

DOI: 10.19783/j.cnki.pspc.240251

基于短时傅里叶变换和两阶段深度迁移学习的 多频段振荡源定位

余明¹, 姚伟¹, 赵一帆¹, 石重托¹, 刘海光², 陈汝斯², 李大虎³, 文劲宇¹

(1. 华中科技大学电气与电子工程学院, 湖北 武汉 430074; 2. 国网湖北省电力有限公司电力科学研究院, 湖北 武汉 430077; 3. 国网湖北电力有限公司, 湖北 武汉 430077)

摘要: 随着以风光为代表的新能源发电大规模并入电力系统以及大型水轮机组的新型调速器的投入使用, 新型电力系统的振荡从传统的低频振荡扩展到多频段振荡, 准确定位多频段振荡源是抑制不利影响扩大的关键手段。基于此, 提出了一种基于短时傅里叶变换和两阶段深度迁移学习的定位方法。首先, 该方法将系统中发电机的有功量测信号通过短时傅里叶变换处理转换得到时频表征矩阵, 并通过线性映射将其转化为特征图像, 从而将定位问题转化为图像分类问题。然后, 将所得到的图像输入到基于 ResNet50 的两阶段分类器。第一阶段用于确定振荡的类型, 第二阶段则用于确定该类型振荡源的具体位置。采用融入图像知识学习的迁移学习进一步提高训练效率和定位准确率。含风电的新英格兰系统和湖北电网算例仿真结果均表明: 相较于支持向量机、决策树和单阶段迁移学习方法, 所提方法在面对噪声时兼顾较高的准确性和鲁棒性。

关键词: 多频段振荡; 短时傅里叶变换; 特征图像; 深度迁移学习; 振荡源定位

Multi-frequency band oscillation source location based on STFT and two-stage deep transfer learning

YU Ming¹, YAO Wei¹, ZHAO Yifan¹, SHI Zhongtuo¹, LIU Haiguang², CHEN Rusi², LI Dahu³, WEN Jinyu¹

(1. School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China; 2. State Grid Hubei Electric Power Research Institute, Wuhan 430077, China; 3. State Grid Hubei Electric Power Co., Ltd., Wuhan 430077, China)

Abstract: With the large-scale integration of new energy, represented by wind and solar power, into the system and the use of new governors of high-power turbine units, the oscillations in the new power system have expanded from the traditional low frequency oscillation to multi-frequency band oscillation. Accurately locating the oscillation source is a key means to suppress the expansion of adverse effects. Thus a novel location method based on short-time Fourier transform (STFT) and two-stage deep transfer learning is proposed. In this method, the active power measurement signals of all generators are converted into time-frequency representation matrices by STFT processing, and the matrices are transformed into feature images by linear mapping, so that the location problem is transformed into an image classification problem. The feature images are then fed into a ResNet50-based two-stage classifier. The first stage is used to determine the type of oscillation, while the second stage is used to locate the source. Transfer learning integrated with image knowledge learning is adopted to further improve the training efficiency and localization accuracy. Simulation results for the New England system with wind power and the Hubei power grid show that, compared to the support vector machine, decision tree and single-step transfer learning method, the proposed method has higher accuracy and robustness in the presence of noise.

This work is supported by the Science and Technology Project of the Headquarters of State Grid Corporation of China (No. 5100-202099522A-0-0-00).

Key words: multi-frequency band oscillation; short-time Fourier transform (STFT); feature image; deep transfer learning; oscillation source location

基金项目: 国家电网公司总部科技项目资助“新一代人工智能技术在未来电网安全分析与决策中的应用”(5100-202099522A-0-0-00)

0 引言

传统电力系统的振荡一般为低频振荡 (low frequency oscillation, LFO), 它主要由电力系统的负阻尼效应而产生。随着电力系统的不断发展, 一方面大容量水电机组引入电力系统, 调速器参数设置不合理可能会引起超低频振荡 (ultra-low frequency oscillation, ULFO)^[1]; 另一方面, 以风光为代表的大规模新能源接入电力系统可能产生次同步振荡 (sub-synchronous oscillation, SSO)^[2-4], 这些新振荡的出现使得新型电力系统的振荡呈现多频段振荡的特点, 这些多频段振荡将严重威胁电力系统稳定运行。迅速准确地定位振荡源的位置是解决和应对电力系统中多频段振荡问题的关键前提条件^[5-6]。

传统的多频段振荡源定位方法主要依赖电气设备的物理特性, 通过对电力系统中多频段振荡问题进行数学建模, 再使用电力系统的动态模型和各种振荡的物理特性来确定扰动位置^[7-9]。这些基于物理机理与数学模型的振荡源定位方法的准确性取决于电力元件建模的精细程度和物理假设的可靠性。然而, 各种电气设备具有强烈的非线性, 同时其动态特性受频率影响, 所以准确获得各种电气设备的结构和参数是困难的。因此, 从数学模型和物理机理的角度来看, 运用数学建模方法实现振荡源定位是较为困难的^[10], 该方法主要用于进行多频段振荡事故发生后的故障分析^[11]。

人工智能可以避免数学建模准确性低的问题, 并且具有自我学习能力与更好的适应性, 可有效应用于电力系统中的各种问题^[12-14]。基于人工智能方法的多频振荡源定位方法可以分析系统中的大量数据及其与振荡位置的关系, 从而确定振荡分布的位置^[15]。文献[16]在特征椭圆的高维空间完成特征提取, 利用决策树模型定位低频振荡源。文献[17]使用稀疏贝叶斯学习方法判断发电机等效阻尼系数的正负, 从而定位负阻尼低频振荡源。文献[18]对仿真系统与实际系统的振荡特征进行对抗学习, 运用瞬时电气量数据提取特征, 实现了次同步振荡源的定位。文献[19]将有功曲线转换成平滑伪 Wigner-Ville 图像, 利用迁移学习完成低频振荡源定位。目前的振荡源定位方法通常仅针对特定种类的振荡源^[17-22], 而缺少对超低频振荡、低频振荡与次同步振荡同时定位的相关研究。

基于此, 本文提出了一种基于短时傅里叶变换 (short-time Fourier transform, STFT) 和两阶段深度迁移学习的多频段振荡源定位方法。该方法将多频段振荡事故曲线换为图像, 从而将复杂的振荡源定位

问题转化为图像分类问题, 利用具有强大图像识别能力的深度迁移学习方法处理该问题。将所得到的特征图像输入到本文所提基于 ResNet50 的两阶段分类器, 其中第一阶段用于确定振荡的类型, 第二阶段则用于确定该类型振荡源的具体位置, 不同定位器具有分析不同频段的定位图像特征的能力, 因此对于超低频振荡、低频振荡与次同步振荡, 本文所提方法能够有针对性地进行定位, 从而提高了定位的准确性。

1 基于短时傅里叶变换与两阶段迁移学习的多频段振荡源定位算法框架

本文提出的基于两阶段深度迁移学习的多频段振荡源定位算法框架如图 1 所示。振荡定位算法分为第一阶段分类模型与第二阶段定位模型两个阶段, 其中, 第二阶段定位模型又包括 ULFO 定位模型、LFO 定位模型与 SSO 定位模型, 这 4 个模型均是基于 ResNet50 网络所构建。

该算法的主体框架如下: 首先使用同步向量测量装置 (phasor measurement unit, PMU) 获取整个系统所有发电机的有功功率量测量值, 使用 STFT 与色彩线性映射将其转换成第一阶段分类图像, 然后将第一阶段分类图像输入训练好的第一阶段分类模型进行分类, 判断该振荡样本是属于无振荡、超低频振荡、低频振荡或者次同步振荡; 根据分类结果, 选择生成相对应的第二阶段定位图像, 并将该定位图像输入至对应的第二阶段定位模型进行具体定位, 输出振荡源定位结果; 在线定位产生的新样本数据将被纳入新的样本数据集, 使用迁移学习进一步更新模型, 持续改进两阶段分类模型的性能。

在整个两阶段定位算法投入使用之前, 历史记录的数据或仿真模型生成的数据被用作多频段振荡的样本集, 使用该样本集对第一阶段分类模型和第二阶段 ULFO 定位模型、LFO 定位模型与 SSO 定位模型 4 个模型使用迁移学习分别进行离线训练。

1.1 基于 STFT 的特征图像样本生成

采用 STFT 对 PMU 录波数据进行处理, STFT 是一种常用的信号分析方法, 具备对信号在时间域和频率域同时进行分析的能力。STFT 将信号划分为多个时间窗口, 并对每个窗口应用傅里叶变换, 从而得到信号在频率域中表示。对于时域信号 $y(t)$ 进行 STFT 时, 可以用式(1)表示。

$$S_y(t, \omega; h) = \int_{-\infty}^{+\infty} y(\tau) h^*(\tau - t) e^{-j2\pi\omega\tau} d\tau \quad (1)$$

式中: $S_y(t, \omega; h)$ 为时域信号 $y(t)$ 的 STFT 变换; t 为时间; ω 为频率; h 为进行 STFT 时所用的窗函数,

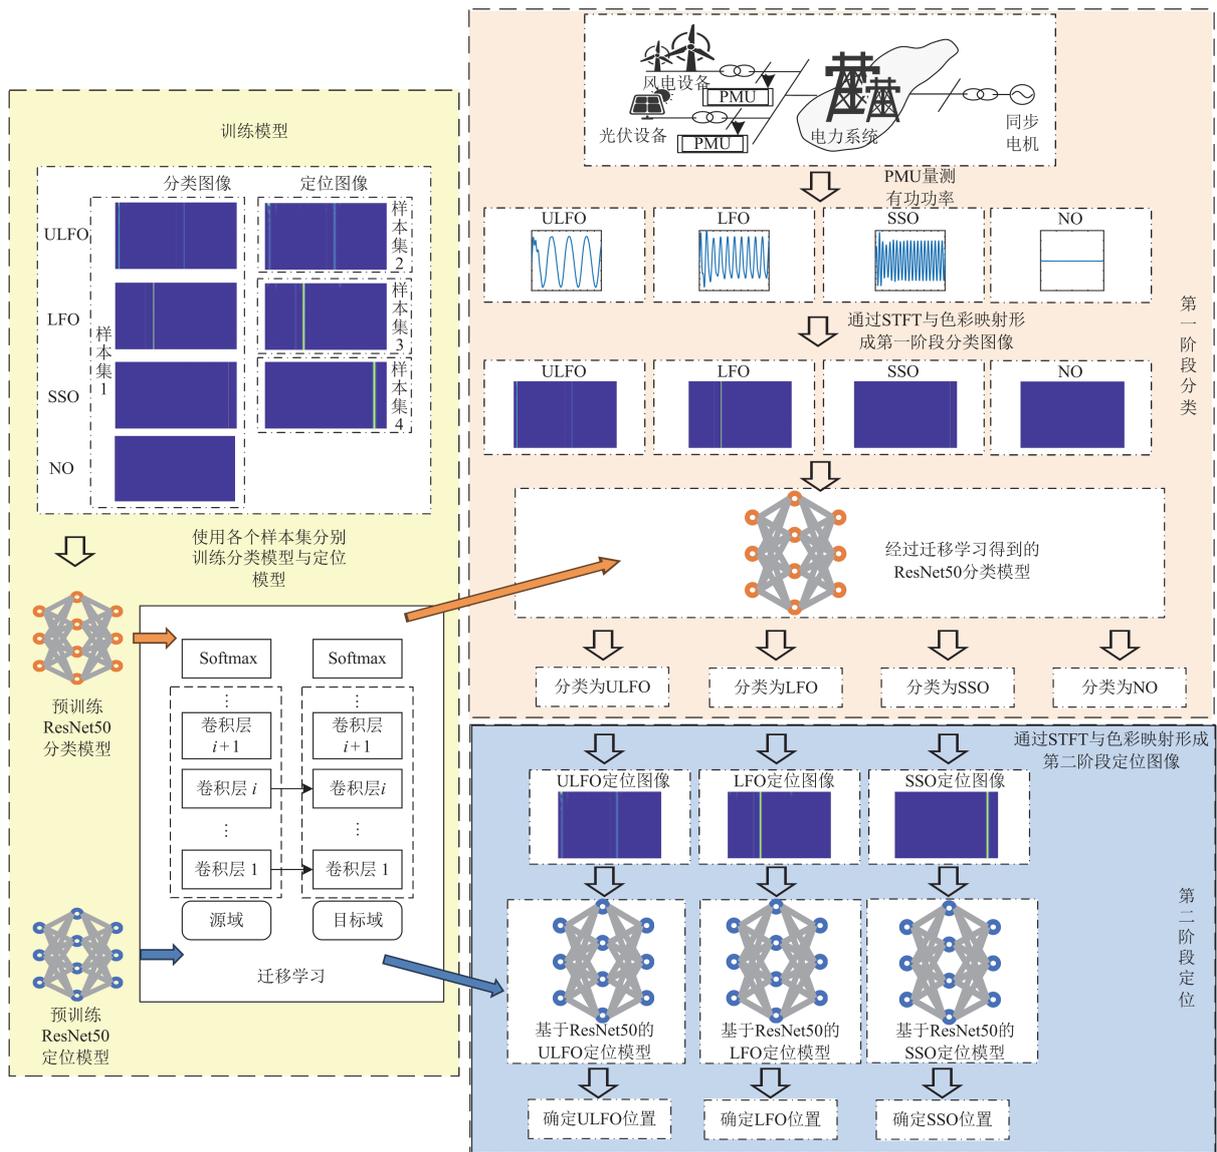


图 1 基于 STFT 和两阶段深度迁移学习的多频段振荡源定位框架图

Fig. 1 Framework diagram of the multi-frequency oscillation source location algorithm based on STFT and two-stage deep transfer learning

用于将信号切分成较短的时间段； h^* 为其共轭。

为了提取信号的能量时频分布特征，计算式(1)的模的平方，从而定义时频表征(time frequency representation, TFR)矩阵的每个元素，如式(2)所示^[23]。

$$E_y(t, \omega) = \left| \int_{-\infty}^{+\infty} y(\tau) h^*(\tau - t) e^{-j2\pi\omega\tau} d\tau \right|^2 \quad (2)$$

TFR 矩阵 E_y 显示了信号在不同频率上的能量分布，通过观察 TFR 矩阵，可以了解信号中频率分量的强度和分布情况。

窗口长度的选择是信号分析中的一个重要考虑因素，它决定了时间和频率的分辨率。较短的窗口

长度提供更好的时间分辨率，并能检测到信号的快速变化。在本研究中，选择不同的窗口长度用于所需研究的 3 个频段进行 STFT 处理。对于 ULFO 与 LFO 的频率范围，选择较长的窗口长度以确保观察到较低频率信号中频率特征的微小变化。对于 SSO 的频率范围，选择较短的窗口长度有助于减少计算和数据负载，并允许对能量的时频分布进行定性分析，无需对具体频率参数进行定量分析。

对于每台发电机的有功功率振荡信号，分别使用 STFT 获取其 ULFO 频段、LFO 频段以及 SSO 频段的 TFR 矩阵 A 、 B 和 C ，其中，矩阵的第 i 行第

j 列的元素分别表示为 a_{ij} 、 b_{ij} 和 c_{ij} ，3 个 TFR 矩阵分别如式(3)一式(5)所示。

$$A = \begin{bmatrix} a_{1,1} & a_{1,2} & \cdots & a_{1,n_1} \\ a_{2,1} & a_{2,2} & \cdots & a_{2,n_1} \\ \vdots & \vdots & & \vdots \\ a_{m,1} & a_{m,2} & \cdots & a_{m,n_1} \end{bmatrix} \quad (3)$$

$$B = \begin{bmatrix} b_{1,1} & b_{1,2} & \cdots & b_{1,n_2} \\ b_{2,1} & b_{2,2} & \cdots & b_{2,n_2} \\ \vdots & \vdots & & \vdots \\ b_{m,1} & b_{m,2} & \cdots & b_{m,n_2} \end{bmatrix} \quad (4)$$

$$C = \begin{bmatrix} c_{1,1} & c_{1,2} & \cdots & c_{1,n_3} \\ c_{2,1} & c_{2,2} & \cdots & c_{2,n_3} \\ \vdots & \vdots & & \vdots \\ c_{m,1} & c_{m,2} & \cdots & c_{m,n_3} \end{bmatrix} \quad (5)$$

对于有 N 台发电机的电力系统，在发生多频段振荡时，每台发电机对应 3 个 TFR 矩阵，即 A 、 B 与 C 。因此，通过连接每台发电机的 TFR 矩阵，可以用式(6)表示单一的振荡事件 O 。

$$O = [A^{(1)} B^{(1)} C^{(1)} \cdots A^{(N)} B^{(N)} C^{(N)}] \quad (6)$$

式中， $A^{(i)}$ 、 $B^{(i)}$ 与 $C^{(i)}$ 分别表示第 i 台发电机的 ULFO 频段 TFR 矩阵、LFO 频段 TFR 矩阵与 SSO 频段 TFR 矩阵。

仅关注超低频范围时，将 ULFO 频段的 TFR 矩阵相连接即可表示 ULFO 振荡事件，ULFO 样本 U 可以用式(7)表示。

$$U = [A^{(1)} A^{(2)} \cdots A^{(N-1)} A^{(N)}] \quad (7)$$

类似地，LFO 样本 L 与 SSO 样本 S 分别可以用式(8)和式(9)表示。

$$L = [B^{(1)} B^{(2)} \cdots B^{(N-1)} B^{(N)}] \quad (8)$$

$$S = [C^{(1)} C^{(2)} \cdots C^{(N-1)} C^{(N)}] \quad (9)$$

通过上述方法得到的 TFR 矩阵具有较大的尺寸，高精度地存储这些矩阵的每个元素将显著增加存储需求，并且将导致数据的传输和处理过程极为耗时，很难满足振荡监测的快速性需求，而将数据转换成图像格式能有效减小所需的存储空间。因此，在训练每个定位模型时，选择占用较小存储空间的图像作为训练样本^[20]。

本文将 TFR 矩阵转化成特征图像生成方法如下：首先，将每个 TFR 矩阵的元素按从大到小的顺序进行排序。然后，将排序后的列表线性映射到色彩谱图 `viridis colormap` 中，形成一个颜色查找表。再根据颜色查找表中的对应关系，将 TFR 矩阵的每个元素的对应位置填充成不同的颜色。根据这种方法，将 4 种 TFR 矩阵分别转换为分类图像与定位图像。以在 M2 处发生的 LFO 振荡事件为例，特征图像的生成流程如图 2 所示。

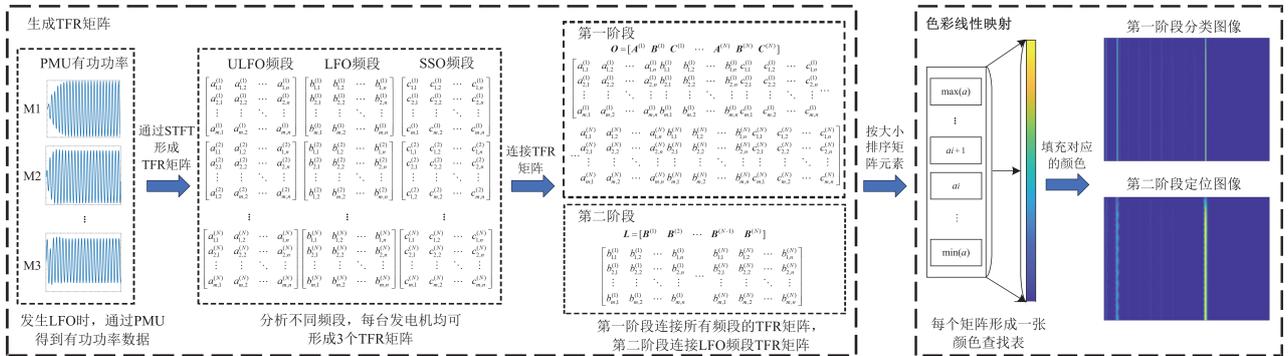


图 2 LFO 特征图像生成流程图

Fig. 2 Schematic diagram of formation of LFO feature image

该方法将 STFT 应用于所有发电机的有功功率振荡信号，并通过色彩线性映射将整个网络的振荡特征信息融合至一张特征图像中。生成的特征图像不仅包含了每台发电机自身振荡信号的时频分布的信息，同时还包含了各台发电机相互作用的时频关系的信息。因此，不同类型不同位置的振荡样本的特征能通过生成的特征图片表征出来，生成样本的同时完成了特征提取工程。

将矩阵 O 通过色彩映射得到第一阶段分类图像，并将其作为样本集 1。类似地，ULFO 振荡样本、LFO 振荡样本与 SSO 振荡样本通过色彩映射分别得到样本集 2、样本集 3 与样本集 4。

1.2 训练模型

分别采样样本集 1、样本集 2、样本集 3 与样本集 4 对算法中的第一阶段分类模型和第二阶段 ULFO 定位模型、LFO 定位模型与 SSO 定位模型 4 个模型

分别进行迁移学习, 主要步骤如下所述。

1) 使用迁移学习构建分类模型与定位模型, 导入预训练模型, 并冻结导入模型的部分层参数。

2) 将样本集划分为训练集和验证集。训练集用于训练定位模型, 而验证集用于评估训练得到的模型的准确性。

3) 如果验证集的定位准确性达到阈值, 说明模型的准确性符合要求, 可以投入使用。否则, 重新设置冻结层数, 使用训练集重新训练模型, 然后评估验证集的定位准确性, 直到达到目标阈值为止。

2 基于深度迁移学习 ResNet50 网络的振荡源定位模型

2.1 ResNet50 网络

ResNet50 是一个受深度残差网络概念启发的卷积神经网络, 其关键特点使用残差模块来构建模型。ResNet50 包含了 5 个阶段, 每个阶段包含了不同数量的残差块, 总共有 50 层卷积层^[24]。

残差模块的特征是引入恒等映射, 通过将输入直接添加到输出上, 学习残差部分即输入与期望输出之间的差异, 残差模块的数学表达如式(10)所示。

$$\begin{cases} y_l = h(x_l) + F(x_l, W_l) \\ x_{l+1} = f(y_l) \end{cases} \quad (10)$$

式中: x_l 为第 l 层的输入; x_{l+1} 为第 l 层的输出; W_l 为第 l 层的权重; F 表示残差块; $f(\cdot)$ 为 ReLU 函数; $h(x_l) = x_l$ 表示恒等映射。

因此, 特征从较浅层向较深层的传递可以用式(11)表示。

$$x_L = x_l + \sum_{i=l}^{L-1} F(x_i, W_i) \quad (11)$$

根据链式法则, 正向过程的梯度计算如式(12)所示。

$$\frac{\partial L_{\text{oss}}}{\partial x_i} = \frac{\partial L_{\text{oss}}}{\partial x_L} \cdot \frac{\partial x_L}{\partial x_i} = \frac{\partial L_{\text{oss}}}{\partial x_L} \cdot \left(1 + \frac{\partial}{\partial x_i} \sum_{i=l}^{L-1} F(x_i, W_i) \right) \quad (12)$$

式中, L_{oss} 为损失函数。

在反向梯度传播中, 残差块中任意两个层的梯度都等于 1, 即使梯度值很小, 也不会导致梯度消失, 有效地避免了梯度消失和梯度爆炸。

利用残差学习有潜力减少模型中的参数数量, 从而降低模型复杂度并减轻过拟合的风险。通过高效传播信息和学习残差组件, 残差学习可以更好地提取数据中的关键特征, 从而增强模型的泛化能力。ResNet50 网络引入了批归一化和全局平均池化技术, 有效地对神经网络中的激活输出进行归一化处理, 加速模型训练过程, 同时也提高了模型的泛化能力。

总之, ResNet50 网络在图像处理任务中表现出高准确性和泛化能力, 可以用于解决强迫振荡干扰源定位问题。

2.2 迁移学习

迁移学习旨在利用从一个任务中获得的知识和经验来有效地解决另一个相关任务, 可以避免对相似特征和模式进行冗余学习, 节省时间和计算资源, 基于 ResNet50 的迁移学习示意图如图 3 所示。为了将 ResNet50 网络应用于强迫振荡干扰源定位问题, 进行了以下设置和修改。

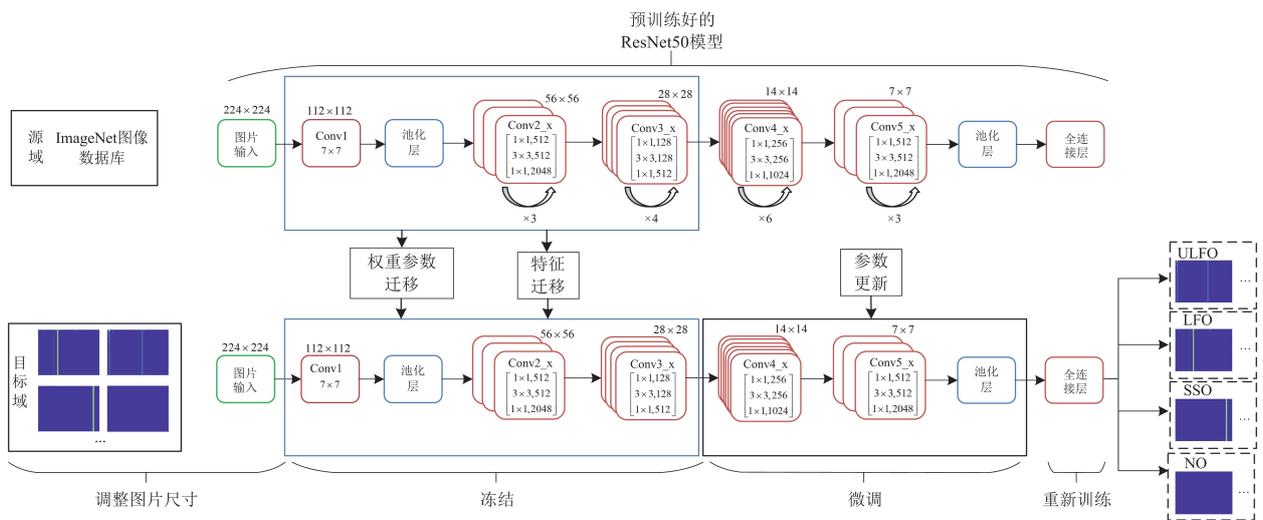


图 3 基于 ResNet50 的迁移学习示意图

Fig. 3 Schematic diagram of ResNet50 based transfer learning

1) 将特征图像的尺寸转换为大小为 224×224 的特征图像，作为 ResNet50 网络的输入图像。

2) 将 ResNet50 网络的 Softmax 层进行替换，使得该层的节点数与相应电力系统中的发电机数量相同。

将调整后的特征图像输入到修改后的网络中，并且全连接层的输出提供与特定电力系统发电机位置相关的预测结果，从而有助于定位干扰源的位置，提高模型的性能和泛化能力。

2.3 基于 STFT 和两阶段深度迁移学习的多频段振荡定位方法流程

结合前文内容，本文提出的基于 STFT 和两阶段深度迁移学习的多频段振荡定位方法可以通过以下步骤实现，如图 4 所示。

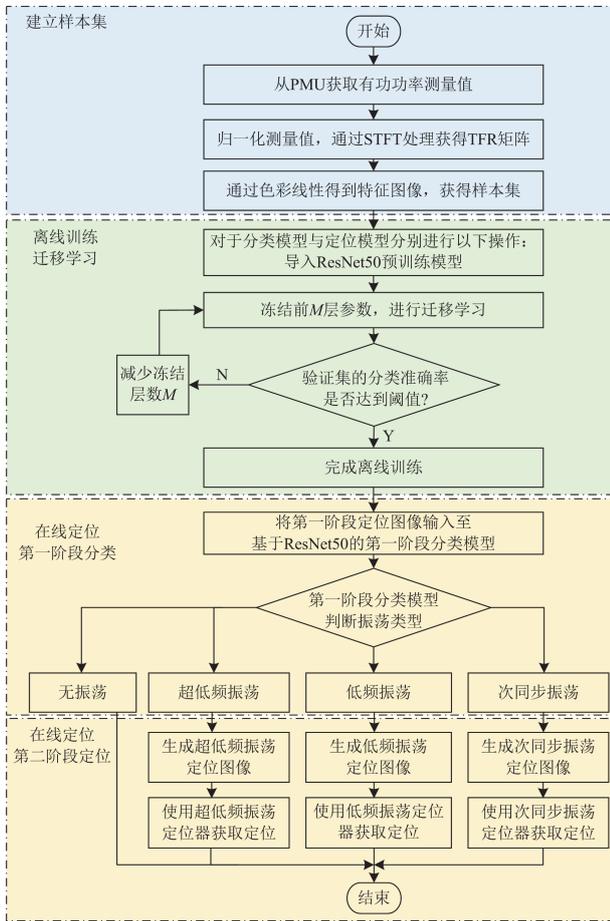


图 4 基于 STFT 与两阶段深度迁移学习的多频段振荡源定位方法流程图

Fig. 4 Flow chart of multi-frequency oscillation location method based on STFT and two-stage transfer learning

第一步：使用 PMU 获取电力系统中所有发电机的有功功率振荡信号。

第二步：对有功功率信号进行归一化，并基于式(6)一式(9)分别计算 4 种类型的 TFR 矩阵。

第三步：使用线性映射方法将 TFR 矩阵转换成图像，获得第一阶段分类图像、ULFO 定位图像、LFO 定位图像和 SSO 定位图像，并将这些图像作为样本集，分别设置训练集和验证集。

第四步：对于每个分类器，导入预训练的 ResNet50 模型，冻结卷积层，使用训练集训练模型，并使用验证集评估分类准确率。

第五步：若验证集上的定位准确度超过阈值，则转到第六步。若不满足条件，则返回第四步，调整冻结层数，并重新训练模型，直到验证集准确度达到阈值条件。获得分类器模型、ULFO 振荡源定位、LFO 振荡源定位模型和 SSO 振荡源定位模型。

第六步：对于实际的多频段振荡事件，获取 PMU 有功功率数据，并按照第一步到第三步的步骤生成第一阶段定位图像，将它输入第一阶段分类器模型。

第七步：第一阶段分类器对第一阶段分类图像进行分类，确定样本的具体振荡类型。

第八步：若被分类为 ULFO，则生成 ULFO 定位图像，并将其输入至 ULFO 定位模型，确定 ULFO 振荡源的具体位置。类似地，使用相同的方法确定 LFO 振荡源与 SSO 振荡源位置。

3 仿真验证

本节首先验证所提方法的可靠性和可行性，然后通过与其他人工智能方法相比，证明该方法的准确率，并在含有噪声的条件下，验证所提方法的鲁棒性。

3.1 算例 1：10 机 39 节点系统

本文基于 Matlab/Simulink 平台搭建了含风电的改进 IEEE39 节点系统^[25]：系统额定频率为 50 Hz，在原 IEEE39 节点系统的 3、4、16、17、18 号节点并入风力发电场，将每个风力发电场聚合为 2 MW 额定容量的双馈风力发电机(doubly fed induction generator, DFIG)，每个风电场包含多台双馈风力发电机，双馈风机采用忽略了定子暂态的三阶模型，其中，各风电场的双馈风机均采用下垂控制措施对频率波动进行调节，各风机下垂控制的输入为 1 号同步机并网点的暂态频率^[26]，该系统的示意图如图 5 所示。

3.1.1 样本集的建立

为了模拟实际的多频段振荡事件，在系统中设置不同类型的干扰：调整发电机的调速系统 PID 参数引发 ULFO，在不同发电机的励磁系统的输入上施加不同大小和频率的正弦扰动激发 LFO，在 DFIG 的网侧控制器处施加不同大小和频率的正弦扰动激

发 SSO。具体的扰动数据设置如表 1 所示。

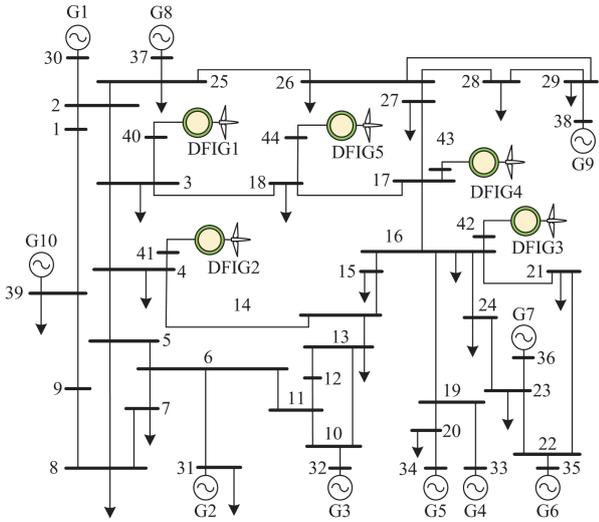


图 5 包含有风电的 10 机 39 节点系统仿真模型接线示意图

Fig. 5 Wiring diagram of the 10-generator 39-bus system with wind power

表 1 样本参数设置

Table 1 Sample parameter setting

振荡类型	故障位置	扰动频率	扰动幅值
ULFO	调速系统	0.05~0.15 Hz	—
LFO	同步发电机	0.2~2.5 Hz	0.05~0.25 p.u.
	励磁系统	(步长 0.1 Hz)	(步长 0.025 p.u.)
SSO	DFIG 网侧 控制器	10~40 Hz (步长 1 Hz)	0.1~0.5 V (步长 0.05 V)

本节采用 Simulink 软件进行时域仿真获取样本数据时, 每个样本的仿真时间设置为 20 s, 采样频率设置为 100 Hz, 选取各台发电机的有功功率信号作为 PMU 测量值, 按照样本的振荡频率与振荡位置设置不同类别的标签。按照第 1.1 节的方法将 PMU 测量值转换成特征图像, 获取样本集数据。

综上所述, 通过仿真模型获得了共 6055 个样本数据(样本集 1), 其中包括 1500 个无扰动样本, 1000 个 ULFO 样本(样本集 2), 2160 个 LFO 样本(样本集

3)和 1395 个 SSO 样本(样本集 4)。将每个样本数据按照 8:1:1 的比例划分为训练集、验证集与测试集, 其中, 训练集用于对模型进行参数训练, 验证集用于检测训练后的模型是否满足阈值要求, 测试集用于进行在线测试的实验。

3.1.2 离线训练

本文通过微调来完成模型的离线训练过程, 冻结不同层数的 ResNet50 网络, 同时比较验证集准确率和训练时间, 选择适合模型的最佳冻结层数。

以 LFO 源定位模型为例, 根据样本集大小和调参结果对比, 设置如下超参数: 批大小为 4, 迭代轮数为 30, 学习率为 10^{-3} , 学习率衰减为 10^{-5} 。模型在不同条件下的训练时间和准确率如表 2 所示。

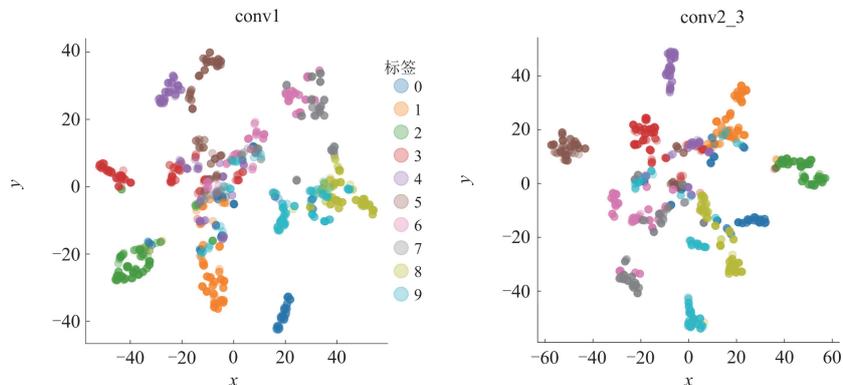
表 2 不同网络的训练时间和验证集定位准确率比较

Table 2 Comparison of training time and location accuracy of validation sample of different networks

冻结层数	训练时间/min	准确率/%
使用预训练参数, 不冻结	100.34	97.31
使用预训练参数, 冻结 conv1 参数	94.89	98.21
使用预训练参数, 冻结 conv1 到 conv2 参数	78.10	98.60
使用预训练参数, 冻结 conv1 到 conv3 参数	75.97	97.68
使用预训练参数, 冻结 conv1 到 conv4 参数	80.96	86.73
使用预训练参数, 冻结 conv1 到 conv5 参数	60.75	56.89

综合考虑定位模型的准确性和效率, 选择冻结 conv1 到 conv2_x 参数的 ResNet50 网络作为预训练网络。

为了验证迁移学习后 ResNet50 模型对图像的处理能力, 选取卷积层 conv1, 卷积层 conv2_3, 卷积层 conv4_6 与池化层 average pool 的输出特征, 作 T 分布随机近邻嵌入(T-distributed stochastic neighbour embeddin, TSNE)降维处理, TSNE 处理后的样本如图 6 所示。



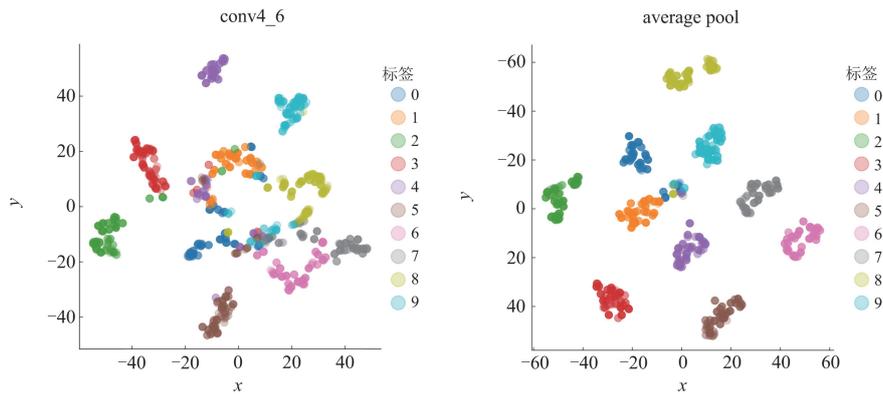


图 6 ResNet50 网络中间层输出的 TSNE 分析

Fig. 6 TSNE analysis of the output of the middle layers of ResNet50 network

由图 6 可知, 经过迁移学习后的 ResNet50 模型对样本集有良好的特征处理能力, 随着 ResNet50 网络对图片样本的深入处理, 不同类型的图片样本特征差异逐渐凸显, TSNE 聚类效果也就越明显。

使用非迁移学习与迁移学习分别训练第二阶段 LFO 源定位模型, 具体仿真实验过程和结果对比如图 7 所示。

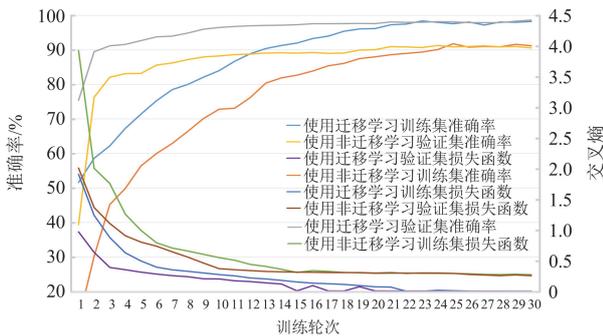


图 7 迁移学习与非迁移学习训练 LFO 定位模型训练过程和结果对比

Fig. 7 Comparison of transfer learning and non-transfer learning training LFO localization model training process and results

通过仿真验证, 最后确定 LFO 振荡源定位模型的验证集定位准确率为 98.60%, 与非迁移学习方法相比, 本文所提出的冻结 conv1 到 conv2_x 卷积层参数的迁移学习方法能够更快地收敛, 同时准确率能稳定在较高的范围, 损失函数能稳定在较低的水平。

类似地, 按照微调方法确定其他 3 个模型的冻结层数与验证集准确率, 最终 4 个模型的验证集分类准确率均在 98% 以上, 本文所提出的基于两阶段深度迁移学习定位方法定位准确率为 96.06%, 准确率较高, 满足实际电力系统中的振荡源定位需求。

3.1.3 不同定位方法的准确率比较

1) 第一阶段分类模型的分类结果

第一阶段的分类结果直接决定数据样本所转化的定位图像种类选取与第二阶段定位模型的选取, 表 3 为在不同数量的训练集下的第一阶段分类模型的分类准确率结果。当训练集占原始训练集比例为 70% 时, 分类模型的混淆矩阵如图 8 所示, 混淆矩阵中每个单元格中整数为样本的数量。

表 3 在不同比例训练集条件下的第一阶段分类模型的准确率比较

Table 3 Comparison of location performance of the first stage classification model under different sample sizes

定位方法	训练集所占原始训练集比例/%		
	100	85	70
分类准确率/%	99.83	98.67	96.53

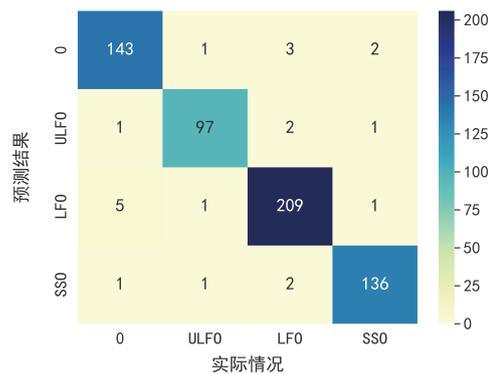


图 8 第一阶段分类模型的混淆矩阵

Fig. 8 Confusion matrix of the first stage classification model

由表 3 与图 8 的信息可知, 第一阶段分类模型的准确度较高, 并且对于各个类型的振荡样本均有很高的分类准确率, 为后续第二阶段定位模型的定位创造了可靠的前提条件。

2) 整个两阶段定位模型的定位结果

本节采用传统机器学习方法中的支持向量机(support vector machine, SVM)模型与决策树(decision tree, DT)模型, 以及单阶段的迁移学习方法, 与本文所提方法的定位准确率进行对比, 对比结果如表 4 所示。当训练集占原始训练集比例为 70% 时, 本文所提定位模型的混淆矩阵如图 9 所示。

表 4 在不同比例训练集条件下的不同定位方法的定位准确率比较

Table 4 Comparison of location performance of different location methods under different sample sizes

定位方法	训练集所占原始训练集比例		
	100%	8%	70%
基于 ResNet50 的两阶段迁移学习	96.06%	94.26%	91.96%
基于 ResNet50 的单阶段迁移学习	88.36%	85.08%	79.18%
SVM	73.61%	64.43%	60.66%
DT	68.20%	60.16%	50.98%

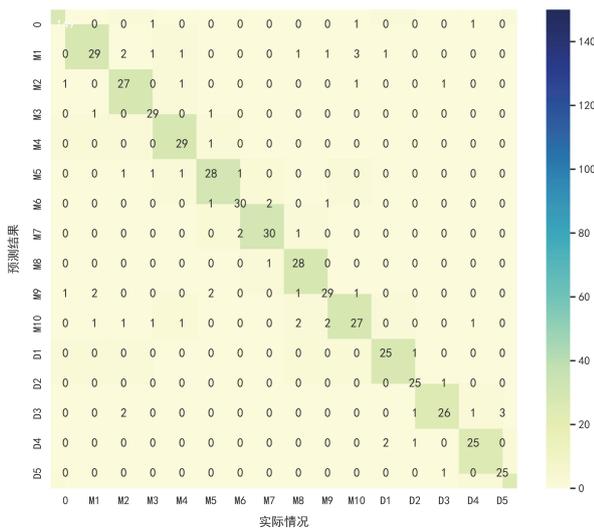


图 9 所提定位模型的混淆矩阵

Fig. 9 Confusion matrix of the proposed localization model

从表 4 可以看出, 与传统的机器学习方法相比, 基于 ResNet50 网络的迁移学习方法具备更高的分类准确率, 并且随着训练样本数量的减少, 机器学习方法的验证集定位准确率将会有较大幅度的下降, 这是由于机器学习的训练模型在训练样本较少时出现过拟合, 导致模型的泛化能力较弱, 因此随着训练所使用的样本数量减少, 机器学习的分类准确率大幅度降低。

同时, 通过与直接使用基于 ResNet50 的迁移学

习方法相比, 本文提出的两阶段定位方法进一步提高了定位准确率, 这是由于输入至定位模型的特征图像尺寸是固定的, 输入至第二阶段定位模型的图像仅包含特定频段的时频信息, 相较于单阶段定位方法的输入图像, 它包含了更多对应频段的细节特征信息, 同时剔除了其他频段的信息, 避免其他频段信息对定位产生干扰。因此, 相较于单阶段的定位方法, 本文所提出的两阶段定位方法具有更高的振荡源定位准确率。

另外, 从图 9 所示的混淆矩阵可以得知, 本文所提出的两阶段分类器对于各个位置的振荡源都有较高的定位准确率。

结合混淆矩阵分析振荡源定位错误的样本, 可以发现, 当扰动源幅值较小时, 该发电机自身所形成的相对有功振荡幅值较低, 其他发电机的相对有功幅值反而更高, 在经过 STFT 与色彩映射处理后, 该振荡样本所形成的定位图像特征并不明显, 不同类型的振荡样本经过色彩映射后可能生成相似的图像特征, 误判的可能性也就更大, 如图 10(a) 与图 10(b) 分别为误判位置为 M1 的 M9 位置振荡的定位图像与判断位置为 M1 的 M1 位置振荡的定位图像, 由于图 10(a) 在 M1、M2、M5、M6 与 M9 处位置具有与图 10(b) 类似的图像特征, 因此定位器将图 10(a) 误判为 M1 处的振荡事件。

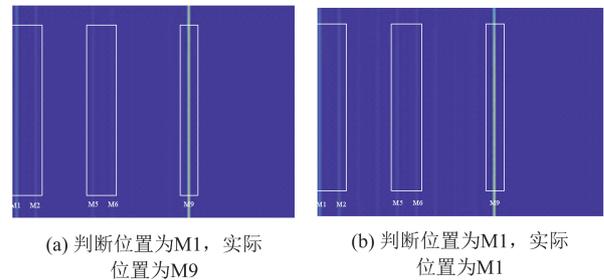


图 10 定位图像示意图

Fig. 10 Schematic diagram of location image

综上所述, 本文所提出的基于 ResNet50 的两阶段迁移学习具有较高的定位准确率, 并且在训练样本较少时也能保持较好的定位性能。

3.1.4 噪声条件下的准确性测试

实际的 PMU 测量系统将会引入随机噪声, 可能影响分类模型与定位模型的准确性, 为了测试噪声条件对本文所提出的两阶段定位方法准确率的影响, 在样本集引入高斯白噪声, 使用含有不同大小噪声的样本对分类模型与定位模型重新进行训练和测试。

1) 第一阶段分类模型的结果

第一阶段分类器的分类准确率如表 5 所示, 噪

声大小为 35 dB 时，对应的混淆矩阵如图 11 所示。

表 5 不同噪声条件下的第一阶段分类模型准确率对比
Table 5 Comparison of location accuracy of different positioning methods under different noise conditions

定位方法	噪声大小/dB		
	35	50	60
分类准确率/%	95.54	97.36	99.01

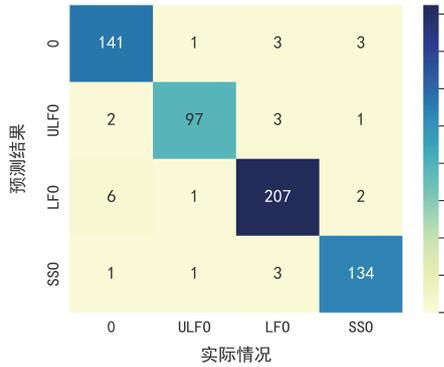


图 11 第一阶段分类模型的混淆矩阵

Fig. 11 Confusion matrix of the first stage classification model

由表 5 与图 11 的信息可知，在噪声为 35 dB 时，第一阶段分类模型仍保持着 95.54% 的分类准确率，并且对于各个类型的振荡样本均有很高的分类准确率，为后续第二阶段定位模型的定位工作创造了前提条件。

2) 整个两阶段定位模型的定位结果

同样采用机器学习方法与所提方法进行对比，在不同噪声条件下的各种定位方法定位准确率比较如表 6 所示。噪声大小为 35 dB 时，本文所提出的两阶段定位模型的混淆矩阵如图 12 所示，图中每个单元格中整数为样本数量。

由仿真结果可知，在 35 dB 的噪声条件下，本文所提方法仍然保持高达 85.54% 的定位精度。这是因为 ResNet50 的卷积运算可以增强图像的特征，使得不同类型的图像样本的差异性与特征性更加显著，减弱了噪声的干扰。综上所述，本文所提定位方法具有较好的抗噪性。

表 6 不同噪声条件下的不同定位方法定位准确率对比
Table 6 Comparison of location accuracy of different location methods under different noise conditions

定位方法	噪声大小/dB		
	35	50	60
基于 ResNet50 的两阶段迁移学习	85.54%	89.71%	92.27%
SVM	50.65%	63.12%	70.49%
DT	43.93%	52.79%	65.90%

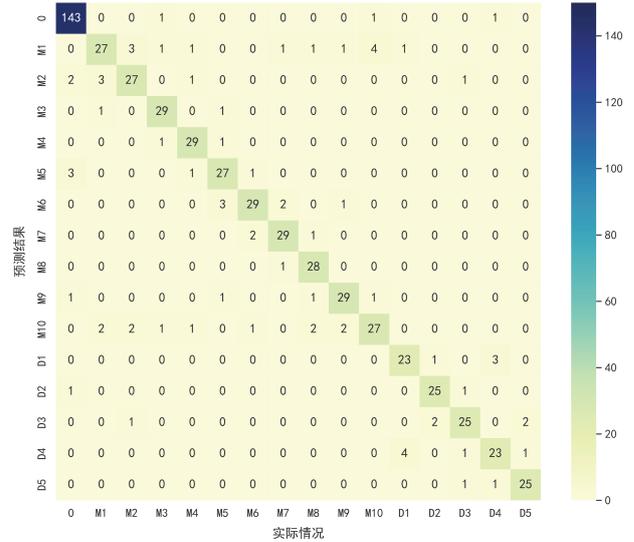


图 12 所提定位模型的混淆矩阵

Fig. 12 Confusion matrix of the proposed localization model

3.2 算例 2: 湖北电网系统

为了测试所提方法在实际电网中的可行性与准确率，在 PSASP 仿真系统对湖北电网进行算例分析，选取鄂西区域(襄阳-宜昌-十堰-恩施)进行具体分析，该区域包括 23 个火电厂、12 个水电厂以及 4 个风电厂。

3.2.1 样本集的建立

使用暂稳态仿真获取样本数据，每个样本的仿真时间设置为 20 s，采样频率设置为 100 Hz，设置 10 种不同的潮流运行方式，选取各个发电机的有功功率作为输出，经过色彩映射形成特征图像样本。每种类型的样本参数设置如下：对于超低频振荡类型，在水电厂的发电机上增加励磁电压波动，扰动频率范围设置为 0.02~0.15 Hz，频率步长设置为 0.02 Hz，扰动幅值范围设置为 0.05~0.25 p.u.，幅值步长设置为 0.025 p.u.；对于低频振荡类型，在水电厂与火电厂的发电机上增加励磁电压波动，扰动频率范围设置为 0.2~2.5 Hz，频率步长设置为 0.1 Hz，扰动幅值范围设置为 0.05~0.25 p.u.，幅值步长设置为 0.025 p.u.；对于次同步振荡类型，在风电场母线上增加阵风风速变化，风速最大值范围设置为 8~20 m/s，风速步长设置为 0.2 m/s。

按照上述参数设置，通过仿真获得了共 58 440 个样本数据(样本集 1)，其中包括 20 000 个无振荡样本，3840 个 ULFO 样本(样本集 2)，32 200 个 LFO 样本(样本集 3)，2400 个 SSO 样本(样本 4)，将每个样本数据按照 8:1:1 的比例划分为训练集、验证集与测试集。

3.2.2 离线训练

使用微调方法训练 ULFO 定位模型, 设置如下超参数: 批大小为 8, 迭代轮数为 30, 学习率为 5×10^{-3} , 学习率衰减为 10^{-5} 。不同条件下模型的训练时间和验证集定位准确度如表 7 所示。

表 7 不同网络的训练时间和验证集定位准确率比较

Table 7 Comparison of training time and location accuracy of validation sample of different networks		
冻结层数	训练时间	准确率/%
使用预训练参数, 不冻结	4 h 18 min	96.69
使用预训练参数, 冻结 conv1 参数	3 h 43 min	98.51
使用预训练参数, 冻结 conv1 到 conv2 参数	3 h 21 min	98.60
使用预训练参数, 冻结 conv1 到 conv3 参数	2 h 43 min	97.91
使用预训练参数, 冻结 conv1 到 conv4 参数	2 h 22 min	89.61
使用预训练参数, 冻结 conv1 到 conv5 参数	2 h 14 min	56.89

综合考虑训练时间与定位准确率, 对于第二阶段 ULFO 定位模型, 选择冻结 conv1 到 conv3 参数的 ResNet50 模型作为预训练模型。使用非迁移学习与迁移学习分别训练第二阶段 ULFO 振荡源定位模型, 具体仿真实验过程和结果对比如图 13 所示。

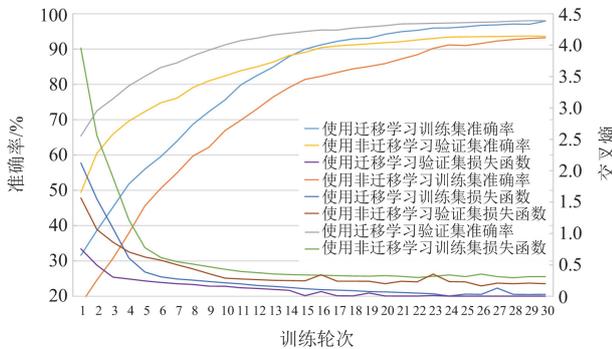


图 13 迁移学习与非迁移学习训练 ULFO 定位模型训练过程和结果对比

Fig. 13 Comparison of transfer learning and non-transfer learning training ULFO localization model training process and results

通过仿真验证, 在该算例中, 第二阶段 ULFO 振荡源定位模型的验证集定位准确率为 97.91%, 验证了本文所提的迁移学习方法具有更高的定位准确率与更好的模型性能。

类似地, 对其他模型进行离线训练, 最终 4 个模型的验证集分类准确率均能达到 97% 以上, 能够满足实际电力系统中的振荡源定位需求。

3.2.3 在线定位

1) 第一阶段分类模型的分类结果

为了验证所提基于 ResNet50 的深度迁移学习 (deep transfer learning, DTL) 方法分类振荡源的准确性, 使用同一样本集对 SVM 模型与 DT 模型进行训练, 并使用测试集进行检验, 比较在不同数量训练集下的分类准确率, 如图 14 所示。

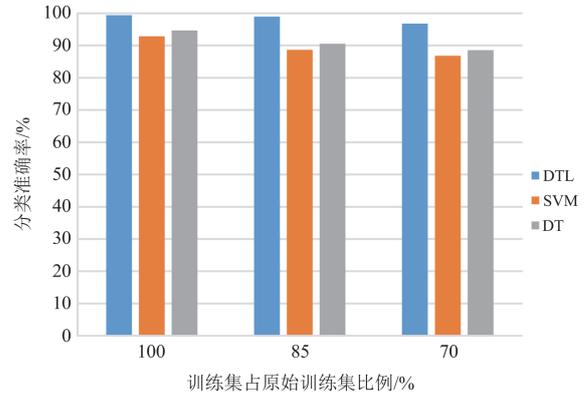


图 14 不同机器学习方法分类准确率

Fig. 14 Classification accuracy of different machine learning methods

结果表明, 相较于其他机器学习方法, 所提出的基于 ResNet 的分类模型具有更高的分类准确率, 同时在训练样本较少时, 仍能维持 96% 的分类准确率, 证明了所提方法的有效性。

2) 第二阶段定位模型的定位结果

为验证所提方法定位各个类型振荡源的准确性, 使用不同机器学习方法进行比较, 结果如图 15 所示。

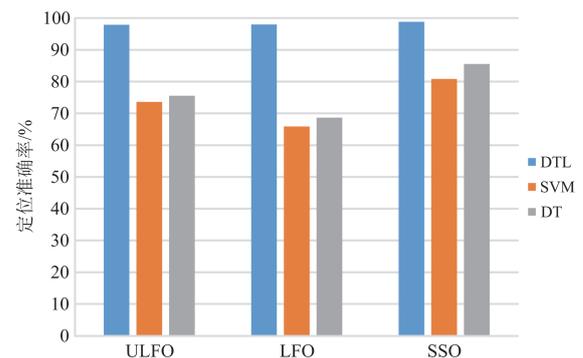
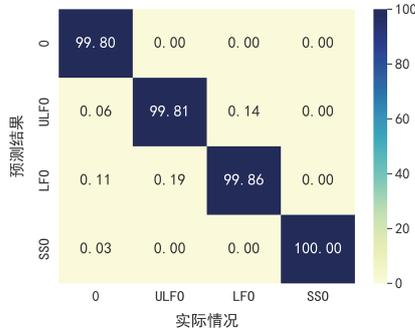


图 15 不同机器学习方法定位准确率

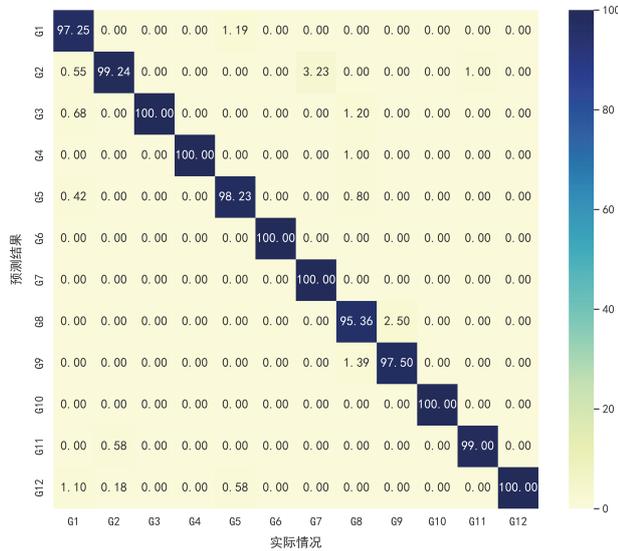
Fig. 15 Location accuracy of different machine learning methods

定位结果证明, 对于 3 种不同类型的振荡源, 所提出的基于 ResNet50 的迁移学习定位模型均具有很高的定位准确率, 同时对于所有类型的振荡样本, 其他机器学习方法定位准确率均明显低于所提方法。

为了进一步验证所提方法对于不同类型振荡源的分类准确率与不同位置振荡源的定位准确率，生成第一阶段分类模型与第二阶段 ULFO 定位模型的混淆矩阵，混淆矩阵的每个单元格表示模型预测样本占实际样本的百分比，如图 16 所示。



(a) 第一阶段分类器模型



(b) 第二阶段 ULFO 定位器模型

图 16 分类器模型与定位器模型的混淆矩阵

Fig. 16 Confusion matrix of classifier model and locator model

混淆矩阵表明，第一阶段分类器模型对每个类型的样本均具有较好的分类能力，第二阶段 ULFO 定位模型对各个位置的振荡源均具有较强的定位能力，进一步验证了所提方法的精确性。

3) 整个两阶段定位器的定位结果

将整个两阶段定位模型投入使用，对使用传统的机器学习方法与本文所提方法的定位准确率进行对比，结果如表 8 所示。

由上述仿真结果可知，相较于传统的 SVM 与 DT 机器学习方法，本文所提基于 ResNet50 网络的迁移学习方法具有更高的振荡分类准确率，同时对

于不同类型的振荡源，本文所提方法具有更高的振荡源定位准确率，在训练样本较少时，该方法仍具备较高的分类准确率与定位准确率。使用基于 ResNet50 的两阶段迁移学习方法可以进一步提高振荡源定位准确率，再次验证了本文所提方法在省级电网应用的可行性与准确性。

表 8 在不同比例训练集条件下的不同定位方法的定位准确率比较

Table 8 Comparison of location performance of different location methods under different sample sizes

定位方法	训练集占原始训练集比例		
	100%	85%	70%
基于 ResNet50 的两阶段迁移学习	95.26%	93.95%	92.96%
基于 ResNet50 的单阶段迁移学习	86.87%	80.71%	73.87%
SVM	70.45%	61.14%	56.57%
DT	63.86%	53.98%	49.37%

4 结论

本文提出了一种基于 STFT 和两阶段深度迁移学习的多频段振荡源定位方法。该方法通过 STFT 将振荡源定位问题转化为图像分类问题。一方面，降低了传输和存储的数据量，另一方面，有效利用了深度学习的图像处理能力。该方法分为两个阶段：第一阶段确定振荡样本类型，第二阶段确定各种类型振荡源的具体位置，引入两个阶段的分类器提高了定位的准确性。

以含有风电的 10 机 39 节点的测试系统为例进行研究，在离线训练环节，训练冻结不同层数的 ResNet50 网络，比较模型的训练速度与验证集的定位准确率，确定深度迁移学习冻结的网络层数，最终使得分类模型能够以较短的训练时间实现高精度的分类，验证了迁移学习的高效性与准确性。在在线定位环节，使用不同数量的训练样本对模型进行训练，分别采用 SVM、DT、单阶段迁移学习方法与所提的两阶段迁移学习方法相比较，结果表明所提方法能够使用较少的训练样本实现高准确率的多频段振荡源定位。同时，使用不同噪声条件的样本对模型进行训练，所提方法仍能保持较高的定位准确率，验证了其对于噪声干扰表现出较强的鲁棒性。

在湖北电网仿真系统中测试所提方法的有效性，仿真结果表明：在离线训练环节，所提方法能兼顾效率与定位准确率；在在线定位环节，本文所提两阶段迁移学习方法进一步提高了定位准确率，验证了所提方法在实际大电网中应用的可行性。

参考文献

- [1] 谢小荣, 贺静波, 毛航银, 等. “双高”电力系统稳定性的新问题及分类探讨[J]. 中国电机工程学报, 2021, 41(2): 461-475.
XIE Xiaorong, HE Jingbo, MAO Hangyin, et al. New problems and classification of “double high” power system stability[J]. Proceedings of the CSEE, 2021, 41(2): 461-475.
- [2] 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 wide-band oscillation in grid-connected doubly-fed wind power systems[J]. Power System Protection and Control, 2023, 51(12): 1-13.
- [3] 王杨, 王超群, 晁苗苗, 等. 基于同步相量数据幅频特征的次超同步振荡模式辨识[J]. 电力系统保护与控制, 2023, 51(19): 1-11.
WANG Yang, WANG Chaoqun, CHAO Miaomiao, et al. Sub-and super-synchronous oscillation mode identification based on amplitude and frequency characteristics of synchronous phasor data[J]. Power System Protection and Control, 2023, 51(19): 1-11.
- [4] 伍双喜, 王晰, 刘洋, 等. 基于构网型储能的风电场-弱电网次同步振荡抑制方法[J]. 电力建设, 2024, 45(4): 147-155.
WU Shuangxi, WANG Xi, LIU Yang, et al. Subsynchronous damping control of grid-forming BESS in wind farms connected to a weak AC grid[J]. Electric Power Construction, 2024, 45(4): 147-155.
- [5] 陈露洁, 徐式蕴, 孙华东, 等. 高比例电力电子电力系统宽频带振荡研究综述[J]. 中国电机工程学报, 2021, 41(7): 2297-2310.
CHEN Lujie, XU Shiyun, SUN Huadong, et al. Survey on wide-frequency oscillation for power systems with high penetration of power electronics[J]. Proceedings of the CSEE, 2021, 41(7): 2297-2310.
- [6] 杨博, 陈义军, 姚伟, 等. 基于新一代人工智能技术的电力系统稳定评估与决策综述[J]. 电力系统自动化, 2022, 46(22): 200-223.
YANG Bo, CHEN Yijun, YAO Wei, et al. A comprehensive review on power system stability assessment and decision-making based on new-generation artificial intelligence technologies[J]. Automation of Electric Power Systems, 2022, 46(22): 200-223.
- [7] 李阳海, 黄莹, 刘巨, 等. 基于阻尼转矩分析的电力系统低频振荡源定位[J]. 电力系统保护与控制, 2015, 43(14): 84-91.
LI Yanghai, HUANG Ying, LIU Ju, et al. Low-frequency oscillation source localization of power systems based on damping torque analysis[J]. Power System Protection and Control, 2015, 43(14): 84-91.
- [8] 李文锋, 郭剑波, 李莹, 等. 基于 WAMS 的电力系统功率振荡分析与振荡源定位(1)割集能量法[J]. 中国电机工程学报, 2013, 33(25): 41-46, 9.
LI Wenfeng, GUO Jianbo, LI Ying, et al. Power oscillation analysis and source localization of power systems based on WAMS: part I-cut-set energy method[J]. Proceedings of the CSEE, 2013, 33(25): 41-46, 9.
- [9] 陈月辉, 张文朝, 徐遐龄, 等. 基于前 K 最短路径的电力系统低频振荡源定位方法[J]. 电力系统保护与控制, 2017, 45(13): 117-123.
CHEN Yuehui, ZHANG Wenchao, XU Xialing, et al. Low frequency oscillation source location method of power system based on front K shortest path[J]. Power System Protection and Control, 2017, 45(13): 117-123.
- [10] 余涛, 周斌, 甄卫国. 强化学习理论在电力系统中的应用及展望[J]. 电力系统保护与控制, 2009, 37(14): 122-128.
YU Tao, ZHOU Bin, ZHEN Weiguo. Application and prospect of reinforcement learning theory in power system[J]. Power System Protection and Control, 2009, 37(14): 122-128.
- [11] 姜涛, 高滢, 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 Tao, GAO Han, LI Xiaojing, et al. Localization of forced oscillation sources in power systems based on wavelet dissipative energy spectrum[J]. Transactions of China Electrotechnical Society, 2023, 38(7): 1737-1750.
- [12] 张国治, 陈康, 方荣行, 等. 基于 DGA 与鲸鱼算法优化 Logit Boost-决策树的变压器故障诊断方法[J]. 电力系统保护与控制, 2023, 51(7): 63-72.
ZHANG Guozhi, CHEN Kang, FANG Rongxing, et al. Transformer fault diagnosis based on DGA and a whale algorithm optimizing a LogitBoost-decision tree[J]. Power System Protection and Control, 2023, 51(7): 63-72.
- [13] 雷朝煜, 郝良收, 戴甲水, 等. 高压直流输电线路故障定位研究综述[J]. 电力系统保护与控制, 2022, 50(11): 178-187.
LEI Zhaoyu, HAO Liangshou, DAI Jiashui, et al. A review of fault location methods in HVDC transmission lines[J]. Power System Protection and Control, 2022, 50(11): 178-187.
- [14] 戴礼国, 杨浩, 陈力, 等. 基于深度强化学习的风电柔直并网系统次同步振荡抑制方法[J]. 智慧电力, 2023,

- 51(4): 1-7, 91.
DAI Liguao, YANG Hao, CHEN Li, et al. Subsynchronous oscillation suppression method for flexible direct grid-connected wind power system based on deep reinforcement learning[J]. Smart Power, 2023, 51(4): 1-7, 91.
- [15] 冯双, 崔昊, 陈佳宁, 等. 人工智能在电力系统宽频振荡中的应用与挑战[J]. 中国电机工程学报, 2021, 41(23): 7889-7905.
FENG Shuang, CUI Hao, CHEN Jianing, et al. Applications and challenges of artificial intelligence in wideband oscillations of power systems[J]. Proceedings of the CSEE, 2021, 41(23): 7889-7905.
- [16] 蒋长江, 刘俊勇, 刘友波, 等. 基于广域测量系统和 CELL 理论的强迫振荡在线感知与定位[J]. 电力自动化设备, 2015, 35(2): 125-132.
JIANG Changjiang, LIU Junyong, LIU Youbo, et al. Online perception and localization of forced oscillations based on wide-area measurement systems and CELL theory[J]. Automation of Electric Power Systems, 2015, 35(2): 125-132.
- [17] PING Z, LI X, HE W, et al. Sparse learning of network reduced models for locating low frequency oscillations in power systems[J]. Applied Energy, 2020, 262: 114541.
- [18] 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 Jian, DU Wenjuan, WANG Haifeng. 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.
- [19] 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 Shuang, CHEN Jianing, TANG Yi, et al. Forced oscillation source localization method based on SPWVD image and deep transfer learning[J]. Automation of Electric Power Systems, 2020, 44(17): 78-87.
- [20] 吴熙, 陈曦, 吕万, 等. 电力系统次同步振荡检测与在线定位技术综述[J]. 电力自动化设备, 2020, 40(9): 129-141.
WU Xi, CHEN Xi, LÜ Wan, et al. A comprehensive review of sub-synchronous oscillation detection and online localization techniques in power systems[J]. Electric Power Automation Equipment, 2020, 40(9): 129-141.
- [21] 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位[J]. 电网技术, 2023, 47(5): 1770-1780.
LI Ying, FU Yazhou, WANG Guanhong, et al. Analysis of ultra-low frequency frequency oscillations and disturbance source localization in power systems[J]. Power System Technology, 2023, 47(5): 1770-1780.
- [22] HUANG T, FRERIS N M, KUMAR P R, et al. Localization of forced oscillations in the power grid under resonance conditions[C]// 2018 52nd Annual Conference on Information Sciences and Systems (CISS), March 21-23, 2018, Princeton, NJ, USA: 1-5.
- [23] LI M, LIU Y, ZHI S, et al. Short-time Fourier transform using odd symmetric window function[J]. Journal of Dynamics, Monitoring and Diagnostics, 2022, 1(1): 37-45.
- [24] MASCARENHAS S, AGARWAL M. A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for image classification[C]// 2021 International conference on disruptive technologies for multi-disciplinary research and applications (CENTCON), November 19-21, 2021, Bengaluru, India: 96-99.
- [25] LIN S, YAO W, XIONG Y, et al. MatPSST: A Matlab/Simulink-based power system simulation toolbox for research and education[J]. IET Generation, Transmission & Distribution, 2023, 17(10): 2272-2288.
- [26] BADESA L, TENG F, STRBAC G. Conditions for regional frequency stability in power system scheduling—part II: application to unit commitment[J]. IEEE Transactions on Power Systems, 2021, 36(6): 5567-5577.

收稿日期: 2024-03-05; 修回日期: 2024-05-22

作者简介:

余明(2000—), 男, 硕士研究生, 研究方向为人工智能在电力系统中的应用; E-mail: 2474650864@qq.com

姚伟(1983—), 男, 通信作者, 博士, 教授, 博士生导师, 研究方向为高比例新能源电力系统稳定分析与控制、新一代电力人工智能技术及应用等。E-mail: w.yao@hust.edu.cn

(编辑 魏小丽)