文章编号：1674-0629(2026)09-0013-12 中图分类号：TM464 文献标志码：A
DOI：10.13648/j.cnki.issn1674-0629.2026.09.002

基于深度算子网络结构的并网逆变器多运行点阻抗辨识方法

汪颖，马子航，肖先勇
（四川大学电气工程学院，成都 610065）

摘要：并网逆变器阻抗特性是分析逆变器与电网交互稳定性的重要依据，准确获取不同运行点阻抗特性是稳定运行的基础。针对实际测量可覆盖的运行点有限的问题，提出了一种基于深度算子网络结构的并网逆变器多运行点阻抗辨识方法，实现了多运行点阻抗特性的准确表征。首先，面向多运行点阻抗辨识，构建了以主干网络进行频率特征映射、以分支网络表征运行点信息的辨识模型，并在训练阶段构造频段加权损失函数，引入关键频段辨识误差约束，实现了多运行点下阻抗辨识。其次，提出面向参数变化场景的小样本阻抗迁移模型，引入源域预训练模型和目标域微调策略，提高了小样本条件下的阻抗辨识效果。最后，通过算例验证了所提方法能够取得较好的多运行点阻抗辨识效果，并在参数变化和多逆变器并联场景下保持较好的适用性。

关键词：并网逆变器；多运行点阻抗辨识；深度算子网络结构；频段加权损失；迁移学习

Multi-Operating-Point Impedance Identification Method for Grid-Connected Inverters Based on Deep Operator Network Structure

WANG Ying, MA Zihang, XIAO Xianyong
（College of Electrical Engineering, Sichuan University, Chengdu 610065, China）

Abstract: Impedance characteristics of grid-connected inverters are an important basis for analyzing inverter-grid interaction stability, and accurately obtaining impedance characteristics under different operating points is essential for stable operation. To address the problem that practical measurements can cover only a limited number of operating points, a multi-operating-point impedance identification method for grid-connected inverters based on a deep operator network structure is proposed to accurately characterize impedance under multiple operating points. Firstly, for multi-operating-point impedance identification, an identification model is constructed in which the trunk network performs frequency feature mapping and the branch network represents operating-point information. During the training stage, a frequency-band-weighted loss function is constructed, and constraints on identification errors in key frequency bands are introduced to achieve impedance identification under multiple operating points. Secondly, a small-sample impedance transfer model for parameter variation scenarios is proposed. A source-domain pretrained model and a target-domain fine-tuning strategy are introduced to improve the impedance identification performance under small-sample conditions. Finally, case studies verify that the proposed method achieves satisfactory multi-operating-point impedance identification performance and maintains good applicability in parameter variation and multi-inverter parallel scenarios.

Key words: grid-connected inverter; multi-operating-point impedance identification; deep operator network structure; frequency-band-weighted loss; transfer learning

基金项目：国家自然科学基金资助项目（U24A20148）。
Foundation item: Supported by the National Natural Science Foundation of China (U24A20148).

0 引言

随着新能源发电设备的大规模接入，并网逆变器已成为发电单元接入电网的关键接口，其与电网之间的交互稳定性问题受到广泛关注[1-5]。阻抗分析法是稳定性分析的典型方法[6-9]，准确获取并网逆变器阻抗特性是重要前提。

目前，获取逆变器阻抗特性的主要方法有两类：现场测试和模型分析。现场测试方法是应用可编程电源注入扰动信号，采集扰动注入前后并网点处电压、电流，通过计算获得测试阶段的阻抗特性。扫频法是典型的现场测试方法，需要在系统运行过程中分次注入不同频率的扰动电流或电压，该方法可获取准确的阻抗信息，但存在测试周期长、成本高等问题[10-11]；由于注入的扰动可能影响系统本身安全稳定运行，所以现场测试法属于短期性实验测试，不适宜长期、持续的扰动注入，这使得测试获取的阻抗特性仅代表测试阶段的阻抗特性，难以充分表征逆变器多运行点下的阻抗信息。

模型分析法根据逆变器物理结构参数或现场测试数据开展建模分析，规避了长期扰动注入可能引发的安全风险。模型分析法可分为基于物理结构的阻抗建模和基于数据的阻抗建模。前者通常采用小信号分析方法建立阻抗模型，并从控制环节、耦合效应和运行点变化等方面分析其对阻抗特性的影响。文献[12]从统一阻抗模型角度揭示了锁相环和电流控制对并网逆变器外特性的影响。文献[13-14]将频率耦合以及交直流端口耦合纳入建模过程，扩展了并网逆变器阻抗模型对复杂动态特性的表征能力。文献[15]针对运行点变化场景提出近似解耦阻抗模型，提高了运行点变化条件下的模型表达能力。上述研究从多维度完善了并网逆变器阻抗解析模型，具有明确的物理含义。但在实际工程中，受设备封装、商业保密等因素影响，并网逆变器内部电路拓扑、控制策略、控制参数等通常难以获取，解析建模方法的适用性受到限制。

基于数据的阻抗建模是以现场测试的阻抗数据为先验信息，通过数据驱动的方法，构建阻抗估计模型，避免了对并网逆变器物理结构与参数的强依赖性，但如何利用有限阻抗测量数据准确表征多运行点下的阻抗变化规律是该类方法面临的挑战。现有方法主要包括基于模型先验的阻抗建模方法和基于神经网络的阻抗建模方法。前者通常在模型特征约束下，结合测量数据构建宽运行范围阻抗模型[16-17]。后者基于先验测量数据，采用神经网络学习运行点与阻抗频率响应之间的非线性映射关系[18-20]。文献[18]采用人工神经网络建立多运行点阻抗模型，在一定规模阻抗测量数据支撑下实现了宽运行范围内逆变器阻抗特性的表征。文献[19]同样以人工神经网络为基础，构建宽运行范围内逆变器阻抗特性的机器学习建模框架，降低了阻抗建模对大规模测量数据的依赖。文献[20]从网络结构设计角度出发，利用电力电子系统潜在特征指导前馈神经网络阻抗模型构建，增强了网络结构与阻抗特性之间的适配性。

上述研究为有限测量数据条件下的多运行点阻抗建模提供了有效思路，但现有方法仍主要关注阻抗频率响应的整体拟合，对关键频段辨识误差的针对性控制不足；在参数变化场景下目标域小样本条件下的阻抗辨识效果仍有进一步提升空间；同时，现有方法多以单逆变器阻抗建模为对象，对多逆变器并联系统总阻抗随多机运行点组合变化的表征仍不充分。针对上述问题，本文提出了一种基于深度算子网络结构的并网逆变器多运行点阻抗辨识方法，整体思路如图 1 所示。首先，在并网逆变器阻抗模型基础上构建基于深度算子网络（deep operator network，DeepONet）结构的多运行点阻抗辨识模型，由主干网络进行频率特征映射，由分支网络生成与运行点相关的组合系数，并在训练阶段构造频段加权损失函数，引入关键频段辨识误差约束，实现不同运行点下阻抗辨识。进一步，提出面向参数变化场景的小样本阻抗迁移模型，将已训练模型作为目标域模型的初始化参数，并结合少量目标域样本进行微调，使模型在小样本条件下仍能保持较好的迁移辨识效果，从而可用于同类型逆变器参数变化后的阻抗估计。最后，围绕单逆变器场景、参数变化下的小样本迁移场景和多逆变器并联系统场景开展算例分析，验证了所提方法的有效性。

1 并网逆变器阻抗模型

并网逆变器阻抗受控制策略、控制参数等因素影响，典型并网逆变器如图 2 所示，其整体结构主要由直流侧电源、三相桥式变换器、滤波电路、锁相环、功率外环、电流控制环以及电网等部分构

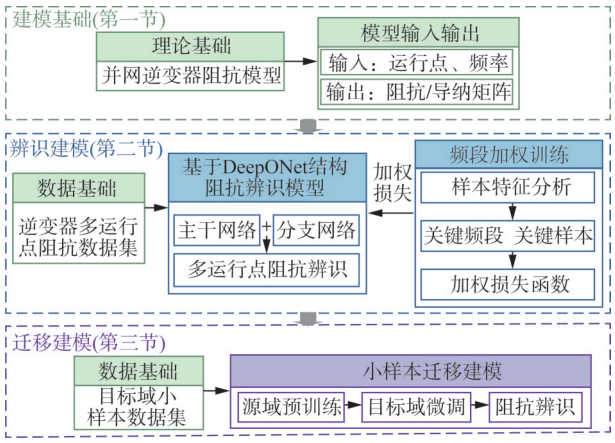


图 1　整体思路图

Fig. 1　Overall framework diagram

成。不考虑直流侧电压波动及其动态过程，将直流侧近似等效为理想恒压源；为保证逆变器与电网之间的同步运行，系统采用同步旋转坐标系锁相环提取电网相角；电流内环和功率外环均采用PI控制；考虑到 dq 坐标系下存在交叉耦合项，在电流内环控制器输出端进一步设置解耦补偿项，以减弱 d、q 轴之间的耦合影响并改善电流跟踪性能。

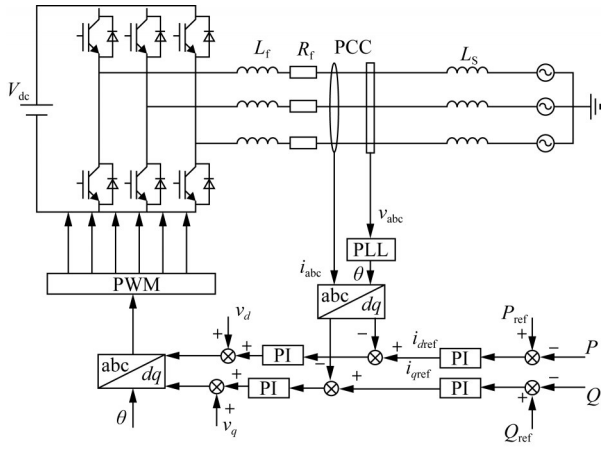


图 2　典型并网逆变器结构图

Fig. 2　Structure of a typical grid-connected inverter

基于小信号分析理论，并网逆变器端口特性可表示为 dq 坐标系下的频域矩阵关系[21]。对于并网逆变器小信号阻抗建模，端口特性可采用阻抗或导纳形式描述。考虑到跟网型逆变器在端口处呈现受控电流源特征，导纳形式更便于表征电压扰动与电流响应之间的关系。因此，本文在阻抗特性建模中采用 dq 导纳矩阵描述并网逆变器端口特性，其一般形式可写为：

$$\begin{bmatrix}\Delta i_d\\ \Delta i_q\end{bmatrix}=\begin{bmatrix}Y_{dd}(s) & Y_{dq}(s)\\ Y_{qd}(s) & Y_{qq}(s)\end{bmatrix}\begin{bmatrix}\Delta u_d\\ \Delta u_q\end{bmatrix} \tag{1}$$

式中：I_d、I_q 分别为 d 轴和 q 轴电流；$Y_{dd}(s)$、$Y_{dq}(s)$、$Y_{qd}(s)$、$Y_{qq}(s)$ 为各频率点处 dq 导纳矩阵4个元素；Δi_d、Δi_q、Δu_d、Δu_q 分别为 d、q 轴电流和电压扰动。对角元素反映同一轴向通道的响应关系，非对角元素反映 dq 轴之间的耦合效应。由小信号理论可知，在控制结构和系统参数给定的条件下，并网逆变器的阻抗特性主要取决于并网点稳态电压 V_{pcc}、dq 轴稳态电流 I_d 和 I_q[21]。本文将 V_{pcc}、I_d、I_q 的一组特定取值所对应的逆变器工作点称为运行点，采用 $\boldsymbol{x}=[V_{pcc},\ I_d,\ I_q]$ 对其进行表征。

在实际运行过程中，并网点电压及逆变器有功、无功功率会随运行条件变化而改变，相应的 dq 导纳频率响应也会发生变化。为支撑宽运行范围下的稳定性分析，有必要开展多运行点阻抗辨识建模，以实现不同运行点下 dq 导纳频率响应的表征。

2　基于深度算子网络结构的多运行点阻抗辨识方法

已有研究表明，深度算子网络通过分别处理不同类型输入并在输出端进行耦合，能够较好地利用不同输入之间的结构差异。相较于将输入变量直接拼接后进行回归的传统全连接网络，该结构在相关算例中表现出较好的泛化能力[22]。基于此，本文借鉴深度算子网络中主干网络与分支网络相结合的结构形式，构建多运行点阻抗辨识模型。下面对模型总体框架与网络结构进行说明。

2.1　多运行点阻抗辨识模型总体框架

多运行点阻抗辨识模型以运行点 $\boldsymbol{x}=[V_{pcc},\ I_d,\ I_q]$ 和频率 f 为输入，以各频率点处 dq 导纳矩阵4个元素 $Y_{dd}(s)$、$Y_{dq}(s)$、$Y_{qd}(s)$、$Y_{qq}(s)$ 的实部与虚部分别作为模型输出。该模型采用深度算子网络结构，由主干网络和分支网络组成：主干网络输入频率 f，并对其进行特征映射；分支网络输入运行点 $\boldsymbol{x}$，用于生成与运行点相关的组合系数；两个子网络的输出经矩阵运算后得到对应导纳辨识值，网络整体结构如图3所示。

2.2　网络结构设计

主干网络和分支网络内部均采用多层前馈全连接神经网络结构，其隐藏层的前向传播过程可统一表示为：

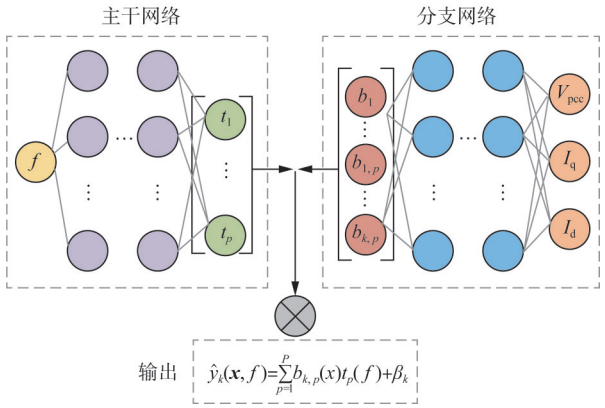


图 3 深度算子网络结构图

Fig. 3 Structure of DeepONet

$$\boldsymbol{h}^{(l)} = \sigma(\boldsymbol{W}^{(l)}\boldsymbol{h}^{(l-1)} + \boldsymbol{b}^{(l)}) \tag{2}$$

式中：l为网络层编号；$\boldsymbol{h}^{(l-1)}$和$\boldsymbol{h}^{(l)}$分别为第$l-1$层和l层的输出；$\boldsymbol{W}^{(l)}$和$\boldsymbol{b}^{(l)}$分别为第l层的权重矩阵和偏置向量；$\sigma(\cdot)$为激活函数，本文取双曲正切函数$\tanh(\cdot)$，以增强网络对非线性映射关系的表征能力。

在上述统一前向传播表达基础上，分别对主干网络、分支网络及其网络输出表达进行说明。

2.2.1 主干网络

对于主干网络，取其输入层为：

$$h_{\mathrm{tr}}^{(0)} = f \tag{3}$$

式中：$h_{\mathrm{tr}}^{(0)}$为主干网络的输入变量；f为输入频率，对应dq导纳频率响应中的一个采样频率点。

基于式(2)所示的前向传播过程，主干网络将输入频率f经过多层非线性映射后，表示为P维特征向量$\boldsymbol{T}(f)$：

$$\boldsymbol{T}(f) = [t_1(f), t_2(f), \cdots, t_P(f)]^{\mathrm{T}} \tag{4}$$

式中：$\boldsymbol{T}(f)$为输入频率f对应的主干网络输出特征向量；P为向量维数；$t_p(f)$为该特征向量的第p个分量，p=1，2，…，P。该特征向量由网络从训练数据中自适应学习得到，用于表征dq导纳矩阵各元素在不同频率点处的响应规律。

需要指出的是，并网逆变器dq导纳矩阵各元素均对应同一逆变器在给定运行点下的频域响应，其变化受相同主电路与控制系统作用，频率响应之间具有一定关联。因此，在主干网络结构设计中，本文不针对各导纳元素分别构造独立的主干网络，而是采用统一的主干网络对输入频率f进行映射，以表征dq导纳矩阵各元素频率响应的共性特征。

2.2.2 分支网络

对于分支网络，取其输入层为：

$$\boldsymbol{h}_{\mathrm{br}}^{(0)} = \boldsymbol{x} \tag{5}$$

式中：$\boldsymbol{h}_{\mathrm{br}}^{(0)}$为分支网络的输入变量；$\boldsymbol{x}$=[$V_{\mathrm{pcc}}$，$I_d$，$I_q$]为输入运行点。

考虑到dq导纳矩阵各元素均为复数，本文将dq导纳矩阵4个元素拆分为实部和虚部进行辨识，模型在每个频率点处共对应8个实值输出分量。由于主干网络在频率f处输出P维特征向量，分支网络输出系数矩阵的列数相应取为P，以保证后续组合运算的维度一致。相应地，分支网络输出$8P$个系数，经重构后形成$8\times P$的系数矩阵，分支网络输出系数矩阵如下：

$$\boldsymbol{B}(\boldsymbol{x}) = \begin{bmatrix} b_{1,1}(\boldsymbol{x}) & b_{1,2}(\boldsymbol{x}) & \cdots & b_{1,P}(\boldsymbol{x}) \\ b_{2,1}(\boldsymbol{x}) & b_{2,2}(\boldsymbol{x}) & \cdots & b_{2,P}(\boldsymbol{x}) \\ \vdots & \vdots & \ddots & \vdots \\ b_{8,1}(\boldsymbol{x}) & b_{8,2}(\boldsymbol{x}) & \cdots & b_{8,P}(\boldsymbol{x}) \end{bmatrix} \tag{6}$$

式中：$\boldsymbol{B}(\boldsymbol{x})$为输入运行点$\boldsymbol{x}$对应的分支网络输出系数矩阵；$b_{k,p}(\boldsymbol{x})$表示在输入运行点$\boldsymbol{x}$下第$k$个输出分量对应的第$p$个组合系数，其中$k$=1，2，…，8，$p$=1，2，…，$P$。

2.2.3 网络输出表达

在主干网络输出特征向量和分支网络输出系数矩阵的基础上，二者通过矩阵运算得到模型在给定运行点和频率处的最终输出如下：

$$\hat{y}_k(\boldsymbol{x}, f) = \sum_{p=1}^{P} b_{k,p}(\boldsymbol{x}) t_p(f) + \beta_k \tag{7}$$

式中：$\hat{y}_k(\boldsymbol{x}, f)$为给定运行点$\boldsymbol{x}$和输入频率$f$处的第$k$个输出分量；$\beta_k$为第$k$个输出分量对应的偏置项；$\hat{y}_k(\boldsymbol{x}, f)$($k$=1，2，…，8)依次对应$dq$导纳矩阵4个元素的实部与虚部辨识值。

具体实现中，特征向量维数P、主干网络与分支网络的隐藏层数及隐藏层宽度均作为模型超参数，根据验证集辨识误差进行调整与确定。

2.3 频段加权损失函数设计

2.3.1 频率权重设计原则

常规数据驱动导纳辨识通常采用全频段均匀加权的回归损失，即默认各频率点处的辨识误差对模型训练具有相同贡献。然而，对于并网逆变器系统，不同频率处的导纳误差对系统开环特征值轨迹的影响程度并不一致，进而会对系统稳定性判别结果产生不同程度的影响。对于给定运行点，逆变器

导纳矩阵与电网阻抗矩阵构成的系统开环矩阵可写为[23]：

$$\boldsymbol{L}(s)=\boldsymbol{Y}_{\mathrm{inv}}(s)\boldsymbol{Z}_{\mathrm{g}}(s) \tag{8}$$

式中：$\boldsymbol{L}(s)$为给定运行点下系统的开环矩阵；$\boldsymbol{Y}_{\mathrm{inv}}(s)$为并网逆变器$dq$导纳矩阵；$\boldsymbol{Z}_{\mathrm{g}}(s)$为电网阻抗矩阵。

根据广义奈奎斯特判据，系统稳定性可由$\boldsymbol{L}(s)$的特征值λ_1、λ_2轨迹相对于临界点−1+j0的位置关系进行判断。当某一频率处特征值轨迹接近临界点时，该频率处的导纳辨识误差更可能引起特征值轨迹相对于临界点位置关系的变化，进而影响系统稳定性判别结果。基于此，本文构建频段加权损失函数，使模型训练更加关注可能影响稳定性判别结果的频率点。

为将上述稳定性敏感信息引入模型训练，下面构造加权损失函数。

2.3.2　加权损失函数构造

对于训练集中第n个样本，设其运行点为$\boldsymbol{x}_n$，对应开环矩阵$\boldsymbol{L}_n(s)$在频率f处的第r个特征值为$\lambda_{n,r}(f)$。由于广义奈奎斯特判据关注特征值轨迹与临界点的相对位置，本文定义第n个样本在频率f处的临界距离为：

$$d_n(f)=\min_{r\in\{1,2\}}\left|\lambda_{n,r}(f)+1\right| \tag{9}$$

式中r为开环矩阵特征值编号。$d_n(f)$越小，说明该运行点在频率f处的特征值轨迹越接近临界点，该频率处的导纳误差越可能影响稳定性判别结果。基于此，定义频率重要度函数为：

$$\eta_n(f)=\exp\left(-\frac{d_n^2(f)}{2\sigma_\eta^2}\right) \tag{10}$$

式中：σ_η为距离尺度参数，用于控制频率重要度随临界距离增大的衰减速度。本文取训练集中所有运行点和频率采样点对应的临界距离$d_n(f)$的中位数作为σ_η。该取值能够以训练样本中临界距离的典型水平作为权重衰减尺度，避免权重过度集中于少数频率采样点。

进一步考虑不同运行点接近临界状态程度的差异，定义第n个样本的临界距离指标为：

$$m_n=\min_{f\in\Omega}d_n(f) \tag{11}$$

式中：Ω为稳定性分析所采用的频率范围；m_n反映第n个运行点下特征值轨迹在所考虑频率范围内接近临界点的程度。该值越小，说明该运行点越接近临界状态，其导纳辨识误差对稳定性判别结果的影响可能更为显著。为消除不同样本m_n数值尺度的影响，先对其进行归一化处理，如式(12)所示。

$$\tilde{m}_n=\frac{m_n-m_{\min}}{m_{\max}-m_{\min}} \tag{12}$$

式中$m_{\min}$和$m_{\max}$分别为训练样本中m_n的最小值和最大值。在此基础上，定义样本权重为：

$$\alpha_n=1+\gamma(1-\tilde{m}_n) \tag{13}$$

式中：γ为调节系数，用于控制接近临界状态样本的权重增强程度，本文取γ=1。由于归一化后的临界距离指标满足$\tilde{m}_n\in[0,1]$，样本权重α_n的取值范围为[1，2]。因此，接近临界状态样本的权重最高为基础权重的2倍，可在增强临界样本约束的同时避免权重差异过大。将各训练样本的频率重要度按照样本权重进行加权汇总，得到训练阶段采用的频率权重，如式(14)所示。

$$w(f)=\frac{\sum_{n=1}^{N}\alpha_n\eta_n(f)}{\sum_{n=1}^{N}\alpha_n} \tag{14}$$

为便于后续分析频段加权损失的作用，本文选取权重$w(f)$最高的前20 %频率采样点定义为关键频段，记为Ω_{key}。其中，Ω_{key}仅用于计算关键频段误差指标，不参与模型训练过程。

在频率采样点f_j处，第n个样本的导纳辨识值和导纳实际值分别记为$\hat{\boldsymbol{y}}(\boldsymbol{x}_n,f_j)$和$\boldsymbol{y}(\boldsymbol{x}_n,f_j)$。二者均为8维实向量。基于所构造的频率权重，总体损失函数定义为：

$$\mathcal{L}=\frac{1}{NN_{\mathrm{f}}}\sum_{n=1}^{N}\sum_{j=1}^{N_{\mathrm{f}}}w(f_j)\left\|\hat{\boldsymbol{y}}(\boldsymbol{x}_n,f_j)-\boldsymbol{y}(\boldsymbol{x}_n,f_j)\right\|_2^2 \tag{15}$$

式中：$\mathcal{L}$为频段加权回归损失函数；N为训练样本数；N_{f}为频率采样点数；$w(f_j)$为频率点f_j对应的权重。

与均匀加权损失相比，式(15)增大了关键频段误差项在总损失中的相对占比，使模型在保持全频段误差约束的同时，更加关注关键频段内的导纳辨识误差，从而提高辨识结果用于稳定性判别时的可靠性。

3　面向参数变化场景的小样本阻抗迁移建模

在实际场景中，通常难以获取覆盖宽运行范围的大规模阻抗数据，而迁移学习能够利用相关任务中的

预训练模型，在目标域数据较少的条件下完成模型适应，进一步降低对实测数据的依赖。考虑到不同参数条件下逆变器的阻抗响应规律存在差异，但其运行点变量形式、频率采样方式及阻抗辨识模型的输出维度保持一致，具备迁移的可行性。基于此，本文在前述阻抗辨识模型基础上引入迁移学习思想。

具体而言，首先利用源域样本完成模型训练，获得能够表征运行点与阻抗频率响应之间基本映射关系的预训练模型；随后将源域训练得到的模型参数作为目标域模型的初始化参数，并结合少量目标域样本对模型进行微调，从而实现由源域到目标域的迁移。

对上述迁移过程进行形式化描述，设源域和目标域样本分别为：

$$\begin{cases} D_{\mathrm{s}} = \left\{ \left(\boldsymbol{x}_n^{\mathrm{s}}, \left\{ \boldsymbol{y}_n^{\mathrm{s}}(f_j) \right\}_{j=1}^{N_{\mathrm{f}}} \right) \right\}_{n=1}^{N_{\mathrm{s}}} \\ D_{\mathrm{t}} = \left\{ \left(\boldsymbol{x}_n^{\mathrm{t}}, \left\{ \boldsymbol{y}_n^{\mathrm{t}}(f_j) \right\}_{j=1}^{N_{\mathrm{f}}} \right) \right\}_{n=1}^{N_{\mathrm{t}}} \end{cases} \tag{16}$$

式中：$\boldsymbol{x}_n^{s}$和$\boldsymbol{x}_n^{t}$分别表示源域和目标域第n个运行点；$\boldsymbol{y}_n^{s}(f_j)$和$\boldsymbol{y}_n^{t}(f_j)$分别为源域和目标域在频率采样点$f_j$处的导纳值；$N_{\mathrm{s}}$和$N_{\mathrm{t}}$分别为源域和目标域的样本数量。

源域预训练参数和目标域初始化参数可分别表示为：

$$\begin{cases} \boldsymbol{\Theta}_{\mathrm{s}}^{*} = \arg\min\limits_{\Theta} \mathcal{L}_{\mathrm{s}}(\boldsymbol{\Theta}) \\ \boldsymbol{\Theta}_{\mathrm{t}}^{(0)} = \boldsymbol{\Theta}_{\mathrm{s}}^{*} \end{cases} \tag{17}$$

式中：$\boldsymbol{\Theta}$为网络全部参数；$\mathcal{L}_{\mathrm{s}}$为源域训练损失函数；$\boldsymbol{\Theta}_s^{*}$为源域训练得到的最优参数；$\boldsymbol{\Theta}_t^{(0)}$为目标域模型的初始化参数。

在目标域中，将源域训练得到的模型参数作为初始化参数，并参考文献[24]中的迁移策略，采用差异化参数更新方式。对于主干网络，仅更新最后一层参数；对于分支网络，冻结首层参数并更新后续各层参数。

设目标域模型中主干网络和分支网络参数分别为：

$$\boldsymbol{\Theta}_{\mathrm{tr}} = \left\{ \boldsymbol{\Theta}_{\mathrm{tr}}^{(l)} \right\}_{l=1}^{L_{\mathrm{tr}}}, \boldsymbol{\Theta}_{\mathrm{br}} = \left\{ \boldsymbol{\Theta}_{\mathrm{br}}^{(l)} \right\}_{l=1}^{L_{\mathrm{br}}} \tag{18}$$

式中：L_{tr}和L_{br}分别为主干网络和分支网络的层数；$\boldsymbol{\Theta}_{\mathrm{tr}}^{(l)}$和$\boldsymbol{\Theta}_{\mathrm{br}}^{(l)}$分别为相应网络第$l$层的参数。根据差异化更新策略，目标域中更新参数块和冻结参数块分别定义为：

$$\begin{cases} \boldsymbol{\Theta}_{\mathrm{upd}} = \left\{ \boldsymbol{\Theta}_{\mathrm{tr}}^{(L_{\mathrm{tr}})}, \boldsymbol{\Theta}_{\mathrm{br}}^{(2)}, \boldsymbol{\Theta}_{\mathrm{br}}^{(3)}, \cdots, \boldsymbol{\Theta}_{\mathrm{br}}^{(L_{\mathrm{br}})}, \boldsymbol{\beta} \right\} \\ \boldsymbol{\Theta}_{\mathrm{frz}} = \left\{ \boldsymbol{\Theta}_{\mathrm{tr}}^{(1)}, \boldsymbol{\Theta}_{\mathrm{tr}}^{(2)}, \cdots, \boldsymbol{\Theta}_{\mathrm{tr}}^{(L_{\mathrm{tr}}-1)}, \boldsymbol{\Theta}_{\mathrm{br}}^{(1)} \right\} \end{cases} \tag{19}$$

式中：$\boldsymbol{\Theta}_{\mathrm{upd}}$和$\boldsymbol{\Theta}_{\mathrm{frz}}$分别为目标域微调过程中参与更新和保持冻结的参数块；$\boldsymbol{\beta}$为输出层偏置向量。在此基础上，目标域微调过程可表示为：

$$\boldsymbol{\Theta}_{\mathrm{upd}}^{*} = \arg\min_{\boldsymbol{\Theta}_{\mathrm{upd}}} \mathcal{L}_{\mathrm{t}} \tag{20}$$

式中：$\boldsymbol{\Theta}_{\mathrm{upd}}^{*}$为目标域微调后得到的最优可更新参数；$\mathcal{L}_{\mathrm{t}}$为目标域微调阶段的损失函数，其形式与式(15)一致，并基于目标域训练集重新计算对应的频率权重。通过上述更新方式实现参数变化场景下的小样本阻抗迁移建模。

4 算例分析

4.1 算例设置与数据集构建

4.1.1 逆变器参数设置

为开展后续算例分析，本文构建了3台并网逆变器，分别记为VSC1、VSC2和VSC3。VSC1与VSC2均采用功率外环控制，但控制参数和滤波电感参数不同；VSC3采用有功功率外环和交流电压幅值外环控制，各逆变器参数分别见表1和表2。

表1 VSC1与VSC2参数

Tab. 1 Parameters of VSC1 and VSC2

参数	VSC1	VSC2
逆变器侧滤波电感L_{f}/ mH	1. 6	1. 4
直流侧电压U_{dc}/ V	600	600
电流内环比例系数k_{pi}	4	4
电流内环积分系数k_{ii}	50	50
锁相环比例系数k_{ppll}	3	2
锁相环积分系数k_{ipll}	12	15
功率外环比例系数k_{pp}	0. 005	0. 001
功率外环积分系数k_{ip}	0. 8	0. 8

表2 VSC3参数

Tab. 2 Parameters of VSC3

参数	数值	参数	数值
逆变器侧滤波电感L_{f}/mH	1	锁相环比例系数k_{ppll}	1. 4
直流侧电压U_{dc}/V	600	锁相环积分系数k_{ipll}	69
电流内环比例系数k_{pi}	2. 7	功率外环比例系数k_{pp}	0. 005
电流内环积分系数k_{ii}	420	功率外环积分系数k_{ip}	0. 08
电压外环比例系数k_{pv}	0. 3	电压外环积分系数k_{iv}	4

4.1.2 数据集构建

本文分别构建VSC1导纳数据集、VSC1稳定

性评估导纳数据集、VSC2 导纳数据集以及 VSC1 与 VSC3 并联系统总导纳数据集。各数据集频率范围统一取 3 Hz~1 kHz，并按对数尺度均匀采样 40 个频率点。构建过程如下。

1）VSC1 导纳数据集

设并网点电压 V_{pcc} 取值范围为［0.9，1.1］p.u.，步长为 0.1 p.u.；dq 轴电流 I_d 和 I_q 取值范围均为［−0.9，0.9］p.u.，步长为 0.3 p.u.，由此构建 147 个运行点。采用文献［25］的方法获得各运行点下的导纳实际值，从而形成 VSC1 导纳数据集，并将数据集按 70 %、15 %、15 %随机划分为训练集、验证集和测试集。

2）VSC1 稳定性评估导纳数据集

为评价频段加权损失对稳定性判别结果的影响，本文在 VSC1 单逆变器场景下构建稳定性评估导纳数据集。设并网点电压 V_{pcc} 为 1 p.u.，I_d 和 I_q 取值范围均为［−1.1，1.1］p.u.，步长为 0.22 p.u.。由此构建 121 个运行点，采用文献［25］的方法获得各运行点下导纳实际值。

3）VSC2 导纳数据集

设并网点电压 V_{pcc} 取值范围为［0.9，1.1］p.u.，步长为 0.2 p.u.；I_d 和 I_q 取值范围均为［−1，1］p.u.，步长为 0.5 p.u.。由此构建 50 个运行点，并按 80 %和 20 %的比例随机划分为训练集和验证集。为分析模型在连续运行点变化条件下的辨识性能，测试集采用更密集的运行点变化轨迹。设定 V_{pcc}=1 p.u.、I_q=0 p.u.，令 I_d 取值范围为［−1，1］p.u.，步长为 0.02 p.u.，共得到 101 个运行点，采用文献［25］的方法获得各运行点下导纳实际值。

4）VSC1 与 VSC3 并联系统总导纳数据集

多逆变器并联系统在并网点处的总导纳与各逆变器的运行点组合有关[25]。因此，本文将运行点输入由单逆变器场景下的［V_{pcc}，I_d，I_q］扩展为［V_{pcc}，I_{d1}，I_{q1}，I_{d2}，I_{q2}］。设并网点电压 V_{pcc} 取值范围为［0.9，1.1］p.u.，步长为 0.1 p.u.；VSC1 和 VSC3 的 d、q 轴电流取值范围均为［−0.9，0.9］p.u.，步长均为 0.3 p.u.。为控制数据构建规模并提高运行点组合的代表性，本文首先根据上述离散取值形成完整候选运行点组合空间，随后采用分层无放回随机抽样方式抽取 200 组运行点，抽样过程中以并网点电压 V_{pcc} 的不同取值作为分层依据，在各电压层内随机抽取两台逆变器的 d、q 轴电流组合，以降低样本集中于单一电压水平或局部运行区域的可能性。采用文献［25-26］中的方法得到各运行点下并联系统总导纳实际值。将数据集按 70 %、15 %、15 %随机划分为训练集、验证集和测试集。

4.1.3　评价指标

本文采用平均绝对误差（mean absolute error，MAE）和均方根误差（root mean square error，RMSE）评价模型全频段导纳辨识精度。在此基础上，进一步采用关键频段平均绝对误差 $\mathrm{MAE}_{\mathrm{key}}$、单运行点平均绝对误差 MAE_n 和稳定性判别一致率 Acc，分别评价关键频段辨识误差、不同运行点下的辨识误差和稳定性判别一致性。

设评价样本数为 N_{e}，频率采样点数为 N_{f}，导纳输出分量数为 K。第 n 个运行点在频率 f_j 处第 k 个导纳分量的实际值和辨识值分别记为 $y_{n,k}(f_j)$ 和 $\hat{y}_{n,k}(f_j)$，则逐点辨识误差定义为：

$$e_{n,j,k}=\hat{y}_{n,k}(f_j)-y_{n,k}(f_j) \tag{21}$$

式中 $e_{n,j,k}$ 为第 n 个运行点在频率 f_j 处第 k 个导纳分量的辨识误差。

在此基础上，全频段 MAE 和 RMSE 分别定义为：

$$E_{\mathrm{MAE}}=\frac{1}{N_{\mathrm{e}}N_{\mathrm{f}}K}\sum_{n=1}^{N_{\mathrm{e}}}\sum_{j=1}^{N_{\mathrm{f}}}\sum_{k=1}^{K}\left|e_{n,j,k}\right| \tag{22}$$

$$E_{\mathrm{RMSE}}=\sqrt{\frac{1}{N_{\mathrm{e}}N_{\mathrm{f}}K}\sum_{n=1}^{N_{\mathrm{e}}}\sum_{j=1}^{N_{\mathrm{f}}}\sum_{k=1}^{K}e_{n,j,k}^{2}} \tag{23}$$

式中 K=8，对应 dq 导纳矩阵 4 个元素实部和虚部。其中，MAE 值反映平均辨识误差，RMSE 对较大误差更为敏感。

设关键频段为 Ω_{key}，其中包含 N_{key} 个频率采样点，则关键频段 $E_{\mathrm{MAE\text{-}key}}$ 定义为：

$$E_{\mathrm{MAE-key}}=\frac{1}{N_{\mathrm{e}}N_{\mathrm{key}}K}\sum_{n=1}^{N_{\mathrm{e}}}\sum_{f_j\in\Omega_{\mathrm{key}}}\sum_{k=1}^{K}\left|e_{n,j,k}\right| \tag{24}$$

该指标用于评价模型在关键频段内的导纳辨识误差。

为分析辨识误差随运行点变化的特点，定义第 n 个运行点对应的 $E_{\mathrm{MAE}n}$：

$$E_{\mathrm{MAE}\,n}=\frac{1}{N_{\mathrm{f}}K}\sum_{j=1}^{N_{\mathrm{f}}}\sum_{k=1}^{K}\left|e_{n,j,k}\right| \tag{25}$$

该指标用于评价单个运行点下导纳在全频率点下的平均辨识误差。

为量化辨识结果用于稳定性判别时的可靠性，

本文定义稳定性判别一致率 Acc。在相同电网阻抗条件下，分别利用导纳实际值和辨识导纳构造系统开环矩阵，并基于广义奈奎斯特判据获得对应运行点稳定或不稳定的判别结果。设第 n 个运行点由导纳实际值和辨识导纳得到的稳定性判别结果标签分别为 c_n 和 $\hat{c}_n$，则 Acc 定义为：

$$E_{\mathrm{Acc}}=\frac{1}{N_{\mathrm{e}}}\sum_{n=1}^{N_{\mathrm{e}}}I(\hat{c}_n=c_n)\times 100\,\% \tag{26}$$

式中 $I(\cdot)$ 为指示函数，当辨识导纳和导纳实际值得到的判别标签一致时取 1，否则取 0。

4.1.4 模型训练配置

本文以表 3 所示配置作为典型训练配置，并根据不同算例的验证集辨识误差对网络规模和训练参数进行适当调整。

表 3 模型典型训练配置

Tab. 3 Typical training configuration of the model

参数	配置	参数	配置
特征向量维数	20	分支网络隐藏层宽度	128
主干网络隐藏层数	3	初始学习率	2×10^{-3}
主干网络隐藏层宽度	128	批大小(batch size)	32
分支网络隐藏层数	3	训练轮数(epoch)	1 000
激活函数	tanh	优化器	AdamW

4.2 单逆变器多运行点导纳辨识

4.2.1 VSC1 导纳辨识结果

本节以 VSC1 为研究对象，采用 4.1.2 节构建的 VSC1 导纳数据集，对所提方法在单逆变器场景下的多运行点导纳辨识能力进行验证。

为展示模型在未见运行点上的导纳辨识效果，本文从测试集中随机选取一个运行点，其辨识结果如图 4 所示。为便于展示，图 4 给出了主对角线元素 Y_{dd} 和 Y_{qq} 的实部与虚部结果。由图 4 可见，在所选运行点下，Y_{dd} 和 Y_{qq} 的辨识曲线与导纳实际值在 3 Hz~1 kHz 范围内整体吻合较好，低频段的平缓变化、中频段的转折以及高频段的变化趋势均能够较准确跟踪，说明所提方法能够取得较好的导纳辨识结果。

进一步分析所提方法在多运行点导纳辨识中的整体效果，图 5 给出了训练集与测试集逐点辨识误差 $e_{n,j,k}$ 的分布结果，图 5 统计了样本集中全部运行点和频率采样点上的导纳辨识误差。由图 5 可见，训练集与测试集的辨识误差均主要分布在 -1×10^{-3} S

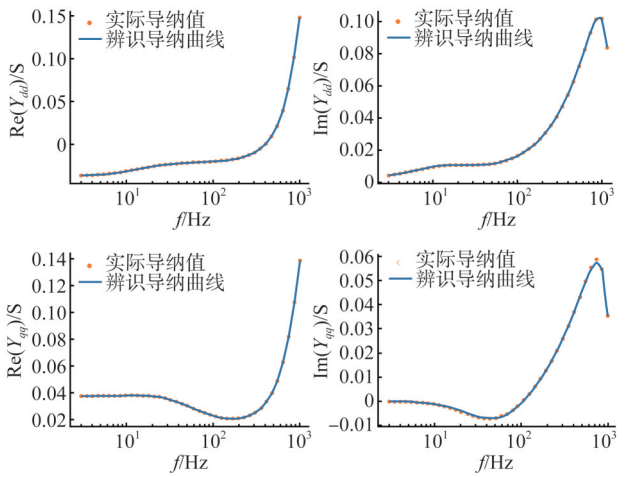
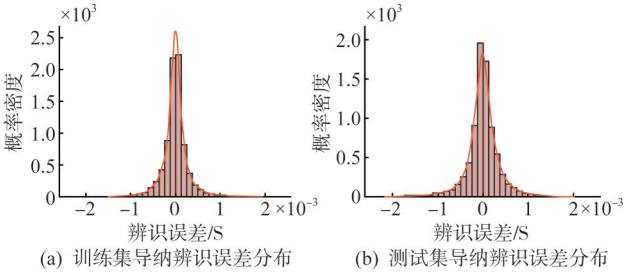


图 4 VSC1 测试集随机运行点下导纳辨识结果

Fig. 4 Admittance identification results at a random test operating point of VSC1

至 1×10^{-3} S 范围内，说明模型在大多数导纳数据点上的辨识偏差较小。测试集误差分布相较于训练集略有扩展，但二者整体分布特征较为接近。同时，训练集 MAE 值和 RMSE 值分别为 1.89×10^{-4} S 和 3.15×10^{-4} S，测试集 MAE 值和 RMSE 值分别为 2.45×10^{-4} S 和 3.97×10^{-4} S，测试集误差相较训练集有所增加，但仍保持在较低水平，说明所提方法在未参与训练的运行点上仍具有较好的导纳辨识能力和泛化效果。



(a) 训练集导纳辨识误差分布 (b) 测试集导纳辨识误差分布

图 5 VSC1 数据集导纳辨识误差分布

Fig. 5 Distribution of admittance identification errors in the VSC1 dataset

4.2.2 不同方法导纳辨识结果对比

为进一步验证所提方法在单逆变器多运行点导纳辨识中的有效性，本文选取人工神经网络(artificial neural network，ANN)、残差网络(residual network，ResNet)和随机森林(random forest，RF)作为对比方法，在相同数据集下开展对比实验。不同方法在测试集上的导纳辨识结果如表 4 所示。

表 4　单逆变器测试集导纳辨识结果对比

Tab. 4　Comparison of admittance identification results on the single-inverter test set

方法	MAE/($\times10^{-4}$ S)	RMSE/($\times10^{-4}$ S)
ANN	6. 34	11. 03
ResNet	5. 64	10. 10
RF	8. 73	14. 20
所提方法	2. 45	3. 97

由表 4 可见，RF 的 MAE 值和 RMSE 值均高于其他方法，误差相对较大；ANN 和 ResNet 的误差有所降低，其中 ResNet 略优于 ANN。相比之下，所提方法的 MAE 值和 RMSE 值均为各方法中最小，表明所提方法在单逆变器多运行点导纳辨识中具有较好的辨识效果。

4. 2. 3　频段加权损失作用分析

为分析频段加权损失的作用，本文在 VSC1 单逆变器场景下设置均匀加权损失模型作为对照。从 VSC1 导纳数据集的训练集中随机选取 60 个运行点作为两组模型的共同训练样本，验证集保持不变。两组模型保持网络结构和训练参数一致，区别仅在于损失函数中的频率权重设置。其中，均匀加权损失模型对各频率采样点赋予相同权重，频段加权损失模型采用前文构建的频率权重。训练完成后，将两组模型应用于 VSC1 稳定性评估导纳数据集进行导纳辨识，并基于导纳辨识结果进行稳定性判别，比较该数据集上的关键频段导纳辨识误差和稳定性判别一致率，结果如表 5 所示。

表 5　关键频段导纳辨识误差与稳定性判别一致率对比

Tab. 5　Comparison of key-frequency-band admittance identification errors and stability discrimination consistency

方法	MAE_{key} 值/($\times10^{-4}$ S)	Acc 值/ %
均匀加权损失模型	4. 66	93. 39
频段加权损失模型	1. 02	100

由表 5 可见，相较于均匀加权损失模型，频段加权损失模型的关键频段 MAE_{key} 值由 4.66×10^{-4} S 降低至 1.02×10^{-4} S，说明频段加权损失能够降低关键频段内的导纳辨识误差。同时，频段加权损失模型的稳定性判别一致率由 93. 39 % 提高至 100 %，说明关键频段导纳辨识误差的降低有助于减少辨识误差对稳定性判别结果的影响，从而提高辨识结果用于稳定性判别时的可靠性。

4. 3　参数变化场景下的小样本迁移导纳辨识

本节采用 4. 1. 2 节构建的 VSC1 和 VSC2 导纳数据集对参数变化场景下的小样本迁移导纳辨识效果进行验证。其中，VSC1 导纳数据集作为源域数据集，用于源域模型训练；VSC2 导纳数据集作为目标域数据集，用于比较直接训练方法与迁移训练方法的导纳辨识效果。

为展示目标域测试集中导纳实际值的变化特征，图 6 给出了在 V_{pcc}=1. 0 p. u. 、I_q=0 p. u. 条件下主对角线导纳元素 Y_{dd} 和 Y_{qq} 的实部与虚部随 I_d 变化的结果。由图可见，导纳频率响应曲线在不同 I_d 取值下的幅值水平和变化趋势存在差异，呈现出一定的非线性特征。由于目标域可用于训练的样本数量有限，上述变化增加了小样本导纳辨识的难度。

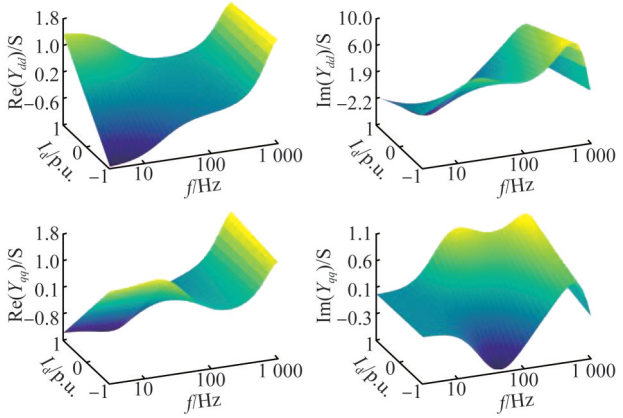


图 6　目标域测试集导纳实际值变化曲面

Fig. 6　Surfaces of actual admittance values in the target-domain test set

为验证迁移学习策略对目标域导纳辨识结果的影响，本文在相同目标域测试集上比较 ANN、直接训练法和迁移训练法 3 种方法的导纳辨识效果。其中，ANN 和直接训练法均利用目标域训练集进行训练；迁移训练法以 VSC1 源域预训练模型为初始模型，并利用目标域训练集进行微调。不同方法在目标域测试集上的导纳辨识结果如表 6 所示。

表 6　目标域测试集导纳辨识结果对比

Tab. 6　Comparison of admittance identification results on the target-domain test set

方法	MAE 值/($\times10^{-4}$ S)	RMSE 值/($\times10^{-4}$ S)
ANN	12. 77	17. 93
直接训练法	8. 63	13. 54
迁移训练法	4. 37	8. 26

由表6可见，ANN在目标域测试集上的误差相对较大，直接训练法的MAE和RMSE均低于ANN。采用迁移训练后，MAE和RMSE相较于直接训练模型进一步降至4.37×10^{-4} S和8.26×10^{-4} S。结果表明，源域预训练模型能够为目标域模型提供较好的参数初始化，从而改善目标域小样本条件下的导纳辨识效果。

进一步比较各方法在不同I_d取值下的辨识效果，本文计算目标域测试集中各运行点对应的E_{MAE_n}，并绘制其随I_d变化的曲线，如图7所示。

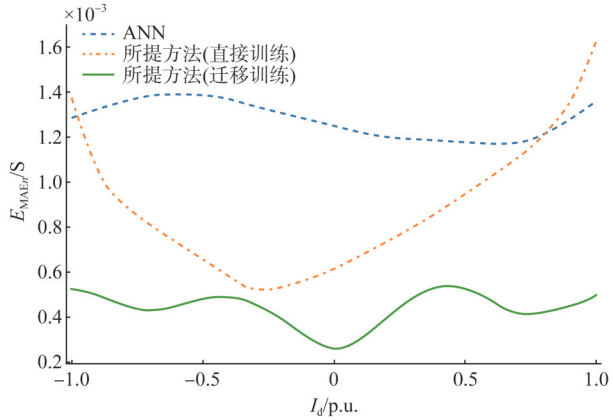


图7 不同方法下E_{MAE_n}随I_d变化曲线

Fig. 7 Curves of E_{MAE_n} versus I_d for different methods

由图7可见，ANN在各运行点下的MAE$_n$整体较高，说明其在目标域小样本条件下对运行点与导纳频率响应之间映射关系的表征能力相对不足。直接训练法的误差整体低于ANN，但其误差随I_d变化较为明显，且在I_d接近区间两端时有所增大。相比之下，迁移训练法在整个I_d变化范围内均保持较低误差，且误差波动相对较小，说明迁移策略能够降低目标域小样本条件下的导纳辨识误差，提高模型对参数变化场景下导纳频率响应的表征能力。

4.4 多逆变器并联系统总导纳辨识

4.4.1 并联系统总导纳辨识结果

本节采用4.1.2节构建的VSC1与VSC3并联系统总导纳数据集，进一步验证所提方法在多逆变器并联系统场景下的适用性。为适应该场景，模型分支网络输入由单逆变器运行点[V_{pcc}，I_d，I_q]扩展为并联系统运行点组合[V_{pcc}，I_{d1}，I_{q1}，I_{d2}，I_{q2}]，其中下标1和2分别表示VSC1和VSC3对应的电流分量；主干网络仍以频率作为输入，模型输出为对应运行点组合下的系统总导纳频率响应。

为直观展示总导纳辨识效果，图8给出了测试集中一个随机运行点组合下的主对角线总导纳辨识结果。由图可见，所提方法得到的辨识曲线与总导纳实际值整体吻合较好，说明在运行点输入维度增加的情况下，模型仍能够较好地表征系统总导纳频率响应。

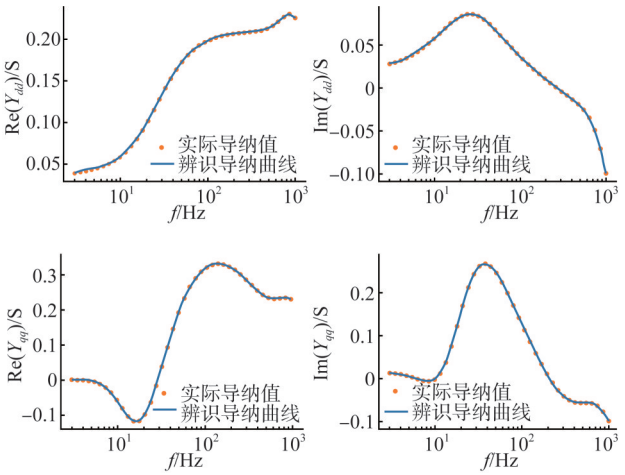
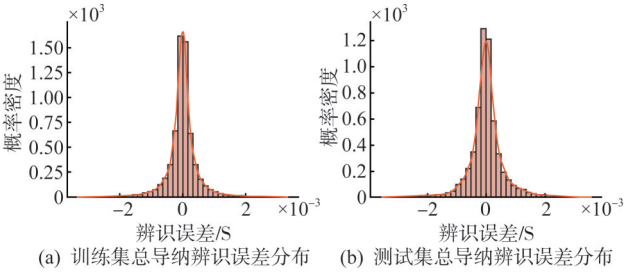


图8 多逆变器随机运行点组合下总导纳辨识结果

Fig. 8 Total admittance identification results at a random operating-point combination in the multi-inverter test set

图9给出了多逆变器总导纳训练集与测试集的逐点辨识误差分布。训练集与测试集误差多数集中在−2×10^{-3} S至2×10^{-3} S范围内，整体分布特征较为接近，表明所提方法在未参与训练的运行点组合上仍能够保持较好的总导纳辨识效果。



(a) 训练集总导纳辨识误差分布 (b) 测试集总导纳辨识误差分布

图9 多逆变器数据集总导纳辨识误差分布

Fig. 9 Distribution of total admittance identification errors in the multi-inverter dataset

4.4.2 不同方法总导纳辨识结果对比

进一步比较不同方法在多逆变器并联系统总导纳辨识中的表现，同样选取ANN、ResNet和RF作为对比方法，在相同数据集下进行测试。不同方法在测试集上的总导纳辨识结果如表7所示。

表 7　多逆变器测试集总导纳辨识结果对比

Tab. 7　Comparison of total admittance identification results on the multi-inverter test set

方法	MAE/($\times10^{-4}$ S)	RMSE/($\times10^{-4}$ S)
ANN	14. 02	21. 59
ResNet	7. 81	13. 54
RF	26. 20	50. 30
所提方法	4. 06	6. 83

由表7可见，在多逆变器并联系统场景下，RF的误差最大，ANN和ResNet的误差较RF有所降低，其中ResNet优于ANN。相比之下，所提方法的MAE值和RMSE值分别为4.06×10^{-4} S和6.83×10^{-4} S，均为各方法中最小。该结果表明，在运行点组合维度增加、系统总导纳由多台逆变器共同决定的情况下，所提方法仍能够保持较好的总导纳辨识精度。

5　结论

本文针对并网逆变器多运行点阻抗辨识问题，提出了基于深度算子网络结构的多运行点阻抗辨识方法，并通过相关算例验证了所提方法的有效性。主要结论如下。

1)构建了基于深度算子网络结构的多运行点阻抗辨识模型。结果表明，所提方法能够较准确地辨识不同运行点下的导纳频率响应，并具有较好的泛化能力。

2)构造了频段加权损失函数。结果表明，频段加权损失能够降低关键频段内的导纳辨识误差，提高辨识结果用于稳定性判别时的可靠性。

3)提出了参数变化场景下的小样本阻抗迁移建模方法。结果表明，迁移训练能够利用源域预训练模型的信息，改善目标域小样本条件下的导纳辨识效果。

4)将所提方法扩展至多逆变器并联系统总导纳辨识场景。结果表明，在运行点输入维度增加、系统总导纳由多台逆变器共同决定的情况下，所提方法仍能够取得较好的总导纳辨识效果，具有一定的多逆变器场景适用性。

参考文献

[1] 徐政. 高比例非同步机电源电网面临的三大技术挑战[J]. 南方电网技术，2020，14(2)：1－9.
XU Zheng. Three technical challenges faced by power grids with high proportion of non-synchronous machine sources[J]. Southern Power System Technology，2020，14(2)：1－9.

[2] 李勇，常樊睿，彭衍建，等. 分散式新能源并网稳定性问题分析与控制方法[J]. 高电压技术，2025，51(4)：1543－1559.
LI Yong，CHANG Fanrui，PENG Yanjian，et al. Analysis and control methods of stability problems for decentralized renewable generations integrated into grid[J]. High Voltage Engineering，2025，51(4)：1543－1559.

[3] 张世聪，徐永海，陶顺，等. 弱电网下多逆变器并网稳定性分析及提高策略[J]. 南方电网技术，2026，20(3)：19－31.
ZHANG Shicong，XU Yonghai，TAO Shun，et al. Stability analysis and improved strategy of multi-inverter grid-connected in weak grid[J]. Southern Power System Technology，2026，20(3)：19－31.

[4] 黄萌，舒思睿，李锡林，等. 面向同步稳定性的电力电子并网变流器分析与控制研究综述[J]. 电工技术学报，2024，39(19)：5978－5994.
HUANG Meng，SHU Sirui，LI Xilin，et al. A review of synchronization-stability-oriented analysis and control of power electronic grid-connected converters[J]. Transactions of China Electrotechnical Society，2024，39(19)：5978－5994.

[5] 殷伟斌，熊连松，赵涛. 并网逆变器发电系统稳定性分析方法综述[J]. 南方电网技术，2019，13(1)：14－26.
YIN Weibin，XIONG Liansong，ZHAO Tao. Review of stability analysis methods of grid-tied inverter power generation systems[J]. Southern Power System Technology，2019，13(1)：14－26.

[6] 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 Pu，CUI Yibo，LIU Zhaofeng，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.

[7] 陈新，王赟程，龚春英，等. 采用阻抗分析方法的并网逆变器稳定性研究综述[J]. 中国电机工程学报，2018，38(7)：2082－2094，2223.
CHEN Xin，WANG Yuncheng，GONG Chunying，et al. Overview of stability research for grid-connected inverters based on impedance analysis method[J]. Proceedings of the CSEE，2018，38(7)：2082－2094，2223.

[8] 王赟程，陈新，张旸，等. 三相并网逆变器锁相环频率特性分析及其稳定性研究[J]. 中国电机工程学报，2017，37(13)：3843－3853.
WANG Yuncheng，CHEN Xin，ZHANG Yang，et al. Frequency characteristics analysis and stability research of phase locked loop for three-phase grid-connected inverters[J]. Proceedings of the CSEE，2017，37(13)：3843－3853.

[9] 王金龙，赵浩然，王鹏，等. 基于阻抗法的并网逆变器小信号稳定功率极限分析与提高[J]. 电力系统保护与控制，2022，50(18)：18－28.
WANG Jinlong，ZHAO Haoran，WANG Peng，et al. Analysis and improvement of the small-signal stable power limit of a grid-connected inverter based on an impedance method[J]. Power System Protection and Control，2022，50(18)：18－28.

[10] RONG Q，HU P，YU Y，et al. Virtual external perturbance-based impedance measurement of grid-connected converter[J]. IEEE Transactions on Industrial Electronics，2025，72(3)：2644－2654.

[11] 汪颖，罗宇岑，殷毓杉，等. 注入式与非注入式协同的逆变器阻抗估计[J]. 电力系统保护与控制，2025，53(24)：38－51.
WANG Ying，LUO Yucen，YIN Yushan，et al. Coordinated injected and non-injected inverter impedance estimation [J]. Power System Protection and Control，2025，53(24)：38－51.

[12] WANG X，HARNEFORS L，BLAABJERG F，et al. Unified impedance model of grid-connected voltage-source converters [J]. IEEE Transactions on Power Electronics，2018，33(2)：1775－1787.

[13] 刘威，谢小荣，黄金魁，等. 并网变流器的频率耦合阻抗模型及其稳定性分析[J]. 电力系统自动化，2019，43(3)：138－146.
LIU Wei，XIE Xiaorong，HUANG Jinkui，et al. Frequency-coupled impedance model and stability analysis of grid-connected converter [J]. Automation of Electric Power Systems，2019，43(3)：138－146.

[14] 吴天昊，谢小荣，姜齐荣，等. 考虑频率耦合及交直流端口耦合效应的并网变流器三端口导纳模型[J]. 中国电机工程学报，2022，42(1)：249－261.
WU Tianhao，XIE Xiaorong，JIANG Qirong，et al. Three-port admittance modeling of grid-connected converters considering frequency-coupling and AC/DC coupling effects [J]. Proceedings of the CSEE，2022，42(1)：249－261.

[15] LIU W，XIE X，SHAIR J，et al. A nearly decoupled admittance model for grid-tied VSCs under variable operating conditions [J]. IEEE Transactions on Power Electronics，2020，35(9)：9380－9389.

[16] 赵崇滨，姜齐荣. 并网变流器全工况阻抗模型的黑箱辨识方法[J]. 电力系统保护与控制，2024，52(4)：48－55.
ZHAO Chongbin，JIANG Qirong. Black-box identification of full operating condition impedance model of grid-tied converter [J]. Power System Protection and Control，2024，52(4)：48－55.

[17] ZHANG Z，WU W，XIE Z，et al. Identification method of all-operating-point admittance model for wind farms considering frequency-coupling characteristics [J]. International Journal of Electrical Power and Energy Systems，2024(158)：109953.

[18] ZHANG M，WANG X，YANG D，et al. Artificial neural network based identification of multi-operating-point impedance model [J]. IEEE Transactions on Power Electronics，2021，36(2)：1231－1235.

[19] LI Y，LIAO Y，ZHAO L，et al. Machine learning at the grid edge：data-driven impedance models for model-free inverters [J]. IEEE Transactions on Power Electronics，2024，39(8)：10465－10481.

[20] LIAO Y，LI Y，CHEN M，et al. Neural network design for impedance modeling of power electronic systems based on latent features [J]. IEEE Transactions on Neural Networks and Learning Systems，2024，35(5)：5968－5980.

[21] WEN B，BOROYEVICH D，BURGOS R，et al. Analysis of D-Q small-signal impedance of grid-tied inverters [J]. IEEE Transactions on Power Electronics，2016，31(1)：675－687.

[22] LU L，JIN P，PANG G，et al. Learning nonlinear operators via DeepONet based on the universal approximation theorem of operators [J]. Nature Machine Intelligence，2021，3(3)：218－229.

[23] SUN J. Impedance-Based stability criterion for grid-connected inverters [J]. IEEE Transactions on Power Electronics，2011，26(11)：3075－3078.

[24] GOSWAMI S，KONTOLATI K，SHIELDS M D，et al. Deep transfer operator learning for partial differential equations under conditional shift [J]. Nature Machine Intelligence，2022，4(12)：1155－1164.

[25] WU Y，WU H，CHENG L，et al. Impedance profile prediction for grid-connected VSCs with data-driven feature extraction [J]. IEEE Transactions on Power Electronics，2025，40(2)：3043－3061.

[26] ZHAO T，WU C，WANG Y. Mechanistic analysis and suppression of the positive feedback of active power for grid-connected converters under a weak grid [J]. International Journal of Electrical Power and Energy Systems，2025(172)：111203.

收稿日期：2026-07-10；**网络首发日期**：2026-08-28

作者简介：

汪颖(1981)，女，教授，博士生导师，博士，研究方向为电能质量与优质供电，tuantuan1125@scu. edu. cn；

马子航(2001)，男，硕士研究生，研究方向为电能质量与新能源；

肖先勇(1968)，男，教授，博士生导师，博士，研究方向为电能质量与优质供电、智能电网与电网安全、超导电力。