5	2
226	5	2
562	10	1
2 500	10	1
2 456	10	1
2 483	10	2
2 468	10	1
1 063	10	1

图 8 反映了 8 类扰动经特征提取后投影到二维平面的分布情况, 从图 8 可以看出, 8 类扰动的界限分明, 验证了本文提出的特征提取方法的可行性, 时域分析通过提取数据的关键性统计特征, 有效地滤除时序数据中的无用信息, 清晰地辨识曲线的细微差异, 该方法减少了类别混叠现象, 得到了高度可分的特征空间。





图 8 二维特征分布图

Fig. 8 Distribution map of two-dimensional feature


4.3 不同模型的分类结果对比

为验证所提模型的可行性, 对仿真生成的 8 类扰动进行分类, 分类结果如图 9 所示, 图 9(a)为测

试集的分类结果未经过特征选择(feature selection, FS)输出的混淆矩阵; 图 9(b)为测试集的分类结果经过 FS 输出的混淆矩阵, 分类精度可从 95.13%提升至 98.55%, 这说明经过特征选择可以提升分类准确率。



(a) 未经过FS的混淆矩阵



(b) 经过FS的混淆矩阵

图 9 分类结果图

Fig. 9 Result graph of classification

将本文提出的模型与 VMD+CNN+BiLSTM (VCBiLSTM)、VMD+CNN+LSTM(VCLSTM)、CNN+LSTM(CLSTM)、CNN+BiLSTM(CBiLSTM) 等进行模型评估指标的比较, 其中, MTCDEN 为基于多变量时间卷积去噪增强网络(multivariable temporal convolutional denoising enhanced network, MTCDEN)的分类方法^[7], VMD+DT 为变分模态分解与决策树的结合算法^[19], HT+ResNet 为基于希尔伯特变换特征提取的深度残差网络的分类方法^[20], 本文所提方法的分类准确率为 98.55%, 相较于文献[7,19-20]分别提升了 0.91%、10.02%、12.83%, 各指标比较结果如表 4 所示。

表 4 模型分类评估对比

模型类别	准确率/%	精确率/%	召回率/%	F ₁ 分数/%
本文方法	98.55	98.54%	98.57	98.53
VCBiLSTM	97.78	97.9	97.78	97.78
VCLSTM	94.91	94.93	94.91	94.85
CLSTM	75.92	74.92	75.92	71.14
CBiLSTM	84.72	85.12	84.72	83.93
MTCDEN	97.64	97.63	97.67	97.62
VMD+DT	88.53	89.26	88.66	87.92
HT+ResNet	85.72	86.91	85.86	84.37

为了验证所提方法的实时性，在 i9-13900HX 2.20 GHz CPU、NVIDIA RTX4060 GPU 和 16 GB 内存的计算机上进行了仿真。

表 5 给出不同方法的运行时间，所提方法平均时间仅需 2.56 s，相比其余分类器具有较低的计算时间。

表 5 不同方法的运行时间

方法	VC-BiLSTM	VC-LSTM	CNNLSTM	CNNBiLSTM	本文方法
时间/s	2.83	2.58	18.43	26.25	2.56

4.4 基于实际电网的算例验证与分析

据统计，在实际电力系统中发生三相短路和单相接地短路故障的概率占所有短路故障类型的 70%，近 5 年来我国线路跳闸次数达 7 000 余次；同时，由于新能源电力系统的容量分布不均、间歇性等特点，为了保障系统的安全与稳定、防止电网过载与设备损坏，电网调度人员会进行发电机出力降低、低频减载等操作^[35]，因此，为了更加真实地反映实际电网的运行状态，本文搭建了中国西部某实际区域电网的模型，电网的新能源渗透率为 23.7%，PMU 安装在 220 kV 以上的变电站^[7]，区域电网拓扑结构图如图 10 所示。




图 10 区域电网拓扑结构图

Fig. 10 Topology structure diagram of regional power grid

以线路 750B—750E 为研究对象，通过仿真的 5 个算例对所提方法的泛化性进行验证与分析，扰动算例具体的参数设置如表 6 所示。


表 6 扰动算例参数设置


算例序号	扰动发生具体位置	扰动类型	仿真时长/s
1	线路 750B-750E	三相短路	15
2	节点 750B	发电机出力降低 400 MW	15
3	线路 750B-750E	线路跳闸	15
4	线路 750B-750E	A 相接地短路	15
5	节点 750E	切除负荷 80 MW	15

利用本文所提方法对上述扰动进行分类，分类准确率达 97.72%，分类结果如图 11 所示。图 11(a) 为分类混淆矩阵；图 11(b)为准确率和损失的迭代收

敛曲线，算法收敛性良好，所提方法能够实现对扰动的准确辨识。

通过实际电网的仿真算例验证了所提方法对扰动有较好的识别能力。





(b) 准确率和误差收敛曲线

图 11 实际电网分类结果

Fig. 11 Classification results of actual power grid

5 基于实测数据的验证与分析

5.1 基于区域电网的算例验证与分析

为了验证所提方法对电网中实际发生的扰动数据进行识别的有效性,研究电网实测发生的3类扰动案例。

案例一:2024年4月11日10:27:00,华北地区分布式电源脱网,使华北地区频率下降0.1 Hz,电源脱网的频率量测信息如图12所示。




图 12 电源脱网的频率量测信息

Fig. 12 Frequency measurement information of power offline

案例二:2020年3月18日17:21:31,华北电网发生断路器跳闸事件,PMU装置的频率量测信息如图13所示^[36]。

案例三:2024年9月22日15:35:00,中国西部的风电场内部进行人工短路试验,故障位置在220 kV#3 变压器处,发生三相故障,约0.5 s时故障发生,出现明显振荡现象,PMU装置记录的频率量测信息如图14所示。

利用本文所提方法对上述扰动进行分类,分类准确率达96.83%,分类结果如图15所示。图15(a)为分类混淆矩阵;图15(b)为准确率和损失的迭代收敛曲线,模型泛化能力较强,所提方法能够实现对实测扰动的准确辨识。




图 13 断路器跳闸的频率量测信息

Fig. 13 Circuit breaker trip frequency measurement information






图 14 三相短路的频率量测信息

Fig. 14 Frequency measurement information of three-phase short circuit



(a) 3类扰动分类混淆矩阵



(b) 准确率和误差收敛曲线

图 15 实测数据分类结果

Fig. 15 Classification results of measured data

5.2 基于离线数据的未知扰动辨识

中国西部某实际区域风电场的风机塔筒内部都安装一台 PMU, 实际在运行风机 79 台, 风电场工程实际现场图如图 16 所示。图 16(a)为区域风电场拓扑图, 图 16(b)为风机塔筒内部 PMU 实际安装结构图。




图 16 风电场工程实际现场图

Fig. 16 Actual site diagram of wind farm engineering

经研究发现, 测风塔附近的 PMU 能够灵敏地捕捉扰动信号。2023 年 6 月 10 日 23:58:57, 测风塔附近 10 台 PMU 同时发生频率暂降现象, PMU 记录的频率量测信息如图 17 所示。




图 17 实际现场的频率量测信息
Fig. 17 Frequency measurement information of actual field

利用本文所提模型对上述扰动进行辨识, 模型较为灵敏地识别该扰动为负荷投入, 并将置信度维持在一个较高水平, 识别过程的置信度变化曲线如图 18 所示。




Fig. 18 Change curve of confidence

通过分析该时间段内风机出力有功功率的变化曲线, 发现有功功率出现明显的上升趋势, 说明风机出力增加以应对负荷投入, 验证了所提方法进行扰动辨识的准确性和有效性。

本文所提方法已经对离线的大量数据进行了扰动的成功辨识, 鉴于所提模型的网络结构简单、参数较少、训练时间较少、占用内存较小等优势, 未来致力于在工程实际现场得到应用, 实现扰动的在线辨识。实施步骤为将训练好的模型保存, 以算子的形式将程序写入主站, 实时监测并辨识 PMU 在线数据, 对扰动信号进行告警。

6 结论

1) 基于 PMU 量测数据, 本文提出一种适用于高比例新能源接入的电力系统扰动辨识方法。该方法提出了改进 VMD 的特征提取方法, 利用排列熵/互信息熵的最小值作为适应度函数指引 LOCSSA 算法优化 VMD 的 $[K_v, \alpha]$, 在此基础上利用 VMD 提取了多维时域特征向量, 有效地避免了新能源电力系统中各类扰动由于类间差异性减小而导致的类别混叠现象;

2) 提出超参数寻优的 CNN-BiGRU 分类模型的扰动识别框架, 优势互补的神经网络区分了特征中细微的差异, 增强了模型的灵活性, 在框架中添加了特征向量权重自适应分配的多头注意力机制模块, 有效地减少了冗余特征的干扰, 提升了模型的计算效率;

3) 仿真算例中与其他模型对比表明, 所提方法具有较高的分类准确度和计算速度, 现场实测数

据的分类准确率高于96%,验证了模型的泛化性和方法的有效性。

参考文献

- [1] 曾辉,孙峰,李铁,等.澳大利亚“9·28”大停电事故分析及对中国启示[J].电力系统自动化,2017,41(13): 1-6.
ZENG Hui, SUN Feng, LI Tie, et al. Analysis of “9·28” blackout in South Australia and its enlightenment to China[J]. Automation of Electric Power Systems, 2017, 41(13): 1-6(in Chinese).
- [2] 汤涌,卜广全,易俊.印度“7.30”、“7.31”大停电事故分析及启示[J].中国电机工程学报,2012,32(25): 167-174.
TANG Yong, BU Guangquan, YI Jun. Analysis and lessons of the blackout in Indian power grid on July 30 and 31, 2012[J]. Proceedings of the CSEE, 2012, 32(25): 167-174(in Chinese).
- [3] 方勇杰.英国“8·9”停电事故对频率稳定控制技术的启示[J].电力系统自动化,2019,43(24): 1-5.
FANG Yongjie. Reflections on frequency stability control technology based on the blackout event of 9 August 2019 in UK[J]. Automation of Electric Power Systems, 2019, 43(24): 1-5(in Chinese).
- [4] 张晓雪,张放,史静舒.基于同步相量的次/超同步振荡参数辨识探究:非频谱分析方法的契机和挑战[J].中国电机工程学报,2025,45(12): 4578-4592.
ZHANG Xiaoxue, ZHANG Fang, SHI Jingshu. Research on sub/supersynchronous oscillation parameter identification based on synchrophasor: the potential opportunities and challenges of non-spectral analytical techniques[J]. Proceedings of the CSEE, 2025, 45(12): 4578-4592(in Chinese).
- [5] LIANG Chengbin, TENG Zhaosheng, LI Jianmin, et al. Improved S-transform for time-frequency analysis for power quality disturbances[J]. IEEE Transactions on Power Delivery, 2022, 37(4): 2942-2952.
- [6] PAVANKUMAR Y, DEBNATH S, PAUL S. A new Lissajous-based technique for islanding detection in microgrid[J]. IEEE Transactions on Smart Grid, 2024, 15(3): 2856-2865.
- [7] 李子康,刘灏,毕天姝,等.基于数据驱动的鲁棒性电力系统扰动识别[J].中国电机工程学报,2021,41(21): 7261-7274.
LI Zikang, LIU Hao, BI Tianshu, et al. Data-driven robust power system disturbance identification [J]. Proceedings of the CSEE, 2021, 41(21): 7261-7274(in Chinese).
- [8] SUN Chong, SUN Dan, CHEN Wenhan, et al. Improved model predictive control with new cost function for hybrid-inverter open-winding PMSM system based on energy storage model[J]. IEEE Transactions on Power Electronics, 2021, 36(9): 10705-10715.
- [9] 饶仪明,吕敬,王众,等.基于数据-模型融合驱动的新能源场站宽频阻抗在线辨识及稳定性评估[J].中国电机工程学报,2024,44(7): 2670-2684.
RAO Yiming, LYU Jing, WANG Zhong, et al. Wideband impedance online identification and stability assessment of renewable power plants based on physics-informed data-driven method[J]. Proceedings of the CSEE, 2024, 44(7): 2670-2684(in Chinese).
- [10] LI Zikang, LIU Hao, ZHAO Junbo, et al. A power system disturbance classification method robust to PMU data quality issues[J]. IEEE Transactions on Industrial Informatics, 2022, 18(1): 130-142.
- [11] 尹柏强,陈奇彬,李兵,等.基于改进Kaiser窗快速S变换和LightGBM的电能质量扰动识别与分类新方法[J].中国电机工程学报,2021,41(24): 8372-8383.
YIN Baiqiang, CHEN Qibin, LI Bing, et al. A new method for identification and classification of power quality disturbance based on modified Kaiser window fast S-transform and LightGBM[J]. Proceedings of the CSEE, 2021, 41(24): 8372-8383(in Chinese).
- [12] 宫泽旭,艾力西尔·亚尔买买提,辛焕海,等.新能源电力系统并网设备小扰动稳定分析(一):机理模型与稳定判据适用性[J].中国电机工程学报,2022,42(12): 4405-4418.
GONG Zexu, YALMAIMAITI A, XIN Huanhai, et al. Small signal stability analysis of equipment in renewable energy power system(Part I): mechanism model and adaptation of stability criterion[J]. Proceedings of the CSEE, 2022, 42(12): 4405-4418(in Chinese).
- [13] 曹丽华,于明鑫,李大才,等.超超临界汽轮机裂纹转子的动力响应与特征提取[J].中国电机工程学报,2025,45(19): 7600-7610.
CAO Lihua, YU Mingxin, LI Dacai, et al. Dynamic response and feature extraction of cracked rotor in ultra-supercritical steam turbine[J]. Proceedings of the CSEE, 2025, 45(19): 7600-7610 (in Chinese).
- [14] 李盼,娄钊瑜,马康,等.一种自适应S变换在电能质量特征提取中的应用[J].中国电机工程学报,2021,41(22): 7660-7667.
LI Pan, LOU Zhaoyu, MA Kang, et al. Application of adaptive S-transform in power quality feature extraction [J]. Proceedings of the CSEE, 2021, 41(22): 7660-7667(in Chinese).

- Chinese).
- [15] LONG Zhuo, ZHANG Xiaofei, HE Min, et al. Motor fault diagnosis based on scale invariant image features[J]. IEEE Transactions on Industrial Informatics, 2022, 18(3): 1605-1617.
- [16] XIONG Siheng, LIU Yadong, FANG Jian, et al. Incipient fault identification in power distribution systems via human-level concept learning[J]. IEEE Transactions on Smart Grid, 2020, 11(6): 5239-5248.
- [17] MAHAPATRA K, LU Sen, SENGUPTA A, et al. Power system disturbance classification with online event-driven neuromorphic computing[J]. IEEE Transactions on Smart Grid, 2021, 12(3): 2343-2354.
- [18] 罗溢, 李开成, 肖贤贵, 等. 基于马尔可夫转移场和深度残差网络的电能质量复合扰动多标签分类[J]. 中国电机工程学报, 2024, 44(7): 2519-2530.
- LUO Yi, LI Kaicheng, XIAO Xiangui, et al. Multi-label classification of power quality composite disturbances based on Markov transfer field and ResNet [J]. Proceedings of the CSEE, 2024, 44(7): 2519-2530(in Chinese).
- [19] SINGH V K, GOVINDARASU M. A cyber-physical anomaly detection for wide-area protection using machine learning[J]. IEEE Transactions on Smart Grid, 2021, 12(4): 3514-3526.
- [20] 兰名扬, 刘宇龙, 金涛, 等. 基于可视化轨迹圆和 ResNet18 的复合电能质量扰动类型识别[J]. 中国电机工程学报, 2022, 42(17): 6274-6285.
- LAN Mingyang, LIU Yulong, JIN Tao, et al. An improved recognition method based on visual trajectory circle and ResnetN18 for complex power quality disturbances [J]. Proceedings of the CSEE, 2022, 42(17): 6274-6285(in Chinese).
- [21] 韩磊, 胥国毅, 王程, 等. 新能源电力系统调频资源与频率时空动态关联分析及分布表征[J]. 中国电机工程学报, 2025, 45(13): 5106-5118.
- HAN Lei, XU Guoyi, WANG Cheng, et al. Correlation analysis and distribution characterization of frequency regulation resources and frequency spatiotemporal dynamics in renewable energy power systems [J]. Proceedings of the CSEE, 2025, 45(13): 5106-5118(in Chinese).
- [22] VOSUGHI A, SADANANDAN S K, SRIVASTAVA A K. Synchrophasor-based event detection, classification, and localization using koopman, transient energy matrix, best worth method, and dynamic graph[J]. IEEE Transactions on Power Delivery, 2022, 37(3): 1986-1996.
- [23] 孟凡成, 郭琦, 康宏伟, 等. 计及集中式和分布式新能源的电力系统连锁故障模拟[J]. 高电压技术, 2022, 48(1): 189-198.
- MENG Fancheng, GUO Qi, KANG Hongwei, et al. Cascading failure simulation for power system with utility-scale and distributed renewable energy[J]. High Voltage Engineering, 2022, 48(1): 189-198(in Chinese).
- [24] LV Lingling, WU Zongyu, ZHANG Jinhua, et al. A VMD and LSTM based hybrid model of load forecasting for power grid security[J]. IEEE Transactions on Industrial Informatics, 2022, 18(9): 6474-6482.
- [25] 肖白, 肖志峰, 姜卓, 等. 基于降噪自编码器、奇异谱分析和长短期记忆神经网络的空间电力负荷态势感知[J]. 中国电机工程学报, 2021, 41(14): 4858-4867.
- XIAO Bai, XIAO Zhifeng, JIANG Zhuo, et al. Spatial load situation awareness based on denoising autoencoder, singular spectrum analysis and long short-term memory neural networks[J]. Proceedings of the CSEE, 2021, 41(14): 4858-4867(in Chinese).
- [26] ZENG Ying, HUANG Tudi, ZHANG Tingyu, et al. System-level performance degradation prediction for power converters based on SSA - Elman NN and empirical knowledge[J]. IEEE Transactions on Industrial Informatics, 2024, 20(2): 1240-1250.
- [27] 王祎颜, 王衍学, 姚家驰. 基于 VMD-CNN-BiLSTM 的轴承故障多级分类识别[J]. 机电工程, 2024, 41(9): 1554-1564.
- WANG Yiyang, WANG Yanxue, YAO Jiachi. Multi-level classification and identification of bearing faults based on VMD-CNN-BiLSTM model[J]. Journal of Mechanical & Electrical Engineering, 2024, 41(9): 1554-1564(in Chinese).
- [28] LIU Hao, LIU Shuo, ZHAO Junbo, et al. Dual-channel convolutional network-based fault cause identification for active distribution system using realistic waveform measurements[J]. IEEE Transactions on Smart Grid, 2022, 13(6): 4899-4908.
- [29] LI Yuze, WANG Shouyang, WEI Yunjie, et al. A new hybrid VMD-ICSS-BiGRU approach for gold futures price forecasting and algorithmic trading[J]. IEEE Transactions on Computational Social Systems, 2021, 8(6): 1357-1368.
- [30] 王碧玲, 周灏, 沈力华, 等. 基于改进凌日搜索算法的风洞天平载荷预测方法[J]. 计算机测量与控制, 2024, 32(11): 25-33.
- WANG Biling, ZHOU Hao, SHEN Lihua, et al. A wind tunnel balance load prediction method based on ITS

- algorithm[J]. Computer Measurement & Control, 2024, 32(11): 25-33(in Chinese).
- [31] ZHAO Baoxuan, CHENG Changming, PENG Zhike, et al. Detecting the early damages in structures with nonlinear output frequency response functions and the CNN-LSTM model[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(12): 9557-9567.
- [32] CHEN Qifan, LIN Nan, BU Siqi, et al. Interpretable time-adaptive transient stability assessment based on dual-stage attention mechanism[J]. IEEE Transactions on Power Systems, 2023, 38(3): 2776-2790.
- [33] WANG Zhenyi, YU Peipei, ZHANG Hongcai. Privacy-preserving regulation capacity evaluation for HVAC systems in heterogeneous buildings based on federated learning and transfer learning[J]. IEEE Transactions on Smart Grid, 2023, 14(5): 3535-3549.
- [34] LI Zikang, LIU Hao, ZHAO Junbo, et al. Fast power system event identification using enhanced LSTM network with renewable energy integration[J]. IEEE Transactions on Power Systems, 2021, 36(5): 4492-4502.
- [35] 梁志峰. 2011—2013 年国家电网公司输电线路故障跳闸统计分析[J]. 华东电力, 2014, 42(11): 2265-2270. LIANG Zhifeng. Statistical analysis of transmission line fault tripping in state grid corporation of China in 2011-2013[J]. East China Electric Power, 2014, 42(11): 2265-2270(in Chinese).
- [36] CHEN Zhilin, LIU Hao, ZHAO Junbo, et al. Real-time event detection based on STA/LTA method using field synchrophasor measurements[J]. IEEE Transactions on Power Delivery, 2023, 38(6): 4070-4080.



刘灏

在线出版日期: 2025-06-04。

收稿日期: 2024-12-23。

作者简介:

刘灏(1985), 男, 博士, 副教授, 博士生导师, 主要研究方向为同步相量测量技术及其应用, hliu@ncepu.edu.cn;

廖梦竹(2001), 女, 硕士研究生, 主要研究方向为基于数据驱动的电力系统扰动辨识, mzliao15395310095@163.com;

*通信作者: 毕天姝(1973), 女, 教授, 博士生导师, 主要研究方向为电力系统保护与控制、广域同步相量测量技术及应用, tsbi@ncepu.edu.cn。

(责任编辑 邱丽萍)