

基于多变量样本卷积交互网络的电力系统频率安全性评估

刘杰^{1,2}, 石访^{1,3}, 宋雪萌², 田硕硕^{1,3}, 聂礼强²

(1. 电动汽车电网接入技术国家地方联合工程实验室(山东大学), 山东省济南市 250061;

2. 山东大学计算机科学与技术学院, 山东省青岛市 266200; 3. 山东大学电气工程学院, 山东省济南市 250061)

摘要: 现有电力系统暂态频率智能评估方法未充分考虑输入数据的时序特征。因此,文中提出一种基于暂态频率响应曲线智能预测的电力系统频率安全性评估方法。设计了一种多变量样本卷积交互网络,可充分挖掘电力系统量测数据的时序特征,从而提高电力系统暂态频率响应曲线的预测精度;基于所预测的频率响应曲线计算最大频率偏差、最大频率偏差发生时间和准稳态频率等关键指标,并综合评估系统的频率安全性。在频率稳定标准算例上进行仿真测试,结果表明,所提方法与深度学习等经典方法相比,频率响应曲线预测和系统频率安全性评估精度均得到有效提升。

关键词: 频率安全; 深度学习; 安全性评估; 时序预测模型; 卷积交互网络; 暂态频率响应

0 引言

为实现“碳达峰·碳中和”的双碳发展目标,中国的能源生产结构和消费结构已发生重大变化。其中,在电力领域,建设以可再生能源为主体、特高压交直流混联的新型电力系统已成为发展趋势^[1-3]。相比于传统电力系统,新型电力系统的一个显著特点就是具有“双高”特征,即高比例可再生能源和高比例电力电子设备大规模接入电网^[4]。然而,以风电、光伏等为代表的新能源发电设备,呈弱惯性特征或无惯性特征,调频能力弱,使得新型电力系统的惯量支撑能力和频率调节能力遭到严重削弱^[5]。

具体地,当电力系统发生扰动(例如大规模功率缺额)时系统频率会严重偏离额定值并经历动态过程,而惯量水平较低的电力系统频率调节能力较差,导致频率变化更快、频率偏移量增大^[6]。在互联电力系统中,各区域电网通过联络线连接,每个区域的频率波动都将影响到与其互联的区域^[7]。当频率偏移量超出电力系统自身调节范围时,紧急切机是防止直流闭锁故障后送端电网暂态频率越限的有效措施^[8]。因此,低惯量水平的新型电力系统受扰后更加容易发生大面积切负荷、切机甚至频率崩溃等问题^[9]。例如,2016年,新能源发电比例高达48.36%的南澳大利亚州(简称南澳)发生大停电事故,使得

南澳电力系统频率迅速下跌至47 Hz^[10];2019年,风电出力占比超30%的英国也发生了大停电事故,使得电网频率跌至49.1 Hz^[11]。这些事件表明,新型电力系统的频率安全性更容易遭到破坏并造成严重后果。

准确评估电力系统受扰后的频率安全性,是提高新型电力系统频率安全的重要方面。国内外在频率安全性评估领域开展了广泛研究,方法主要分为3种:时域仿真法、等值模型法以及人工智能方法^[12]。时域仿真法主要通过仿真软件对电力系统进行详细模拟,计算精度较高,但计算量大、时效性较差,无法实时应用于实际电力系统^[13]。等值模型法通过对系统进行单机等值或忽略部分电气量进行简化分析,虽然评估速度较快,但对于由多机组成的复杂电力系统而言,运行方式、扰动场景与频率响应之间的物理关系难以等效为单一固定的模型,很难适用于大规模的新型电力系统。而基于数据驱动的人工智能方法,不需要建立复杂的物理模型,利用大量训练数据建立系统量测数据与频率响应数据之间的映射关系,具有预测精度高、计算速度快等优点。同时,以相量测量单元为基础的广域测量系统快速发展,能够同步采集各测量节点的实时相量数据,为人工智能方法在电力系统中各领域广泛应用提供了充足的数据支撑^[14]。

因在预测精度和计算速度等方面的优势,基于人工智能方法的电力系统暂态频率安全评估研究获得了广泛关注。文献[9]采用轻量级梯度提升机器学习(light gradient boosting machine, LightGBM)方

收稿日期: 2023-11-01; 修回日期: 2024-02-29。

上网日期: 2024-09-27。

国家重点研发计划资助项目(2021YFB2400800)。

法分别对频率变化率、暂态频率极值和准稳态频率3个指标建立预测模型,进而综合判断系统频率安全性。相比于直接分类的方法,该方法显著地提高了电力系统暂态频率安全评估准确率。文献[15]根据系统扰动后的频率偏差对频率安全进行多级划分,然后,基于改进残差网络分别构建了频率安全分类模型和频率安全裕度回归模型,可以准确、直观地预测频率风险^[15]。该方法具有评估精度高、泛化和抗噪声能力强等特点。

虽然人工智能方法已经取得了显著效果,但现有方法均直接利用电网受扰前后短暂时间内的量测数据直接估计频率最低值等暂态频率关键指标。事实上,通过预测系统受扰后的全过程频率响应曲线,可为频率安全评估提供更加全面的信息支撑。近年来,面向电力系统的暂态频率响应曲线预测得到广泛关注。文献[16]提出基于深度置信网络(deep belief network, DBN)的系统动态频率预测方法,采用扰动前后瞬间时刻的系统特征值作为输入,预测扰动后60 s内的系统频率值。文献[17]针对频率安全的在线评估问题,提出基于度量学习与生成对抗网络的数据驱动频率安全评估方法,提高了预测模型对未来待评估场景的泛化能力。文献[18]通过特征去冗余方法降低输入特征数量,并提取反映电网动态频率响应的关键特征,在基于随机森林的电网频率预测方法上验证特征选择的正确性,结果表明,利用关键特征在短时间内可建立准确快速的频率响应预测模型。虽然上述方法取得了较好的效果,但并未充分挖掘电网量测数据的时序特征,无法取得最优的频率动态预测和安全评估效果。

本文提出一种基于多变量样本卷积交互网络(multivariable sample convolution and interaction network, M-SCINet)的电力系统频率安全性评估方法。考虑到电力系统量测数据中普遍存在的时序特征,基于现有时序预测模型,即样本卷积交互网络(sample convolution and interaction network, SCINet)^[19],设计了M-SCINet,精准预测受扰后暂态过程的频率响应曲线;基于频率响应曲线计算得到最大频率偏差、最大频率偏差发生时间和准稳态频率等关键响应指标,并根据这些频率响应指标综合评估系统频率安全性;最后,在频率稳定标准算例上进行仿真验证。结果表明,所提M-SCINet模型与经典深度学习模型相比,能够更精确地预测频率响应曲线;在保证频率响应指标预测精度的同时,可以提供频率响应全过程的信息,能准确、可靠地给出频率安全性评估结果。

1 频率响应曲线预测问题描述

1.1 问题定义

一般地,若系统包含 C 个输入电气量,这些电气量的量测数据定义为:

$$\begin{cases} X = \{X_{1,1}, X_{1,2}, \dots, X_{C,L}\} \\ X_{C,L} = \{x_{C,1}, x_{C,2}, \dots, x_{C,L}\} \end{cases} \quad (1)$$

式中: X 为输入电气量的量测数据集; L 为输入电气量的长度; C 为输入电气量的维度; $X_{C,L}$ 为第 C 个输入电气量量测数据序列; $x_{C,L}$ 为第 C 个输入电气量在第 L 个时刻的测量值。

频率响应曲线预测的任务是基于输入电气量的量测数据预测系统频率在未来 T 个时刻的时间序列值,可记为:

$$Y = \{y_{L+1}, y_{L+2}, \dots, y_{L+T}\} \quad (2)$$

式中: Y 为预测的频率响应曲线时间序列值; y_{L+T} 为频率响应曲线在第 $L+T$ 个时刻的值; T 为预测的系统频率的时间跨度。

电力系统量测数据通常随着时间变化而变化,属于时间序列数据。该类数据本身隐含着大量可挖掘的时序特征,例如,单变量序列在时间维度上一般具有自相关性,多变量序列在特征维度上也具有一定的变量相关性,为引入时序预测模型挖掘量测数据中潜在的时序特征提供了基础。

1.2 时间序列预测

传统的时间序列预测方法(例如,整合移动平均自回归(autoregressive integrated moving average, ARIMA)模型^[20])主要适用于单变量预测任务,其应用能力受到数据复杂程度的限制^[19]。随着数据规模和计算能力的增长,基于深度学习的时间序列预测方法表现出优越的性能。

SCINet模型^[19]在时间序列预测任务上取得了较好的结果,具有表示能力强、结构简单、扩展性好等优点,故本文引入该模型并进行改进以适用于电力系统频率响应曲线预测。

SCINet模型中的基础结构是样本卷积交互(sample convolution and interaction, SCI)单元,主要包括奇偶序列分解、多尺度卷积、交互学习等模块。

1)奇偶序列分解。为了挖掘时间序列中的信息,通常会将时间序列分解为若干子序列,并分别对每个部分进行建模和分析。文献[21]提出将时间序列分解为趋势分量、季节分量和随机分量,但考虑到并非所有时间序列均具有明显的周期性,SCI单元采用更加通用的奇偶序列分解方法,根据元素位置将原始序列 F 分解为奇子序列 F_{odd} 和偶子序列

F_{even} ,如式(3)所示。

$$\begin{cases} F_{\text{odd}} = \{F_1, F_3, \dots, F_{2k+1}\} \\ F_{\text{even}} = \{F_0, F_2, \dots, F_{2k}\} \end{cases} \quad (3)$$

式中: F_{2k+1} 和 F_{2k} 分别为原始序列 F 中奇数位置和偶数位置的元素。

该操作本质上是对原始序列进行欠采样,分解得到的子序列最大程度地保留了原始序列中的趋势信息。

2)多尺度卷积。SCI单元中使用一维卷积神经网络(one-dimensional convolution neural network, 1D-CNN)对时间序列进行特征提取,具体过程为卷积核沿着一个方向滑动,并与时间窗口内的区域进行卷积运算,其局部特征提取能力主要取决于卷积核的大小。使用不同尺寸的卷积核组成多尺度卷积,可以提取时间序列中不同尺度的局部依赖关系,这使得模块具有更加强大的表示能力。

3)交互学习。为了减少奇偶序列分解可能带来的潜在信息损失,SCI单元在奇偶子序列特征提取的过程中使用交互学习策略,使得子序列之间可以通过特征变换进行信息交互。具体地,首先使用两种具有不同卷积核尺寸的卷积层 $\alpha(\cdot)$ 和 $\beta(\cdot)$ 分别对奇偶子序列进行特征变换,变换后的特征与原始奇偶子序列进行交互式矩阵运算(本文选为哈达玛乘积),得到奇、偶子序列的特征 $F_{s,\text{odd}}$ 和 $F_{s,\text{even}}$,如式(4)所示。

$$\begin{cases} F_{s,\text{odd}} = F_{\text{odd}} \odot f_{\text{exp}}(\alpha(F_{\text{even}})) \\ F_{s,\text{even}} = F_{\text{even}} \odot f_{\text{exp}}(\beta(F_{\text{odd}})) \end{cases} \quad (4)$$

式中: \odot 为哈达玛乘积符号; $f_{\text{exp}}(\cdot)$ 为以自然常数为底的指数函数。

其次,进一步使用两种具有不同卷积核尺寸的卷积层 $\gamma(\cdot)$ 和 $\delta(\cdot)$ 进行特征变换,变换后得到的特征与 $F_{s,\text{odd}}$ 和 $F_{s,\text{even}}$ 进行交互式融合,得到特征变换后新的奇、偶子序列 F'_{odd} 和 F'_{even} ,如下式所示:

$$\begin{cases} F'_{\text{odd}} = F_{s,\text{odd}} + \gamma(F_{s,\text{even}}) \\ F'_{\text{even}} = F_{s,\text{even}} - \delta(F_{s,\text{odd}}) \end{cases} \quad (5)$$

式中: F'_{odd} 和 F'_{even} 分别为特征变换后的奇、偶子序列。

SCINet模型是由若干个SCI单元以二叉树结构组成的,如图1所示。具体地,SCINet模型的输入序列 X 经过位于“根节点”的SCI单元,得到两个特征变换后的奇、偶子序列,这两个子序列 $\{X_{1,1}, X_{2,1}\}$ 又会分别作为下一层位于“分支节点”的SCI单元的输入,以上述形式递归地对 $\{X_{1,1}, X_{2,1}\}$ 进行分解;将经过最后一层SCI单元得到的所有奇、

偶子序列重新排列,合并拼接得到输入序列 X 的特征表示。为了避免过深的二叉树结构带来额外信息损失,引入残差连接结构^[22],再经全连接层映射得到SCINet模型的输出 \hat{X} 。整个过程可以表示为:

$$\hat{X} = f_c(X \oplus \{X_{1,l}, X_{2,l}, \dots, X_{2^l,l}\}) \quad (6)$$

式中: \hat{X} 为提取到的时序特征; f_c 为全连接层; \oplus 为残差连接符号; l 为二叉树结构的深度,即SCINet模型中SCI单元的层数; $X_{2^l,l}$ 为第 l 层SCI单元分解得到的第 2^l 个子序列。

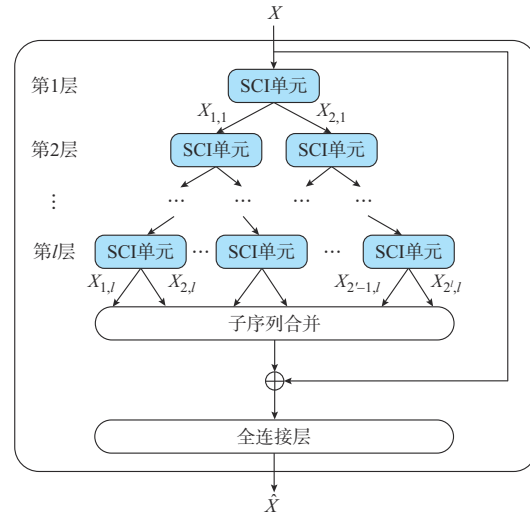


图1 SCINet模型结构
Fig. 1 Structure of SCINet model

SCINet模型通过对原始输入序列进行多次奇偶分解,可以充分利用多尺度卷积提取时间序列中不同尺度的局部依赖关系。同时,多尺度卷积也大大增强了模型的表示能力。位于浅层的SCI单元可以从全局的视角对时间序列进行特征提取,随着层数的增加,SCI单元也可关注到局部时序特征,这使得SCINet模型具有提取时间序列中短期和长期依赖关系的能力。此外,SCINet模型还引入了交互式学习、残差连接和合并拼接等,这些结构可以在很大程度上减少上述分解过程可能带来的信息损失,保证了特征挖掘的有效性。

1.3 频率响应预测模型

如前所述,SCINet模型可以单独对每个电气量的输入序列进行时序特征提取,故既可以应用于单变量时间序列预测问题,又可以应用于多个独立变量的时间序列预测问题。但考虑到电力系统频率响应曲线预测任务中,输入电气量间存在不可忽视的潜在相关性。为此,本文设计了M-SCINet这一频率响应预测模型,其整体结构如图2所示。该模型在SCINet模型分别提取不同输入电气量序列的时

序特征的基础上,利用1D-CNN进行多变量特征融合,再经线性层和非线性激活函数映射得到频率响应曲线。




图2 M-SCINet模型结构
Fig. 2 Structure of M-SCINet model

2 电力系统频率安全性评估

本文在M-SCINet模型预测频率响应曲线的基础上,进一步计算得到频率响应指标和系统频率安全性评估结果,从而构建基于响应曲线预测的电力系统频率安全性评估方法。

2.1 频率安全性指标

惯性中心(center of inertia, COI)频率反映了电力系统作为整体在遭受扰动后所呈现的动态行为,广泛应用于电力系统频率动态分析^[23]。为判断电力系统频率是否安全,通常以该系统的COI频率作为评估依据,其可视为系统总不平衡功率作用于系统惯性中心等效转子所产生的转速变化^[17]。COI频率定义为:

$$\omega_{\text{COI}} = \frac{\sum_{i=1}^{N_G} M_i \omega_i}{\sum_{i=1}^{N_G} M_i} \quad (7)$$

式中: ω_{COI} 为COI频率; N_G 为同步发电机数量; M_i 和 ω_i 分别为第*i*台同步发电机的惯性常量和转子角速度^[16]。

由定义可知,由于COI频率是各同步发电机转子角速度的加权平均值,系统COI频率可以用于近似表征系统中各节点频率^[17]。选取最大频率偏差 f_{nadir} 、最大频率偏差发生时间 t_{nadir} 、准稳态频率 f_{ss} ,作为描述频率响应的3个指标,如图3所示。

2.2 输入电气量选择

电力系统是一个典型的非线性时变复杂系统,其运行状态由众多电气量动态决定,故选择的输入电气量应当能够直接反映频率动态响应过程。考虑到在实际电力系统中的应用场景,用于模型学习的输入电气量应当在电力系统中可观测,并且易于获取。

本文仅考虑同步发电机中随时间动态变化的电气量。假定所有发电机转矩和功率标幺值均采用统




图3 频率响应曲线与响应指标
Fig. 3 Frequency response curve and response indicators

一基准,可以得到多机系统频率动态方程如下:

$$M_{\text{sys}} \omega_{\text{COI}} = \sum_{i=1}^N P_{m,i} - \sum_{i=1}^N P_{e,i} - \sum_{i=1}^N D \omega_i \quad (8)$$

式中: M_{sys} 为系统中各同步发电机惯性常量之和; D 为同步发电机机组的阻尼系数; $P_{m,i}$ 、 $P_{e,i}$ 、 ω_i 分别为第*i*台发电机的机械功率、电磁功率和转子角速度^[24]。

由式(8)可知,影响系统COI频率的电气量主要为各发电机的机械功率、电磁功率和转子角速度。

电力系统频率反映了有功出力 and 负荷之间的平衡关系^[25]。系统受扰后,发电机加速功率与系统频率变化趋势直接相关,无功功率影响机端电压和发电机可发出的有功功率^[26];系统发生有功功率缺额时,发电机的功角和无功功率也会随之变化。故选取如表1所示的6个电气量作为模型输入,这些电气量在仿真时均可直接输出,在实际应用时可通过直接测量或间接计算的方式获得。

表1 输入电气量集合
Table 1 Input electrical variable set

序号	电气量类别
1	扰动前后各发电机的电磁功率
2	扰动前后各发电机的机械功率
3	扰动前后各发电机的加速功率
4	扰动前后各发电机的无功功率
5	扰动前后各发电机的功角
6	扰动前后各发电机的转子角速度

2.3 评估方法整体流程

基于M-SCINet频率响应曲线预测模型的电力系统频率安全性评估方法整体框架如图4所示。

具体步骤如下:

1)数据生成。使用PSD-BPA仿真软件,设定不同的运行方式和故障场景,进行时域仿真(本文设

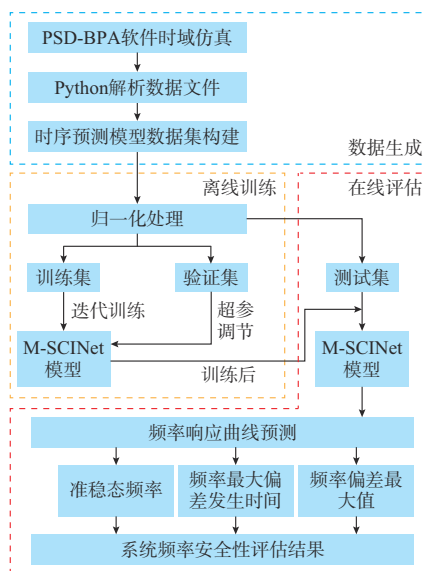


图4 基于M-SCINet的系统频率安全性评估框架
Fig. 4 Framework of system frequency safety assessment based on M-SCINet

定时长为2 000个周期),生成模型训练与测试所需的样本集;通过Python程序对数据文件进行分析和处理,得到输入电气量与系统COI频率的观测数据。

2)数据集构建。从生成的数据文件中加载输入电气量的仿真数据,并根据超参数 L (式(1))将数据切分为输入时序数据和输出时序数据,为保证在实际电力系统中可用, L 通常为1~2 s,且越小越好。

3)归一化处理。考虑到仿真数据与实际运行数据的数值分布存在一定偏差,若采用通用归一化方法,例如,根据数据的最大值和最小值或均值和方差进行归一化处理,会引入计算误差。本文根据物理意义预先设定电气量的阈值,针对线性特征使用最大-最小归一化;针对非线性特征,使用对数函数非线性映射后再进行最大-最小归一化。

4)数据集划分。将切分后的数据按照6:2:2的比例随机划分为训练集、验证集和测试集,不同数据集分布的差异性能够在一定程度上保障模型的泛化能力。

5)模型训练。构建M-SCINet模型,设定其中SCI单元的层数、初始学习率等超参数;模型在训练集上进行多轮迭代训练,在每轮迭代训练结束时,基于验证集计算模型的验证误差;若验证误差一直持续减小,则继续进行迭代训练,直至达到最大迭代轮次或验证误差不再减小,退出训练并保存当前的模型参数。

6)超参数调优。设置所有可调节超参数的阈值与调节步长,遍历所有参数组合,分别进行模型训

练。最终,在验证集上对比误差大小,挑选出相对最优的参数组合,用于进行模型测试。

7)模型测试。模拟在电力系统中实际应用的场景,将测试集中的每个样本输入上述步骤得到的最优模型进行测试,得到受扰后模型预测的系统COI频率,并与仿真结果进行对比并评估误差大小。

8)频率安全性评估。根据模型预测得到的系统COI频率曲线计算3种频率响应指标,即最大频率偏差及其发生时间、准稳态频率;综合频率响应指标与相应的频率安全范围对系统频率安全性进行分类判断。

3 算例分析

3.1 CSEE-FS算例

为支撑新型电力系统不同场景下频率安全稳定分析与控制研究需求,中国电力科学研究院有限公司基于中国实际电网结构与数据,建立了频率稳定标准算例CSEE-FS,包含水电、火电、风电和光伏等不同类型电源,以500 kV交流和±500 kV直流为主网架,构建了含高比例新能源的高频、低频场景^[27]。系统拓扑见附录A图A1,共有直流线路3回、关键节点47个,其中,500 kV主网架节点16个;常规机组共7台,总装机容量为5 400 MW,其中,5台火电机组装机容量为3 400 MW,2台水电机组装机容量为2 000 MW;风电、光伏2种新能源总装机容量为6 900 MW,其中,风电机组装机容量为3 150 MW,光伏装机容量为3 750 MW,新能源装机容量比例为56.1%^[27]。

CSEE-FS算例提供了高频和低频场景下的仿真数据,并分别对高、低频场景设计了不同的故障集。具体地,针对高频场景,设置了切负荷和直流闭锁两种故障形式,包括母线B01至B07设置负荷突增400 MW、双回直流DC01和DC02设置双极闭锁;针对低频场景,设置了负荷突增、切机和直流功率突增3种故障形式,包括母线B01至B07设置负荷突增400 MW、分别切除7台发电机组以及双回直流DC01、DC02功率突增250 MW^[27]。通过设置不同的负荷水平,调整新能源机组和其他机组的出力,生成多种组合运行方式,见附录A表A1。在不同的运行方式下,搭配上述故障场景,共仿真得到10 152组样本。

3.2 实验设置

3.2.1 评估指标

为了准确评估所提方法用于电力系统受扰后的COI频率预测误差,选取均方根误差(root mean square error, RMSE)和平均绝对百分比误差(mean

absolute percentage error, MAPE) 作为评估指标。RMSE 主要用来衡量绝对误差的大小,能够反映预测值与真实值的离散程度;MAPE 主要用来衡量相对误差的大小,计算结果不会受到量纲大小的影响,可以直观地反映模型预测的准确度,适合于电力系统中不同仿真数据之间的横向对比。

$$I_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (9)$$

$$I_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (10)$$

式中: I_{RMSE} 为预测的绝对误差值; I_{MAPE} 为预测的相对误差值; N 为样本数量; y_i 和 \hat{y}_i 分别为第 i 个样本的真实值和预测值。

3.2.2 超参数设置

通过在验证集上对比所有超参数组合,得到 M-SCINet 模型相对最优的参数组合。具体地,SCI 单元的层数为 3,多尺度卷积核的尺寸大小为 3 和 5,随机失活的比例为 50%,初始学习率为 0.001,学习率衰减的速度为 0.95,最大训练轮次为 100,批处理大小为 8。

由表 1 可知,模型的输入特征为所选取的 6 个电气量,算例中共有 7 台发电机组,每台发电机组均采用上述 6 个输入电气量,故模型输入数据的特征维度为 42。为权衡输入时序数据信息量与反应控制时间,设置时间窗口长度为 200 个采样点(采样周期为 0.01 s);待预测的频率响应曲线长度等于总仿真时长(4 000 个采样点)与时间窗口长度的差值,故模型的输出映射层神经元数量为 3 800 个,每个神经元的输出值对应于每个采样点的系统 COI 频率值。

3.3 结果对比与分析

分别构建基于 1D-CNN、卷积神经网络-长短期记忆(convolution neural network and long short-term memory, CNN-LSTM)网络和深度残差神经网络(residual neural network, ResNet)等经典模型的电力系统受扰频率响应预测,并将模型预测结果与本文所提方法进行对比。各模型频率曲线预测误差对比结果如表 2 所示。

表 2 各模型频率曲线预测误差对比
Table 2 Comparison of prediction errors of frequency curves of different models

模型	$I_{\text{RMSE}}/\text{Hz}$	$I_{\text{MAPE}}/\%$
深度 ResNet	0.136 5	0.224 6
CNN-LSTM 网络	0.120 2	0.076 2
1D-CNN	0.044 6	0.073 1
M-SCINet	0.030 6	0.050 3

由表 2 可知,对于电力系统受扰后频率响应曲线的预测,本文所提基于 M-SCINet 模型的方法得到的 RMSE 为 0.030 6 Hz, MAPE 为 0.050 3%,相比于所选对比模型,所提方法的整体误差最低,在一定程度上表明了时序预测模型的有效性。1D-CNN 和 M-SCINet 的误差明显小于基于二维卷积网络的深度 ResNet 和 CNN-LSTM 网络,这在一定程度上可以说明一维卷积网络更适用于作为时序任务的基础架构,能够更高效地提取时间序列中潜在的依赖关系。相比于次优模型 1D-CNN, M-SCINet 模型的 RMSE 和 MAPE 降低约 31%,这表明 M-SCINet 模型的结构能够更加准确地提取时序数据特征,充分发挥了一维卷积网络强大、高效的表示能力。

为直观展示各模型频率响应曲线预测结果,从测试集的高频场景和低频场景中分别随机选取一个样本,低频样本的预测结果如图 5 所示。图中:GT 表示真实频率响应曲线。高频样本的预测结果见附录 A 图 A2。

可以看出,平均预测误差最大的深度 ResNet 模型在频率曲线上升/下降阶段和准稳态阶段与真实曲线均存在较大出入,模型无法准确地预测频率响应曲线,故也就无法对系统频率安全性进行准确评估。误差相对较小的 CNN-LSTM 模型和 1D-CNN 模型虽然在总体上能够较好地拟合频率响应曲线的变化趋势,但 1D-CNN 网络模型在频率曲线最低/最高处仍存在较大的预测误差,这会直接影响到后续的频率响应指标误差计算。本文所提出的 M-SCINet 模型不仅能够准确预测频率最低/最高偏差及发生时间和准稳态频率等曲线的关键节点,还能进一步拟合真实频率响应曲线的变化趋势。与其他模型相比,可以准确预测出更多的频率曲线变化细节。这表明, M-SCINet 模型具有更优的表示能力,能够正确地反映频率响应曲线与输入电气量之间的映射关系。

3.4 时间窗口长度取值分析

为探究选取不同长度时间窗口对模型预测结果的影响,对仿真结果中 COI 频率最大频率偏差发生时间进行统计分析。高频场景为 2.57~3.45 s,低频场景为 2.24~10.46 s(系统扰动时间为 $t=1.0$ s),模型输入的有效数据长度不应超过 1.24 s。

本文选取一系列不同时间窗口长度的时序数据作为 M-SCINet 模型的输入,探究时间窗口长度取值对频率响应曲线预测误差的影响,具体结果如附录 A 表 A2 所示。由于在 $t=1.0$ s 内,量测数据因系统未发生故障而保持不变,故无法为模型提供有效信息,模型也会过度拟合无效噪声,这表现为:随着

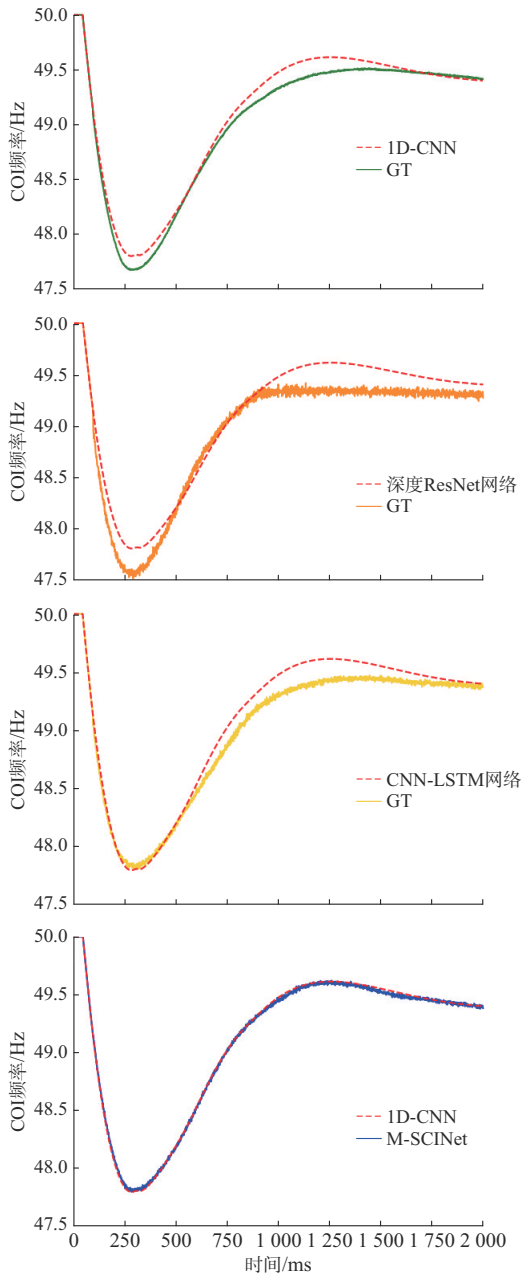


图5 低频样本不同模型预测结果对比
Fig. 5 Comparison of prediction results of different models for low-frequency sample

输入长度的增加,模型预测误差反而随之增大。当时间窗口覆盖扰动后动态过程时,模型可以根据变化的信息学习特征,故随着时间窗口长度的逐渐增加,模型预测误差逐渐减小,其中,时间窗口长度为1.52 s、1.92 s和2.00 s的模型预测误差比较接近,效果提升不明显。这表明,扰动后较短时间内的数据对频率响应曲线预测的影响较大,实际应用中需要权衡时间窗口长度与反应时间,本文算例时间窗口长度取值为1.44 s左右最为适宜,即有效动态数据长度为扰动后的0.44 s。

与仿真过程不同,在实际应用时,无法预知故障发生时间,故一般采用滑动窗口数据作为模型输入。以本文仿真获取的数据样本为例,设置数据滑动窗口长度为0.44 s,并以频率偏差大于设定阈值作为启动依据。利用滑动窗口内的数据作为输入,受扰频率响应曲线预测误差为0.043 3 Hz、相对误差为0.070 7%,此时,距离频率偏差最大节点低频减载启动,仍有0.80~9.02 s的控制反应时间;若增加滑动窗口长度至1.00 s,会牺牲一定的反应时间,但预测精度更高。综合考虑高频场景和低频场景的最大偏差发生时间,在忽略模型单次推理时间(平均为0.014 9 s)的前提下,可为系统采取控制措施预留出0.24~8.46 s的控制反应时间。

4 频率安全评估结果分析

在上述频率响应曲线准确预测的基础上,计算得到频率响应指标,首先,对频率响应曲线进行降采样处理,消除数据高频噪声并保留曲线特征;其次,计算出频率偏移最大值并记录其发生时间,选取频率响应曲线末段一段时间内的平均值作为准稳态频率;最后,根据频率响应指标,综合判断系统暂态频率安全性。

4.1 评价指标

相比于 t_{nadir} 和 f_{ss} 这两个频率响应指标, f_{nadir} 在一定程度上可以直接判断功率扰动事件是否会触发切机、切负荷紧急控制或导致系统频率崩溃^[9]。通常将低频减载首轮动作频率整定值设定为频率安全阈值,由于仿真算例的系统规模小、转动惯量低,更容易遭受功率扰动的影响,导致频率变化范围较大。在频率稳定标准算例CSEE-FS上的仿真结果显示,频率变化的范围为42.1~52.6 Hz。据此,本文将频率安全范围设置为48.5~51.5 Hz,并作为频率安全与否的阈值。当系统COI频率超过此范围时,认为系统频率安全无法得到保证,根据此标准对测试样本进行频率安全性评估^[28]。为直观准确地评价频率安全性评估结果,本文选取混淆矩阵、准确率 A_{cc} 和F1得分 S_{F1} 作为评价指标。其中, A_{cc} 和 S_{F1} 为:

$$A_{\text{cc}} = \frac{T_{\text{P}} + T_{\text{N}}}{T_{\text{P}} + T_{\text{N}} + F_{\text{P}} + F_{\text{N}}} \quad (11)$$

$$S_{\text{F1}} = \frac{2T_{\text{P}}}{2T_{\text{P}} + F_{\text{P}} + F_{\text{N}}} \quad (12)$$

式中: T_{P} 和 F_{P} 分别为安全样本中被正确和错误分类的样本数量; T_{N} 和 F_{N} 分别为不安全样本中被正确和错误分类的样本数量。

4.2 结果展示与分析

根据式(9)、式(10)对频率响应指标和频率安全

性评估结果进行误差计算,将所提方法与仿真结果、基线模型进行对比。

1)频率响应指标分析

由表3可知,使用M-SCINet模型得到的最大频率偏差和准稳态频率的RMSE分别为0.021 2 Hz和0.019 5 Hz,MAPE分别为0.044 3%和0.040 2%,误差明显低于其他模型且在可接受范围之内。这表明,所提方法不仅可以准确预测出频率响应曲线,还可以准确预知系统受扰后的频率偏差最大值和准稳

态频率。为进一步描述暂态频率响应过程,还需要给出准确的最大频率偏差发生时间,考虑到本文所用仿真样本的 t_{nadir} 理论分布区间为0~40 s,实际分布区间为2.24~10.46 s,较广的数值分布区间大大增加了频率响应曲线精准预测的难度。应用M-SCINet模型,最大频率偏差发生时间RMSE为0.183 5 s,MAPE为2.862 8%,该结果在可接受范围之内。这表明所提方法可以准确预测系统受扰后频率最大偏移发生时间。

表3 各模型频率响应指标误差对比
Table 3 Comparison of frequency response indicator errors of different models

模型	f_{nadir}		t_{nadir}		f_{ss}	
	I_{RMSE}/Hz	$I_{MAPE}/\%$	I_{RMSE}/s	$I_{MAPE}/\%$	I_{RMSE}/Hz	$I_{MAPE}/\%$
深度 ResNet	0.088 9	0.184 6	0.786 4	16.556 0	0.071 6	0.144 5
CNN-LSTM网络	0.048 1	0.099 5	0.538 4	10.350 0	0.049 4	0.100 6
1D-CNN	0.035 9	0.078 6	0.225 3	3.167 4	0.025 2	0.051 5
M-SCINet	0.021 2	0.044 3	0.183 5	2.862 8	0.019 5	0.040 2

2)频率安全性分析

综合频率偏差最大值与所设频率安全范围判断得到的系统频率安全评估结果与仿真结果的误差如表4所示。

表4 各模型频率安全性评估误差对比
Table 4 Comparison of frequency safety assessment errors of different models

模型	$A_{cc}/\%$	S_{F1}
深度 ResNet	98.98	0.977 5
CNN-LSTM网络	99.69	0.992 9
1D-CNN	99.61	0.991 2
M-SCINet	99.84	0.996 5

由表4可知,各模型均能相对准确地对系统频率安全性给出评估结果,准确率均超过98%。但如前所述,部分模型无法做到对频率响应曲线的精准预测。M-SCINet模型的 S_{F1} 平均值可以达到0.996 5,这表明该模型可以兼顾频率安全场景和不安全场景的准确评估。附录A图A2展示了各模型系统频率安全评估结果的混淆矩阵。可以直观地看出,M-SCINet模型对测试样本频率安全性错判的数量最少。

4.3 噪声鲁棒性分析

在实际应用中,对真实电力系统进行数据采集和数据传输等环节会不可避免地引入随机噪声,与仿真数据相比,存在一定的分布偏差。为评估模型的抗噪声性能,本文通过在仿真数据中加入不同水平的高斯白噪声,以更好地模拟实际情况。具体过程如式(13)所示。

$$X_{noise} = X(1 + \theta) \quad (13)$$

式中: X_{noise} 为添加噪声后的输入数据; θ 为服从均值为0、标准差为 α' 的高斯白噪声。

本文在原始训练集和验证集上对模型进行训练和调优,在测试集上分别添加 $\alpha' \in \{0.0, 0.1, 0.2, 0.3\}$ 的高斯白噪声,使用频率安全判别准确率作为评价指标。图6为各个模型在不同噪声水平下的评估结果对比。可以看出,随着所添加高斯白噪声的标准差 α' 增加,各个模型的准确率均随之下降,这说明了模型抗噪声干扰能力的重要性。随着噪声水平的增加,M-SCINet模型的系统频率安全性评估准确率具有小幅度衰减,但仍远高于其他模型在同等噪声水平下的准确率。同时,当添加低水平噪声时,例如 $\alpha' = 0.2$,M-SCINet模型仅损失了4.62%的准确率。这表明,所提出的M-SCINet模型不仅噪声鲁棒性超过对比模型,而且在低水平噪声干扰下,判别准确率衰减程度在可接受范围内,具有较好的实用性。

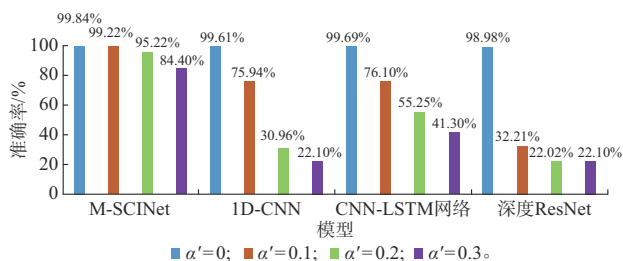


图6 不同噪声水平下的模型评估结果
Fig. 6 Model evaluation results at different noise levels

5 结语

本文提出了一种基于M-SCINet的电力系统频率安全性评估方法。考虑到电力系统量测数据中普遍存在的时序特征,本文基于SCINet,提出M-SCINet频率响应预测模型,以挖掘时序特征并预测受扰后系统频率响应曲线。算例测试结果表明,与经典深度学习方法相比,所提方法可以更精准地预测频率响应曲线,不仅具有预测精度高、表示能力强等优点,还可以提供频率响应全过程的信息。在频率响应曲线准确预测的基础上,本文所提方法可以准确、可靠地给出系统频率安全性评估结果,且M-SCINet模型的抗噪声干扰能力较强,在实际场景中具有较大的应用潜力。

下一步工作重点包括:基于先进的时间序列预测模型,融合电力系统时间与空间信息,研究时空信息驱动的电力系统受扰后频率安全性评估方法;进一步研究结构简单、参数量少的时间序列预测模型,重点考虑模型的泛化性和可解释性,提高频率安全性评估的可信度。

本文算例及仿真数据已共享,可在本刊网站支撑数据处下载(<http://www.aeps-info.com/aeps/article/abstract/20231101004>)。

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。

参考文献

- [1] 习近平.在第七十五届联合国大会一般性辩论上的讲话[J].中华人民共和国国务院公报,2020(28):5-7.
XI Jinping. Statement at the general debate of the 75th Session of the United Nations General Assembly[J]. Gazette of the State Council of the People's Republic of China, 2020(28): 5-7.
- [2] 卢锦玲,郭鲁豫.基于改进深度残差收缩网络的电力系统暂态稳定评估[J].电工技术学报,2021,36(11):2233-2244.
LU Jinling, GUO Luyu. Power system transient stability assessment based on improved deep residual shrinkage network [J]. Transactions of China Electrotechnical Society, 2021, 36 (11): 2233-2244.
- [3] 滕贤亮,谈超,昌力,等.高比例新能源电力系统有功功率与频率控制研究综述及展望[J].电力系统自动化,2023,47(15):12-35.
TENG Xianliang, TAN Chao, CHANG Li, et al. Review and prospect of research on active power and frequency control in power system with high proportion of renewable energy [J]. Automation of Electric Power Systems, 2023, 47 (15) : 12-35.
- [4] 徐三敏,张云飞,赵添辰,等.“双碳”目标下新型电力系统发展综述[J].水电与抽水蓄能,2022,8(6):21-25.
XU Sanmin, ZHANG Yunfei, ZHAO Tianchen, et al. Overview of new-type power system development under the background of carbon peaking and carbon neutrality [J]. Hydropower and Pumped Storage, 2022, 8(6): 21-25.
- [5] HEYLEN E, TENG F, STRBAC G. Challenges and opportunities of inertia estimation and forecasting in low-inertia power systems [J]. Renewable and Sustainable Energy Reviews, 2021, 147: 111176.
- [6] 刘方蕾,胥国毅,刘家豪,等.考虑电网结构和参数的电力系统惯量分布特性[J].电力系统自动化,2021,45(23):60-67.
LIU Fanglei, XU Guoyi, LIU Jiahao, et al. Inertia distribution characteristics of power system considering structure and parameters of power grid [J]. Automation of Electric Power Systems, 2021, 45(23): 60-67.
- [7] 陈宗遥,卜旭辉,郭金丽.基于神经网络的数据驱动互联电力系统负荷频率控制[J].电工技术学报,2022,37(21):5451-5461.
CHEN Zongyao, BU Xuhui, GUO Jinli. Neural network based data-driven load frequency control for interconnected power systems [J]. Transactions of China Electrotechnical Society, 2022, 37(21): 5451-5461.
- [8] 柯德平,冯帅帅,刘福锁,等.新能源发电调控参与的送端电网直流闭锁紧急频率控制策略快速优化[J].电工技术学报,2022,37(5):1204-1218.
KE Deping, FENG Shuaishuai, LIU Fusuo, et al. Rapid optimization for emergent frequency control strategy with the power regulation of renewable energy during the loss of DC connection [J]. Transactions of China Electrotechnical Society, 2022, 37(5): 1204-1218.
- [9] 赵冬梅,郑亚锐,谢家康,等.基于轻量级梯度提升机和生成对抗网络的含风电电力系统频率稳定评估[J].电网技术,2022,46(8):3181-3190.
ZHAO Dongmei, ZHENG Yarui, XIE Jiakang, et al. Frequency stability evaluation of power system containing wind power based on light gradient boosting machine and generative adversarial network [J]. Power System Technology, 2022, 46 (8) : 3181-3190.
- [10] OPERATOR A E M. Black system South Australia 28 September 2016: final report [R/OL]. [2023-10-07]. <http://apo.org.au/node/748862017>.
- [11] ESO N G. Technical report on the events of 9 August 2019 [R]. 2019.
- [12] SOBAJIC D J, PAO Y H. Artificial neural-net based dynamic security assessment for electric power systems [J]. IEEE Transactions on Power Systems, 1989, 4(1): 220-228.
- [13] 刘灏,商峻,毕天姝,等.基于实测数据的电网频率信号特征分析与提取方法[J].电力系统自动化,2023,47(10):135-144.
LIU Hao, SHANG Jun, BI Tianshu, et al. Feature analysis

- and extraction method of power grid frequency signal based on measured data [J]. Automation of Electric Power Systems, 2023, 47(10): 135-144.
- [14] ADHIKARI U, MORRIS T, PAN S Y. WAMS cyber-physical test bed for power system, cybersecurity study, and data mining[J]. IEEE Transactions on Smart Grid, 2017, 8(6): 2744-2753.
- [15] 李枬苏, 吴俊勇, 李宝琴, 等. 基于改进残差网络的两阶段电力系统频率安全多级预警[J]. 电力系统自动化, 2023, 47(1): 22-34.
LI Lusu, WU Junyong, LI Baoqin, et al. Two-stage multi-level early warning for power system frequency safety based on improved residual network [J]. Automation of Electric Power Systems, 2023, 47(1): 22-34.
- [16] 仇怡超, 闻达, 王晓茹, 等. 基于深度置信网络的电力系统扰动后频率曲线预测[J]. 中国电机工程学报, 2019, 39(17): 5095-5104.
ZHANG Yichao, WEN Da, WANG Xiaoru, et al. A method of frequency curve prediction based on deep belief network of post-disturbance power system [J]. Proceedings of the CSEE, 2019, 39(17): 5095-5104.
- [17] 李华瑞, 李文博, 李铮, 等. 基于生成对抗网络与度量学习的数据驱动频率安全评估[J]. 电力系统保护与控制, 2024, 52(18): 101-111.
LI Huarui, LI Wenbo, LI Zheng, et al. Data-driven frequency security assessment based on generative adversarial networks and metric learning [J]. Power System Protection and Control, 2024, 52(18): 101-111.
- [18] 李冠争, 李斌, 王帅, 等. 基于特征选择和随机森林的电力系统受扰后动态频率预测[J]. 电网技术, 2021, 45(7): 2492-2502.
LI Guanzheng, LI Bin, WANG Shuai, et al. Dynamic frequency prediction of power system post-disturbance based on feature selection and random forest [J]. Power System Technology, 2021, 45(7): 2492-2502.
- [19] LIU M, ZENG A, CHEN M, et al. SCINet: time series modeling and forecasting with sample convolution and interaction [J]. Advances in Neural Information Processing Systems, 2022, 35: 5816-5828.
- [20] BOX G E P, JENKINS G M. Some recent advances in forecasting and control [J]. Journal of the Royal Statistical Society Series C: Applied Statistics, 1968, 17(2): 91-109.
- [21] THEODOSIOU M. Forecasting monthly and quarterly time series using STL decomposition [J]. International Journal of Forecasting, 2011, 27(4): 1178-1195.
- [22] HE K M, ZHANG X Y, REN S Q, 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: 770-778.
- [23] 刘克天, 张钧, 李军, 等. 基于频率偏移面积的功率缺额计算及低频减载整定[J]. 电工技术学报, 2021, 36(5): 1040-1051.
LIU Ketian, ZHANG Jun, LI Jun, et al. Power deficit calculation and under frequency load shedding strategy based on the frequency deviation area [J]. Transactions of China Electrotechnical Society, 2021, 36(5): 1040-1051.
- [24] 薄其滨, 王晓茹, 刘克天. 基于v-SVR的电力系统扰动后最低频率预测[J]. 电力自动化设备, 2015, 35(7): 83-88.
BO Qibin, WANG Xiaoru, LIU Ketian. Minimum frequency prediction based on v-SVR for post-disturbance power system [J]. Electric Power Automation Equipment, 2015, 35(7): 83-88.
- [25] 侯智圆. 电力系统频率动态行为特征分析[D]. 济南: 山东大学, 2012.
HOU Zhiyuan. Analysis of frequency dynamic behavior characteristics of power system [D]. Jinan: Shandong University, 2012.
- [26] 王琦, 李峰, 汤奕, 等. 基于物理-数据融合模型的电网暂态频率特征在线预测方法[J]. 电力系统自动化, 2018, 42(19): 1-9.
WANG Qi, LI Feng, TANG Yi, et al. On-line prediction method of transient frequency characteristics for power grid based on physical-statistical model [J]. Automation of Electric Power Systems, 2018, 42(19): 1-9.
- [27] 吴萍, 赵兵, 程奕, 等. 新型电力系统标准算例(2): 频率稳定 CSEE-FS [J/OL]. 中国电机工程学报: 1-12 [2024-01-03]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20230901.2141.004.html>.
WU Ping, ZHAO Bing, CHENG Yi, et al. Standard calculation example of new power system (2): frequency stability CSEE-FS [J/OL]. Proceedings of the CSEE: 1-12 [2024-01-03]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20230901.2141.004.html>.
- [28] 张武其, 文云峰, 迟方德, 等. 电力系统惯量评估研究框架与展望[J]. 中国电机工程学报, 2021, 41(20): 6842-6855.
ZHANG Wuqi, WEN Yunfeng, CHI Fangde, et al. Research framework and prospect on power system inertia estimation [J]. Proceedings of the CSEE, 2021, 41(20): 6842-6855.

刘杰(1999—), 男, 硕士研究生, 主要研究方向: 电力系统频率安全。

石访(1982—), 男, 通信作者, 博士, 副教授, 主要研究方向: 电力系统稳定分析与控制、电力系统同步测量技术与应用。E-mail: shifang@sdu.edu.cn

宋雪萌(1990—), 女, 副教授, 博士生导师, 主要研究方向: 信息技术与人工智能。

(编辑 代长振)

Frequency Safety Assessment of Power Systems Based on Multivariable-sample Convolution and Interaction Network

LIU Jie^{1,2}, SHI Fang^{1,3}, SONG Xuemeng², TIAN Shuoshuo^{1,3}, NIE Liqiang²

(1. National Joint Engineering Laboratory of Power Grid with Electric Vehicles (Shandong University), Jinan 250061, China;

2. School of Computer Science and Technology, Shandong University, Qingdao 266200, China;

3. School of Electrical Engineering, Shandong University, Jinan 250061, China)

Abstract: The existing intelligent transient frequency assessment methods in power systems do not adequately consider the temporal characteristics of input data. Therefore, a frequency safety assessment method for power systems based on intelligent prediction of transient frequency response curves is proposed. A multivariate-sample convolutional interactive network is designed to fully exploit the temporal characteristics of power system measurement data, thereby improving the prediction accuracy of transient frequency response curves of the power system. Key indicators, such as the maximum frequency deviation, occurrence time of the maximum frequency deviation, and the metastability frequency are calculated based on the predicted frequency response curves, and the frequency safety of the system is comprehensively assessed. Simulation tests are conducted on frequency stability standard cases, and the results show that the proposed method effectively improves the accuracies of frequency response curve prediction and system frequency safety assessment compared with classical methods such as deep learning.

This work is supported by National Key R&D Program of China (No. 2021YFB2400800).

Key words: frequency safety; deep learning; safety assessment time series forecasting model; convolutional interactive network; transient frequency response

