

基于 1D-SE-ResNet 的含风电电力系统动态分区惯量评估

徐艳春^{1,2}, 任建新^{1,2}, 宋文字³, 席磊^{1,2}, MI Lu⁴

(1. 湖北省输电线路工程技术研究中心(三峡大学), 湖北 宜昌 443002; 2. 三峡大学电气与新能源学院, 湖北 宜昌 443002; 3. 国网湖北省电力有限公司武汉供电公司洪山供电中心, 武汉 430000; 4. 德克萨斯农工大学电气与计算机工程系, 美国 德州 77843)

摘要: 随着风电机组渗透率的提高, 电力系统惯量水平逐年下降。同时, 频率响应存在分区特性, 以区域为单位评估电力系统惯量更加灵活和准确。因此, 提出了一种基于一维压缩激励残差神经网络(one-dimensional squeeze and excitation residual neural network, 1D-SE-ResNet)的系统动态分区惯量评估方法。首先, 计算频率曲线趋势和数值近似距离, 采用 k-means 聚类方法对系统进行动态分区并由 S-C 指标确定分区数量。然后, 通过增加压缩和激励模块对一维残差神经网络进行改进, 为每个通道提供权重从而提升网络性能, 采集系统不同惯量水平和负荷扰动下的区域簇中心节点频率和频率变化率数据作为一维特征输入, 区域有效惯量为输出, 训练网络实现区域惯量评估。最后, 在含风电的 IEEE 39 和 IEEE 118 系统上进行仿真。结果表明, 在动态分区的基础上, 训练好的 1D-SE-ResNet 可实现区域惯量的准确评估。

关键词: 频率响应特性; 系统分区; 分区惯量; 一维压缩激励残差神经网络; 惯量评估

Dynamic Partition Inertia Estimation of Power System Containing Wind Power Based on 1D-SE-ResNet

XU Yanchun^{1,2}, REN Jianxin^{1,2}, SONG Wenyu³, XI Lei^{1,2}, MI Lu⁴

(1. Hubei Provincial Engineering Technology Research Center of Transmission Line, China Three Gorges University, Yichang, Hubei 443002, China; 2. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang, Hubei 443002, China; 3. Wuhan Power Supply Company Hongshan Power Supply Center, State Grid Hubei Electric Power Co., Ltd., Wuhan 430000, China; 4. Department of Electrical and Computer Engineering, Texas A&M University, Texas 77843, USA)

Abstract: As the penetration rate of wind turbines increases, the power system inertia level decreases year by year. At the same time, the frequency response has partition characteristics, and it is more flexible and accurate to evaluate the power system inertia in terms of region. Therefore, a dynamic partition inertia estimation method is presented based on one-dimensional squeeze and excitation residual neural network (1D-SE-ResNet). Firstly, the trend and value approximation of frequency distance are computed, and the k-means clustering method is used to dynamically partition the system and the number of partitions is determined by the S-C metric. Then, the 1D-ResNet is improved by adding the squeeze and excitation module, which enables it to provide weights for each channel to enhance the network performance. The regional cluster centre node frequency and frequency change rate data under different inertia levels and load perturbations of the system are collected as one-dimensional feature inputs, and the regional effective inertia is the output, training the network to achieve regional inertia estimation. Finally, simulations are carried out on the IEEE 39-node and IEEE 118- node systems containing wind power. The results show that the trained 1D-SE-ResNet can achieve accurate evaluation of regional inertia based on dynamic partitioning.

Key words: frequency response characteristics; system partitioning; partition inertia; 1D-SE-ResNet; inertia assessment

基金项目: 国家自然科学基金资助项目(52277108)。

Foundation item: Supported by the National Natural Science Foundation of China (52277108).

0 引言

“双碳”目标的提出使得新能源机组装机容量进一步增长,此类机组经过电力电子变换器接入电网,在系统动态过程中表现出无惯量或者弱惯量的外特性^[1-4]。电力系统惯量水平正在逐渐下降,系统惯性评估引起了电力行业和学术界的广泛关注。另外,电力系统频率响应具有分区特性,且分区结果受系统运行状态和功率扰动位置影响并非一成不变。因此,动态分区评估含风电系统等效惯量对提升新能源消纳与构建新型电力系统等方面有重要意义。从考虑系统频率响应的分区方法和惯量评估方法两方面均开展了相关研究工作。

在系统分区方面,文献[5-6]都是基于发电机同调性的分区方法,但此类方法未考虑新能源机组,随着新能源机组的增多,该方法实际应用受限。文献[7]将振荡特性相似且距离较近的母线分为同一区域,但所提算法未能完全程序化运行。文献[8]仅考虑系统内各节点间的电气距离,采用谱聚类算法实现系统分区,未考虑系统受扰动后潮流变化的影响。频率响应分区情况不仅与机组频率响应特性和电网结构参数有关,还受扰动类型和位置影响^[9],以上分区方法都未考虑扰动位置的变化,只能得到固定的分区方案,难以确保分区结果满足系统可能发生的各种扰动和运行工况。因此,文献[9]提出一种基于频率曲线之间动态时间弯曲(dynamic time warping, DTW)距离的系统实时分区方法,指出动态变更分区结果的重要性,但DTW距离在实际应用时易发生病理性扭曲现象,且时间复杂度高^[10],所得动态分区结果可能会出现错误。

在惯量评估方面,部分文献以负荷侧、节点侧或风电场侧为切入点评估惯量,而大多数研究是基于系统层面的惯量评估,主要有如下3种方法:基于大扰动的评估方法^[11-12]、基于小扰动的评估方法和基于准稳态的评估方法。大扰动评估方法通过计算有功功率偏差和频率变化率的比值来估计系统惯量,但系统内大扰动事件不常发生,无法及时准确获取系统惯量信息。小扰动方法依靠机电暂态的响应特性与系统惯量之间的联系实现惯量评估,文献[13]利用非侵入信号,采用滚动时域估计评估系统的惯量;文献[14]通过电力电子设备施加微小扰动

采用闭环辨识算法评估系统惯量;但这些方法易受系统运行和噪声的影响,造成结果不准确。基于准稳态的方法能够利用类噪声信号或运行中的功率波动时间评估系统惯量,文献[15-16]分别利用自动回归滑动平均模型和输出误差模型辨识系统惯量,然而这些方法依赖相当复杂的模型。文献[17]使用马尔可夫-高斯方法估计系统惯量,提供了一种采用无模型的数据驱动方法估计惯量的思路;文献[18-19]分别提出基于人工神经网络(artificial neural network, ANN)和卷积神经网络(convolutional neural network, CNN)的惯性估计方法;但上述网络泛化性能差,只应用于小型系统。

风电机组并网一方面造成了系统低惯量和惯量分布不均的问题,另一方面也丰富了系统的惯量来源,使得各区域惯量响应过程更为复杂。风机虚拟惯量处于动态变化之中,量化较为困难,增加了评估的难度^[20]。上述惯量评估方法精度有待提高且较少计及风机虚拟惯量,为更加准确地评估含风电系统区域惯量,揭示电网惯量区域分布,指导风电接入比例和提高系统安全稳定运行,亟须提出更好的方法。

近年来,深度学习(deep learning, DL)在电力系统稳定控制、源荷预测和故障诊断等方面已有诸多应用^[21-22],成为了解决电力系统复杂问题的有效工具之一。关于DL是否适用于惯量评估需从必要性和可实现性两方面论述:1)运行方式、扰动信息和频率响应模式之间的数学关系是频率问题分析的根本。然而,对多机复杂电力系统,此物理关系难以在数学上直接描述,建模难度大^[23]。面对风电并网、扰动多样性和频率时空分布特性等海量信息,传统方法有诸多局限,而DL因其优异的拟合和泛化能力,可以脱离复杂的等值模型,从数据角度挖掘惯量评估问题潜在的相关因素,非常适用于求解惯量评估这种复杂的非线性问题。2)目前以通信技术和同步相量测量单元(phasor measurement units, PMU)为基础的广域量测系统(wide area measurement system, WAMS)能够同步采集测量节点数据,具有时间同步性高、更新周期短和测量精度高等优点,可为DL提供数据支持,加速了DL在电力系统中的应用。

鉴于上述分区和惯量评估方法的不足,结合DL的诸多优点,本文主要工作如下:1)分析频率

响应的时空分布特性,引入频率曲线趋势和数值近似(trend and value approximation of frequency, TVA-F)距离对系统进行动态分区;2)对一维残差神经网络(one-dimensional residual network, 1D-ResNet)进行改进,提出了一种基于一维压缩激励残差神经网络(one-dimensional squeeze and excitation residual network, 1D-SE-ResNet)的动态分区惯量评估方法;3)对含风电的IEEE 39和IEEE118系统进行动态分区并生成数据集训练1D-SE-ResNet,利用训练好的模型评估区域惯量并进行了方法对比和模型泛化性验证。

1 电力系统惯量理论

1.1 同步机组有效旋转机械惯量

传统电力系统中,惯量主要由同步机组提供,当系统发生有功功率波动时,有功功率不平衡导致转子转速变化,转子吸收或释放储存的动能,进而引起系统频率变化。通常低频减载和高频切机装置动作阈值分别为49 Hz和50.5 Hz^[24],为避免出现低频减载或高频切机影响可靠供电,同步机组只能释放或吸收从初始转速到允许转速限值的动能差额用于支撑系统惯量。因此,有学者根据系统允许频率限值提出同步机组有效旋转机械惯量的概念^[24],具体如式(1)所示。

$$E_G = \left| \frac{1}{2} J \omega_0^2 - \frac{1}{2} J \omega_{lim}^2 \right| = \frac{|\omega_0^2 - \omega_{lim}^2|}{\omega_n^2} H \cdot S_N \quad (1)$$

式中: E_G 为同步机组有效机械惯量, MW·s; J 为发电机的转动惯量, kg·m²; ω_n 为同步机组额定角速度, rad/s; ω_0 为初始转速; ω_{lim} 为同步机转速限值, 对应于频率的上限50.5 Hz或下限49 Hz; S_N 为发电机额定容量, MW; H 为同步机组惯量常数, s。

1.2 风电机组有效虚拟惯量

大规模风电并网降低系统惯量水平,恶化频率响应特性,为满足系统稳定运行的频率要求,国内外大多对风电机组施加虚拟惯量控制,保障含风电系统频率安全^[25-27]。施加虚拟惯量控制后的风机可参与系统频率调节,风机转子通过释放或吸收部分动能向系统发出或吸收功率。根据风机转子转速运行要求,为防止风机脱网,转速存在限值,上限1.3 p.u., 下限0.7 p.u., 因此在额定风速下风电机组可用有效虚拟惯量 E_w 为^[24]:

$$E_w = \left| \frac{1}{2} J_w \omega_r^2 - \frac{1}{2} J_w \omega_{r_lim}^2 \right| \quad (2)$$

式中: J_w 为风机转子转动惯量; ω_{r_lim} 为风机转子转速限制; ω_r 为风机运行转速。

1.3 含风电系统频率响应

风机接入系统后其虚拟惯量响应将提供频率主动支撑功能,含风电系统发生有功扰动,系统频率支撑由同步机组和风电机组协同完成。系统区域有效惯量包括同步机组机械惯量和风电机组虚拟惯量,具体如式(3)所示。

$$E_s = \sum_{i=1}^n E_{Gi} + \sum_{j=1}^m E_{wj} \quad (3)$$

式中: E_s 、 E_{Gi} 、 E_{wj} 分别为区域有效惯量、同步机组 i 的有效机械惯量和风电机组 j 的有效虚拟惯量; n 和 m 分别为区域内同步机组和风电机组数量。

图1以负荷突增为例说明含风电系统频率响应过程,其中, t_0 、 t_b 、 t_c 和 t_d 分别为扰动发生时刻、一次调频动作时刻、频率最低时刻和一次调频结束时刻; E_{gs} 和 E_{ws} 分别为同步机组和风电机组释放动能; ΔP_d 、 ΔP_e 和 ΔP_m 分别为负荷突增、电磁功率和机械功率; f 、 f_0 、 f_d 和 f_{min} 分别为系统频率、初始频率、一次调频启动频率和频率最低值。

$t_0 \sim t_c$ 阶段, $df/dt < 0$: t_0 时刻负荷突增 ΔP_d , 风机由于施加了虚拟惯量控制,将和同步机组一起承担不平衡功率,减缓频率跌落速度,此时频率变化率小于0,向系统中释放功率,减轻了同步机组动能需求。在频率降到 f_d 以下时,一次调频动作;

$t_c \sim t_d$ 阶段, $df/dt > 0$: 在此阶段,风机在虚拟惯量的控制下从系统中吸收功率,同步机组一次调频增发的部分机械功率被风机吸收。

风电机组通过附加控制虚拟输出的转动惯量与风机的固有惯量、初始转速及控制参数和系统频率变化密切相关,其惯量灵活可调,特性复杂多变,无疑增加了含风电系统惯量评估的难度。

2 考虑电力系统频率响应时空分布特性的动态分区方法

电力系统内部各节点频率变化率和频率响应延时两个指标反应了系统受扰动后的频率空间分布特性^[28],标准IEEE 39节点系统^[29]总发电功率为6 262 MW,节点7负荷突增200 MW时该系统各节




图1 含风电系统功率支撑与频率响应

Fig. 1 Power support and frequency response of power systems with wind power

点频率变化率和频率响应延时的分布情况如图2所示。




图2 IEEE 39节点系统频率变化率和频率响应延时空间分布

Fig. 2 Spatial distribution of frequency change rate and frequency response delay of IEEE 39-node system

由图2可知,距扰动较近的区域有更大的频率变化率和更低的频率响应延时,频率动态响应空间分布特性明显。随着系统运行状态和功率扰动位置的改变,频率变化率和频率响应延时的空间分布亦会发生变化,本文采用文献[30]中的方法综合考虑系统扰动后各区域频率变化率和频率响应延时两个指标计算 TVA-F 距离,运用 k-means 算法进行系统分区得到动态分区结果。该动态分区方法根据扰动

后频率响应曲线动态划分区域,适用于含风电电力系统,保证了各种运行工况下区域内频率响应的相似性,可有效减小频率响应分散应对后续区域惯量评估带来的影响。

3 基于 1D-SE-ResNet 的动态分区有效惯量评估方法

基于 DL 估计系统惯量属于回归问题,回归问题中各个输入之间的多重共线性会影响估计结果,文献[19]研究了系统扰动功率大小、惯量中心频率和频率变化率三者的相关性,指出扰动功率和频率之间具有较强的相关性,表明这二者中有一个是多余的。实际系统中扰动功率一般难以直接获取,因此可不考虑扰动功率,仅选择区域频率和频率变化率组成双通道一维数据作为模型输入,将区域惯量作为输出,运用 DL 来拟合二者之间的复杂非线性关系。

3.1 一维残差神经网络

传统二维残差神经网络 (two-dimensional residual network, 2D-ResNet) 最初用于图像识别,但近几年来许多研究^[31-32]表明 1D-ResNet 在处理序列数据时存在时间复杂度低,计算成本低参数较少等诸多优点。本文惯量评估方法需用到系统频率和频率变化率这类一维时序数据,1D-ResNet 可直接在一维时间序列上对其进行卷积操作,精准捕捉频率时序波动特征,识别系统惯量水平变化时不同区域的频率响应区别,达到区域惯量评估的目的。如果采用 2D-ResNet,则需采用一定的映射方式将一维频率数据强行转换为二维“图像”,在此过程中频率数据本身的连续性被打破,可能会弱化或丢失频率时域变化过程中的关键信息,同时也增加了额外的转换误差,因此从神经网络基本结构上来讲,一维神经网络更适用于本文惯量评估问题。

一维卷积神经网络 (one-dimensional convolutional neural networks, 1D-CNN) 利用一维卷积模块对频率序列进行特征提取,但 1D-CNN 的层数通常较浅。1D-ResNet 在 1D-CNN 的基础上引入残差连接,显著缓解了深层网络的梯度消失和爆炸的问题,使得网络可以加得更深^[33]。网络深度与参数数量的增加不仅扩大了对频率序列的感受野,还有助于提取更复杂、更高层次的频率特征并增强其表征能力。1D-ResNet 的核心是一维残差模块,包括卷积

层、批量归一化层、激活函数层和快捷连接,如图3所示。




图3 一维残差模块

Fig. 3 One-dimensional residual block

一维残差模块输入为 x , 经过两个一维卷积块后输出为 $L(x)$, 之后还应将前面的输入通过快捷连接共同作为下一单元输出, 则输出为:

$$F(x) = L(x) + x \quad (4)$$

此时, 中间堆叠层需拟合的函数为 $L(x)$, 由残差块结构可知 $L(x)$ 的表达式为:

$$L(x) = W_2 \sigma(W_1 x) \quad (5)$$

式中: W_1 和 W_2 分别表示第一、第二个一维卷积层的权重; σ 为ReLU激活函数。

3.2 改进一维残差神经网络

本文所提惯量评估方法本质上仍基于扰动事件, 根据现有文献以及电力系统扰动后惯量评估的理论与实践, 频率变化率对于挖掘系统惯量信息往往更为直接和敏感^[5, 34-35], 使得其在网络训练时具有更高的特征贡献度。在负荷扰动发生前, 电网频率往往并不严格维持在50 Hz, 而是在额定值附近小幅波动, 因此频率本身无法直接衡量不同惯量水平下的动态响应差异。虽重要程度不及频率变化率, 但频率数据依然是训练惯量评估模型时不可或缺的关键特征。

在训练网络进行惯量评估时, 适当增强高价值通道的表征信息并抑制无关的通道, 有助于引导网络更聚焦于关键特征, 从而提升模型稳定性、加快收敛速度, 并在最终的准确率与泛化能力上取得更佳表现^[36]。但1D-ResNet并没有明确地对不同通道特征之间的关系进行建模, 仍认为所有通道的重要性一致, 导致忽视某些关键信息。为了克服这一局限性, 引入一种轻量级通道注意力机制, 即压缩和激励(squeeze and excitation, SE)模块^[37], 将SE模块嵌入现有的一维残差模块中得到1D-SE-ResNet, 使用注意力机制以最小的计算成本为每个通道提供新的权重, 强化频率变化率通道特征对惯量评估的影响, 弱化频率通道特征, 以此来提高1D-ResNet

在惯量评估方面的性能, 改进后的一维残差模块如图4所示。




图4 改进一维残差模块

Fig. 4 Improved one-dimensional residual block

SE模块主要包括压缩和激励两个步骤, 输入首先经过一维残差模块得到特征 U , 通道数量为 c , 高为 h , 宽为1, 故形状表示为 $c \times h \times 1$ 。其中通道 a 上对应特征为 U_a , U_a 大小为 $h \times 1$, 压缩操作对每个通道上的整体信息进行挤压, 即利用全局平均池化将每个通道上特征压缩为 1×1 , 用此标量表示通道上的全局信息, 通道 a 的压缩过程如式(6)所示。

$$z_a = F_{sq}(U_a) = \frac{1}{h \times 1} \sum_{i=0}^h u_a(i) \quad (6)$$

式中: z_a 为通道 a 压缩后的标量信息; $F_{sq}(\cdot)$ 为压缩操作; $u_a(i)$ 为 U_a 内特征。

激励操作为每个通道分配权重, 这是通过全连接层(fully connected layer, FC)完成的, z 为经过压缩后的特征, 在其后面接两个全连接层, 并分别使用ReLU和Sigmoid激活函数, 激励过程如式(7)所示。

$$s = F_{ex}(z, W') = \delta(W'_2 \sigma(W'_1 z)) \quad (7)$$

式中: s 为经过激励操作后的特征; W' 为全连接层; $\delta(\cdot)$ 和 $\sigma(\cdot)$ 分别为Sigmoid和ReLU激活函数; W'_1 和 W'_2 分别为第一、第二个全连接层的权重。

通过激励获得新权重 s 后再与 U 相乘, 这样就为每一个通道施加了权重系数, 最后再与初始输入 x 建立快捷连接。在图4中以不同的颜色加以区分, 改进前每个通道的重要程度相同, 改进后每个通道的重要性发生改变, 蓝色越深的通道表示重要程度更高, 分配的权重更大, 越浅的通道则表示重要程度较低, 应该弱化。

3.3 基于1D-SE-ResNet的动态分区惯量评估流程

在大规模风电并网的背景下, 系统运行状态发

生改变,惯量水平降低且惯量分布不均,致使频率动态行为愈加复杂,对神经网络的选择带来很大影响。具体而言,面对系统存在的扰动多样性、频率时空分布、运行方式不确定性和风机虚拟惯量控制等多源信息,基于数据学习的智能算法想要取得更好的惯量评估结果需增大数据学习样本规模,同时提高特征提取质量。传统浅层神经网络对海量数据的特征提取能力受限,泛化能力差,对含风电系统下的复杂问题求解与分析较难适用,而本文所提的1D-SE-ResNet不仅采用了更深层的ResNet结构,而且加入了注意力机制SE模块进行改进,使其非常善于处理大规模数据,提取更深层次的特征,有效提升了模型对含风电系统动态特性的分析能力。

区域惯量评估主要分为离线训练和在线评估两个阶段,在离线训练阶段,采用PSASP进行系统功率扰动仿真,仿真步长为0.01 s,考虑到分区结果差异,对系统进行动态分区,汇总所有动态分区结果。因为区域簇中心节点与其他节点的相似度最大,因此选择各区域簇中心节点反应区域整体频率

动态特征^[8]。获取所有动态分区情况下各区域簇中心节点扰动后前2 s惯量响应期间的频率、频率变化率和有效惯量数据组成数据集训练1D-SE-ResNet网络。其中网络的输入是频率和频率变化率组成的双通道数据,因仿真步长为0.01 s,故每个通道都是一个200维的向量,输出为区域有效惯量值。在线评估阶段,通过仿真获取系统发生扰动后PMU配置节点频率数据并首先进行动态分区,然后将待评估区域簇中心频率和频率变化率数据输入训练好的1D-SE-ResNet便可直接获取区域有效惯量,整体实施框架如图5所示。

模型采用均方误差(mean square error, MSE)作为损失函数,采用适应性矩估计(adaptive moment estimation, ADAM)算法修正每个参数的学习率,使得网络参数较为平稳。评价指标选择平均绝对百分误差(mean absolute percentage error, MAPE)、均方根误差(root mean square error, RMSE)和平均绝对误差(mean absolute error, MAE),其计算公式分别如式(8)—(10)所示。




图5 动态分区惯量评估框架图

Fig. 5 Dynamic partitions inertia estimation framework diagram

$$M_{\text{APE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (8)$$

$$R_{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

$$M_{\text{AE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

式中: M_{APE} 为平均绝对百分误差; R_{MSE} 为均方根误差; M_{AE} 为平均绝对误差; n 为测试样本数量; y_i 和 $\hat{y}_i$ 分别为测试集中第 i 个惯量的真实值和估计值。

4 算例分析

4.1 IEEE 39 节点系统动态分区惯量评估

4.1.1 系统动态分区和数据集生成

在 PSASP 中搭建标准 IEEE 39 节点系统, 共有 10 台发电机和 46 条输电线路, 稳定频率 50 Hz。按照 PMU 配备准则^[38], 系统中节点集合 {2, 6, 10, 13, 16, 19, 20, 22, 23, 25, 26, 29, 39} 配备 PMU 观察频率变化。以系统中所有机组容量总和为基准计算, 系统整体惯量常数通常处于 4~10 s 之间^[19], 在标准 IEEE 39 节点系统中, 保持各发电机惯量常数之间比例不变, 同时更改各发电机惯量使得系统惯量常数从 4~10 s 增长, 步长为 0.5 s, 得到 13 种系统惯量水平。取系统频率下限 49 Hz, 按照式(1)计算得到各同步机组有效惯量如表 1 所示。

表 1 IEEE 39 节点系统同步机组参数及有效惯量

Tab. 1 Synchronous generator parameters and effective inertia of IEEE 39-node system

机组	额定容量/MW	惯量常数/s	有效惯量/(MW·s)
G01	10 000	10.00	3 960.00
G02	630	14.00	349.27
G03	680	14.00	376.99
G04	720	8.00	228.10
G05	510	8.00	161.57
G06	600	8.00	190.08
G07	630	8.00	199.58
G08	680	11.58	311.83
G09	900	7.00	249.48
G10	900	12.00	427.68

为模拟风电接入, 在上述系统较高惯量水平 8~10 s, 步长为 0.5 s 增长的过程中, 将 IEEE 39 节点系统中的发电机 G03、G05、G06 和 G08 替换为风电场 WF1、WF2、WF3 和 WF4 得到改进 IEEE 39 节

点系统的 5 种惯量水平, 新能源渗透率 36.09%, 双馈风机施加虚拟惯量控制, 取双馈风机转速下限 0.7 p. u., 按照式(2)计算得到单台风机有效虚拟惯量 0.963 9 MW·s, 由此可得各风电场有效虚拟惯量见表 2。共得到标准 IEEE 39 节点和改进 IEEE 39 节点系统的 18 种惯量水平情况。

表 2 改进 IEEE 39 节点系统风电场有效惯量

Tab. 2 Effective inertia of each wind farm in the improved IEEE 39-node system

节点	风电场	风机台数	额定容量/MW	有效惯量/(MW·s)
32	WF1	433	650	417.37
34	WF2	340	510	327.73
35	WF3	373	560	359.53
37	WF4	360	540	347.00

因为发电机惯量等比例改变, 所以相对于系统惯量水平和功率扰动大小而言, 扰动位置对分区影响较大^[9, 30], 考虑不同的扰动类型和位置, 在 18 种惯量水平情况下依次对所有负荷和发电机节点设置负荷突增或切机扰动并对系统进行分区, 发现在所有惯量水平下, 扰动大小不同但扰动位置相同时会有相同的分区结果。因此, 根据扰动位置不同在 IEEE 39 节点系统和改进 IEEE 39 节点系统中共得到 3 种动态分区结果, 下面详细介绍动态分区情况 1。

在原 IEEE 39 节点系统惯量常数为 10 s 时加入风电场得到改进 IEEE 39 节点系统, 设置系统内节点 24 负荷 0 s 时突增 200 MW, 仿真获取系统中各 PMU 配置节点 0~2 s 频率后, 利用第 2 节的分区算法对系统进行分区, 系统被分为 3 个区域。各区域内 PMU 节点分别为: 区域 1 {39}; 区域 2 {2, 6, 10, 13, 25, 26, 29}; 区域 3 {16, 19, 20, 22, 23}, 其中 k-means 聚类所得区域各簇中心点分别为 39、10、19。系统分区情况如图 6 所示, 各区域内 PMU 配置节点频率如图 7 所示。由图 7 可知, 系统内各区域频率曲线差别较大, 原因是不同区域间频率响应不同, 分区算法可将相似性较高的频率曲线分到同一区域, 同时使得不同区域间频率曲线差异尽可能的大, 分区结果正确。

通过数据分析分区结果, 表 3 给出了区域内部各节点和区域间节点的 TVA-F 距离平均值, 由表 3 可知, 区域内 TVA-F 距离较小, 同样表明区域内频




图6 改进 IEEE 39 节点系统动态分区情况 1

Fig. 6 The first dynamic partitioning scenario for the improved IEEE 39-node system




图7 改进 IEEE 39 节点各区域频率曲线

Fig. 7 Regional frequency curves of the improved IEEE 39-node system

率曲线相似性较高。相比之下, 区域间 TVA-F 距离较大, TVA-F 距离可正确度量各频率曲线之间的相似性。从获得频率数据后开始, 实测利用所提算法对改进 IEEE 39 节点系统进行单次分区所需时间为 0.048 s, 耗时很短, 可迅速给出各种动态分区结果。

表3 改进 IEEE 39 节点系统中各区域间 TVA-F 距离平均值

Tab. 3 Mean TVA-F distances between regions in the improved IEEE 39-node system

	区域1	区域2	区域3
区域1	0	12.35	12.89
区域2	12.35	0.53	5.16
区域3	12.89	5.16	0.32

各区域有效惯量按照式(3)计算, 得到改进 IEEE 39 节点系统此时各区域有效惯量为: 区域1, 3 960 MW·s; 区域2, 1 790.80 MW·s; 区域3,

1 114.94 MW·s。对其余 17 种惯量水平下重复实验进行分区, 结果均属于系统动态分区情况 1。

在上述 18 种惯量常数下分别对节点 25 和节点 8 设置负荷突增, 对应于动态分区情况 2 和 3, 所得分区结果见如图 8 所示, 系统仍被分为 3 个区域。由分区结果可知, 扰动位置发生改变后, 各区域频率响应也发生改变, 如仍采用之前的分区结果, 会导致区域内频率曲线有较大差别, 而动态分区可依据目前实测系统频率数据重新对系统进行分区, 归类到正确的动态分区情况, 确保区域内频率响应的相似性。




图8 改进 IEEE 39 节点系统动态分区情况 2 和 3

Fig. 8 The second and third dynamic partitioning scenarios for the improved IEEE 39-node system

数据集的质量对网络训练的好坏有较大影响, 为提高数据集的丰富性, 提取重要相关信息, 在 3 种动态分区情况下分别生成数据。对于分区情况 1, 在上述 IEEE 39 节点和改进 IEEE 39 节点系统的 18 种惯量水平下, 0 s 时在节点 24 设置负荷突增扰动, 变化范围是从总负荷的 1 % 变化到 10 %, 步长为 0.09 %, 共得到 1 800 组仿真结果, 所有仿真中系统仍保持频率稳定, 低频减载未动作, 频率变化率 (rate of change of frequency, RoCoF) 满足系统要求。获取扰动后 0~2 s 内获得 3 个区域簇中心点频率和频率变化率信息, 共得到 5 400 组数据。对于动态分区情况 2 和 3, 分别在节点 25 和节点 8 负荷处重复实验, 也得到 5 400 组数据。汇总 3 种动态分区情况, 共得到 16 200 组区域簇中心频率、频率变化率数据和相对应的区域有效惯量数据用于模型训

练和测试。

4.1.2 模型训练

将所得的16 200组数据进行最大最小归一化,压缩到 $[0, 1]$ 之间并按照6:2:2划分训练集、验证集和测试集。本文深度学习网络模型基于Python中的PyTorch框架实现,设置模型迭代次数为200次,在训练前对网络进行初始化,学习率为0.000 1,批量为256。模型迭代过程中训练集和验证集的损失函数如图9所示,由图9可知,在迭代200次后模型达到收敛,训练集和验证集上损失函数分别降至98.79和276.41。图10展示了训练集和测试集上准确率随迭代次数的变化,最终训练集和验证集准确率分别为99.49%和99.09%。模型训练完成且没有出现欠拟合和过拟合。




图9 损失函数曲线

Fig. 9 The curves of loss function




图10 区域有效惯量评估准确率

Fig. 10 Effective inertia assessment accuracies in the region

4.1.3 不同网络对比实验

为验证1D-SE-ResNet的优越性,选择常用的多层感知机(multilayer perceptron, MLP)、1D-CNN和1D-ResNet与本文1D-SE-ResNet进行对比。在训练数据和环境相同的情况下,各网络训练损失函数和准确率对比如图11—12所示。由图11—12可知,由于MLP网络较为简单,在处理复杂数据时拟合能力不足,其损失函数下降和准确率提升

过程均差于其他网络。随着模型结构复杂化及层数的加深,1D-CNN和1D-ResNet具有更高级的特征提取能力,表现出较好的性能。特别是引入通道注意力后的1D-SE-ResNet损失值最低、准确率最高,并且与改进前的1D-ResNet相比,改进后网络可实现重标定通道特征,有效增强了网络对重要通道特征的响应能力,在区域有效惯量评估任务中展现出最佳性能。




图11 损失函数曲线对比

Fig. 11 Comparison of loss function curves




图12 区域有效惯量评估准确率对比

Fig. 12 Comparison of effective inertia assessment accuracies in the region

下面对比各个模型在测试集上的表现,测试集样本总数3 240,图13展示了各个模型在测试集上区域有效惯量评估结果相对误差分布情况。由图13可知,在测试集区域惯量评估结果相对误差小于等于1%的区间内,1D-SE-ResNet分布的数量最多,表明其区域惯量评估精度最高,网络泛化性最好,并且随着相对误差的提高,分布数量迅速下降,所有样本的相对误差都分布于小于等于5%以内,测试集误差分布情况明显优于其他网络。MLP网络测试集相对误差的分布并没有集中于小于1%的范围,而是更加分散,最终图中统计的相对误差小于等于5%的样本数量仅占总样本的70.4%,其区域惯量评估准确率最低,模型泛化性能最差。




图 13 区域有效惯量评估结果相对误差分布

Fig. 13 Distribution of relative errors in regional effective inertia assessment results

4 个模型在测试集合上的 MAPE、RMSE 和 MAE 评价指标和 1D-SE-ResNet 相对于其他各模型在评价指标方面的下降百分比如表 4 所示, 综合各指标分析可知, 本文所提基于 1D-SE-ResNet 的惯量评估值与真实值拟合程度更好, 在 IEEE 39 节点系统和改进 IEEE 39 节点系统上有更准确的区域惯量估计结果。

表 4 不同网络惯量评估结果

Tab. 2 Inertia evaluation results of different networks

网络	$M_{APE}/\%$	降低比例/%	$R_{MSE}/$ (MW·s)	降低比例/%	$M_{AE}/$ (MW·s)	降低比例/%
MLP	5.73	90.58	132.84	92.68	73.93	90.41
1D-CNN	2.05	73.66	38.41	74.69	24.77	71.38
1D-ResNet	1.07	49.53	24.45	60.25	16.42	56.82
1D-SE-ResNet	0.54		9.72		7.09	

4.2 IEEE 118 节点系统动态分区惯量评估

4.2.1 系统动态分区和数据集生成

在大系统上继续仿真, 标准 IEEE 118 节点系统参数见文献[39]。在 PSASP 中搭建标准 IEEE 118 节点系统, 根据 PMU 配备准则^[38], 系统中共有 43 个节点配备 PMU 观察频率。保持各发电机惯量常数之间比例不变, 同时更改各发电机惯量使得系统惯量常数从 4~10 s 增长, 步长为 0.5 s, 得到 13 种系统惯量水平。在上述系统较高惯量水平 8~10 s, 步长为 0.5 s 增长的过程中, 将 IEEE 118 节点系统中的部分发电机替换为风电场得到改进 IEEE 118 节点系统的 5 种惯量水平, 新能源渗透率 20.98%, 共得到标准 IEEE 118 节点和改进 IEEE 118 节点系统的 18 种惯量水平情况。根据扰动位置不同在 IEEE 118 节点系统和改进 IEEE 118 节点系统中共

得到 3 种动态分区结果, 在 3 种动态分区情况下分别生成数据集, 共得到 21 600 组数据。

4.2.2 模型训练

将所得的 21 600 组数据按相同处理方法划分训练集、验证集和测试集。设置模型迭代次数为 200 次, 学习率为 0.000 1, 批量为 256。训练 1D-SE-ResNet, 在迭代 200 次后模型收敛, 训练集和验证集上损失函数分别降至 99.28 和 173.37。最终训练集和验证集准确率分别为 99.38% 和 99.16%, 模型训练完成。

4.2.3 不同网络对比实验

依旧选择常用的 MLP、1D-CNN 和 1D-ResNet 与本文 1D-SE-ResNet 进行对比, 分析结果可知, 1D-SE-ResNet 仍然表现最好, 拥有最低的损失函数和最高的准确率, 在区域惯量评估方面有更大的优势, 进一步证明了本文改进方法的有效性。

对比各个模型在测试集上的表现, 测试集样本数量为 4 320, 分析各模型在测试集上惯量评估相对误差的分布情况可知, 1D-SE-ResNet 依旧优于其他网络。各个模型在测试集上的 MAPE、RMSE 和 MAE 评价指标和 1D-SE-ResNet 相对于其他各模型在评价指标方面的下降百分比如表 5 所示。

表 5 不同网络惯量评估结果

Tab. 5 Inertia evaluation results of different networks

网络	$M_{APE}/\%$	降低比例/%	$R_{MSE}/$ (MW·s)	降低比例/%	$M_{AE}/$ (MW·s)	降低比例/%
MLP	6.43	93.16	44.88	91.62	30.85	91.80
1D-CNN	2.13	79.34	18.09	79.21	11.63	78.25
1D-ResNet	0.78	43.59	6.85	45.11	4.51	43.90
1D-SE-ResNet	0.44		3.76		2.53	

由表 5 中可知, 1D-SE-ResNet 相对于其他网络的评价指标都有明显下降, 在 IEEE 118 节点系统和改进 IEEE 118 节点系统上也有更准确的区域惯量估计结果, 可以很好地适用于较大网络惯量评估。

4.3 网络泛化性验证

4.3.1 负荷波动节点变化时网络泛化性验证

为模拟惯量评估实际情况, 使用未经训练的数据进一步验证模型的泛化性, 在有风机接入的改进 IEEE 39 节点系统中设置其他节点负荷波动, 分别考虑 3 种动态分区情况评估区域有效惯量。在节点

21 设置负荷突增, 大小为从总负荷的 1% 变化到 10 %, 步长为 0.09 %, 获取 100 组频率数据。在每次功率扰动测得频率数据后首先利用动态分区算法对系统进行分区并找到区域簇中心, 结果均属于动态分区情况 1。将各区域簇中心的频率和频率变化率数据输入 4.1 节训练好的网络, 对每个区域进行 100 次有效惯量评估得到平均值, 并计算其与真实值之间的误差。在节点 28、节点 4 重复上述试验, 结果分别属于动态分区情况 2 和 3, 每种动态分区下区域惯量评估结果的平均值和误差汇总如表 6 所示。

表 6 改进 IEEE 39 节点系统区域有效惯量评估结果

Tab. 6 Regional effective inertia evaluation results in the improved IEEE 39-node system

分区	有效惯量	区域 1	区域 2	区域 3
动态分区 1	真实值/(MW·s)	3 960.00	1 790.80	1 114.94
	估计值/(MW·s)	3 874.09	1 755.61	1 161.36
	误差/%	2.19	1.97	4.17
动态分区 2	真实值/(MW·s)	3 960.00	1 024.16	1 881.58
	估计值/(MW·s)	3 899.83	966.65	1 968.67
	误差/%	1.52	5.60	4.63
动态分区 3	真实值/(MW·s)	3 960.00	766.64	2 139.10
	估计值/(MW·s)	3 815.54	737.43	2 077.12
	误差/%	3.65	3.81	2.90

表 6 可知, 本文所提基于 1D-SE-ResNet 的动态分区惯量评估方法在未经训练的数据上依旧表现良好, 各区域惯量评估误差在 1.97 %~5.60 % 之间, 网络泛化性较强, 可同时计及风电机组虚拟惯量实现各区域有效惯量的精确评估。

在有风机接入的改进 IEEE 118 节点系统中重复上述动态分区惯量评估实验, 在节点 14、58 和 94 设置负荷突增分别属于动态分区情况 1、2 和 3。运用 4.2 节训练好的网络进行惯量评估, 3 种动态分区下各区域惯量评估结果的平均值和误差汇总如表 7—9 所示。由区域惯量评估结果可知, 训练好的 1D-SE-ResNet 在改进 IEEE 118 节点系统未知数据集上依旧表现良好, 各区域惯量评估误差在 1.25 %~5.38 % 之间, 面对较大系统时各区域有效惯量评估精度仍满足实际应用需求。

4.3.2 风电机组变化时网络泛化性验证

对改进 IEEE 39 节点系统, 将风电机组 WF3 改为最大功率跟踪 (maximum power point tracking,

表 7 改进 IEEE 118 系统动态分区情况 1 有效惯量

Tab. 7 Effective inertia in the first dynamic partitioning scenario for the improved IEEE 118-node system

区域	有效惯量 真实值/(MW·s)	有效惯量 估计值/(MW·s)	误差/%
区域 1	682.11	665.32	2.9
区域 2	1 237.74	1 283.42	3.69
区域 3	1 338.45	1 304.79	2.51

表 8 改进 IEEE 118 节点系统动态分区情况 2 有效惯量

Tab. 8 Effective inertia in the second dynamic partitioning scenario for the improved IEEE 118-node system

区域	有效惯量 真实值/(MW·s)	有效惯量 估计值/(MW·s)	误差/%
区域 1	682.11	671.56	1.54
区域 2	283.24	294.65	4.02
区域 3	703.2	665.34	5.38
区域 4	360.99	377.61	4.6
区域 5	1 228.75	1 250.5	1.77

表 9 改进 IEEE 118 节点系统动态分区情况 3 有效惯量

Tab. 9 Effective inertia in the third dynamic partitioning scenario for the improved IEEE 118-node system

区域	有效惯量 真实值/(MW·s)	有效惯量 估计值/(MW·s)	误差/%
区域 1	682.11	673.58	1.25
区域 2	986.45	945.34	4.17
区域 3	525.54	546.07	3.91
区域 4	1 064.2	1 095.91	2.98

MPPT) 模式运行, 不再提供虚拟惯量, 在节点 24 重复上述负荷扰动, 得到动态分区结果 1 并评估各区域惯量, 结果汇总如表 10 所示。由表 10 可知, 风电机组变化导致区域 3 内有效惯量降低, 惯量评估误差较小。

表 10 改进 IEEE 39 节点系统区域有效惯量评估结果

Tab. 10 Regional effective inertia evaluation results in the improved IEEE 39-node system

区域	有效惯量 真实值/(MW·s)	有效惯量 估计值/(MW·s)	误差/%
区域 1	3 960.00	3 830.65	3.27
区域 2	1 790.80	1 695.53	5.32
区域 3	755.41	711.14	5.86

将改进 IEEE 118 节点系统中节点 113 的风电机组 WF2 改为 MPPT 运行模式, 对节点 18 重复上述

负荷扰动,得到动态分区结果 1 并评估各区域惯量,结果汇总如表 11 所示。

表 11 改进 IEEE 118 节点系统区域有效惯量评估结果
Tab. 11 Regional effective inertia evaluation results in the improved IEEE 118-node system

区域	有效惯量 真实值/(MW·s)	有效惯量 估计值/(MW·s)	误差/%
区域 1	617.53	588.74	4.66
区域 2	1 237.74	1 291.44	4.34
区域 3	1 338.45	1 296.67	3.12

由表 10—11 可知,经过大量数据训练得到的 1D-SE-ResNet 在对风电机组发生变化后的系统进行惯量评估时依旧表现出良好的准确性和泛化性。

4.4 方法对比与实际应用价值

本节对改进 IEEE 39 节点系统进行仿真,将本文方法与文献[8]中固定分区下的惯量评估方法进行对比。运用文献中的分区方法进行分区,结果与本文动态分区情况 1 相同。设置两种工况进行区域惯量评估:1)工况 1:节点 21 负荷突增 300 MW;2)工况 2:节点 28 负荷突增 300 MW,结果如表 12 所示。

表 12 不同分区下的有效惯量评估结果

Tab. 12 Regional effective inertia evaluation results under different partitioning scenarios

工况	有效惯量	区域 1	区域 2	区域 3
工况 1	真实值/(MW·s)	3 960.00	1 790.80	1 114.94
	估计值/(MW·s)	4 102.16	1 655.77	1 198.22
	误差/%	3.59	7.54	7.47
工况 2	真实值/(MW·s)	3 960.00	1 790.80	1 114.94
	估计值/(MW·s)	4 125.13	1 546.53	1 202.69
	误差/%	4.17	13.64	7.87

将表 12 中的工况 1 与表 6 动态分区情况 1 中的区域惯量评估结果进行对比,可知在相同分区结果下,本文惯量评估方法表现更好。区域惯量评估结果误差更小。在工况 2 下区域惯量评估结果误差增大,原因在于文献[8]使用固定分区方法仍沿用之前分区结果,但在扰动位置发生改变后各个区域频率动态发生了变化,此分区结果下区域内频率响应相似性较差,频率曲线分散性较大,运用区域频率数据评估惯量产生了较大误差,其中区域 2 受影响最严重,达到了 13.64%。而本文充分考虑扰动位

置的影响,在工况 2 下及时改变分区结果为动态分区情况 2,确保了各种工况下区域频率响应相似性,惯量评估结果如表 6 所示,误差处于 1.52%~5.60%之间,相比之下拥有更高准确度。

实际应用时可通过以下两种方法解决数据获取难题:1)事先通过软件对实际系统进行建模,仿真得到所需的数据集;2)汇总近年来系统内发生扰动时 PMU 测得的实际频率数据组成数据集。之后该惯量评估方法便有望用于工程实践。

5 结论

本文分析了含风电系统频率响应,在动态分区基础上提出了基于 1D-SE-ResNet 的惯量评估方法,并通过 IEEE 39 节点系统和 IEEE 118 节点系统验证了动态分区惯量评估的准确性。主要结论如下。

1)通过引入 SE 模块,改进后的 1D-SE-ResNet 能够更加关注频率变化率通道特征,弱化频率通道特征,有效提高了其在惯量评估方面的性能。

2)基于 1D-SE-ResNet 的区域惯量评估方法仅需获取区域簇中心点频率和频率变化率信息便可估计区域惯量,所需数据较少且易于获取,同时可计及风电机组虚拟惯量,与其他网络相比,惯量评估准确度更高、泛化性更好。

3)在训练 1D-SE-ResNet 时没有涉及非阶跃扰动,后续如何实现对非阶跃扰动下的惯量进行评估,提升其在各类小扰动下或准稳态下的惯量评估能力仍是需要攻克的难题。

参考文献

- [1] 孙华东,王宝财,李文峰,等.高比例电力电子电力系统频率响应的惯量体系研究[J].中国电机工程学报,2020,40(16):5179-5192.
SUN Huadong, WANG Baocai, LI Wenfeng, et al. Research on inertia system of frequency response for power system with high penetration electronics [J]. Proceedings of the CSEE, 2020, 40(16):5179-5192.
- [2] 王雪,刘林,卓庆东,等.基于虚拟惯量控制的新型电力系统功率差前馈振荡抑制方法[J].中国电力,2024,57(4):68-76.
WANG Xue, LIU Lin, ZHUO Qingdong, et al. Power difference feed-forward oscillation suppression method for new power system based on virtual inertial control [J]. Electric Power, 2024, 57(4): 68-76.
- [3] 杨桂兴,郭小龙,孙谊嫻,等.虚拟同步发电机频率偏差前馈阻尼控制策略的参数整定方法[J].高压电器,2024,60(10):46-53.
YANG Guixing, GUO Xiaolong, SUN Yiqian, et al.

- Parameter tuning method of frequency deviation feedforward based damping control strategy for virtual synchronous generator[J]. High Voltage Apparatus, 2024, 60(10): 46–53.
- [4] 王正男, 张新慧, 彭克, 等. 惯量阻尼自适应虚拟直流发电机控制策略[J]. 电测与仪表, 2024, 61(1): 189–194.
WANG Zhengnan, ZHANG Xinhui, PENG Ke, et al. Control strategy of inertia damping adaptive virtual DC generator[J]. Electrical Measurement & Instrumentation, 2024, 61(1): 189–194.
- [5] 刘方蕾, 胥国毅, 王凡, 等. 基于差值计算法的系统分区惯量评估方法[J]. 电力系统自动化, 2020, 44(20): 46–53.
LIU Fanglei, XU Guoyi, WANG Fan, et al. Assessment method of system partition inertia based on differential calculation method [J]. Automation of Electric Power Systems, 2020, 44(20): 46–53.
- [6] 张智, 陈艳波, 宋新甫, 等. 基于多指标面板数据特征提取的同调机组分群方法[J]. 电力系统保护与控制, 2020, 48(17): 27–36.
ZHANG Zhi, CHEN Yanbo, SONG Xinfu, et al. Coherent clustering method based on feature extraction for multi-index panel data[J]. Power System Protection and Control, 2020, 48(17): 27–36.
- [7] 陈义宣, 冯帅帅, 李玲芳, 等. 基于常规扰动数据的电网分区及惯量在线辨识方法[J]. 南方电网技术, 2023, 17(7): 83–94.
CHEN Yixuan, FENG Shuaishuai, LI Lingfang, et al. Area division and online inertia identification method based on routine disturbance data[J]. Southern Power System Technology, 2023, 17(7): 83–94.
- [8] 李东东, 董楠, 姚寅, 等. 考虑频率响应分散性及系统分区的含风电系统等效惯量估计[J]. 电力系统保护与控制, 2023, 51(3): 36–45.
LI Dongdong, DONG Nan, YAO Yin, et al. Equivalent inertia estimation of a power system containing wind power considering dispersion of frequency response and system partitioning [J]. Power System Protection and Control, 2023, 51(3): 36–45.
- [9] 曹斌, 原帅, 刘家豪, 等. 考虑频率动态响应实时分区的电力系统惯量在线评估方法[J]. 电网技术, 2023, 47(3): 930–941.
CAO Bin, YUAN Shuai, LIU Jiahao, et al. Power system online inertia estimation considering real-time clustering of frequency dynamic response [J]. Power System Technology, 2023, 47(3): 930–941.
- [10] ZHANG Z, TAVENARD R, BAILLY A, et al. Dynamic time warping under limited warping path length[J]. Information Sciences, 2017, 393(1): 91–107.
- [11] PHURAILATPAM C, RATHER Z H, BEHROOZ B, et al. Measurement-based estimation of inertia in AC microgrids[J]. IEEE Transactions on Sustainable Energy, 2019, 11(3): 1975–1984.
- [12] ASHTON P M, TAYLOR G A, IRVING M R, et al. Novel application of detrended fluctuation analysis for state estimation using synchrophasor measurements [J]. IEEE Transactions on Power Systems, 2013, 28(2): 1930–1938.
- [13] TAMEAKAR U, COPP D A, NGUYEN T A, et al. Real-time estimation of microgrid inertia and damping constant[J]. IEEE Access, 2021(9): 114523–114534.
- [14] ZHANG J B, XU H C. Online identification of power system equivalent inertia constant[J]. IEEE Transactions on Industrial Electronics, 2017, 64(10): 8098–8107.
- [15] TUTTELBERG K, KILTER J, WILSON D, et al. Estimation of power system inertia from ambient wide area measurements [J]. IEEE Transactions on Power Systems, 2018, 33(6): 7249–7257.
- [16] 李世春, 夏智雄, 程绪长, 等. 基于类噪声扰动的电网惯量常态化连续估计方法[J]. 中国电机工程学报, 2020, 40(14): 4430–4438.
LI Shichun, XIA Zhixiong, CHENG Xuchang, et al. Continuous estimation method of power system inertia based on ambient disturbance[J]. Proceedings of the CSEE, 2020, 40(14): 4430–4438.
- [17] CAO X, STEPHEN B, ABDULHADI IF, et al. Switching Markov Gaussian models for dynamic power system inertia estimation[J]. IEEE Transactions on Power Systems, 2016, 31(5): 3394–3403.
- [18] PAIDIE S N R, MARZOOGHI H, YU J M, et al. Development and validation of artificial neural network-based tools for forecasting of power system inertia with wind farms penetration [J]. IEEE Systems Journal, 2020, 14(4): 4978–4989.
- [19] POUDYAL A, FOURNEY R, TONKOSKI R, et al. Convolutional neural network-based inertia estimation using local frequency measurements[C]//2020 52nd North American Power Symposium (NAPS), April 11–13, 2020, Tempe, USA. New York: IEEE, 2021: 1–6.
- [20] 闵勇, 陈磊, 刘瑞阔, 等. 电力系统频率动态中惯量与惯量响应特性辨析[J]. 中国电机工程学报, 2023, 43(3): 855–868.
MIN Yong, CHEN Lei, LIU Ruikuo, et al. Analysis on characteristics of inertia and inertial response in power system frequency dynamics [J]. Proceedings of the CSEE, 2023, 43(3): 855–868.
- [21] 王小君, 窦嘉铭, 刘墨, 等. 可解释人工智能在电力系统中的应用综述与展望[J]. 电力系统自动化, 2024, 48(4): 169–191.
WANG Xiaojun, DOU Jiaming, LIU Zhao, et al. Review and prospect of explainable artificial intelligence and its application in power systems [J]. Automation of Electric Power Systems, 2024, 48(4): 169–191.
- [22] 徐钰涵, 季天瑶, 李梦诗. 基于深度强化学习的微电网日前日内协调优化调度[J]. 南方电网技术, 2024, 18(9): 106–116.
XU Yuhuan, JI Tianyao, LI Mengshi. Day-ahead and intra-day coordinated optimal scheduling of microgrid based on deep reinforcement learning [J]. Southern Power System Technology, 2024, 18(9): 106–116.
- [23] 张怡, 张恒旭, 李常刚, 等. 深度学习在电力系统频率分析与控制中的应用综述[J]. 中国电机工程学报, 2021, 41(10): 3392–3406.
ZHANG Yi, ZHANG Hengxu, LI Changgang, et al. Review on deep learning applications in power system frequency analysis and control [J]. Proceedings of the CSEE, 2021, 41(10): 3392–3406.
- [24] 王强强, 姚良忠, 徐箭, 等. 基于切片采样-马尔科夫链蒙特卡洛模的高比例新能源电力系统等效惯量概率评估[J]. 电网技术, 2024, 48(1): 140–152.
WANG Qiangqiang, YAO Liangzhong, XU Jian, et al. S-MCMC based equivalent inertia probability evaluation for power systems with high proportional renewable energy [J].

- Power System Technology, 2024, 48(1): 140 – 152.
- [25] 陈宇航, 王刚, 侍乔明, 等. 一种新型风电场虚拟惯量协同控制策略[J]. 电力系统自动化, 2015, 39(5): 27 – 33.
- CHEN Yuhang, WANG Gang, SHI Qiaoming, et al. A new coordinated virtual inertia control strategy for wind farms[J]. Automation of Electric Power Systems, 2015, 39(5): 27 – 33.
- [26] 王鑫, 杨德健, 基于变系数PI控制的双馈风电机组自适应转速恢复策略[J]. 电工技术学报, 2023, 38(15): 4120 – 4129.
- WANG Xin, YANG Dejian. Adaptive speed recovery strategy of doubly-fed induction generator based on variable PI control coefficient[J]. Transactions of China Electrotechnical Society, 2023, 38(15): 4120 – 4129.
- [27] 安军, 盛帅, 周毅博, 等. 基于量测数据的风电场等效虚拟惯量评估方法[J]. 电网技术, 2023, 47(5): 1819 – 1827.
- AN Jun, SHENG Shuai, ZHOU Yibo, et al. Evaluation of equivalent virtual inertia of wind farm based on measured data[J]. Power System Technology, 2023, 47(5): 1819 – 1827.
- [28] 马宇嘉, 谢小荣, 孙谊嫒, 等. 新能源电力系统频率时空分布特性分析[J]. 高电压技术, 2024, 50(1): 406 – 413.
- MA Ningjia, XIE Xiaorong, SUN Yiqian, et al. Analysis of frequency space-time distribution characteristics of power systems with renewables[J]. High Voltage Engineering, 2024, 50(1): 406 – 413.
- [29] PAI M A. Energy function analysis for power system stability[M]. London: Kluwer Academic Publishers, 1989.
- [30] 徐艳春, 任建新, 宋文字, 等. 考虑新能源电力系统频率响应时空分布特性的实时分区方法[J]. 电力建设, 2025, 46(3): 128 – 145.
- XU Yanchun, REN Jianxin, SONG Wenyu, et al. A real-time partitioning method considering the spatial and temporal distribution characteristics of renewable power system frequency response[J]. Electric Power Construction, 2025, 46(3): 128 – 145.
- [31] JIHUN H, J PRASANTH R, YOUNG J K, et al. Data-driven two-stage fault detection and diagnosis method for photovoltaic power generation[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73(8): 1 – 11.
- [32] LI D, CHEN W, TIAN H, et al. Short term power load forecasting method based on VMD-ResNet[C]//2023 5th International Conference on Power and Energy Technology (ICPET), July 27 – 30, 2023, Tianjin, China. New York: IEEE, 2023: 976 – 981.
- [33] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27 – 30, 2016, Las Vegas, USA. New York: IEEE, 2016: 770 – 778.
- [34] ASHTON P M, SAUNDERS C S, TAYLOR G A, et al. Inertia estimation of the GB power system using synchro phasor measurements[J]. IEEE Transactions on Power Systems, 2015, 30(2): 701 – 709.
- [35] 李勇, 常樊睿, 彭衍建, 等. 基于小扰动频率量测数据的电网友节点惯量分布评估方法[J]. 电力系统自动化, 2024, 48(13): 50 – 59.
- LI Yong, CHANG Fanrui, PENG Yanjian, et al. Evaluation method for node inertia distribution of power grids based on small disturbance frequency measurement data[J]. Automation of Electric Power Systems, 2024, 48(13): 50 – 59.
- [36] IGE A O, MOHDNOOR M H. A lightweight deep learning with feature weighting for activity recognition[J]. Applied Soft Computing, 2023(149): 315 – 343.
- [37] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 18 – 23, 2018, Salt Lake City, USA. New York: IEEE, 2018: 7132 – 7141.
- [38] 国家标准化管理委员会. 量度继电器和保护装置第118部分: 电力系统同步相量测量: GB/T 14598.118—2021[S]. 北京: 中国标准出版社, 2021.
- [39] IVONNE P, CARLO B M A, BRI M H, et al. An extended IEEE 118-bus test system with high renewable penetration[J]. IEEE Transactions on Power Systems, 2018. 33(1): 281 – 289.

收稿日期: 2024-11-19; 网络首发日期: 2025-04-14

作者简介:

徐艳春(1973), 女, 副教授, 博士, 研究方向为主动配电网电能质量检测与治理、电力系统稳定性, xyc7309@163.com;

任建新(1997), 男, 通信作者, 硕士研究生, 研究方向为新能源电力系统惯量评估, 2870281606@qq.com;

宋文字(1992), 女, 硕士, 研究方向为风电并网系统备用容量分析, rdigpe815377@126.com。