

基于 STFT 图像和迁移学习的次同步振荡源定位方法

刘志坚*, 黄建, 骆军

(昆明理工大学 电力工程学院 云南 昆明 650500)

Localization Method for Sub-Synchronous Oscillation Sources Based on STFT Images and Transfer Learning

LIU Zhijian*, HUANG Jian, LUO Jun

(School of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: Sub-synchronous oscillations induced by the interaction between direct-drive wind turbines and the grid pose a serious threat to the safe and stable operation of the power grid. To rapidly identify the triggering unit, a localization method for sub-synchronous oscillation source based on short-time Fourier transform (STFT) images and transfer learning is proposed. Firstly, compressive sensing technology is employed to transform output data into observation signals, and then the STFT is performed on the observation signals to obtain the mapping image with oscillation characteristics, and the link between the mapping image and the oscillation source unit is constructed. Secondly, an adversarial transfer learning architecture is utilized in conjunction with the power system to achieve rapid generalization of unlabeled oscillation data in the target domain. Finally, the traditional transfer learning method is introduced for comparison, the results show that the proposed method performs better in terms of localization accuracy and efficiency, and has strong noise resistance.

Key words: sub-synchronous oscillation source; short-time Fourier transform; compressive sensing; mapping image; transfer learning

摘要: 直驱风机与电网交互引发次同步振荡,严重威胁电网的安全稳定运行。为快速定位诱发机组,提出了一种基于短时傅里叶变换(STFT)图像和迁移学习的次同步振荡源定位方法。首先,采用压缩感知技术将出口数据

转化为观测信号,再对观测信号进行 STFT 得到具备振荡特征的映射图,构建映射图与振荡源机组之间的联系;然后,采用对抗式迁移学习架构,结合电力系统,实现对目标域无标签振荡数据的快速泛化;最后,与传统迁移学习方法进行比较,结果表明所提方法在定位准确率和效率方面表现更优,且具备较强的抗噪能力。

关键词: 次同步振荡源; 短时傅里叶变换; 压缩感知; 映射图; 迁移学习

0 引言

大规模风电远距离输送至电网侧,导致受端电网连接强度降低,引发次同步振荡的风险增加^[1-2]。为此,对大规模风电并网系统的稳定性进行评估,在振荡发生时及时进行振荡源定位,并实施抑制策略,为电力系统安全稳定运行提供强有力的帮助^[3]。

目前,振荡源识别方法可分为两类^[4]。第一类是基于机理分析的数值仿真方法,该类方法通过物理推导的方法找到诱发振荡的物理特征,结合一系列数学关系寻得振荡源。较早的有模式分析法^[5]和阻抗分析法^[6-7]等,其核心是利用计算振荡模式或根据奈奎斯特判据^[8]推导振荡失稳判别条件,通过计算参与因子或根据频域分析的无源性判据,实现诱发振荡的环节识别。除此之外,以能量耗散理论或其衍生的能量函数法为基础^[9],推导振荡源判据,也成为一种主流的方法。文献[10]定义能流功率作为判断能量流向的指标,通过计算能流功率找出强迫电压源和强迫电

基金项目:国家重点研发计划项目(2022YFB2703500)

National Key Research and Development Program of China
(2022YFB2703500)

流源。文献[11]提出一种基于小波耗散能量谱的定位方法,阐述小波耗散能量谱和传统时域耗散能量流的关联关系。此外,还有基于扰动行波相似性^[12]、功率波动相位^[13]、功率谱密度^[14]以及相位法^[15]与能量法相结合^[16]的定位方法。这些方法需根据物理机理构建相应的参数模型,但随着新能源的持续接入,模型阶数增多,理想化的物理假设已无法满足实际运行要求。实际系统发生振荡时条件复杂多样,基于物理机理的模型无法同时模拟多种工况诱发的振荡。

第二类是基于数据驱动的方法,即结合量测装置和物理模型的数值算法。典型的有相量测量单元(Phasor Measurement Unit, PMU)的广域测量系统(Wide Area Measurement System, WAMS)为振荡风险识别提供数据基础^[17]。文献[18]通过基于 PMU 的相量频谱叠加特性,在同步相量数据丢失条件下,实现了动态同步监测。文献[19]应用动态相量测量算法,对大电网频率振荡形态和机组动态行为进行全景式感知监测。文献[20]提出数据驱动的强迫振荡源定位方法,使用孤立森林算法对原始数据进行清洗,将原问题转化为鲁棒主成分分析问题。但随着电网规模的持续扩大,在计算幅值和初始相角时引起的误差显著增加,仅依赖振荡监测设备和算法也难以实现振荡源的定位。

基于机器学习的振荡源识别发展较为成熟,主流方法大致分为两种。一种是通过智能编码的方式将端口数据转化为具有振荡特征的特征矩阵,将该矩阵输入到深度学习模型中进行学习^[21]。文献[22]采用压缩感知技术对振荡信号进行稀疏采样,结合神经网络对振荡源进行识别,但该方法需大量数据支撑。另一种是以参与因子和特征根之间的非线性关系为介质,建立数据驱动模型,通过迁移学习的方法学习少量实测数据,将模型泛化到实际系统中^[23]。文献[24]定义振荡数据与振荡源间的关系,结合领域自适应学习对目标域进行对抗学习。文献[25-26]通过迁移学习方法对高比例电力电子器件引起的振荡模式进行研究。虽然此类方法能够解决实际发生振荡时的数据匮乏问题,但仅能用于离线训练,且由于电力系统双高的特点,导致引发宽频振荡时的机理特征复杂,在训练模型和识别振荡源时耗时过

久,不利于电力系统安全稳定运行。此外,也有基于图像和深度迁移学习识别振荡源的案例,该方法首先将振荡发生时的能量分布特征转化为平滑伪 Wigner-Ville 分布(Smoothed Pseudo Wigner-Ville Distribution, SPWVD)图,再输入模型进行学习^[27]。但计算能量分布和转化 SPWVD 图的过程涉及大量矩阵变换,计算过程复杂且耗时长。

鉴于此,本文针对永磁同步发电机(Permanent Magnet Synchronous Generator, PMSG)接入电网引发次同步振荡的场景,提出一种基于图像处理的迁移学习方法,对 PMSG 引发的次同步振荡源进行定位。首先,采用压缩感知技术对端口数据进行压缩变换,得到具备振荡特征的低维观测信号;然后,对观测信号进行短时傅里叶变换(Short Time Fourier Transform, STFT),得到具备振荡特征的三通道映射图;其次,结合迁移学习方法,采用一种基于对抗式迁移学习的自适应学习手段,通过无标签图像的域自适应学习,达到特征分类的目的;最后,考虑噪声影响,结合仿真算例对所提定位方法进行验证分析,结果表明,所提次同步振荡源定位方法可以在较短时间内获得较为精确的定位结果,且具备良好的抗噪能力。

1 基于 STFT 的映射图生成

本文次同步振荡信号在频域的振荡频率点外系数均为零,可通过压缩感知将高维信号映射至低维潜在空间,生成一组具备振荡特征的低维观测信号,再通过 STFT 将压缩观测信号映射到图像中,实现数据特征的提取与变换。

1.1 次同步振荡数据压缩感知

单个风机端口数据一般为 $N \times 1$ 维的数组,现假定任意一个 N 维向量,由 $N \times 1$ 维正交向量基组 ϕ_i 构成。对于一个任意 N 维次同步振荡信号 x 可以定义为

$$x = \phi s \quad (1)$$

式中: $\phi = [\phi_1, \phi_2, \dots, \phi_N]$ 为基矩阵; $s = [s_1, s_2, \dots, s_N]^T$ 为权重系数列向量。

s 为信号 x 的 ϕ 域表示。当 s 的非零个数远小于 x 的维数时, ϕ 代表信号 x 的稀疏变换基。稀疏变换基能实现特征信号观测的有效表达,本文基于离散数据点的时序变换,采用离散余弦变

换基来表示:

$$\begin{cases} \mathbf{X}_c(0) = \frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} x(n) \\ \mathbf{X}_c(k) = \sqrt{\frac{2}{N}} \sum_{n=0}^{N-1} \left[x(n) \cos \frac{(2n+1)k\pi}{2N} \right] \end{cases} \quad (2)$$

根据信号 x 在 ϕ 基下的稀疏性, 考虑建立一个与稀疏变换基 ϕ 不相关的 $M \times N$ 维特征矩阵 Φ , 并对权重系数列向量进行等效变换, 如式(3)所示。通过建立与原始次同步振荡信号 x 的联系, 等效变换为一个 M 维的压缩特征信号 x' , 实现低维特征变换。

$$\mathbf{x}' = \Phi \mathbf{x} = \Phi \Psi \mathbf{s} = \Theta \mathbf{s} \quad (3)$$

式中: $\Phi = [\Phi_1, \Phi_2, \dots, \Phi_N]^T$; $\Theta = \Phi \Psi$ 为变换矩阵。

1.2 STFT 振荡映射图

STFT 的基本思路是保留数据的特征信息, 将信号傅里叶变换的积分区间局部化^[28], 其原理是将压缩感知技术处理的压缩特征信号 x' 与窗函数 $\omega(\cdot)$ 相乘后再进行离散化傅里叶变换, 定义为如式(4)所示:

$$\text{STFT}_x(k, b) = \sum_{m=0}^{M-1} x'(a) \omega(a - bR) e^{-j2\pi ak/N} \quad (4)$$

式中: b 为窗口的时间索引; a 为整数时间索引; R 为窗口的移动步长; $x'(a)$ 为压缩特征信号; $\omega(\cdot)$ 为窗函数, 其时间上翻转并有 k 个样本的偏移量。

输入信号的时频图定义为

$$S(\omega, b) = |\text{STFT}_x(k, b)|^2 \quad (5)$$

窗函数的选取与信号相匹配, 窗长最佳时频信号具有最高的频率分辨率。窗长定义为

$$T = \sqrt{\frac{b+2}{4^b b!}} / W \quad (6)$$

式中: T 为窗长; W 为谱宽系数。

2 基于对抗式迁移学习的模型构建

2.1 迁移学习

用于学习的数据样本划分为源域 D_s 和目标域 D_t , 每个数据都由其特征空间 X 和概率分布 $P(X)$ 构成。对于 D_s 和 D_t 内的任务由标签空间 Y 和预测函数 $f(\cdot)$ 构成。迁移学习定义一个源域 $D_s = \{X_s, P(X_s)\}$ 和源任务 $T_s = \{Y_s, f_s(\cdot)\}$ 、

一个目标域 $D_t = \{X_t, P(X_t)\}$ 和目标任务 $T_t = \{Y_t, f_t(\cdot)\}$, 迁移学习从源域 D_s 和源任务 T_s 中获取特征来帮助提升少量样本的目标域 D_t 和目标任务 X_t 的学习, 从而实现不同领域间的跨领域学习^[29]。图 1 为传统深度学习和迁移学习的区别。




图 1 深度学习和迁移学习的区别

Fig. 1 Difference between deep learning and transfer learning

考虑实际的振荡数据难以获取, 迁移学习能解决数据匮乏的问题, 与目标域的数据特征完美适配。因此, 可以利用仿真手段建立大量振荡数据集作为源域, 将模型通过大量学习迁移到实际系统振荡特征中来。

2.2 源任务定义

本文的任务是从多台 PMSG 中识别出振荡源标签的风机。为此, 需要找出与振荡特征有较大关系的机组特征变量, 确定迁移学习的学习目标。图 2 为 M 台 PMSG 并网示意图。




图 2 M 台 PMSG 并网示意图

Fig. 2 Schematic diagram of grid-connected containing M PMSGs

考虑将“风机子系统”和“剩余子系统”组成风机并网的闭环互联系统^[29], 如图 3 所示。状态方程如式(7)所示:

$$\begin{cases} \frac{d\Delta \mathbf{x}}{dt} = \mathbf{A} \Delta \mathbf{x} \\ \Delta \mathbf{x} = \begin{bmatrix} \Delta \mathbf{x}_g^T \\ \Delta \mathbf{x}_l^T \end{bmatrix} \end{cases} \quad (7)$$

式中: $\Delta \mathbf{x}$ 为系统状态变量, 包括风机子系统状态

变量 Δx_1 和剩余子系统 Δx_g 两部分; A 为系统的特征矩阵。




图3 闭环互联系统

Fig. 3 Closed-loop inter-connected system

根据模式分析法可知,当两个系统发生出强交互作用时,可通过(7)式中的状态空间矩阵求出系统中的闭环特征根和参与因子。根据特征根所处复平面位置和参与因子参与程度来定位引发系统失稳的振荡源位置。采用模式分析法定位振荡源位置的计算步骤为

$$x \rightarrow A \rightarrow \hat{\lambda}_{mn}(\lambda_{li}, \lambda_{gj}) \rightarrow PF_{mn} \rightarrow i, j \quad (8)$$

式中: $\hat{\lambda}_{mn}$ 为系统的闭环特征根; λ_{li} 为风机子系统第 i 个开环特征根; λ_{gj} 为剩余子系统第 j 个开环特征根; i, j 为振荡模态 $\hat{\lambda}_{mn}$ 对应的参与因子编号; PF_{mn} 为 $\hat{\lambda}_{mn}$ 的参与因子,表示第 m 个状态变量激励的第 n 个模式在该状态变量时域响应中的参与程度,定义为

$$PF_{mn} = \frac{|v_{mn} w_{mn}|}{\sum_{n=1}^N |v_{mn} w_{mn}|} \quad (9)$$

式中: v_{mn} 、 w_{mn} 分别为系统开环特征根对应的左、右特征向量。

结合第1节子系统的端口数据 x 与映射图 $S(\omega, n)$ 的对应关系。由(8)式可知,不同运行条件下的端口参数对应不同的特征矩阵 A ,其对不同状态变量时域响应中的参与程度有影响。为此可以建立对应关系式:

$$Y_s = f_s(PF) = f_s[\delta_s(S_s)] \quad (10)$$

式中: Y_s 为 PMSG 标签; S_s 为 STFT 映射图; $f_s(\cdot)$ 为标签 Y_s 与参与因子 PF 的关系函数; $\delta_s(\cdot)$ 为映射图 S_s 和 PF 的关系函数。

综上所述,建立的状态空间方程从机理出发,可以映射到实际系统中。当发生次同步振荡时,特征矩阵表征的风机控制环节参数与电网发生强交互作用,表现为不同参与因子对应不同状态变量时域响应中的参与程度。记录闭环互联系统模型的端口参数特征,建立参与因子与映射图的关系函数,将通过参与因子的参与程度判断振荡源,

转化为通过特征映射图判断振荡源,为迁移学习样本空间的模型构建提供先决条件。

2.3 对抗式迁移学习的模型构建

本文采用一种对抗式网络架构,其目的是更改或保留预训练模型的某些数据特征,通过训练模型来达到预测、识别、分类及生成等效果。相比传统迁移学习,该方法的预训练模型能够保留并跳过领域的公共特征,不仅加快了学习速度,而且更容易适应新领域的特征。此外该方法能够弥补源域和目标域的数据差,并保证图像特征的快速捕捉。对抗式网络结构图如图4所示。




图4 对抗式网络结构图

Fig. 4 Adversarial network structure diagram

图4中: F 、 H 和 J 为鉴别器,用于计算损失 l ,其输入包含源域 S_s 和目标域 S_t 两部分; Y_s 和 Y_t 分别为源域和目标域鉴别标签; Y_{st} 为 Y_s 和 Y_t 的联合项; $P(S_s)$ 和 $P(S_t)$ 分别为数据分布和潜在分布; ϵ 和 θ 为编码函数,其作用是从数据分布 $P(S_s)$ 和编码函数 ϵ 的输出中采样,或从编码函数 θ 和潜在分布 $P(S_t)$ 的输出中采样。本文增加 S_t 进行对抗学习,通过编码函数学习区分输入数据项与输入潜在项,从而达到对抗的效果。编码器整体为 E ,鉴别器整体为 D ,函数定义如式(11)所示:

$$\min_{\epsilon, \theta} \max_D \{ E_{S_s \sim P(S_s), \hat{S}_s \sim \epsilon(S_s)} \{ \log [\sigma (D (S_s, S_t))] \} + E_{S_t \sim P(S_t), \hat{S}_t \sim \theta(S_t)} \{ \log [1 - \sigma (D (S_s, S_t))] \} \} \quad (11)$$

式中: σ 为密度分布。

在最优 D 、 ϵ 和 θ 的情况下,编码器中 ϵ 和 θ 是全局最优的逆,其联合分布的 Jensen-Shannon (JS) 散度最小化。

目标强制学习的联合分布在全局最优时匹配,意味着 S_s 和 S_t 的边际分布也匹配,直观地说就是引导特征学习朝着相互的方向靠拢。例如,对于两个相似但不重合目标, S_s 上的一元损失项

l 匹配原始目标, 并提供学习信号, 该学习信号会引导潜在输入来匹配任务分布。函数具体定义如式(12)~式(14)所示:

$$\mathbf{Y}_s = \theta_{s,T} F(\mathbf{S}_s) \quad (12)$$

$$\mathbf{Y}_t = \theta_{t,T} H(\mathbf{S}_t) \quad (13)$$

$$\mathbf{Y}_{st} = \theta_{st,T} J[F(\mathbf{S}_s), H(\mathbf{S}_t)] \quad (14)$$

式中: $\theta_{s,T}$ 、 $\theta_{t,T}$ 和 $\theta_{st,T}$ 分别为任务标签 \mathbf{Y}_s 、 \mathbf{Y}_t 和 \mathbf{Y}_{st} 的学习投影参数。

每个样本的编码损失和鉴别损失定义为

$$l_{\varepsilon\theta}(\mathbf{S}_s, \mathbf{S}_t, y) = y[\mathbf{Y}_s(\mathbf{S}_s) + \mathbf{Y}_t(\mathbf{S}_t) + \mathbf{Y}_{st}(\mathbf{S}_s, \mathbf{S}_t)] \quad (15)$$

$$l_D(\mathbf{S}_s, \mathbf{S}_t, y) = h[y\mathbf{Y}_s(\mathbf{S}_s)] + h[y\mathbf{Y}_t(\mathbf{S}_t)] + h[y\mathbf{Y}_{st}(\mathbf{S}_s, \mathbf{S}_t)] \quad (16)$$

式中: $l_{\varepsilon\theta}$ 为一个样本对应的编码损失; l_D 为一个样本对应的鉴别损失; y 为模型输出, 且 $y \in \{-1, 1\}$; $h(t)$ 为正则化函数, $h(t) = \max(0, 1-t)$ 。

结合式(11)定义的目标函数, 可得总编码损失为

$$L_{\varepsilon\theta}[P(\mathbf{S}_s), P(\mathbf{S}_t)] = E_{\mathbf{S}_s \sim P(\mathbf{S}_s), \hat{\mathbf{S}}_t \sim \varepsilon(\mathbf{S}_s)} [l_{\varepsilon\theta}(\mathbf{S}_s, \hat{\mathbf{S}}_t, 1)] + E_{\mathbf{S}_t \sim P(\mathbf{S}_t), \hat{\mathbf{S}}_s \sim \vartheta(\mathbf{S}_t)} [l_{\varepsilon\theta}(\hat{\mathbf{S}}_s, \mathbf{S}_t, -1)] \quad (17)$$

式中: $L_{\varepsilon\theta}$ 为样本总编码损失。

同理, 可得总鉴别损失为

$$L_D[P(\mathbf{S}_s), P(\mathbf{S}_t)] = E_{\mathbf{S}_s \sim P(\mathbf{S}_s), \hat{\mathbf{S}}_t \sim \varepsilon(\mathbf{S}_s)} [l_D(\mathbf{S}_s, \hat{\mathbf{S}}_t, 1)] + E_{\mathbf{S}_t \sim P(\mathbf{S}_t), \hat{\mathbf{S}}_s \sim \vartheta(\mathbf{S}_t)} [l_D(\hat{\mathbf{S}}_s, \mathbf{S}_t, -1)] \quad (18)$$

式中: L_D 为样本总鉴别损失。

函数中 \mathbf{S}_s 和 \mathbf{S}_t 作为图像输入, 优化 ε 和 ϑ 中参数以最小化损失 $L_{\varepsilon\theta}$, 编码损失 $L_{\varepsilon\theta}$ 训练这两个模块从而引导鉴别器舍弃错误信号, 实际上迫使 \mathbf{S}_s 和 \mathbf{S}_t 创建匹配的联合数据潜在分布。优化 D 中参数以最小化损失 L_D , 鉴别损失 L_D 直观地训练鉴别器区分来自编码器传来的两个联合数据潜在分布。

3 次同步振荡源定位模型构建

3.1 样本空间构建

取少量实际系统发生次同步振荡的数据构成目标域, 仿真系统模拟 PMSG 接入弱电网引发扰动源, 生成的大量次同步强迫振荡数据构成源域。具体步骤如下:

1) 源域基本构建

模拟固定时长和固定步长的出口数据, 为体现模型的有效性, 考虑扰动所在位置、输入类型以及负荷水平等参数的变化, 在不同 PMSG 的控制环节的输入上注入不同频率和幅值的正弦扰动信号。仿真记录的出口数据大致分为三类: 正常运行状态、次同步振荡状态和正常运行转入次同步振荡状态。正常运行时, 在不影响系统的情况下, 随机时间节点改变负荷水平以及开关状态, 得到多组正常运行的数据; 模拟单台 PMSG、多台 PMSG 以及 PMSG 之间耦合引发的次同步振荡, 随机时间节点注入扰动信号, 得到多组次同步振荡状态的数据; 基于正常运行状态的模拟方法, 随机时间节点接入能引发次同步振荡的机组, 使其与弱电网、不同的 PMSG 耦合, 得到多组正常运行转入次同步振荡状态的数据。汇集三类数据, 形成大量包含有功功率 P 、无功功率 Q 和节点电压 V 的源域样本集 $\mathbf{X}_s = [P_s, Q_s, V_s]$, 对应源域标签下 $\mathbf{Y}_s = [1, 2, \dots, m]$, 对训练集和测试集进行比例划分。

2) 目标域基本构建

基于源域仿真的步长和时长, 同样分为三类进行记录。调节风机出力和系统参数、改变耦合关系和振荡机组位置, 仿真形成少量包含有功功率 P 、无功功率 Q 和节点电压 V 的目标域样本集 $\mathbf{X}_t = [P_t, Q_t, V_t]$, 对训练集和测试集进行比例划分。

3) 图像化处理

为适应视觉领域的训练, 需要将出口数据集 $\mathbf{X}_s = [P_s, Q_s, V_s]$ 和 $\mathbf{X}_t = [P_t, Q_t, V_t]$ 进行图像化处理, 以满足模型的输入条件, 并保证数据的时频特性, 流程如图 5 所示。

为保证振荡特征的有效性, 利用压缩感知技术将样本集 $\mathbf{X}_s = [P_s, Q_s, V_s]$ 和 $\mathbf{X}_t = [P_t, Q_t, V_t]$ 进行数据压缩和图像变换。首先, 对数据进行压缩处理, 得到具备次同步振荡特征的观测信号样本集 \mathbf{X}'_s 和 \mathbf{X}'_t ; 然后, 为适应视觉领域的训练, 将压缩处理后的特征样本集作为 STFT 的输入, 并确定进行 STFT 需要的窗口函数类型、长度和重叠部分等; 最后, 根据所采用的窗口函数类型, 将预处理后的数据传入 STFT 算法, STFT 将时序数据转换为特征映射图 \mathbf{S}_s 和 \mathbf{S}_t , 进行伪彩

色处理。




图 5 STFT 图像生成过程

Fig. 5 STFT image generation process

3.2 次同步振荡源定位流程

次同步振荡源定位流程分为三个部分:样本集构建、预训练模型迁移和模型运用,如图 6 所示。

1) 样本集构建

搭建仿真系统和实际系统,模拟不同工况,包括风机控制环节参数、额定功率以及电网强度,分别记录多组端口参数作为源域和目标域。随后按照比例分配原则为源域和目标域进行划分,通过压缩感知技术和 STFT 生成伪彩色时频图,并为源域定义好分类标签。

2) 预训练模型迁移

基于 2.2 节任务关系,使分类器能准确定位次同步振荡源;再将有关标签的源域样本和无标签的目标域样本输入到特征提取器,两域共享特征经过编码函数编译的特征矩阵,同时将共享后打乱的特征矩阵输入到域鉴别器中,通过挖掘联合潜在分布特征,鉴别出源域与目标域之间的潜在区别,并对源域和目标域进行域分类。

3) 模型运用

为验证训练得到的次同步振荡源定位模型的准确性,从目标域中划分少量样本作为验证集,保留模型权重和网络结构,将验证集输入到模型中,得到相应标签来判断模型是否符合预期,验证模型对无标签数据的识别力,从而使模型快速识别实际系统次同步振荡源。

4 仿真分析

基于 Matlab/Simulink 搭建仿真系统,如图 7 所示。该四机两区系统由四台 PMSG 以及输电线

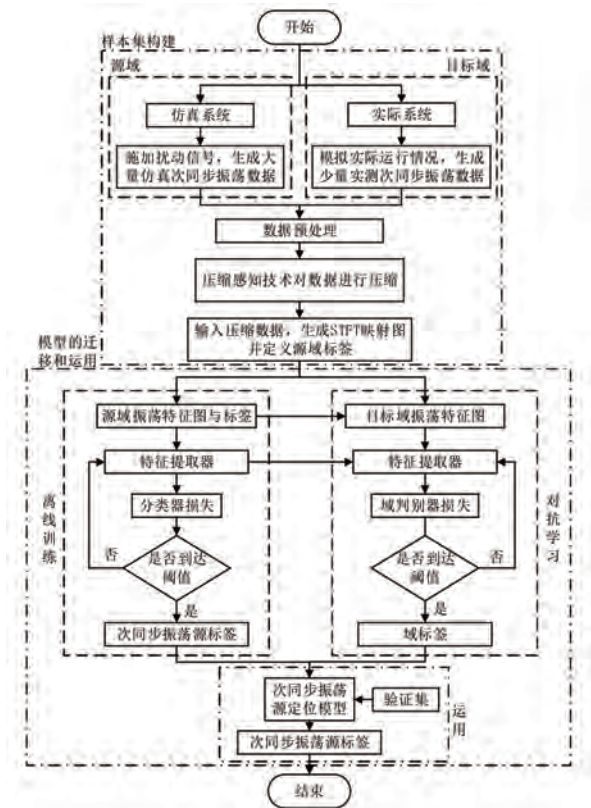


图 6 次同步振荡源定位流程图

Fig. 6 Sub-synchronous oscillation sources localization flowchart

路构成,其中 PMSG1 和 PMSG2 组成等效风电场 1, PMSG3 和 PMSG4 组成等效风电场 2。运行仿真系统,记录每台 PMSG 的出口数据,包括有功功率、无功功率以及节点电压,为后续研究提供数据支撑。




图 7 四机两区系统示意图

Fig. 7 Schematic diagram of the four-machine two-zone system

4.1 参数设置

考虑实际电力系统运行工况的多样性,发生次同步振荡机理情况复杂,仿真模型往往无法完全模拟实际多变的情况,且仿真模型模拟实际情况时耗时太久,不利于机器进行大量的学习。为此,通过仿真模拟实际发生次同步振荡得到的风

机出口数据作为无标签待学习的目标域;在不同 PMSG 出口附加噪声和扰动得到的出口数据作为源域,以此弥补实际振荡数据匮乏的不足。具体按照如下规则设置。

1) 按照规则调整振荡源风机控制参数,在某一时刻风机接入电网形成强交互关系诱导引发次同步振荡,并记录振荡源风机参数。其他正常风机参数在正常范围内调节,保持系统总出力不变,调整机组额定出力在 0.9 p.u. ~ 1.1 p.u. 内浮动,调节输电线路阻抗值以模拟不同的电网强度,得到少量模拟实际的数据。具体系统参数如表 1 所示。

2) 在不同 PMSG 出口母线处注入频率为 15 Hz~35 Hz 的正弦扰动信号,扰动幅值为 0.01~0.05。得到若干个运行点模拟发生次同步振荡的情况。仿真系统数据采集的采样频率为 2 kHz,采样时间为 2 s。

3) 对 ε 和 ϑ 编码器进行对称设置。 ε 的架构是用于图像分类的 ResNet18 网络, ε 通过全局平均池化输出后连接具有 2 个残差块的 4 层感知器,含 4 096 个隐藏层。取分辨率为 256×256 的图像作为输入,包括跳过连接和共享噪声嵌入。其余鉴别器 H 和 J 连接具有 4 个残差块的 8 层感知器,含 2 048 个隐藏层。

表 1 直驱风机并网系统参数

Tab. 1 Parameters of direct-drive wind turbines grid-connected system

风机编号	参数名称	参数值
正常机组	发电机额定容量/kW	5
	发电机额定电压/V	690
	滤波电感/mH	0.395
	直流电容/mF	10
	变压器变比 K_1	35/220
	K_{p-L1}, K_{i-L1}	180, 3200
	K_{p1}, K_{i1}	2.6, 200
	K_{p2}, K_{i2}	11, 5
	K_{p3}, K_{i3}	11, 5
	发电机额定容量/kW	5
振荡源机组	发电机额定电压/V	690
	滤波电感/mH	0.395
	直流电容/mF	10
	变压器变比 K_1	35/220
	K_{p-L1}, K_{i-L1}	0.15~0.4, 20~40
	K_{p1}, K_{i1}	0.15~0.3, 40~60
	K_{p2}, K_{i2}	11, 5
	K_{p3}, K_{i3}	11, 5

采集风机出口母线的有功功率作为本次算例

的数据样本;施加扰动信号得到的大量次同步振荡数据经处理后作为源域;模拟实际运行情况得到的少量振荡数据经处理后作为目标域。具体过程如下所示:

1) 源域:按照前述源域构建方法,采集 PMSG 出口有功数据形成源域数据集 $X_s = [P_{s1}, P_{s2}, P_{s3}, P_{s4}]$,并定义振荡源标签 $Y_s = [1, 2, 3, 4]$;利用压缩感知技术对有功功率信号进行 10 倍压缩,得到低维观测信号 X'_s ,将 X'_s 输入到 STFT 函数进行变换,确定函数窗为汉宁窗,窗长取 0.8,采样点数为 400;再对特征图进行伪彩色处理,得到具备次同步振荡特征的三通道图像 S_s ;最终得到 6 400 个样本图片,将图片按比例划分为 5 120 个训练样本和 1 280 个测试样本。

2) 目标域:同理,采集 PMSG 出口有功数据形成目标域数据集 $X_t = [P_{t1}, P_{t2}, P_{t3}, P_{t4}]$,目标域作为对抗迁移学习的对象,对其进行未知标签的对抗式学习。因目标域样本集较少,验证时,要求较少的样本需要尽可能覆盖大多数情况。最终得到 1 600 个样本图,其中 1 280 个样本图用于模型泛化训练,320 个样本图用于验证。

4.2 模型训练结果

为验证本文提出的次同步振荡源识别的有效性,计算机采用 i5-12600kf 处理器,2×8 G 内存,英伟达 RTX3070 的 GPU,在 window11 操作系统下进行。框架采用 python 的 tensorlow-gpu2.6.0 加速实现本文迁移学习算法,并结合学习结果进行相关验证。模型学习的批次大小设置为 32,学习次数为 500 次,调整学习率为 0.01。训练后的模型利用 TensorBoard 可视化工具对学习的准确率进行计算,结果如图 8 所示。

由图 8 可知,用对抗式迁移学习架构对源域与目标域进行训练时,准确率整体呈上升趋势,具有较强的适应能力。模型对源域次同步振荡映射图进行 150 个周期的学习,准确率能达到 95%;通过与目标域对抗学习,在训练 100 个周期时,准确率也能稳定达到 90% 以上。可见通过迁移学习,不仅能提高准确率,而且模型的迁移也展现出良好稳定的性能。

进一步对迁移学习前后的模型的具体变化进行分析,采用 t 分布-随机邻近嵌入 (t-distributed Stochastic Neighbor Embedding, t-SNE) 降维技术对




图 8 源域和目标域的准确率对比

Fig. 8 Comparison of the accuracy in source and target domains

迁移学习前后的特征层进行可视化展示,其原理是通过创建一个缩小的特征空间,将相似的样本聚类,非相似样本远离,从而直观体现迁移学习的效果。训练样本经迁移学习前后的域特征分布如图 9 所示。

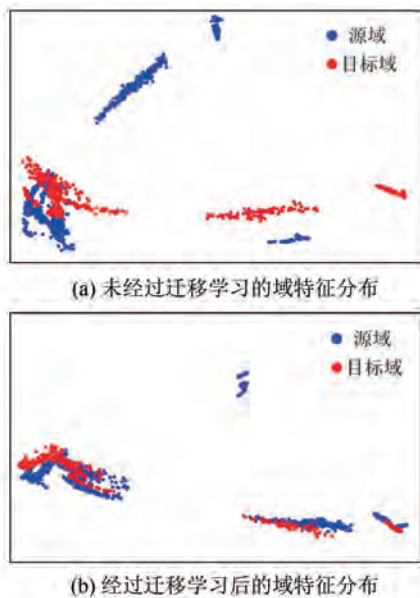


图 9 训练样本经迁移学习前后的域特征分布

Fig. 9 Domain feature distribution of training samples before and after transfer learning

图 9(a)为对抗式迁移学习前源域和目标域的特征分布,未经对抗训练时,两域无法相互适应,相似特征并未靠拢,但目标域样本的空间分布与源域有部分重合,即在次同步振荡映射图中两域存在部分共同特征。图 9(b)为源域和目标域经过对抗式迁移学习后的特征分布,经对抗训练后的特征散点分布已具备相似性特征,两域在学习过程中挖掘潜在特征,并相互靠拢,即便两域差

异并未完全消除,但对于分类任务而言,结合图 8 的准确率可知通过迁移学习模型有较好的泛化性,并具备较为准确的分辨能力。

为了更详细的分析新模型学习过程中图像特征分布,本文采用类激活映射(Class Activation Mapping, CAM)来展示模型对次同步振荡数据的特征学习状况。将 CAM 运用到迁移学习的最后一层特征层,通过划分特征层学习贡献大小,分数越高代表图片对应区域对网络的响应越高,最终用热力图呈现,如图 10 所示。上述分析证明了实际系统中发生次同步振荡时模型的实用性和泛化能力。




图 10 基于 CAM 的特征层热力图

Fig. 10 Thermal map of characteristic layer based on CAM

4.3 抗噪性能测试

在实际系统中,由于测量误差、通信延迟等影响,PMU 在测量时会存在量测噪声,影响定位方法的性能,因此本节测试注入噪声后的模型定位结果。根据 IEEE Std C37.118.1-2011 同步相量测量标准,PMU 同步相量的幅值测量误差小于 0.2%,信噪比大于 54 dB,为此在原始样本基础上注入 40 dB、50 dB 和 60 dB 的噪声,并采用算例训练的对抗式迁移模型进行准确率验证,结果如表 2 所示。

表 2 注入噪声的样本准确率

Tab. 2 Sample accuracy of injected noise

噪声/dB	准确率/%
40	91.36
50	94.55
60	95.98

当注入 40 dB、50 dB 和 60 dB 的噪声后,虽然相比原始样本准确率有所下降但样本总体的定位准确率依旧能达到 90% 以上,验证了该方法具有

较强的抗噪能力。总体样本的定位准确率分别为 93.91%、96.61% 和 97.52%, 与不含噪声样本的准确率 97.79% 相差较小。

4.4 传统迁移模型训练对比

为进一步评估对抗式迁移学习模型的性能, 将其与传统的 ResNet18 模型进行对比。针对传统的 ResNet18 模型, 选用与 4.1 节同样的源域和目标域样本集, 在环境和参数均相等情况下对其进行训练, 不同的是需要对目标域定义标签。对抗式网络与 ResNet18 的准确率对比如图 11 所示。由图 11 可知, 与传统网络架构相比, 本文网络架构的学习稳定性得到了大幅提升, 准确率也相对较高。




图 11 对抗式网络与 ResNet18 的准确率对比

Fig. 11 Accuracy comparison of adversarial network and ResNet18

通过监测训练过程中的准确率以及学习时长来反映模型的性能和收敛速度, 如表 3 所示。

表 3 对抗式网络与 ResNet18 的学习时长

Tab. 3 Learning duration of adversarial network and ResNet18

网络结构	训练次数/次	用时/s
对抗式	500	1 864.10
ResNet18	500	4 344.60

由表 3 可知, 本文所提对抗式迁移模型, 在准确率和训练时长上都更优, 原因可以从模型架构上来解释。

本文迁移学习的优势:

1) 模型采用对抗式学习架构。这种架构相较于通用的 ResNet18 模型能更快捕捉数据中的相关特征。

2) 模型通过监督学习, 省去传统迁移学习特征层繁琐和漫长的调节任务。

3) 待学习的目标域无需定义标签, 通过源域

大量地学习, 可实现领域自适应, 省去给目标域定义标签的任务, 节省了大量时间。

ResNet18 模型的局限性:

1) ResNet18 是一种广泛使用的架构, 并未专门针对电力系统振荡源识别进行设计。作为一个通用模型, ResNet18 可能无法很好地适应电力系统数据的特定特征, 尤其是与振荡模式有关的特征。

2) ResNet18 的架构虽然对各种图像相关任务非常有效, 但对于特定任务可能会过于复杂, 由此可能导致训练时间较长, 同时可能出现过拟合或不收敛的问题。

总之, 相对于传统模型, 本文所提的对抗式迁移学习模型在电力系统振荡源识别方面具有诸多优势。直观表现为更高的准确率和更优的性能, 也表明在复杂任务如振荡源识别中, 领域自适应模型的重要性。

5 结语

针对直驱风机与电网交互引发次同步振荡而影响电网安全的问题, 基于迁移学习方法提出一种新的学习架构。相较传统迁移学习模型, 本文所提方法在电力系统次同步振荡领域表现出更强的适应性, 同时能辐射到其他领域。为此, 本文提出以下展望:

1) 宽频振荡源识别的可行性。光伏、风电以及柔性直流输电工程等“双高”代表接入, 往往单一地分析一类振荡源已经无法满足实际需求, 本文方法对于宽频振荡源的识别及分类具有较高的参考价值。

2) 电力系统故障分类和识别的可行性。基于人工智能算法领域, 故障分类和识别的研究集中于传统深度学习或改进算法, 此类方法需要大量实测数据作为支撑, 学习周期长。此外构建模型时对模型架构要求高, 前期需耗费大量人力物力。本文方法可基于相似领域进行泛化学习, 节省了大量数据集构造时间。

综上所述, 本文所提的基于 STFT 和迁移学习的次同步振荡源定位方法在应对电力系统稳定性挑战方面具有一定的实际应用价值。基于压缩感知、STFT 图像转换以及对抗式迁移学习策略, 所提方法成功提升了振荡源定位的精准性和效

率。为电力系统稳定可靠地持续输电提供一种创新方法,也为人工智能融入新型电力系统提供了一种新的思路。

参考文献

- [1] 张天翼,王海风. 风电并入弱交流系统引发次同步振荡的研究方法综述[J]. 电力系统保护与控制, 2021, 49(16): 177-187.
ZHANG T Y, WANG H F. Research methods for subsynchronous oscillation induced by wind power under weak AC system: A review [J]. Power System Protection and Control, 2021, 49(16): 177-187.
- [2] 王渝红,王馨瑶,廖建权,等. 交直流电网宽频振荡产生、识别及抑制研究综述[J]. 高电压技术, 2023, 49(8): 3148-3162.
WANG Y H, WANG X Y, LIAO J Q, et al. Review of generation, identification and suppression of wide-band oscillation in AC-DC power system [J]. High Voltage Engineering, 2023, 49(8): 3148-3162.
- [3] 孙士奇,单俊豪,仇志华,等. 并联永磁同步风电机组小干扰稳定性分析[J]. 电机与控制应用, 2024, 51(3): 38-48.
SUN S Q, SHAN J H, ZHANG Z H, et al. Small signal stability analysis of parallel permanent magnet synchronous wind turbine [J]. Electric Machines & Control Application, 2024, 51(3): 38-48.
- [4] 陈剑,杜文娟,王海风. 基于对抗式迁移学习的含柔性高压直流输电的风电系统次同步振荡源定位[J]. 电工技术学报, 2021, 36(22): 4703-4715.
CHEN J, DU W J, WANG H F. Location method of subsynchronous oscillation source in wind power system with VSC-HVDC based on adversarial transfer learning[J]. Transactions of China Electrotechnical Society, 2021, 36(22): 4703-4715.
- [5] 薛静玮,林毅,唐雨晨,等. 基于 RSC 反馈线性化的含 SVG 双馈风机系统次同步振荡抑制[J]. 电机与控制应用, 2022, 49(7): 77-86.
XUE J W, LIN Y, TANG Y C, et al. Sub-synchronous oscillation mitigation of DFIG system with SVG based on RSC feedback linearization [J]. Electric Machines & Control Application, 2022, 49(7): 77-86.
- [6] XIE H, ZHAO Y G, WU X Y, et al. Unified AC/DC hybrid admittance modelling and oscillation stability analysis for interlinking voltage source converter system [J]. IET Renewable Power Generation, 2023, 17(16): 3755-3776.
- [7] 刘侃,贾祺,翟文超,等. 面向次同步振荡的直驱风电机组阻抗频率响应特性辨识[J]. 智慧电力, 2021, 49(9): 39-46.
LIU K, JIA Q, ZHAI W C, et al. Identification of impedance frequency response characteristics of PMSG for subsynchronous oscillation [J]. New Energy, 2021, 49(9): 39-46.
- [8] 刘普,崔艺博,刘兆峰,等. 基于阻抗分析法的并网变流器稳定性统一分析方法研究[J]. 电力系统保护与控制, 2023, 51(4): 114-125.
LIU P, CUI Y B, LIU Z F, et al. The unified analysis method of grid-connected converter stability based on impedance analysis [J]. Power System Protection and Control, 2023, 51(4): 114-125.
- [9] YAN G G, WANG Y P, YANG C, et al. Analysis of sub-synchronous oscillation characteristics of PMSGs based on transient energy [J]. Frontiers in Energy Research, 2023, 11(2): 1-12.
- [10] 曹娜,赵旭,于群. 基于暂态能量流的双馈风电机组强迫振荡源定位[J]. 电力系统自动化, 2020, 44(10): 103-110.
CAO N, ZHAO X, YU Q. Forced oscillation source location of doubly-fed wind turbine based on transient energy flow [J]. Automation of Electric Power Systems, 2020, 44(10): 103-110.
- [11] 姜涛,高洽,李筱静,等. 基于小波耗散能量谱的电力系统强迫振荡源定位[J]. 电工技术学报, 2023, 38(7): 1737-1750.
JIANG T, GAO H, LI X J, et al. Forced oscillation source location in power system using wavelet dissipation energy spectrum [J]. Transactions of China Electrotechnical Society, 2023, 38(7): 1737-1750.
- [12] 李洁,王海云,党晓圆. 基于行波理论的滤波器电能质量扰动控制仿真[J]. 计算机仿真, 2020, 37(1): 56-59+75.
LI J, WANG H Y, DANG X Y. Simulation of filter power quality disturbance control based on traveling wave theory [J]. Computer Simulation, 2020, 37(1): 56-59+75.
- [13] 田桂珍,卢栋,刘广忱,等. 基于零相位低通滤波器的混合储能平抑直驱风电机组功率波动控制策略的研究[J]. 太阳能学报, 2021, 42(06): 72-78.

- TIAN G Z, LU D, LIU G C, et al. Research on control strategy of suppressing power fluctuation of direct-drive wind power system with hybrid energy storage based on zero-phase low-pass filter [J]. *Acta Energetica Solaris Sinica*, 2021, 42(6): 72-78.
- [14] 栾某德, 甘德强, 李振垚, 等. 基于模型响应功率谱密度预测的强迫振荡扰动源设备定位法[J]. *电力系统自动化*, 2022, 46(22): 111-119.
- LUAN M D, GAN D Q, LI Z Y, et al. Location method for forced oscillation source device based on power spectral density prediction of model responses [J]. *Automation of Electric Power Systems*, 2022, 46(22): 111-119.
- [15] JAFARIGIV D, SHESHYKANI K, KASSOUF M, et al. Countering FDI attacks on DERs coordinated control system using FMI-compatible simulation [J]. *IEEE Transactions on Smart Grid*, 2021, 12(2): 1640-1650.
- [16] 张程, 邱炳林, 刘佳静. 基于 EFEMD-HT 能量法的电力系统低频振荡模态辨识[J]. *南方电网技术*, 2022, 16(3): 48-57.
- ZHANG C, QIU B L, LIU J J. Power system low frequency oscillation modal identification based on EFEMD-HT energy algorithm [J]. *Southern Power System Technology*, 2022, 16(3): 48-57.
- [17] PAREDE V T, AOKI A R, TEIXEIRA M D, et al. Electrical event detection and monitoring data storage from wide area measurement system [J]. *Energies*, 2023, 16(4): 1713-1713.
- [18] 李悦蕾, 张放, 申洪明, 等. 基于同步相量频谱拟合的电力系统次/超同步振荡的动态参数辨识[J/OL]. *中国电机工程学报*, 2023-10-13. <http://kns.cnki.net/kcms/detail/11.2107.TM.20231011.1401.002.html>.
- LI Y L, ZHANG F, SHEN H M, et al. Dynamic parameter identification with synchronous spectrum fitting technique for sub / supersynchronous oscillations in power systems [J/OL]. *Proceedings of the CSEE*, 2023-10-13. <http://kns.cnki.net/kcms/detail/11.2107.TM.20231011.1401.002.html>.
- [19] 李莹, 富亚洲, 王官宏, 等. 电力系统超低频频率振荡分析及扰动源定[J]. *电网技术*, 2023, 47(5): 1770-1780.
- LI Y, FU Y Z, WANG G H, et al. Ultra-low frequency oscillation analysis and location in power system [J]. *Power System Technology*, 2023, 47(5): 1770-1780.
- [20] 戴珍, 曹尚, 黄文琦, 等. 基于广域测量数据驱动的电力系统强迫振荡源定位[J]. *电力信息与通信技术*, 2023, 21(6): 24-30.
- DAI Z, CAO S, HUANG W Q, et al. Forced oscillation location in power systems using wide area measurement data-driven method [J]. *Electric Power Information and Communication Technology*, 2023, 21(6): 24-30.
- [21] 崔昊, 冯双, 陈佳宁, 等. 基于自编码器与长短期记忆网络的宽频振荡广域定位方法[J]. *电力系统自动化*, 2022, 46(12): 194-201.
- CUI H, FENG S, CHEN J N, et al. Wide-area location method of wide-band oscillations based on autoencoder and long short-term memory network [J]. *Automation of Electric Power Systems*, 2022, 46(12): 194-201.
- [22] 王渝红, 李晨鑫, 周旭, 等. 压缩感知和图卷积神经网络相结合的宽频振荡扰动源定位方法[J]. *高电压技术*, 2024, 50(3): 1080-1089.
- WANG Y H, LI C X, ZHOU X, et al. Localization method of wide-band oscillation disturbance sources based on compressed sensing and graph convolutional neural networks [J]. *High Voltage Engineering*, 2024, 50(3): 1080-1089.
- [23] YAO M, ZHE Y, NING L, et al. Time series classification for locating forced oscillation sources [J]. *IEEE Transactions on Smart Grid*, 2021, 12(2): 1712-1721.
- [24] 郝琪, 刘崇茹, 王瑾媛, 等. 基于深度子领域自适应的直驱风机次/超同步振荡源定位[J]. *电力系统自动化*, 2023, 47(17): 27-37.
- HAO Q, LIU C R, WANG J Y, et al. Location of sub-/super-synchronous oscillation source for direct-driven wind turbines based on deep subdomain adaptation [J]. *Automation of Electric Power Systems*, 2023, 47(17): 27-37.
- [25] 陈剑, 杜文娟, 王海风. 采用深度迁移学习定位含直驱风机次同步振荡源机组的方法[J]. *电工技术学报*, 2021, 36(1): 179-190.
- CHEN J, DU W J, WANG H F. A method of locating the power system subsynchronous oscillation source unit with grid-connected PMSG using deep transfer learning [J]. *Transactions of China Electrotechnical Society*, 2021, 36(1): 179-190.
- [26] 黄睿. 含风机并网的电力系统低频振荡源定位方

- 法研究[D]. 北京:华北电力大学, 2020.
- HUANG R. Research on location method of low frequency oscillation source in power systems with wind power integration [D]. Beijing: North China Electric Power University, 2020.
- [27] 冯双, 陈佳宁, 汤奕, 等. 基于 SPWVD 图像和深度迁移学习的强迫振荡源定位方法[J]. 电力系统自动化, 2020, 44(17): 78-87.
- FENG S, CHEN J N, TANG Y, et al. Location method of forced oscillation source based on SPWVD image and deep transfer learning [J]. Automation of Electric Power Systems, 2020, 44(17): 78-87.
- [28] 周蕾蕾, 孙世林, 张宗堂, 等. 基于 STFT-FRFT 的声纳脉冲信号实时检测和参数估计[J]. 电子信息对抗技术, 2023, 38(6): 37-44.
- ZHOU L L, SUN S L, ZHANG Z T, et al. Real-time detection and parameter estimation of sonar pulse signal based on STFT-FRFT [J]. Electronic Information Warfare Technology, 2023, 38(6): 37-44.
- [29] 周旷, 姜名. 基于迁移学习的小样本目标识别研究进展与展望[J]. 航空科学技术, 2023, 34(2): 1-9.
- ZHOU K, JIANG M. Research progress and prospect of small sample target recognition based on transfer learning [J]. Aeronautical Science and Technology, 2023, 34(2): 1-9.
- [30] 刘文元, 任必兴, 李海峰, 等. 直驱风电场和串补之间的次同步振荡风险[J]. 电力工程技术, 2022, 41(4): 25-32.
- LIU W Y, REN B X, LI H F, et al. Sub-synchronous oscillation risk between PMSG farm and series complement [J]. Electric Power Engineering Technology, 2022, 41(4): 25-32.
-
- 收稿日期:2024-01-21
收到修改稿日期:2024-04-10
作者简介:
刘志坚(1975-),男,博士,教授,研究方向为电力系统安全稳定分析、电力系统优化、电网智能化、电力设备智能检测及电力系统带电作业机器人等,248400248@qq.com;
* 通信作者:刘志坚(1975-),男,博士,教授,研究方向为电力系统安全稳定分析、电力系统优化、电网智能化、电力设备智能检测及电力系统带电作业机器人等,248400248@qq.com。

Localization Method for Sub-Synchronous Oscillation Sources Based on STFT Images and Transfer Learning

LIU Zhijian^{*}, HUANG Jian, LUO Jun

(School of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650500, China)

Key words: subsynchronous oscillation source; short-time Fourier transform; compressive sensing; mapping image; transfer learning

With the swift growth of global clean energy, wind power is gradually replacing traditional fossil fuel-based electricity generation. However, this transition presents unprecedented challenges to power system stability, particularly in integrating large-scale wind power. The connection strength at the receiving end diminishes, increasing the risk of sub-synchronous oscillations transmitted over long distances. Evaluating and identifying oscillation sources are crucial for ensuring power system security.

Currently, oscillatory source identification methods can be divided into two categories. The first category is numerical simulation methods based on mechanism analysis. However, in the face of increasingly complex actual systems and diverse operating conditions, physical mechanism-based models cannot simulate multiple operating condition-induced oscillations at the same time. The second category is based on data-driven methods, combining

measurement devices and numerical algorithms with physical models. Yet, as power grids expand, errors in calculations become significant, challenging accurate source localization.

To address the subsynchronous oscillations induced by direct-drive wind turbines connected to a grid, a short-time Fourier transform (STFT) image and transfer learning based subsynchronous oscillation source localization method is proposed. The process of transfer learning is shown in Fig.1. Firstly, the signals are converted into mapping images with time-frequency domain characteristics using compressed sensing techniques and STFT processing. The adversarial transfer learning network structure is used to extend the simulated data to the real system data, overcoming the limitation of scarce actual oscillation samples. The proposed method is validated using an actual power system simulation model, indicating more accurate positioning within a shorter timeframe.

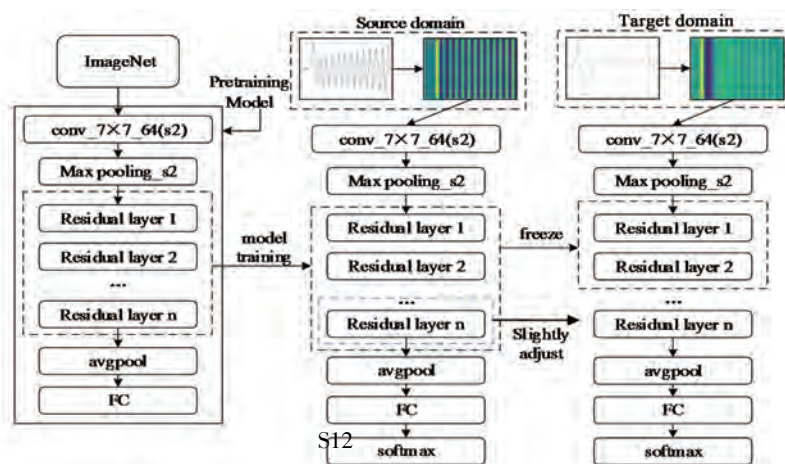


Fig. 1 Process of transfer learning