

DOI: 10.19783/j.cnki.pspc.256114

基于改进 CNNA 的含风电电力系统暂态稳定评估

刘伟^{1,2}, 胡歆岳¹, 路敬祎²

(1. 东北石油大学电气信息工程学院, 黑龙江 大庆 163318; 2. 东北石油大学三亚海洋油气研究院, 海南 三亚 572000)

摘要: 随着风电渗透率的不断提高, 电力系统的功率波动性和不确定性显著加剧, 传统暂态稳定评估方法在精度和效率方面均面临严峻挑战。为此提出一种改进一维注意力卷积神经网络(CNN-Attention, CNNA)的暂态稳定评估模型。首先, 充分发挥 CNNA 的特征提取与重点时序捕捉能力, 引入残差块以改善模型的梯度消失问题, 并结合维纳滤波技术抑制样本噪声干扰。其次, 基于功角稳定与电压稳定联合判据设计暂态稳定评估流程, 并建立相应的评价指标体系。最后, 通过 PSASP 软件仿真实验对 IEEE39 和 IEEE118 含风力发电机组节点系统进行了算例验证。结果表明所提方法在不同噪声、风机工况下均保持较高的准确率, 能有效降低“误判稳定”风险, 对失稳状态具备较高的识别能力。

关键词: 含风电电力系统; 暂态稳定评估; 残差块; 维纳滤波

Transient stability assessment of power systems with wind turbines based on an improved CNNA model

LIU Wei^{1,2}, HU Xinyue¹, LU Jingyi²

(1. School of Electrical and Information Engineering, Northeast Petroleum University, Daqing 163318, China;

2. NEPU Sanya Offshore Oil & Gas Research Insititute, Sanya 572000, China)

Abstract: With the continuous increase in wind power penetration, the power fluctuation and uncertainty of power systems have significantly intensified, posing severe challenges to traditional transient stability assessment methods in terms of both accuracy and efficiency. To address this issue, a transient stability assessment model based on an improved one-dimensional convolutional neural network with attention (CNN-Attention, CNNA) is proposed. First, by fully exploiting the feature extraction capability and key temporal sequence focusing ability of the CNNA, residual blocks are introduced to alleviate the gradient vanishing problem, and Wiener filtering is incorporated to suppress noise interference in the samples. Second, a transient stability assessment framework is designed based on a combined criterion of rotor angle stability and voltage stability, and a corresponding evaluation index system is established. Finally, simulation studies are carried out using PSASP software on the IEEE 39-bus and IEEE 118-bus systems with wind turbine generator. The results show that the proposed method maintains high accuracy under different noise levels and wind turbine operating conditions, effectively reduces the risk of “false stable” misjudgment, and exhibits strong capability in identifying unstable states.

This work is supported by the National Natural Science Foundation of China (No. 62473096).

Key words: power systems with wind power; transient stability assessment; residual block; Wiener filtering

0 引言

由于风力发电低碳环保, 我国电网将持续提升风电机组的装机规模, 旨在全面挖掘风能资源的潜力, 进而有效减轻电力供应的紧张压力^[1]。但由于风电机组接入系统后呈现出了抗干扰性弱、过载能力低、出力波动性强等特点^[2-4], 因此对含风电的电

力系统进行暂态稳定评估已成为业界关注的焦点。

目前, 电力系统暂态稳定评估方法主要有时域仿真法、能量函数法和人工智能方法^[5-6]。时域仿真法通过求解全系统的微分代数方程组对系统的运行状态进行评估^[7], 此方法能够计及元件详细模型, 计算结果精确可靠, 但面临着复杂度高、计算效率低的瓶颈^[8]。能量函数法通过计算系统的总能量、考虑系统的全局稳定性、比较系统初始状态与临界状态之间的能量差评估系统是否稳定^[9], 具有更快的

基金项目: 国家自然科学基金项目资助(62473096)

计算速度,但其需要忽略某些非线性因素和动态过程,对电力系统进行一定的简化和假设,随着新能源并网的增多,“双高”特性愈发显著,给确定暂态能量函数稳定特性带来了更多挑战。人工智能方法的兴起,如神经网络(artificial neural network, ANN)^[10]、卷积神经网络(convolutional neural network, CNN)^[11]、循环神经网络(recurrent neural network, RNN)^[12]等算法为电力系统暂态稳定评估问题提供了新的思路,其具有训练速度较快、特征提取能力强的优点,能较好地处理分类问题^[13]。

文献[14]基于一维 CNN 提出了一种快速批量暂态稳定评估方法,但其忽略了样本中失稳样本与稳定样本的数量关系,难以突出因样本数据量不平衡造成的对暂态稳定评估结果的影响^[15]。电力系统暂态失稳在实际电网中发生较少,故障失稳样本数据量远少于稳定样本,而暂态稳定故障切除后系统有可能处在临界稳定或临界失稳状态,临界样本数量更少^[16]。针对该问题,文献[17]考虑重叠区域样本和失稳样本数据量少的情況对损失函数做出改进。文献[18]结合注意力机制与重采样策略构建了改进的暂态稳定评估模型,但这些研究中用到的样本多为仿真生成,数据过于理想。同步相量测量单元(phasor measurement unit, PMU)由于测量和通信设备的缺陷、随机负载波动等情况^[19],采集到的数据存在缺失、含有噪声的问题,会对暂态稳定评估结果造成很大的影响。文献[20]设计了一种融合噪声鲁棒特征的混合深度学习框架,显著提升了含噪声情况下的系统稳定性及分类精度。文献[21]将注意力机制与 CNN 相结合,并引入了批归一化(batch normalization, BN)处理技术,其在含噪声的情况下具有较高的准确率,但只验证了传统电力系统暂态稳定,没有验证含风电等新能源的电力系统暂态稳定。

针对含风电的电力系统暂态稳定评估问题,本文提出了具有残差和维纳滤波的一维注意力卷积神经网络(CNNA with residual blocks and Wiener filtering, WRCNNA)暂态稳定评估模型。在 CNNA 基础上进行改进,利用其能突出时序样本中重要信息的特征,并针对待分类样本不平衡的问题,对其融入残差块,缓解梯度消失和爆炸问题,提高了模型的表达能力和泛化性能,针对待分类样本含噪声的问题,引入维纳滤波去噪,提高模型对样本识别的准确率。

1 基于 CNNA 模型的改进方法研究

1.1 CNNA 模型结构

模型 CNNA 主要由卷积层(convolutional layer, Conv)、BN 层、激活函数 ReLU 层、最大池化层(max

pooling layer, MaxPool)、注意力机制层(attention)和全连接层(fully connected layer, FC)组成,如图 1 所示。

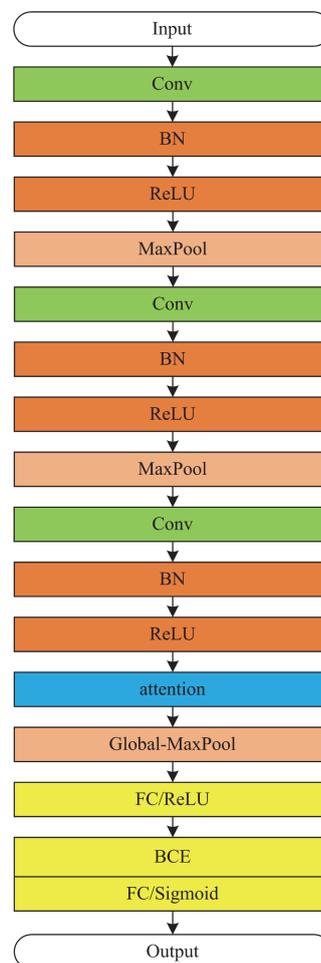


图 1 CNNA 结构

Fig. 1 Structural diagram of CNNA

将 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_s, \dots, \mathbf{x}_n]^T$ 作为模型输入层,其中 $\mathbf{X} \in \mathbf{R}_{n \times s}$, n 为 PMU 采集电气量的时间序列(如某节点的某相角随时间变化的列向量)的个数, s 为时间序列的长度, \mathbf{x}_n 为第 n 个电气量的时间序列。输入层通过卷积层自动提取特征^[22],在此过程中 BN 层和 ReLU 层抑制其过拟合,由于输入层的特征图较大导致卷积层的特征图尺寸较大,因此最大池化层会通过池化操作降低特征图的尺寸,提高计算速度。对于输入经 3 次卷积提取特征后,该模型通过注意力机制层为不同特征分配相应的注意力权重, \mathbf{h}_i 为 \mathbf{H} 中注意力权重, $\mathbf{H} = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_s, \dots, \mathbf{h}_n]^T$,以突出关键输入对输出结果的重要影响^[23],进而促进模型更快收敛并提高分类效率。最后,其通过全局最大池化层压缩时间维度,再经由两层全连接网络实现最终判别输出。其中最后的输出层使用

Sigmoid 激活函数，将输入的任意连续数值归一化至(0,1)区间，用于衡量系统失稳风险的相对大小。

在机器学习和深度学习中，损失函数提供了一种量化模型预测与实际目标之间差异的方法，对于不平衡的二分类问题，通常采用二元交叉熵函数(binary cross-entropy, BCE)作为损失函数。其表达式为

$$L = -\frac{1}{N} \left[\sum_{i=1}^N y_i \lg \hat{y}_i + \sum_{i=1}^N (1 - y_i) \lg (1 - \hat{y}_i) \right] \quad (1)$$

式中： L 为二元交叉熵损失函数的计算结果； N 为样本的总数； y_i 为第*i*个样本的真实稳定或失稳标签； \hat{y}_i 为模型判定第*i*个样本处于稳定的概率，取值范围为 $\hat{y}_i \in (0,1)$ ，当 L 降到最小后，式(1)中的预测概率 \hat{y}_i 需要通过一个规则转换为最终的稳定性分类结果。该规则基于一个预设的分类阈值定义二分类阈值 β ，可将模型输出概率变换为稳定性结果 $y_{\text{pred}}(i)$ ，如式(2)所示。

$$y_{\text{pred}}(i) = \begin{cases} 1, & \hat{y}_i > \beta \\ 0, & \hat{y}_i \leq \beta \end{cases} \quad (2)$$

本文 β 暂时设置为0.5(本文后续会对其性能进行讨论)，当 $\hat{y}_i > 0.5$ 时， $y_{\text{pred}}(i) = 1$ ，表示系统稳定；当 $\hat{y}_i \leq 0.5$ 时， $y_{\text{pred}}(i) = 0$ ，表示系统失稳。

1.2 残差块的原理

为了提取到更多的特征搭建的深度神经网络往往有更多层，但过深的网络容易导致过拟合，且由于梯度消失问题，深层的网络难以训练。对此，文献[24]提出了残差网络(residual network, ResNet)，该网络的核心是残差块。在残差块中，输入信号会通过两条路径传递：1) 通过多个卷积层进行非线性变换的主路径；2) 不经过任何复杂非线性变换的“直通通道”。最终，将这两条路径的输出相加作为块的输出。如图2所示，则理想映射 $f(\mathbf{X})$ 为

$$f(\mathbf{X}) = f_{\text{conv}}(\mathbf{X}) + \mathbf{X} \quad (3)$$

式中： $f_{\text{conv}}(\mathbf{X})$ 为输入经过连续卷积后的结果，这样可以通过叠加多个残差块构建的ResNet，使得深层网络更容易训练。

1.3 维纳滤波器

尽管BN层可以在一定程度上提高了模型对噪声影响的鲁棒性，但其本身并非专门为滤波设计的。由于对于数据中的高斯噪声，BN层可能无法显著改善噪声问题，因此本文引入维纳滤波器。维纳滤波器是一种基于最小均方误差准则的线性滤波器，通常在频域中实现，常用于信号去噪^[25]，其核心目标是通过噪声与信号的统计特性进行建模，去除信号中噪声成分，同时最大限度保留信号的细节特

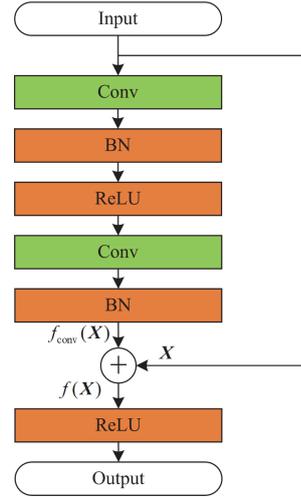


图2 残差块结构

Fig. 2 Structural diagram of residual block

征。维纳滤波器观测到的信号 $y(t)$ 是理想信号 $x(t)$ 和噪声信号 $n(t)$ 的叠加，如式(4)所示。

$$y(t) = x(t) + n(t) \quad (4)$$

通过计算理想信号的功率谱密度 $S_x(f)$ 和噪声信号的功率谱密度 $S_n(f)$ 来估计信号。维纳滤波器的频域响应函数 $H(f)$ 为

$$H(f) = \frac{S_x(f)}{S_x(f) + S_n(f)} \quad (5)$$

$y(t)$ 在频域上的表示为 $Y(f)$ ，如式(6)所示。

$$Y(f) = X(f) + N(f) \quad (6)$$

式中： $X(f)$ 、 $N(f)$ 分别为 $x(t)$ 、 $n(t)$ 的傅里叶变换函数，维纳滤波后最终输出的信号 $\hat{x}(t)$ 为

$$\hat{x}(t) = F_{\text{fourier}}^{-1}[H(f)Y(f)] \quad (7)$$

式中： $F_{\text{fourier}}^{-1}[\cdot]$ 为傅里叶逆变换函数，维纳滤波对于高斯噪声的去除效果良好，能够在大多数情况下有效地复原信号。

1.4 WRCNNA 模型结构

为了有效提取电力系统暂态过程的时序特征，本文设计了一种改进CNNA模型的暂态稳定评估模型WRCNNA，如图3所示。3Conv-64表示卷积核尺寸为3，个数为64(其余含义与此类似)；attention-256表示注意力机制中有256个输入。输入层由电气量的时间序列构成，输出层采用二元交叉熵损失函数。

数据集在输入后，首先经过维纳滤波器，再传输到残差网络中，第1个残差块采用恒等映射，其中2个卷积层用3Conv-64，初步提取64种特征；第2个残差块将第1个残差块的通道数翻倍，此外在残差支路中加入尺寸为1、个数为128的卷积核

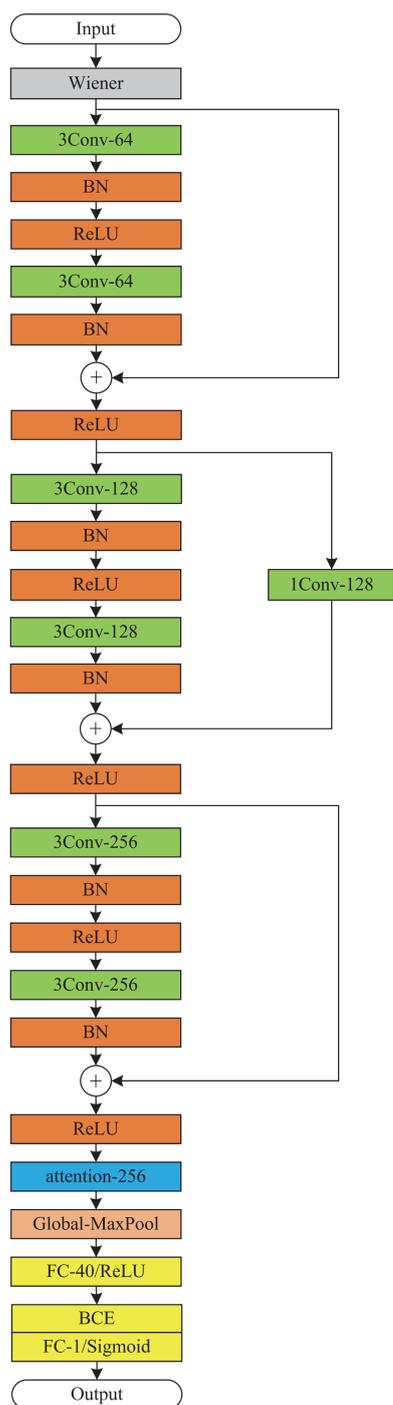


图3 WRCNNA 结构

Fig. 3 Structural diagram of WRCNNA

提升分辨率；第3个残差块将第2个残差块的通道数翻倍，在经过注意力机制层后通过全局最大池化将时间序列维度压缩至1，基于抽象时序特征的建模方法为表征暂态稳定动态过程提供了有效手段。40个隐含单元的全连接层对256维全局时序特征降维，最后将暂态稳定分类结果输出。

2 暂态稳定评估方法

2.1 暂态稳定判据

在机器学习和深度学习中，数据集需要手动打上标签。而对于样本是否失稳的判据，目前电力系统暂态稳定评估的相关文献多采用暂态稳定指数 (transient stability index, TSI) 对样本进行稳定性标注，暂态稳定指数 η_{TSI} 表示为^[26]

$$\eta_{\text{TSI}} = \frac{360^\circ - |\Delta\delta_{\max}|}{360^\circ + |\Delta\delta_{\max}|} \quad (8)$$

式中： $\Delta\delta_{\max}$ 为任意两台发电机功角差最大值。对于电力系统，若 $\Delta\delta_{\max}$ 的绝对值小于 360° ，即 $\eta_{\text{TSI}} > 0$ ，则系统稳定，反之则系统失稳。

由式(8)可知，该判据主要是根据发电机的功角进行判断，而如今风力发电机多为双馈风机，其本质是异步发电机，没有功角这一电气量^[27]，因此对于双馈风机并网的电力系统，文献[28]采用频率稳定性对含风电系统的稳定性进行判断，当频率下降至 47 Hz 时，该系统表现出严重的失稳情况。但电力系统的暂态过程主要集中在大扰动发生后几秒内 (通常 0~10 s) 系统的动态响应特性。在这一时间尺度内，系统频率变化相对较慢，主要由惯量特性主导，频率偏移尚未超过判断标准，而功角与电压在短时间内剧烈波动。同时频率稳定性本质上是在系统受到扰动后，网络各节点频率围绕惯量中心频率变化，且假设扰动发生后电网电压幅值几乎不变，属于小扰动稳定研究范畴^[29]。因此频率稳定判据也无法适用于含双馈风机并网系统的暂态稳定评估。

电力系统的暂态稳定除了功角稳定性和频率稳定性以外，还包含电压稳定性。无论系统中是否有新能源并网，线路发生大扰动故障类型时会引起负荷母线电压跌落，造成系统中一些母线出现暂态电压失稳。因此文献[30]考虑电压稳定性，根据我国电力行业标准，选取 0.7 倍标幺值的安全阈值，当系统中最低母线电压低于该阈值超过 1 s 时，则判定母线电压无法保持或恢复到电压要求范围之内，即系统不满足电压稳定判据。然而电压稳定判据需要计及所有节点的电压值，式(8)TSI 判据只需要计及所有同步发电机的功角，而电压失稳节点在系统节点中的特征远不如功角失稳发电机在全体发电机中那样明显，因此文献[30]采用“功角稳定性判据与电压稳定性判据”进行联合判定：同时满足功角稳定性与电压未跌破安全阈值时，才将样本判定为“稳定”；若任意一项不满足，则判为“失稳”，并通过含新能源并网的交直流混联 EPRI36 节点算

例验证了该判据的有效性。本文根据该文献也采用“功角稳定性与电压稳定性”联合判据。

2.2 暂态稳定评估模型评价指标

WRCNNA 模型在分类后的结果中会有被正确分类的稳定样本 T_s 和失稳样本 T_{us} , 以及被误判稳定的样本 F_s 和被误判失稳的样本 F_{us} , 则准确率 A_{cc} 为

$$A_{cc} = \frac{T_s + T_{us}}{T_s + F_s + T_{us} + F_{us}} \quad (9)$$

此外, 稳定性分析中“误判稳定”和“误判失稳”对系统造成的影响不同。如果将濒临失稳的样本误判为稳定状态, 运行人员可能不会对系统即将出现的失稳情况采取预防措施, 这样一来, 很可能导致系统遭受严重的破坏。而相比之下, 将稳定样本错误地判定为失稳, 其带来的影响则相对较小。鉴于这两种误判所带来的后果严重性不同, 因此引入精确度 P_{rec} 、召回率 R_{cc} 以及综合性的 F_1 分数多项统计学指标, 分别如式(10)一式(12)所示^[31]。

$$P_{rec} = \frac{T_{us}}{T_{us} + F_{us}} \quad (10)$$

$$R_{cc} = \frac{T_{us}}{T_{us} + F_s} \quad (11)$$

$$F_1 = \frac{2P_{rec}R_{cc}}{P_{rec} + R_{cc}} \quad (12)$$

在暂态稳定评估中失稳样本是否正确分类较为重要, 本文对这些统计学指标进行了相应的优化和调整。在暂态稳定评估中, A_{cc} 的提高意味着模型对稳定分类的准确性越高, 这是衡量模型性能的首要标准, 然而 R_{cc} 同样重要, 提高 R_{cc} 有助于减少将失稳样本误判为稳定的情况, 但 R_{cc} 与 P_{rec} 之间存在相互制约的关系, 即一方提升往往伴随着另一方的下降。当 P_{rec} 降低时, 会导致“误判失稳”的情况频繁出现, 若将此类模型投入实际使用, 可能会引发系统频繁报警, 从而降低模型的实用价值。因此, 在确保 A_{cc} 尽可能高的基础上, 本文通过调整分类阈值 β 来平衡模型的评估侧重提高召回率, 减少“误判稳定”的发生, 使评估结果更加贴近实际使用需求。

2.3 暂态稳定评估流程

本文设计的 WRCNNA 模型暂态稳定评估流程如图 4 所示, 主要由离线状态与在线状态两部分组成。

在离线状态下, 本文选取样本故障前某一时刻、故障发生时刻以及故障切除时刻的数据, 由于故障时间相对于仿真时间很短, 因此本文根据文献[31]将采样区间选取为发生故障前的 4 个周期至继电保护切除故障后的 6 个周期, 根据 2.1 节中的判

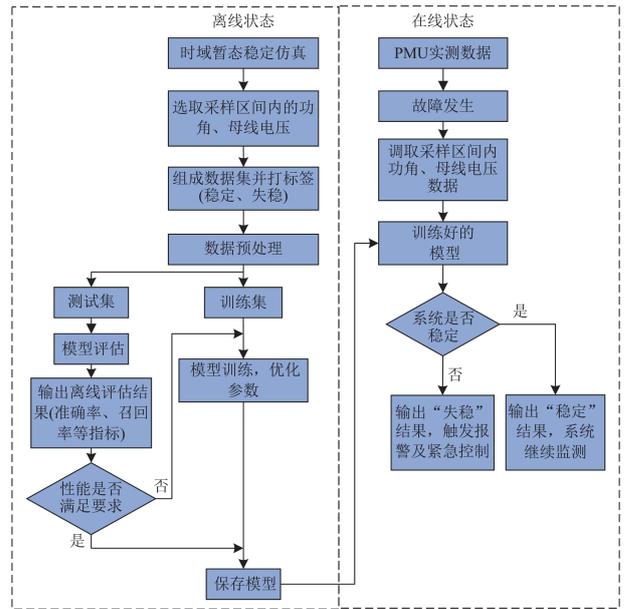


图 4 基于 WRCNNA 的暂态稳定评估流程

Fig. 4 Transient stability assessment process based on WRCNNA

据提取所需的电气量组成样本集并进行稳定性标注, 最终得到数据集。再将数据集进行预处理, 按一定的比例随机形成训练集和测试集; 在模型训练阶段, 训练集中的模型参数会得到优化, 测试集用于评估模型性能, 直至评估结果满足要求后停止训练并保存模型。在线评估中, PMU 会实时采集发电机功角和电压相量数据, 在故障发生后会按照采样区间调取数据生成测试样本输入到训练好的模型中, 如果判定为失稳, 则会提醒工作人员采取紧急控制措施, 如果判定为稳定, 则继续监测。

3 算例分析

3.1 样本集构建

本文的算例使用电力系统暂态稳定常用的评估 IEEE10 机 39 节点系统^[32], 将其中的 30 号节点和 35 号节点替换成双馈风机, 如图 5 所示。

本文基于 PSASP 软件仿真生成源域样本数据, 对所提方法进行验证。在软件的“暂态稳定计算”功能中选择软件默认的系统频率(50 Hz)和采样时间间隔(0.01 s)。由于在进行暂态分析时主要考虑同步发电机的机电暂态过程, 所以同步发电机采用二阶经典模型, 负荷模型采用恒阻抗模型^[33]。基于系统的基准负荷设置了 3 种负荷水平, 分别为 90%、100%、110%, 并相应调整发电机出力使潮流收敛。由于在电力系统中三相短路故障产生的危害最大, 最容易使系统失稳, 因此在功能设置中, 本文将“网络故障”模拟为线路三相短路情况。在故障持续一

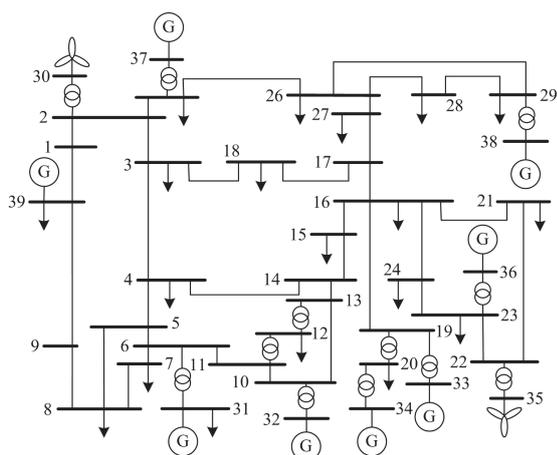


图5 含风机的 IEEE10 机 39 节点系统

Fig. 5 IEEE 10-machine 39-bus system with wind turbines

段时间后, 会对相应的故障线路进行切除。为了确保在切除故障线路时系统不会形成孤岛状态, 本文从 46 条线路中选取了除变压器支路外的 34 条线路, 参与暂态故障的扫描分析。故障位置分别设置为每条线路全长的 20%、40%、60%、80%, 故障发生时刻为 2 s, 故障切除时刻分别为 2.12 s、2.16 s、2.2 s。

本文的风机模型使用系统自带的双馈风机模型, 额定风速 11.8 m/s, 切入风速 3.0 m/s, 切出风速 25.0 m/s, 调整两台风机的额定容量使风电渗透率达到 10%。通过观察新疆地区某风电场的某一天的风速数据发现, 虽然现实生活中一天的时间内风速变化无常, 但在几秒的时间内风速几乎不变, 因此本文设置每台风机有 11.8 m/s、5.9 m/s 两种风速。

本文仿真时长选择软件默认的 5 s, 仿真结束后根据 2.1 节中的判据对样本稳定性标签进行标注, 共生成 4896 个样本, 其中稳定样本 3287 个, 失稳样本 1609 个。根据 2.3 节中的观察窗口设置, 由于故障时间设置的不同, 为了方便对模型进行训练, 本文以最长的故障时间为基准, 且为可靠采集到故障前的信息, 本文取 1.92~2.32 s 为采样区间, 区间内的样本数据形成数据集。

3.2 考虑噪声情况下的模型性能对比

由于软件在仿真的过程中无法添加噪声, 因此本文在划分训练集、测试集之前为数据集添加噪声, 根据 IEEE C37.118 标准, PMU 相量测量误差应小于 1.0%^[34], 故将 3.1 节中的数据集分别处理成含高斯白噪声信噪比(signal-to-noise ratio, SNR)为 0.5%的数据集和 1.0%的数据集。由于失稳样本数量较少, 为确保划分数据集后测试集中含有失稳样本, 因此本文不再设置验证集, 将数据集按 7:3 的比例划分为训练集和测试集, 各子集通过分层随机抽样从总样

本集中取出, 保证稳定/失稳样本比例与总体样本一致。训练集用于对模型参数寻优, 测试集用于验证模型泛化能力。在模型训练之前, 需要对数据进行标准化处理, 标准化后的数据具有相似的尺度, 使得梯度下降在寻找最优解时更加高效。在模型训练的过程中, 学习算法 Adam 通过自适应调整学习率加速模型收敛, 本文使用其默认参数, 学习率设置为 0.001。正则化惩罚系数设为 0.5。本文分别将这 3 种数据集输入到 WRCNNA、RCNNA、CNNA、CNN-LSTM、Transformer、Bi-LSTM、TCN 这些主流模型进行对比, 迭代 50 次后结果如图 6 所示, 评价指标见表 1。

通过观察图 6(a)和图 6(b)可知, 在无噪声的情况下, 模型 WRCNNA 与 RCNNA 的准确率接近, 高于模型 CNNA、CNN-LSTM、Transformer、Bi-LSTM、TCN, 同时 7 种模型的损失曲线均有较好的收敛性; 通过观察图 6(c)和图 6(d)可知, 当信噪比为 0.5%时, 模型 WRCNNA、RCNNA、CNNA 的准确率曲线与无噪声时相差不大, 但模型 CNN-

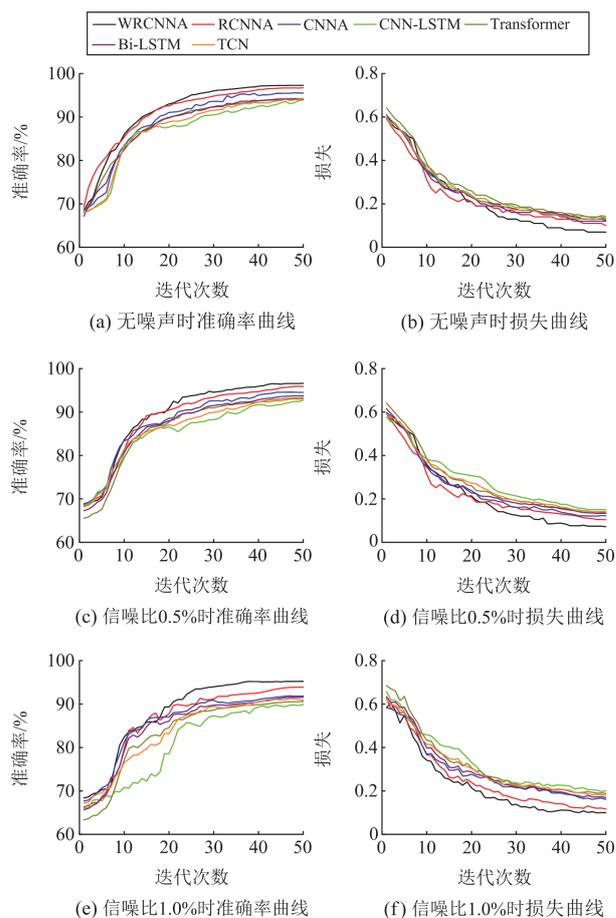


图6 不同信噪比下模型性能对比

Fig. 6 Comparison of model performance under different SNRs

表 1 不同信噪比下模型的评价指标

Table 1 Evaluation metrics of the model under different SNRs

信噪比/%	模型	$A_{cc}/\%$	$P_{rec}/\%$	$R_{cc}/\%$	F_1
0	WRCNNA	97.28	94.04	97.92	0.9594
	RCNNA	96.73	93.24	97.10	0.9513
	CNNA	95.51	91.29	95.45	0.9332
	CNN-LSTM	93.94	88.63	93.58	0.9104
	Transformer	94.01	88.35	94.20	0.9118
	Bi-LSTM	94.21	88.72	94.41	0.9148
	TCN	94.15	88.85	94.00	0.9135
0.5	WRCNNA	96.66	92.89	97.31	0.9505
	RCNNA	95.92	92.22	95.65	0.9390
	CNNA	94.55	89.90	94.00	0.9190
	CNN-LSTM	92.72	86.58	92.13	0.8927
	Transformer	93.33	87.09	93.58	0.9022
	Bi-LSTM	93.67	87.79	93.79	0.9069
	TCN	93.06	86.71	93.17	0.8982
1.0	WRCNNA	95.23	90.73	95.24	0.9293
	RCNNA	93.87	88.45	93.58	0.9094
	CNNA	91.83	86.67	88.82	0.8773
	CNN-LSTM	89.93	82.52	87.99	0.8517
	Transformer	90.45	82.30	90.48	0.8620
	Bi-LSTM	91.56	84.19	91.51	0.8770
	TCN	90.88	83.11	90.68	0.8673

LSTM、Transformer、Bi-LSTM、TCN 的准确率曲线与无噪声时相差较大；通过观察图 6(e)和图 6(f)可知，当信噪比为 1.0%时，迭代 25 次之后 WRCNNA、RCNNA 的准确率明显高于模型 CNNA、CNN-LSTM、Transformer、Bi-LSTM、TCN，WRCNNA、RCNNA 的损失值相比其他 5 个模型更小。

除同一信噪比下不同模型的准确率对比外，本文还对比了同一模型在不同信噪比下的准确率，如图 7 所示。TCN、Transformer 模型的准确率和 F_1 分数比较接近，略小于 Bi-LSTM 的准确率和 F_1 分数，但 Bi-LSTM 在无噪声的情况下，准确率不到 95%，而当信噪比继续增大至 1.0%时，准确率低至 91.56%，尽管 Bi-LSTM 的准确率高于模型 CNN-LSTM，但总的来看，这些模型准确率和 F_1 分数较低，不适用于含风电的电力系统暂态稳定评估。对于 CNNA 模型，当信噪比从 0 增大至 0.5%时，准确率从 95.51% 降至 94.55%，其 F_1 分数大于 0.91，但当信噪比继续增大至 1.0%时，准确率从 94.55% 降至 91.83%，该模型难以适用于 1.0%信噪比情况下的暂态稳定评估。对于 RCNNA 和 WRCNNA 模型，当信噪比从 0 增大至 1.0%时，准确率从 97%左右降至 94%左右，相较于其他 5 个模型略有下降，可以用于含噪声情况下的暂态稳定评估，但相比于 RCNNA，无论在哪种信噪比下 WRCNNA 的准确率均更高，其随着信噪比的升高而下降得比较缓慢，且其 F_1 分数均更

高，该模型在输入信号含噪声的情况下暂态稳定评估显著优于其他模型。

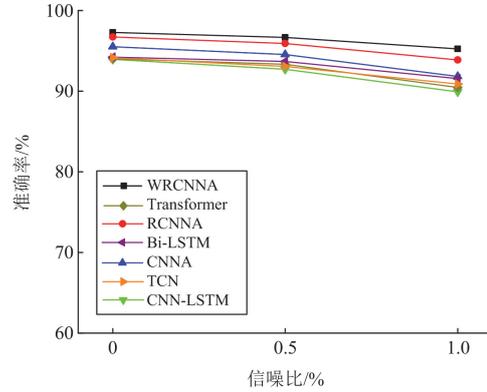


图 7 不同信噪比下模型的准确率

Fig. 7 Comparison of model accuracy under different SNRs

3.3 分类阈值对评价指标的影响

对于高度非线性的电力系统而言，暂态稳定评估模型需要学习的信息很复杂^[35-36]，尽管本文设计的 WRCNNA 模型的评估准确率在 95%以上，但仍无法达到 100%的评估准确率，因此“误判稳定”总会发生。本文通过修改分类阈值 β ，提高召回率 R_{cc} ，减少“误判稳定”的发生。本文以 3.2 节中信噪比 1.0%的数据集为例，对分类阈值 β 进行调整，以 0.1 为步长从 0.1 调整到 0.9，与 1.1 节中设置的 0.5 进行对比，模型在不同分类阈值 β 下的混淆矩阵和评价指标如表 2 所示。

表 2 不同分类阈值的混淆矩阵与评价指标

Table 2 Confusion matrix and evaluation metrics with different thresholds

β	$A_{cc}/\%$	$P_{rec}/\%$	$R_{cc}/\%$	F_1	混淆矩阵		
					模型预测 测标签	实际标签	
						稳定	失稳
0.9	94.01	85.71	98.14	0.9150	稳定	907	9
					失稳	79	474
0.8	94.42	87.06	97.52	0.9199	稳定	916	12
					失稳	70	471
0.7	94.76	88.45	96.69	0.9239	稳定	925	16
					失稳	61	467
0.6	95.03	89.73	95.27	0.9242	稳定	933	20
					失稳	53	463
0.5	95.23	90.73	95.24	0.9293	稳定	939	23
					失稳	47	460
0.4	95.10	91.52	93.21	0.9236	稳定	944	30
					失稳	42	453
0.3	94.96	92.52	92.13	0.9232	稳定	950	38
					失稳	36	445
0.2	94.83	93.58	90.48	0.9200	稳定	956	46
					失稳	30	437
0.1	94.69	94.51	89.03	0.9169	稳定	961	53
					失稳	25	430

由表 2 可知, 当 β 从 0.5 减小到 0.1 时, “误判失稳”数从 47 降至 25, P_{rec} 从 90.73% 提高到了 94.51%, 模型评估误判失稳精度提高, 但“误判稳定”数从 23 增大到 53, 考虑到“误判稳定”造成的后果比“误判失稳”更严重, 因此降低“误判稳定”更重要。当 β 从 0.5 提高到 0.9 时, 尽管“误判失稳”数从 47 增大到 79, P_{rec} 从 90.73% 下降到了 85.71%, 但“误判稳定”数从 23 降到了 9, R_{cc} 从 95.24% 提高到了 98.14%, 提高了对失稳状态预测的可靠性, 因此本文将分类阈值调整为 0.9, 适当牺牲 P_{rec} 提高 R_{cc} , 以降低“误判稳定”情况造成的

影响。

为进一步验证所提方法在更大节点的电力系统的适应性, 本节使用 IEEE 54 机 118 节点系统作为算例^[37], 将其中的 1、4、6 号节点和 110、111、112 号节点替换成双馈风机, 如图 8 所示。与 3.1 节同理, 选取其中 102 条线路参与暂态故障的扫描分析, 其他条件不变, 将 1、4、6 号节点的风机划为一组, 将 110、111、112 号节点的风机划为另一组, 每组风机的风速情况与 3.1 节相同, 共生成 14 688 个样本, 其中稳定样本 10 279 个, 失稳样本 4409 个。

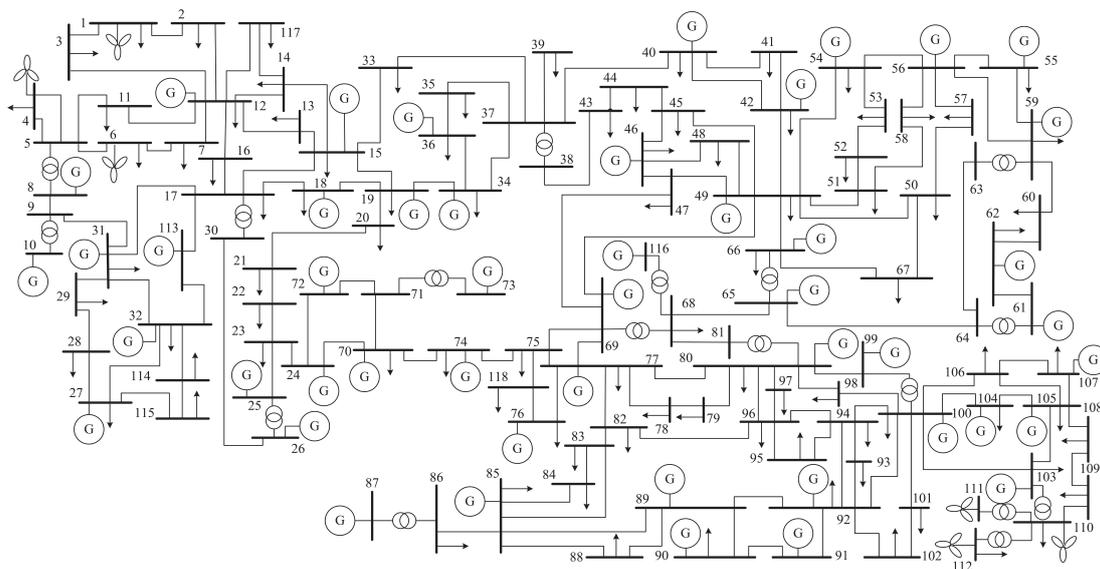


图 8 含风机的 IEEE54 机 118 节点系统

Fig. 8 IEEE 54-machine 118-bus system with wind turbines

与 3.2 节同理, 本节在数据集添加信噪比为 1.0% 的噪声后将其输入到 3.2 节的 7 个模型中, 验证分类阈值为 0.9 以及信噪比为 1.0% 时所提方法在更复杂电力系统中的性能, 迭代 50 次后结果如图 9 所示, 评价指标见表 3。

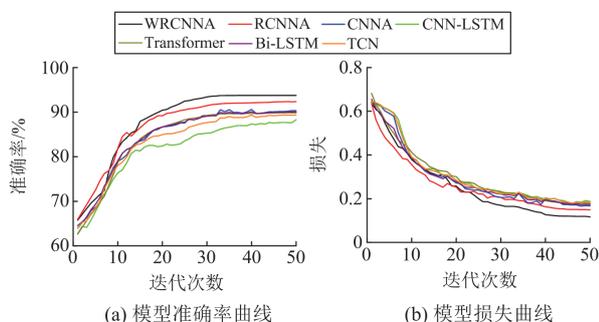


图 9 IEEE118 节点下模型性能对比

Fig. 9 Comparison of model performance of IEEE118-bus system

表 3 IEEE118 节点下模型的评价指标

Table 3 Evaluation metrics of the model of the IEEE118-bus system

模型	$A_{\text{cc}}/\%$	$P_{\text{rec}}/\%$	$R_{\text{cc}}/\%$	F_1
WRCNNA	93.78	83.86	98.19	0.9046
RCNNA	92.35	81.20	96.98	0.8839
CNNA	90.29	77.37	95.62	0.8553
CNN-LSTM	88.29	74.09	93.80	0.8279
Transformer	89.88	76.79	95.01	0.8493
Bi-LSTM	90.06	77.03	95.31	0.8520
TCN	89.38	76.02	94.41	0.8422

通过观察图 9 和表 3 可知, 模型 WRCNNA、RCNNA 与其他 5 个模型的准确率差距比较明显, 由于改变了分类阈值, 这 7 种模型的准确率普遍偏低, 但他们的召回率均在 93% 以上, 模型 WRCNNA 相比于其他模型有着更高的召回率以及准确率, 其在含噪声的情况下暂态稳定评估表现更加可靠。

3.4 评估模型对风机不同工况的鲁棒性分析

为评估模型对风机不同工况的鲁棒性分析，本文设置了两种极端工况与 3.1 节中的工况进行对比，如图 10 所示。图 10(a)中急升风的初始风速为 5.9 m/s，在 1.92 s 开始线性增加，至 2.32 s 达到 11.8 m/s 后保持；急降风初始风速为 11.8 m/s，在相同时间窗内线性下降至 5.9 m/s 后保持。根据风机的保护机制设置切入风速和切出风速，只有当风速高于切入风速且低于切出风速时风机才会并网。图 10(b)中对每台风机设置了切入风速曲线和切出风速曲线，切入风的初始风速为 2.9 m/s，在 1.92 s 开始增大，在 2.32 s 增至 11.8 m/s 后保持不变直至结束；切出风的初始风速为 11.8 m/s，在 1.92 s 开始增大，在 2.32 s 增至 25.1 m/s 后保持不变直至结束。

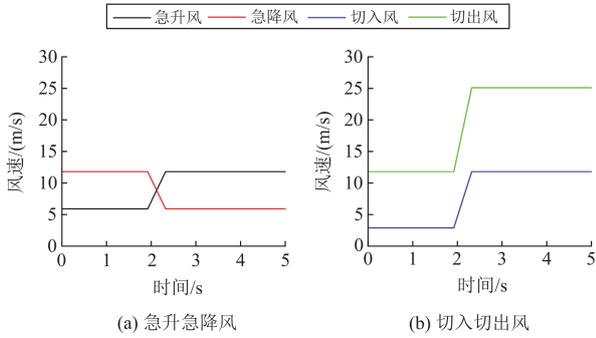


图 10 风机极端工况的风速

Fig. 10 Wind speed of the wind turbine under extreme conditions

本文将 3.1 节中的工况命名为工况 1，将图 10(a)中的工况命名为工况 2，图 10(b)中的工况命名为工况 3。在采集样本时，除风机风速不同外，其余条件与 3.2 节相同，工况 2 共生成 14 688 个样本，其中稳定样本 10 135 个，失稳样本 4553 个；工况 3 共生成 14 688 个样本，其中稳定样本 9841 个，失稳样本 4847 个，将这 3 种数据集输入到本文所提模型中，其在 3 种不同工况下的评价结果如图 11 所示，评价指标见表 4。

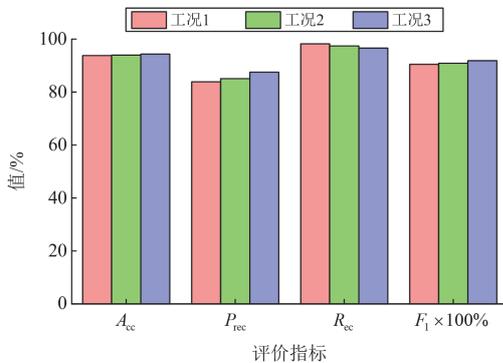


图 11 不同工况下的评价结果

Fig. 11 Evaluation results under different conditions

表 4 不同工况下的评价指标

Table 4 Evaluation metrics under different conditions				
工况	$A_{cc}/\%$	$P_{rec}/\%$	$R_{cc}/\%$	F_1
1	93.78	83.86	98.19	0.9046
2	93.92	85.10	97.44	0.9085
3	94.33	87.48	96.63	0.9183

由图 11 和表 4 所示，工况 1—工况 3 的 A_{cc} 、 R_{cc} 相差不大，只有工况 3 的 P_{rec} 明显大于工况 1 和工况 2，可能是由于失稳样本的增多使得模型不易发生误判失稳的情况。从整体来看，模型在风机不同的工况下准确率 A_{cc} 在 94% 左右，召回率 R_{cc} 在 97% 左右，该含风电的电力系统暂态稳定评估模型对于系统暂态稳定的评估准确率以及失稳状态的预测可靠度，均具备很好的鲁棒性能。

4 结论

本文针对含风电的电力系统暂态稳定评估问题提出了一种 WRCNNA 的暂态稳定评估方法。本文通过 PSASP 软件仿真生成训练样本并在含风机的 IEEE10 机 39 节点以及 54 机 118 节点系统上进行算例分析验证该模型，其在不同噪声、不同分类阈值、不同工况的情况下进行分析，得到以下结论：

1) 相较于 CNNA、TCN、Bi-LSTM 等主流模型，本文提出的 WRCNNA 模型的准确率受噪声的影响最小，且在 1.0% 信噪比的情况下仍然有较高的准确率；

2) 通过提高模型的分类阈值，大幅减少了“误判稳定”的发生，提高了失稳样本召回率进而提高了模型可靠性，符合暂态稳定评估实际使用要求；

3) 该含风电的电力系统暂态稳定评估模型具有很好的鲁棒性，体现在对系统暂态稳定的评估准确率以及对失稳状态预测的可靠度两方面。

此外，本文还对所提模型在 IEEE39 节点系统与 IEEE118 节点系统中的性能进行了比较。相较于 39 节点系统，由于 118 节点系统的结构更复杂、风电接入节点更多，模型在 118 节点系统中的准确率略有下降，但召回率更高，体现出所提方法在不同规模系统中具有良好的适应性，并在大规模电力系统中依然保持评估可靠性。

后续研究将探讨风电渗透率变化对模型泛化能力的影响，并重点考察模型在系统拓扑结构变化下的鲁棒性评估问题。

参考文献

[1] 龙潇, 张晋宾, 陈令特. 未来能源技术展望[J]. 发电技术, 2025, 46(4): 651-693.

- LONG Xiao, ZHANG Jinbin, CHEN Lingte. Prospects for future energy technologies[J]. *Power Generation Technology*, 2025, 46(4): 651-693.
- [2] 李振兴, 崔丹阳, 胡聪, 等. 大规模风电接入场景下的失步振荡中心定位方法[J]. *电力系统保护与控制*, 2024, 52(14): 1-12.
- LI Zhenxing, CUI Danyang, HU Cong, et al. Out-of-step oscillation center location method in a large-scale wind power integration scenario[J]. *Power System Protection and Control*, 2024, 52(14): 1-12.
- [3] ZHAO S, SHAO C, DING J, et al. Unreliability tracing of power systems for identifying the most critical risk factors considering mixed uncertainties in wind power output[J]. *Protection and Control of Modern Power Systems*, 2024, 9(5): 96-111.
- [4] 陈阔海, 彭乔, 刘天琪, 等. 考虑电压恢复的风电系统改进分段协调频率控制[J]. *电力工程技术*, 2025, 44(2): 160-171, 196.
- CHEN Yuehai, PENG Qiao, LIU Tianqi, et al. Improved piecewise coordinated frequency control of wind power generation system considering voltage restoration[J]. *Electric Power Engineering Technology*, 2025, 44(2): 160-171, 196.
- [5] 刘颂凯, 龚潇, 杨超, 等. 结合更新机制的电力系统暂态稳定评估研究[J]. *电力科学与技术学报*, 2025, 40(2): 1-9.
- LIU Songkai, GONG Xiao, YANG Chao, et al. Transient stability assessment of power system in combination with update mechanism[J]. *Journal of Electric Power Science And Technology*, 2025, 40(2): 1-9.
- [6] 王曼, 周小雨, 陈凡, 等. 融合 MHA 与 Boruta 的电力系统暂态功角稳定关键特征筛选[J]. *电力工程技术*, 2025, 44(1): 155-164.
- WANG Man, ZHOU Xiaoyu, CHEN Fan, et al. Fusion of MHA and Boruta for key feature selection in power system transient angle stability[J]. *Electric Power Engineering Technology*, 2025, 44(1): 155-164.
- [7] 姜力杨, 盖晨昊, 齐航, 等. 数据驱动的电力系统动态安全评估研究综述[J]. *山东电力技术*, 2024, 51(4): 27-35.
- JIANG Liyang, GAI Chenhao, QI Hang, et al. Review on data-driven dynamic security assessment of power systems[J]. *Shandong Electric Power*, 2024, 51(4): 27-35.
- [8] 胡伟, 郑乐, 闵勇, 等. 基于深度学习的电力系统故障后暂态稳定评估研究[J]. *电网技术*, 2017, 41(10): 3140-3146.
- HU Wei, ZHENG Le, MIN Yong, et al. Research on power system transient stability assessment based on deep learning of big data technique[J]. *Power System Technology*, 2017, 41(10): 3140-3146.
- [9] SHRIVASTAVA D, SIDDIQUI S, VERMA K. New data driven scheme for real-time power system transient stability assessment[J]. *Journal of Electrical Engineering & Technology*, 2023, 18(3): 1745-1756.
- [10] KUMKRATUG P, LAOHACHAI P. Direct method for transient stability assessment of a power system with a SSSC[J]. *Journal of Computers*, 2007, 2(8): 77-82.
- [11] YAN R, GENG G, JANG Q, et al. Fast transient stability batch assessment using cascaded convolutional neural networks[J]. *IEEE Transactions on Power Systems*, 2019, 34(4): 2802-2813.
- [12] HONG C, HUANG R, CHEN L, et al. Towards accurate and efficient classification of power system contingencies and cyber-attacks using recurrent neural networks[J]. *IEEE Access*, 2020, 8: 123297-123309.
- [13] SHAO Z, WANG Q, CAO Y, et al. A novel data-driven LSTM-SAF model for power systems transient stability assessment[J]. *IEEE Transactions on Industrial Informatics*, 2024, 20(7): 9083-9097.
- [14] 齐放. 基于一维卷积神经网络的电力系统暂态稳定在线评估[J]. *四川电力技术*, 2021, 44(4): 38-42, 89.
- QI Fang. Online transient stability assessment of power system based on one-dimensional convolutional neural network[J]. *Sichuan Electric Power Technology*, 2021, 44(4): 38-42, 89.
- [15] SHI W, LIU X, WU J, et al. Power system transient stability prediction using attention-based hybrid neural network[J]. *Applied Energy*, 2020, 279.
- [16] BOGODOROVA T, OSIPOV D, CHOW J. Misclassification prediction for transient stability assessment[J]. *IEEE Transactions on Power Systems*, 2024, 39(6): 7429-7432.
- [17] 李嘉敏, 杨红英, 闫莉萍, 等. 样本不平衡情况下的电力系统暂态稳定集成评估方法[J]. *电力系统自动化*, 2021, 45(10): 34-41.
- LI Jiamin, YANG Hongying, YAN Liping, et al. Integrated assessment method for transient stability of power system under sample imbalance[J]. *Automation of Electric Power Systems*, 2021, 45(10): 34-41.
- [18] SHI H, LI M, XU Y, et al. Transient stability assessment using imbalanced learning with attention and resampling strategies[J]. *Applied Energy*, 2023, 331.
- [19] MENEZES T, BARRA P, DIZIOLI F, et al. A survey on the application of phasor measurement units to the protection of transmission and smart distribution systems[J]. *Electric Power Components and Systems*, 2024, 52(8): 1379-1396.
- [20] ZHOU Z, WANG L, SUN Y, et al. A hybrid deep learning framework for power system stability classification with noise-robust features[J]. *Electric Power Systems Research*,

- 2023, 213.
- [21] 王雁红. 基于改进卷积神经网络的电力系统暂态稳定评估[D]. 昆明: 昆明理工大学, 2020.
WANG Yanhong. Transient stability assessment of power systems based on improved convolutional neural networks[D]. Kunming: Kunming University of Science and Technology, 2020.
- [22] 王凯. 基于深度卷积神经网络的电能质量扰动识别方法研究[D]. 大庆: 东北石油大学, 2023.
WANG Kai. Research on power quality disturbance identification method based on deep convolutional neural network[D]. Daqing: Northeast Petroleum University, 2023.
- [23] TREISMAN A, GELADE G. A feature-integration theory of attention[J]. *Cognitive Psychology*, 1980, 12(1): 97-136.
- [24] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 27-30, 2016, Las Vegas, NV, USA: 770-778.
- [25] LEE J. Digital image enhancement and noise filtering by use of local statistics[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1980, 2(2): 165-168.
- [26] 李楠, 张帅, 胡禹先, 等. 一种基于深度自适应网络迁移的暂稳评估模型更新框架[J]. *电力系统保护与控制*, 2024, 52(14): 25-35.
LI Nan, ZHANG Shuai, HU Yuxian, et al. An updating framework of a model for transient stability assessment based on a deep adaptive network transfer[J]. *Power System Protection and Control*, 2024, 52(14): 25-35.
- [27] 程静, 苏乐, 岳雷. 双馈风电并网系统的宽频振荡机理分析与抑制[J]. *电力系统保护与控制*, 2023, 51(12): 1-13.
CHENG Jing, SU Le, YUE Lei. Mechanism analysis and suppression of broadband oscillation in a DFIG wind power grid-connected system[J]. *Power System Protection and Control*, 2023, 51(12): 1-13.
- [28] 彭聪, 黄官兵, 黄伏林, 等. 高比例可再生能源集成下的新型电力系统频率稳定性分析[J]. *电子元器件与信息技术*, 2024, 8(1): 154-156, 166.
PENG Cong, HUANG Guanbing, HUANG Fulin, et al. Frequency stability analysis of the new power system under the integration of high proportion of renewable energy[J]. *Electronic Components and Information Technology*, 2024, 8(1): 154-156, 166.
- [29] 李国庆, 刘先超, 辛业春, 等. 含高比例新能源的电力系统频率稳定研究综述[J]. *高电压技术*, 2024, 50(3): 1165-1181.
LI Guoqing, LIU Xianchao, XIN Yechun, et al. Research on frequency stability of power system with high penetration renewable energy: a review[J]. *High Voltage Engineering*, 2024, 50(3): 1165-1181.
- [30] 刘瑶. 计及新能源出力及负荷不确定性的交直流混联电网安全稳定评估研究[D]. 南京: 东南大学, 2019.
LIU Yao. Study on safety and stability assessment of AC/DC hybrid power grid considering the uncertainty of loads and new energy generator outputs[D]. Nanjing: Southeast University, 2019.
- [31] 高昆仑, 杨帅, 刘思言, 等. 基于一维卷积神经网络的电力系统暂态稳定评估[J]. *电力系统自动化*, 2019, 43(12): 18-26.
GAO Kunlun, YANG Shuai, LIU Siyan, et al. Transient stability assessment for power system based on one-dimensional convolutional neural network[J]. *Automation of Electric Power Systems*, 2019, 43(12): 18-26.
- [32] MACHOWSKI J, BIALEK J, BUMBY J. Power system dynamics and stability[M]. New York: John Wiley & Sons, 1997.
- [33] VITTAL V, MCCALLEY J, ANDERSON P, et al. Power system control and stability[M]. New York: John Wiley & Sons, 2019.
- [34] HE M, VITAL V, ZHANG J. Online dynamic security assessment with missing PMU measurements: a data mining approach[J]. *IEEE Transactions on Power Systems*, 2013, 28(2): 1969-1977.
- [35] 刘珂, 顾雪平, 白岩松, 等. 考虑风电不确定性的电力系统在线动态分区恢复优化方法[J]. *电力系统保护与控制*, 2024, 52(19): 60-73.
LIU Ke, GU Xueping, BAI Yansong, et al. Online dynamic partition restoration optimization method of a power system considering wind power uncertainty[J]. *Power System Protection and Control*, 2024, 52(19): 60-73.
- [36] 张静, 毕天姝, 刘灏. 电力系统状态估计精度综合评价与分析体系[J]. *电力系统保护与控制*, 2024, 52(20): 12-24.
ZHANG Jing, BI Tianshu, LIU Hao. A comprehensive evaluation and analysis system for accuracy of power system state estimation[J]. *Power System Protection and Control*, 2024, 52(20): 12-24.
- [37] SAUER P, PAI M. Power system dynamics and stability[M]. New York: John Wiley & Sons, 1998.

收稿日期: 2025-03-01; 修回日期: 2025-09-07

作者简介:

刘伟(1971—), 男, 通信作者, 教授, 研究方向为电力系统分析与智能控制、智能监测与诊断系统; E-mail: 442780146@qq.com

胡歆岳(1998—), 男, 硕士, 研究方向为电力系统及其自动化。E-mail: 543826786@qq.com

(编辑 张颖)