

# 基于DBN-ELM的构网型并网逆变器 控制参数自适应调整方法

张梦琪<sup>1</sup>,李永刚<sup>1</sup>,孙庚<sup>2</sup>,吴滨源<sup>1</sup>,刘淇玉<sup>1</sup>,张驰<sup>1</sup>

(1. 华北电力大学 新能源电力系统国家重点实验室,河北 保定 071003;

2. 国网辽宁省电力有限公司阜新供电公司,辽宁 阜新 123000)

**摘要:**“双高”电力系统中电网阻抗呈现宽范围时变特性,构网型并网逆变器控制参数缺乏自适应调整能力,存在失稳风险。对此,提出一种基于深度置信网络-极限学习机的构网型并网逆变器控制参数自适应调整方法。建立闭环极点映射模型,利用深层架构对控制参数与关键极点之间的映射关系进行训练;通过训练好的闭环极点映射模型预测得到相应的关键极点,识别出关键极点最接近参考极点时构网型并网逆变器的控制参数;通过自适应调整控制参数,确保系统在电网阻抗变化时跟踪参考极点,实现自适应稳定控制。理论分析和仿真结果均表明,所提方法能够实现控制参数的自适应调整,有效提高构网型并网逆变器对电网阻抗变化的适应性。

**关键词:**构网型并网逆变器;自适应调整;深度置信网络-极限学习机;复矢量建模;电网阻抗

**中图分类号:**TM464

**文献标志码:**A

**DOI:**10.16081/j.epae.202308008

## 0 引言

作为新能源设备与电网的关键接口,构网型并网逆变器通过功率同步控制<sup>[1]</sup>、下垂控制<sup>[2]</sup>或虚拟同步机控制<sup>[3]</sup>实现同步发电机惯量和阻尼特性模拟,可增强电力系统稳定性。现有研究表明:强弱电网变化时电网阻抗呈现宽范围变化,可能影响构网型并网逆变器的控制性能,甚至失去稳定性。为了提高构网型并网逆变器在电网阻抗变化下的稳定性,有必要提出一种能够实现自适应稳定控制的方法。

构网型并网逆变器建模是稳定性分析的基础和关键前提,现有稳定性分析方法主要包括基于状态空间模型的特征值分析法和基于阻抗模型的频域分析法。基于状态空间模型的特征值分析法依赖构网型并网逆变器及电网的详细模型和参数,然而状态空间模型阶数会随着构网型并网逆变器数量的增加而增加,可能出现“维数灾”问题。而构网型并网逆变器阻抗模型可采用现场测试获得,减少了频域分析法对其内部参数的依赖<sup>[4]</sup>。根据选取坐标系的不同,阻抗模型主要分为 $dq$ 阻抗模型<sup>[5]</sup>和序阻抗模型<sup>[1]</sup>。然而,构网型并网逆变器和电网阻抗无论是在 $dq$ 坐标系下还是在正负序坐标系下都是二维的阻抗矩阵,且难以同时对角化,削弱了频域分析法的优势<sup>[6]</sup>。复矢量理论可以将结构对称的多输入多输

出系统降阶为单输入单输出系统,避免了模型降阶过程中信息的损失,保证了系统信息的完整性<sup>[7]</sup>。文献[8]提出一种基于复矢量的坐标变换方法,表明 $dq$ 阻抗模型和序阻抗模型均可通过复传递函数转换为复矢量形式,然而复传递函数仅限于对称系统的建模。文献[9]介绍了复矢量形式下构网型并网逆变器有功功率-频率( $P-f$ )下垂控制等效为虚拟阻抗的推导过程,但并未对并网逆变器电压电流控制环节和滤波环节进行详细说明。文献[10]给出非对称系统在 $dq$ 坐标系下阻抗矩阵的复矢量形式,能够统一静止坐标系与旋转坐标系的阻抗模型,进而采用广义奈奎斯特稳定判据,在并网系统稳定性分析领域有广阔的运用前景。

为避免电网阻抗变化带来的潜在失稳问题,通常采用2种方式:①设计非线性控制器,如D- $\Sigma$ 数字控制<sup>[11]</sup>、滑模控制<sup>[12]</sup>、 $H_\infty$ 控制<sup>[13]</sup>等,提高系统对参数变化的鲁棒性;②根据电网阻抗的变化自适应调整控制器的参数,其中电网阻抗的变化可以通过递归最小二乘法<sup>[14]</sup>、基于最大长度二进制序列注入<sup>[15]</sup>等方法进行在线估计。文献[16]提出一种基于电网阻抗估计的自适应控制方法,即时调整调节器参数以保证跟网型并网逆变器在弱电网下具有较好的相位裕度或高带宽。文献[17]以相角裕度为约束条件,在线调整跟网型并网逆变器阻抗环路的串并联微分系数,提高了并网系统对电网的鲁棒性和抗扰性能。文献[18]采用人工神经网络(artificial neural network, ANN)建立系统控制参数与闭环极点之间的映射关系,提出一种可同时调优多个控制器和参数的在线参数搜索算法,实现了系统的在线稳定控

收稿日期:2023-03-11;修回日期:2023-07-31

在线出版日期:2023-08-08

基金项目:国网辽宁省电力有限公司管理科技项目(2022YF-36)

Project supported by the Management and Technology Project of State Grid Liaoning Electric Power Co.,Ltd.(2022YF-36)

制。然而,以ANN为代表的传统机器学习算法的层数较浅,对数据特征的学习能力有限,无法准确拟合特征与输出间的映射关系<sup>[19]</sup>。可以看出,目前大多数研究集中在对弱电网下跟网型并网逆变器的控制方式进行改进,对提高构网型并网逆变器对电网阻抗变化适应性的改进方法以及将深度学习用于自适应稳定控制的研究鲜有提及。

为此,本文提出一种基于深度置信网络-极限学习机(deep belief network-extreme learning machine, DBN-ELM)的构网型并网逆变器控制参数自适应调整方法。首先,建立构网型并网逆变器的复矢量阻抗电路模型,降低计算量的同时保证建模的准确性;然后,基于改进DBN-ELM模型和实时电网阻抗实现闭环极点预测和控制参数的识别,提高了预测的速度和精度;最后,通过控制参数的自适应调整,确保系统在电网阻抗变化时能够稳定运行,仿真结果证明了本文所提方法的有效性。

## 1 构网型并网逆变器的建模与控制

文献[20]提出的阻抗电路建模方法可揭示不同控制回路的虚拟阻抗特性,可为控制参数的调整提供理论依据。因此,本文将复矢量理论与阻抗电路模型的优势相结合,建立构网型并网逆变器的复矢量阻抗电路模型。复矢量理论的基本原理和受控源的等效虚拟阻抗原理分别如附录A和附录B所示。

由于新型电力系统存在惯量和阻尼降低的趋势,能够模拟同步发电机惯量和阻尼特性的构网型并网逆变器成为研究热点。文献[21]指出,在特定情况下,含低通滤波器的下垂控制可等价于虚拟同步机控制,两者均可模拟惯量。因此,本文将含下垂控制的构网型并网逆变器作为研究对象。构网型并网逆变器经线路阻抗接入无穷大电源系统及其控制结构如图1所示。图中: $v_i$ 为构网型并网逆变器的端口电压; $v_o$ 、 $i_o$ 分别为构网型并网逆变器的输出电压、电流; $i_L$ 和 $i_C$ 分别为构网型并网逆变器滤波电感 $L_f$ 和滤波电容 $C_f$ 上的电流; $r_f$ 为LC滤波器的等效电阻; $u_g$ 为电网电压; $v_{odq}$ 和 $i_{Ldq}$ 分别为构网型并网逆变器在 $dq$ 坐标系下的输出电压和逆变器侧电流; $v_{odq}^*$ 和 $i_{Ldq}^*$ 分

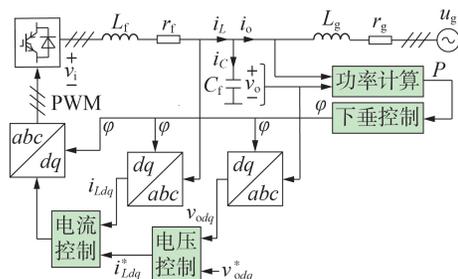


图1 构网型并网逆变器控制结构

Fig.1 Control structure of grid-forming inverter

别为电压和电流给定信号; $P$ 为输出有功功率; $L_g$ 和 $r_g$ 分别为电网的等效电感和等效电阻,由于电网阻抗中阻性分量对并网系统的稳定性更有利,本文仅考虑电网感抗以分析最不利的情况<sup>[22]</sup>。构网型并网逆变器通过有功功率-频率下垂控制产生相位值 $\varphi$ ,该相位即为同步信号。

构网型并网逆变器 $P$ - $f$ 下垂控制的控制框图如图2所示。图中: $P^*$ 为输出有功功率给定值; $\omega^*$ 为给定角速度; $\omega$ 为角速度; $G_{PF}$ 为下垂控制调节器,其表达式如式(1)所示。

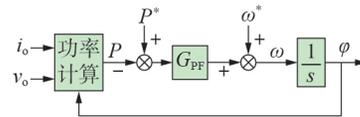


图2 有功功率控制闭环等效框图

Fig.2 Closed-loop equivalent block diagram of active power control

$$G_{PF} = m_{PF} \frac{1}{1 + s/\omega_f} \quad (1)$$

式中: $m_{PF}$ 为下垂增益; $1/(1 + s/\omega_f)$ 表示低通滤波器,可以衰减高频噪声, $\omega_f$ 为低通滤波器截止角频率。

当不考虑功率下垂控制环节时,构网型并网逆变器的阻抗矩阵对称,其阻抗电路模型如图3所示。图中: $v_{odq+}^*$ 为正频率电压给定值; $v_{odq+}$ 、 $i_{odq+}$ 和 $Z_{s+}$ 分别为不考虑功率下垂控制环节时构网型并网逆变器正频率输出电压、正频率输出电流和正频率输出阻抗; $G_v$ 为电压控制环路增益; $Z_{loopi}$ 为电流环控制等效虚拟阻抗; $Z_{loopvc}$ 为电压环控制和滤波电容的等效虚拟阻抗之和,具体推导过程如附录C所示。

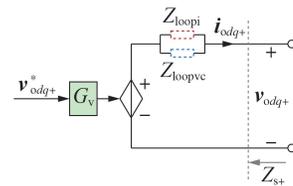


图3 构网型并网逆变器复矢量阻抗电路模型

Fig.3 Complex vector impedance circuit model for grid-forming inverter

当不考虑功率下垂控制环节时,构网型并网逆变器的输出电压可以表示为:

$$v_{odq+} = G_v v_{odq+}^* - \frac{Z_{loopi} Z_{loopvc}}{Z_{loopi} + Z_{loopvc}} i_{odq+} \quad (2)$$

因此,构网型并网逆变器的输出阻抗 $Z_{s\pm}$ 可以表示为:

$$Z_{s\pm} = \begin{bmatrix} Z_{s+} & Z_{s-} \\ \bar{Z}_{s-} & \bar{Z}_{s+} \end{bmatrix} \quad (3)$$

式中: $Z_{s+} = \frac{Z_{loopi} Z_{loopvc}}{Z_{loopi} + Z_{loopvc}}$ ;  $Z_{s-} = 0$ ;“-”表示复共轭。

由于功率下垂控制使得构网型并网逆变器的输出阻抗不对称,因此考虑功率下垂控制时,其阻抗电路模型如附录D图D1所示。图中, $Z_{PF\pm}$ 为P-f下垂控制的等效虚拟阻抗,其表达式如式(4)所示<sup>[9]</sup>。

$$Z_{PF\pm} = \begin{bmatrix} Z_{PF+} & Z_{PF-} \\ \bar{Z}_{PF-} & \bar{Z}_{PF+} \end{bmatrix} = \frac{1}{2S_{\theta}} \begin{bmatrix} jV_{+0} & jV_{+0} \\ -jV_{-0} & -jV_{-0} \end{bmatrix} \quad (4)$$

式中: $V_{+0}$ 、 $V_{-0}$ 分别为稳态运行点电压的正、负频率分量; $S_{\theta} = s/G_{PF} + j(I_{+0} - I_{-0})/2$ , $I_{+0}$ 、 $I_{-0}$ 分别为稳态运行点电流的正、负频率分量。

因此,考虑功率下垂控制的构网型并网逆变器输出阻抗可以表示为:

$$Z_{o\pm} = \begin{bmatrix} Z_{o+} & Z_{o-} \\ \bar{Z}_{o-} & \bar{Z}_{o+} \end{bmatrix} \quad (5)$$

式中: $Z_{o+} = Z_{s+} + Z_{PF+}$ ;  $Z_{o-} = Z_{PF-}$ 。

## 2 电网阻抗变化下的逆变器稳定性分析

### 2.1 闭环稳定分析法原理

构网型并网逆变器的戴维南等效电路及其等效控制框图如附录D图D2所示。由图推导可得,构网型并网逆变器的输出电压 $v_o(s)$ 的表达式为:

$$v_o(s) = \left[ u_s(s) + \frac{Z_o(s)}{Z_g(s)} u_g(s) \right] \underbrace{\frac{1}{1 + Z_o(s)/Z_g(s)}}_{G_o(s)} \quad (6)$$

式中: $u_s(s)$ 和 $Z_o(s)$ 分别为构网型并网逆变器的等效电压源和输出阻抗; $Z_g(s)$ 为电网阻抗。

本文假设没有并网逆变器时,电网电压 $u_g$ 稳定;当电网阻抗为0时,并网逆变器的输出稳定,此时并网逆变器输出的稳定性取决于闭环传递函数 $G_o(s)$ ,其表达式为:

$$G_o(s) = \frac{1}{1 + Z_o(s)/Z_g(s)} = \sum_{i=1}^{n_p} \left( \frac{R_i}{s - \lambda_i} + C_i \right) \quad (7)$$

式中: $\lambda_i$ 为闭环极点, $\lambda_i = \alpha_i + j\beta_i = \alpha_i + j2\pi f_i$ , $\alpha_i$ 为闭环极点 $\lambda_i$ 的实部, $f_i$ 、 $\beta_i$ 分别为对应的振荡频率、角频率; $R_i$ 为闭环极点所对应的留数; $C_i$ 为常数项; $n_p$ 为极点个数。

系统的稳定性可由闭环极点来判断,每个闭环极点都代表了系统的一个振荡模式,闭环极点的实部为阻尼系数,虚部为振荡频率。系统所有的闭环极点实部为负时,系统稳定。若某一对闭环极点 $\lambda_i$ 的实部 $\alpha_i$ 为正,则表示系统会发生频率为 $f_i$ 的不稳定振荡。

### 2.2 电网阻抗变化下的逆变器稳定性分析

构网型并网逆变器系统模型的参数如附录D表D1所示(表中 $L_f$ 、 $C_f$ 和 $r_f$ 均为标么值)。电网阻抗变化时的闭环极点结果如附录D图D3所示。由图可知,随着构网型并网逆变器电网阻抗的减小,闭环极点由复平面的左边逐渐向右移动,最终越过虚轴,系

统变得不稳定。因此,构网型并网逆变器在大电网阻抗下易达到稳定状态,而在电网阻抗减小时其稳定裕度有所降低,可能失去与电网的同步。

## 3 控制参数自适应调整方法

为了解决电网阻抗变化引起的不稳定问题,本章提出了一种控制参数自适应调整方法以提高系统的鲁棒性。首先,根据给定参数确定参数搜索范围,生成样本数据集,并建立闭环极点映射模型;然后,将测量到的电网阻抗值输入训练好的闭环极点映射模型中,实现闭环极点实部的预测;最后,计算预测得到的极点和参考极点的均方误差(mean-square error, MSE)(本文记为 $\varepsilon_{MSE}$ ),当 $\varepsilon_{MSE}$ 最小值 $\varepsilon_{MSE, \min}$ 小于预定义的容差时将系统控制参数调整为与 $\varepsilon_{MSE, \min}$ 对应的控制参数 $u_{ctrl\_new}$ 。

为实现电网阻抗的快速、准确测量,本文采用文献[15]提出的最大长度二进制序列信号(maximum length binary sequence, MLBS)信号注入法,对电网阻抗实现快速、精准的测量。该方法原理简述如下:首先,将2个正交MLBS同时注入并网逆变器控制的dq轴给定电流中;然后,应用频域插值技术调整测量的电流和电压响应;最后,通过计算求得电网阻抗。受篇幅限制及研究重点影响,具体实施流程在此不再赘述。文献[23]从测量的准确性与快速性2个方面,对应用于新能源发电设备阻抗测量的扰动信号类型在各种应用场景下的适用性进行分析,指出采用MLBS的宽频带扰动信号能够实现电网阻抗时变情况下的电网阻抗快速测量,论证了文献[15]所提方法的优势,满足本文方法对电网阻抗测量精度及速度的需求。

### 3.1 建立闭环极点映射模型

由2.1节的分析可以看出,并网逆变器的稳定性主要由式(7)求得的闭环极点决定。由于系统闭环极点存在实部为正的共轭极点时,系统不稳定,因此本文映射模型的输出主要考虑最靠近虚轴的一对共轭极点(以下称之为关键极点)。构网型并网逆变器的等效阻抗 $Z_o$ 主要与系统的控制参数和滤波参数有关,而在实际工程中,其滤波参数通常为定值。因而当电网阻抗变化导致系统不稳定时,可以通过调整构网型并网逆变器的控制参数提高系统稳定性,即构网型并网逆变器控制参数和电网阻抗的组合与系统闭环极点之间存在非线性关系。

值得说明的是,尽管本文是根据闭环极点定位其相应的控制参数,但电网阻抗是实时测量得到的,将系统关键极点作为输入时无法得到特定电网阻抗下的系统控制参数。因此,本文通过改进DBN-ELM映射模型将构网型并网逆变器的控制参数 $u_{ctrl}$ 和电网等效电感 $L_g$ 作为映射模型的输入,系统关键极点

作为映射模型的输出。

### 3.1.1 改进DBN-ELM原理

#### 1) DBN-ELM原理。

传统DBN模型存在超参数设置复杂、泛化能力弱的不足,本文采用基于DBN-ELM的非线性映射回归模型。DBN-ELM由多层受限玻尔兹曼机(restricted Boltzmann machine, RBM)和全连接层叠加构成,其结构图见附录D图D4。图中:输入 $\mathbf{x}=[x_1, x_2, \dots, x_p]$ 为 $p$ 维训练样本; $\mathbf{y}=[y_1, y_2, \dots, y_q]$ 为 $q$ 维网络输出。该模型由负责特征提取的DBN和作为回归层的极限学习机两部分组成,将DBN在特征提取上的优越性能与ELM学习速度快、泛化性能好的特点相结合,从而提高了预测性能。DBN-ELM原理的具体说明如附录E所示。

#### 2) 遗传算法优化。

尽管DBN-ELM模型与DBN相比具有较高的泛化性,但其隐含层各层节点数的确定仍存在随机性大的问题。针对这一缺陷,本文采用遗传算法对DBN-ELM模型的隐含层各层节点数进行优化,进一步增强模型的泛化性。具体优化过程见附录F的F1部分,其中适应度选用预测值和真实值间的平均绝对均方根误差(root mean square error, RMSE),本文记为 $\varepsilon_{\text{RMSE}}$ 。

### 3.1.2 闭环极点映射模型

本文中的闭环极点映射由改进DBN-ELM模型实现。通过对关键极点与系统参数(控制参数 $\mathbf{u}_{\text{ctrl}}$ 和电网等效电感 $L_g$ )之间映射关系的训练学习,可以得到训练完成的改进DBN-ELM模型,即判断稳定性的闭环极点映射模型,记为:

$$\mathbf{y}_{\text{out}} = \boldsymbol{\sigma} = H(\mathbf{u}_{\text{in}}) \quad (8)$$

式中: $\boldsymbol{\sigma}$ 为系统闭环极点中的关键极点,由于系统存在2个关键极点,且DBN-ELM模型的样本数据应表示为实数,因此关键极点被进一步划分为实部和虚部,则有 $\boldsymbol{\sigma}=[\alpha_1, \beta_1, \alpha_2, \beta_2]^T$ ;  $H(\cdot)$ 为系统关键极点和系统参数之间的关系函数。

为了在较大程度上以相对较低的数据量获取输入参数的各种组合,训练集的输入 $\mathbf{u}_{\text{in}}$ 如式(9)所示。其中, $L_g$ 、 $\mathbf{u}_{\text{ctrl}}$ 中每个参数样本由服从均匀分布的 $N$ 个随机数生成。参数样本随机生成的范围可根据不同类型的并网逆变器以及电网的实际情况确定。

$$\mathbf{u}_{\text{in}} = \begin{bmatrix} L_g(1) & \cdots & L_g(k) & \cdots & L_g(N) \\ \mathbf{u}_{\text{ctrl}}(1) & \cdots & \mathbf{u}_{\text{ctrl}}(k) & \cdots & \mathbf{u}_{\text{ctrl}}(N) \end{bmatrix} \quad (9)$$

基于训练集的输入 $\mathbf{u}_{\text{in}}$ ,根据式(7)计算相应的关键极点,可得样本数据集输出 $\mathbf{y}_{\text{out}}$ 为:

$$\mathbf{y}_{\text{out}} = [\boldsymbol{\sigma}(1) \cdots \boldsymbol{\sigma}(k) \cdots \boldsymbol{\sigma}(N)] \quad (10)$$

式中: $\boldsymbol{\sigma}(k)$ 表示 $\mathbf{u}_{\text{in}}$ 第 $k$ 列控制参数对应的关键极点。

### 3.2 控制参数搜索方法

控制参数搜索方法的流程如附录F的F2部分

所示,其主要分为离线训练与在线定位2个环节。

#### 1) 离线训练。

(1)基于给定的电网等效电感和系统控制参数,确定控制参数的搜索范围,即 $\mathbf{u}_{\text{ctrl}} \in [\mathbf{u}_{\text{ctrl}}^L, \mathbf{u}_{\text{ctrl}}^U]$ (上标L、U分别对应各参数的下限和上限),生成 $N$ 个控制参数组合。

(2)样本数据集的输入为 $L_g$ 和 $\mathbf{u}_{\text{ctrl}}$ 组成的 $N$ 个控制参数组合 $\mathbf{u}_{\text{in}}$ ,计算得到相应的关键极点作为样本数据集的输出,并对数据进行预处理。

(3)采用3.1.1节介绍的改进DBN-ELM模型对样本数据集进行学习和训练,得到闭环极点映射模型。

#### 2) 在线应用。

(1)检测到 $L_g$ 发生变化后,获取 $L_g$ 测量值,判断相应的关键极点实部是否大于0。若关键极点实部大于0,则开始控制参数搜索方法,否则保持控制参数不变。

(2)基于给定的电网等效电感和系统控制参数,设定控制参数的搜索范围,生成 $N_{\text{spl}}$ 个样本向量,形成 $N_{\text{vol}} = n_1 N_{\text{spl}}$ 个控制参数组合( $n_1$ 为控制参数个数)。

(3)应用控制参数和实时测得的 $L_g$ 作为改进DBN-ELM模型的输入,通过训练好的闭环极点映射模型预测得到相应的输出极点 $\boldsymbol{\sigma}$ ,从中可以识别出 $\varepsilon_{\text{MSE}, \text{min}}$ 对应的控制参数。 $\varepsilon_{\text{MSE}}$ 的计算公式为:

$$\varepsilon_{\text{MSE}} = \frac{1}{N_{\text{vol}}} \sum_{i=1}^{N_{\text{vol}}} (\boldsymbol{\sigma}^* - \boldsymbol{\sigma}_i)^2 \quad (11)$$

式中: $\boldsymbol{\sigma}^*$ 为给定极点。

(4)使用类似二分的概念更新控制参数的上、下限,更新后的控制参数表达式如式(12)所示。利用式(12)更新参数上、下限的有效性证明如附录G所示。

$$\mathbf{u}_{\text{ctrl}}^{\text{L/U}} = (\mathbf{u}_{\text{ctrl}}^{\text{opt}} + \mathbf{u}_{\text{ctrl}}^{\text{L/U}}) / 2 \quad (12)$$

式中: $\mathbf{u}_{\text{ctrl}}^{\text{opt}}$ 为迭代过程中 $\varepsilon_{\text{MSE}, \text{min}}$ 对应的控制参数。

重复上述过程,当满足 $\varepsilon_{\text{MSE}, \text{min}} < \eta$  ( $\eta$ 为预定义的容差)时,意味着找到了一组满足极点跟踪目标的控制参数,令 $\mathbf{u}_{\text{ctrl}, \text{new}} = \mathbf{u}_{\text{ctrl}}^{\text{opt}}$ ,迭代结束。

## 4 案例分析

### 4.1 建立闭环极点映射模型

本文的闭环极点映射由改进DBN-ELM实现,其输入 $\mathbf{u}_{\text{in}}$ 由电网等效电感 $L_g$ 和逆变器的控制参数 $\mathbf{u}_{\text{ctrl}}$ 组成。

#### 1) 训练样本集构造。

在本研究中,训练样本集由输入矩阵 $\mathbf{u}_{\text{in}}$ 和输出矩阵 $\mathbf{y}_{\text{out}}$ 组成,训练样本数 $N=500$ 。在参数搜索范围内生成500组系统控制参数组合,即闭环极点映射模型输入矩阵 $\mathbf{u}_{\text{in}}$ ,进而通过计算得到相应的输出矩阵 $\mathbf{y}_{\text{out}}$ 。设置给定电网等效电感 $L_g^* = 0.4$  p.u.,给定系

统控制参数  $u_{\text{ctrl}}^*$  和参数搜索范围的上限  $u_{\text{in}}^U$ 、下限  $u_{\text{in}}^L$  等参数如附录 H 表 H1 所示。

### 2) 数据预处理。

为缩小输入特征的数值差异,采用最大最小法进行归一化处理,然后将所有训练样本集按照 4:1 的比例分为训练集和测试集。

### 3) 离线模型训练。

将训练样本集输入构建的闭环极点映射改进 DBN-ELM 模型中进行训练学习,以  $\varepsilon_{\text{RMSE}}$  为目标函数,通过遗传算法对该模型的隐含层各层节点数进行优化。由于深度神经网络模型的预测正确率随着隐含层层数增加而上升,但增至 4 层以上时正确率及泛化性能反而会下降<sup>[24]</sup>,因此设置模型隐含层层数为 3。其他主要参数设置如下:学习率为 0.01;迭代次数为 20 次;最大遗传代数 60;种群大小为 40;个体长度为 20;迭代间隙为 0.95;交叉概率为 0.7;变异概率为 0.01。 $\varepsilon_{\text{RMSE}}$  的收敛结果如附录 H 图 H1 所示。由图可知,当种群进化到 30 代时, $\varepsilon_{\text{RMSE}}$  达到较小值,随着代数的增加,适应度减小幅度变化不大,说明本文设置的遗传算法具有更强的寻优能力,参数设置合理有效。寻优后隐含层各层节点数分别为 107、289、492,此时  $\varepsilon_{\text{RMSE}}$  为 1.9285。待模型达到最大遗传代数后,对最优个体进行解码,改进 DBN-ELM 模型训练完成。测试集的输出结果如附录 H 图 H2 所示。由图可知,该模型能够较好地预测出关键点,可作为本文的在线预测模型。

## 4.2 模型有效性及优越性分析

为更好地评价模型,通过  $\varepsilon_{\text{RMSE}}$  和百分比误差 (mean absolute percentage error, MAPE) (本文记为  $\varepsilon_{\text{MAPE}}$ ) 反映模型优劣。 $\varepsilon_{\text{RMSE}}$  和  $\varepsilon_{\text{MAPE}}$  越小,说明模型预测值与实际值的误差越小。 $\varepsilon_{\text{MAPE}}$  的计算公式为:

$$\varepsilon_{\text{MAPE}} = \sum_{i=1}^L \left| \frac{y_{ir} - y'_{ir}}{y_{ir}} \right| / L \times 100\% \quad r=1, 2, 3, 4 \quad (13)$$

式中:  $L$  为数据长度;  $y_{ir}$ 、 $y'_{ir}$  分别为第  $i$  个样本数据第  $r$  个输出节点的实际值、预测值。

为了验证本文方法的优越性,将 DBN-ELM、DBN、ELM、反向神经网络 (back propagation neural network, BPNN) 与改进 DBN-ELM 模型 (本文方法) 进行对比。其中, DBN-ELM 的隐含层各层节点数分别为 300、200、150; DBN 模型的隐含层节点数与改进 DBN-ELM 一致, ELM 和 BPNN 的隐含层节点数为 13, 学习率为 0.001。考虑预测结果不稳定性, 各方法实验 10 次, 并对结果取平均值, 不同算法模型预测结果的评价指标如附录 H 表 H2 所示, 具体分析如下。

1) ELM 模型的  $\varepsilon_{\text{RMSE}}$  和  $\varepsilon_{\text{MAPE}}$  较 DBN 模型分别降低了 29.54% 和 22.67%; BPNN 模型的  $\varepsilon_{\text{RMSE}}$  和  $\varepsilon_{\text{MAPE}}$  较 DBN 模型分别降低了 41.21% 和 28.49%。可见,

由于 DBN 模型克服了 ELM 模型和 BPNN 只含有单隐含层, 对训练样本的特征学习不准确、泛化性不高以及出现局部最优解的问题, 提升了预测精度。

2) DBN-ELM 模型的  $\varepsilon_{\text{RMSE}}$  和  $\varepsilon_{\text{MAPE}}$  较 DBN 模型分别降低了 20.82% 和 14.77%, 所需运行时间更短, 这是由于 ELM 模型学习速度快、泛化能力强, 使得 DBN-ELM 模型克服了 DBN 中梯度下降反向传播算法的不足。

3) 改进 DBN-ELM 模型相对于 DBN-ELM 模型, 其  $\varepsilon_{\text{MAPE}}$  和  $\varepsilon_{\text{RMSE}}$  分别降低了 28.57% 和 53.63%, 这主要是因为隐含层节点数的优化对 DBN-ELM 模型预测精度的改善。因此, 改进 DBN-ELM 模型对本文生成的样本数据集的预测能力要优于其他几种模型。

## 4.3 控制参数调整方法的实现

本文运用 MATLAB 软件编程实现控制参数调整方法, 其中  $N_{\text{sp}}=3$ , 容差  $\eta$  通过控制参数调整方法输出控制参数对应的  $\varepsilon_{\text{MSE}, \text{min}}$  和调整控制参数所需时间  $t$  确定。不同容差下  $\varepsilon_{\text{MSE}, \text{min}}$  和  $t$  的变化趋势如附录 H 图 H3 所示。由图可知: 随着容差  $\eta$  的减小,  $\varepsilon_{\text{MSE}, \text{min}}$  降低, 调整控制参数所需时间  $t$  更长; 当  $\eta$  值约为 0.001 时, 2 条曲线相交, 表明  $\eta$  值取 0.001 时可以兼顾实时性与准确性。因此, 控制参数自适应调整方法中容差  $\eta$  取 0.001。

为对比说明本文提出的控制参数自适应调整方法的有效性, 对比  $L_g$  由 0.4 p.u. 减小为 0.2 p.u. 时, 未采用控制参数自适应调整与采用本文所提控制参数调整方法后的系统极点计算结果, 如图 4 所示。其中, 未采用控制参数自适应调整时仅包含  $P$ - $f$  下垂控制和电压电流控制, 其控制结构和参数分别如图 1、表 D1 所示。

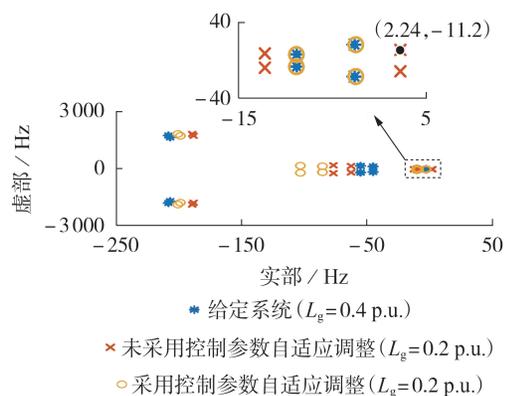


图4 2种控制方法的结果对比

Fig.4 Comparison of results between two control methods

从图 4 可以看出, 当未采用控制参数自适应调整时, 存在 1 对实部为正的极点, 系统不稳定; 采用本文提出的控制参数自适应调整方法时, 得到的极点基本与给定系统的极点一致, 关键

极点实部均为负,系统稳定。由此可知,采用本文提出的自适应调整方法后,系统在电网等效电感变化后仍可保持良好的稳定性。

## 5 仿真验证

### 5.1 复矢量阻抗电路模型准确性验证

为了验证所建立的复矢量阻抗电路模型的有效性和准确性,按照图1所示的构网型并网逆变器控制结构在MATLAB/Simulink中搭建了仿真模型,其系统参数如表D1所示。复矢量阻抗电路模型的理论曲线和通过扫频法得到的仿真结果如附录H图H4所示。值得注意的是,由于不考虑 $P$ - $f$ 下垂控制时构网型并网逆变器的负频域阻抗为0,其对数幅频特性曲线因趋向于无穷大而无法绘制,此处省略不考虑功率下垂控制时复矢量阻抗电路模型的理论曲线。从图中可以看出,与未考虑 $P$ - $f$ 下垂控制的阻抗电路模型结果相比,考虑 $P$ - $f$ 下垂控制的复矢量阻抗电路模型的结果更符合仿真扫频结果,验证了所建模型的准确性。

### 5.2 电网阻抗测量方法的验证

本文采用文献[15]提出的注入正交MLBS信号的方法对电网阻抗进行测量。设置电网等效电感初始状态为0.4 p.u.,于 $t=1$  s时减小为0.2 p.u.,得到的 $L_g$ 仿真波形如图5所示(图中 $L_g$ 为标么值)。

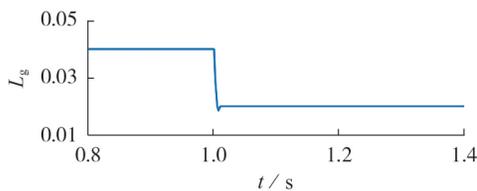


图5 电网等效电感测量结果

Fig.5 Measured results of grid equivalent inductance

由图5可知,所采用的电网阻抗检测方法能够较为准确地检测到电网等效电感值,且在切换不同电网等效电感后反应速度很快,在0.01 s之内就能更新检测值,估计值与实际值基本一致,测量精度较高,验证了电网阻抗检测方法的有效性。

### 5.3 控制参数自适应调整方法有效性验证

为验证本文所提方法的正确性及有效性,在1 s时将 $L_g$ 由0.4 p.u.减小为0.2 p.u.

图6为 $L_g$ 减小时,未采用控制参数自适应调整方法的构网型并网逆变器 $dq$ 轴输出电压波形图(图中, $v_{od}$ 、 $v_{oq}$ 均为标么值,后同)。由图可知,随着电网阻抗的减小,逆变器 $dq$ 轴输出电压发生11.2 Hz的低频振荡,且振荡幅度逐渐增大,系统失稳,仿真结果与闭环稳定分析结果一致。

图7为 $L_g$ 减小时构网型并网逆变器采用控制参

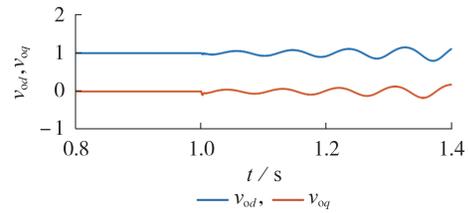


图6  $L_g$ 减小时未采用控制参数自适应调整的仿真结果  
Fig.6 Simulative results without adaptive adjustment of control parameters under  $L_g$  reduction

数自适应调整方法的仿真结果。图中: $k_{pv}$ 、 $k_{iv}$ 分别为电压调节器的比例、积分系数; $k_{iv}$ 、 $k_{ii}$ 分别为电流调节器的比例、积分系数。从图7(a)、图7(b)可以看出, $t=1$  s时 $L_g$ 减小,开始进行控制参数搜索, $\varepsilon_{MSE}$ 的逐渐减小表明闭环极点正在向给定闭环极点移动,经过0.06 s后 $\varepsilon_{MSE}$ 达到阈值,在1.06 s时控制参数搜索结束,对控制参数进行调整。由图7(c)可知,电网阻抗减小后,逆变器输出电压 $d$ 轴分量经过短暂振荡后趋于稳定,与4.3节中的闭环稳定分析结果一致。仿真结果表明:通过控制参数自适应调整方法,能够在 $L_g$ 变化0.06 s后调整控制参数恢复系统稳定,满足系统稳定性要求<sup>[25]</sup>,证明了自适应调整方法的有效性。

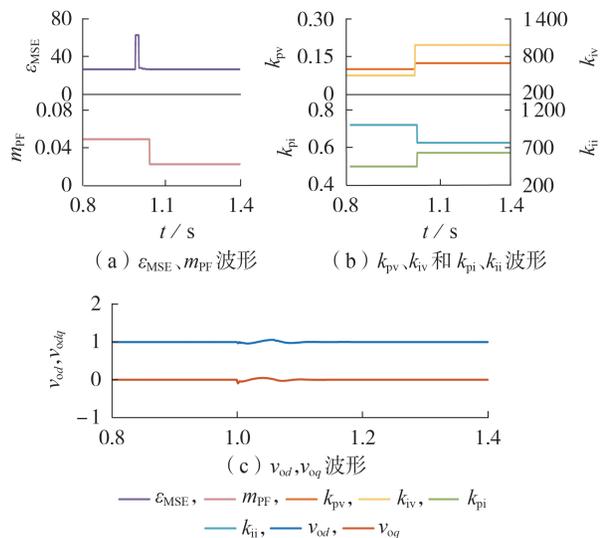


图7  $L_g$ 减小时采用控制参数自适应调整方法的仿真结果  
Fig.7 Simulative results with adaptive adjustment method of control parameters under  $L_g$  reduction

## 6 结论

本文提出一种基于DBN-ELM的构网型并网逆变器控制参数自适应调整方法。首先,建立构网型并网逆变器的复矢量阻抗电路模型;然后,基于实时测量到的电网阻抗对控制参数进行调整;最后,在MATLAB/Simulink中进行仿真验证,仿真结果证明了本文所提方法的有效性。本文所得主要结

论如下:

1)通过控制参数自适应调整方法来调节多个控制参数,可以在电网阻抗变化后将不稳定极点拉回参考极点,使系统恢复稳定;

2)采用改进DBN-ELM闭环模型对极点进行预测,利用遗传算法对每个隐含层的神经元节点数分别进行寻优,有效提高了预测性能。

本文提出的控制参数自适应调整方法可以保证系统在电网阻抗变化时跟踪参考极点,实现自适应稳定控制。然而,本文所提方法也存在一定的局限性:对于含有多并网逆变器的分布式系统,当地负荷的随机波动、并网逆变器运行工作点发生偏移、线路参数的变化等均可能影响分布式系统的稳定,如何提高含有多并网逆变器的分布式系统的稳定性有待进一步研究。

附录见本刊网络版(<http://www.epae.cn>)。

#### 参考文献:

- [1] 陈哲,朱森,侯川川,等. 复合型功率同步逆变器:序阻抗建模与并网特性[J]. 中国电机工程学报,2023,43(5):1927-1940.  
CHEN Zhe,ZHU Miao,HOU Chuanchuan,et al. Compound power synchronized inverters:sequence impedance modelling and grid integration characteristics[J]. Proceedings of the CSEE, 2023,43(5):1927-1940.
- [2] 薛翼程,张哲任,徐政,等. 构网型变流器对交流系统低频振荡的影响分析与阻尼控制[J]. 电力系统自动化,2023,47(16):103-113.  
XUE Yicheng,ZHANG Zheren,XU Zheng,et al. Impact analysis and damping control of grid-forming converter for low-frequency oscillation of AC system[J]. Automation of Electric Power Systems,2023,47(16):103-113.
- [3] 褚文从,刘静利,李永刚,等. 考虑源端特性的虚拟同步直驱风机小信号建模与稳定性分析[J]. 电力自动化设备,2022,42(8):3-10.  
CHU Wencong,LIU Jingli,LI Yonggang,et al. Small-signal modeling and stability analysis of virtual synchronous PMSG considering source characteristics[J]. Electric Power Automation Equipment,2022,42(8):3-10.
- [4] 曾志杰,肖华锋,高博,等. 并网逆变器小信号建模简化方法与应用[J]. 中国电机工程学报,2020,40(21):7002-7012.  
ZENG Zhijie,XIAO Huafeng,GAO Bo,et al. Simplified small-signal modeling method of grid-connected inverters and its applications[J]. Proceedings of the CSEE,2020,40(21):7002-7012.
- [5] 杨蕾,黄伟,郭成,等. 基于Ostrowski圆盘定理的并网逆变器系统稳定性分析[J]. 电力自动化设备,2022,42(4):92-98.  
YANG Lei,HUANG Wei,GUO Cheng,et al. Stability analysis of grid-connected inverter system based on Ostrowski disc theorem[J]. Electric Power Automation Equipment, 2022, 42(4):92-98.
- [6] 辛焕海,李子恒,董炜,等. 三相变流器并网系统的广义阻抗及稳定判据[J]. 中国电机工程学报,2017,37(5):1277-1293.  
XIN Huanhai,LI Ziheng,DONG Wei,et al. Generalized-impedance and stability criterion for grid-connected converters[J]. Proceedings of the CSEE,2017,37(5):1277-1293.
- [7] 吴为,丁信忠,严彩忠. 基于复矢量的电流环解耦控制方法研究[J]. 中国电机工程学报,2017,37(14):4184-4191.  
WU Wei,DING Xinzong,YAN Caizhong. Research on control method of current loop decoupling based on complex vector[J]. Proceedings of the CSEE,2017,37(14):4184-4191.
- [8] HARNEFORS L. Modeling of three-phase dynamic systems using complex transfer functions and transfer matrices[J]. IEEE Transactions on Industrial Electronics,2007,54(4):2239-2248.
- [9] LI Yitong, GU Yunjie, GREEN T C. Revisiting grid-forming and grid-following inverters: a duality theory[J]. IEEE Transactions on Power Systems,2022,37(6):4541-4554.
- [10] WANG Xiongfei, HARNEFORS L, BLAABJERG F. Unified impedance model of grid-forming voltage-source converters[J]. IEEE Transactions on Power Electronics, 2018, 33(2): 1775-1787.
- [11] WU T F, HSIEH H C, HSU C W, et al. Three-phase three-wire active power filter with  $D-\Sigma$  digital control to accommodate filter-inductance variation[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2016, 4(1): 44-53.
- [12] VIEIRA R P, MARTINS L T, MASSING J R, et al. Sliding mode controller in a multiloop framework for a grid-connected VSI with LCL filter[J]. IEEE Transactions on Industrial Electronics, 2018, 65(6): 4714-4723.
- [13] 马兴,徐瑞林,陈民铀,等. 弱电网下并网逆变器自适应 $H_\infty$ 控制方法[J]. 电力系统自动化,2018,42(13):189-195.  
MA Xing,XU Ruilin,CHEN Minyou,et al. Adaptive  $H_\infty$  control method for grid-connected inverters in weak current networks[J]. Automation of Electric Power Systems,2018,42(13):189-195.
- [14] BHUNIA M, SUBUDHI B. A self-tuning adaptive control scheme for a grid-connected three-phase PV system[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2022, 10(5): 5709-5716.
- [15] BERG M, ALENIUS H, ROINILA T. Rapid multivariable identification of grid impedance in DQ domain considering impedance coupling[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2022, 10(3): 2710-2721.
- [16] 许泽铭,谢少军,唐婷. 弱电网下LCL滤波并网逆变器自适应电流控制[J]. 中国电机工程学报,2014,34(24):4031-4039.  
XU Jinming, XIE Shaojun, TANG Ting. An adaptive current control for grid-connected LCL-filtered inverters in weak grid case[J]. Proceedings of the CSEE, 2014, 34(24): 4031-4039.
- [17] 杜燕,崔林波,杨向真,等. 并网逆变器的阻抗自适应控制方法[J]. 电力系统自动化,2018,42(6):120-127.  
DU Yan, CUI Linbo, YANG Xiangzhen, et al. Adaptive control method of impedance for grid-connected inverters[J]. Automation of Electric Power Systems, 2018, 42(6): 120-127.
- [18] ZHANG C, MIJATOVIC N, CAI X, et al. Artificial neural network-based pole-tracking method for online stabilization control of grid-tied VSC[J]. IEEE Transactions on Industrial Electronics, 2022, 69(12): 13902-13909.
- [19] 李宝琴,吴俊勇,张若愚,等. 融合多类型深度迁移学习的电力系统暂态稳定自适应评估[J]. 电力自动化设备,2023,43(1):184-192.  
LI Baoqin, WU Junyong, ZHANG Ruoyu, et al. Adaptive assessment of transient stability for power system based on transfer multi-type of deep learning model[J]. Electric Power Automation Equipment, 2023, 43(1): 184-192.
- [20] LIN Gang, LIU Jiayan, WANG Pengcheng, et al. Low-frequency oscillation analysis of virtual-inertia-controlled DC microgrids based on multi-timescale impedance model[J]. IEEE Transactions on Sustainable Energy, 2022, 13(3): 1536-1552.
- [21] D'ARCO S, A. SUUL J. Equivalence of virtual synchronous

- machines and frequency-droops for converter-based microgrids [J]. IEEE Transactions on Smart Grid, 2014, 5(1):394-395.
- [22] 朱坤龙, 孙鹏菊, 王林, 等. 弱电网下 LCL 型并网逆变器的高鲁棒性加权平均电流控制策略[J]. 中国电机工程学报, 2020, 40(11):3592-3602.
- ZHU Kunlong, SUN Pengju, WANG Lin, et al. High robustness weighted average current control for LCL-type grid-connected inverter in a weak grid[J]. Proceedings of the CSEE, 2020, 40(11):3592-3602.
- [23] 李萌, 年珩, 胡彬, 等. 应用于新能源发电设备阻抗测量的扰动信号类型综述[J]. 中国电机工程学报, 2022, 42(17):6296-6316.
- LI Meng, NIAN Heng, HU Bin, et al. Review of perturbation signals applied to impedance measurement of renewable generator[J]. Proceedings of the CSEE, 2022, 42(17):6296-6316.
- [24] 李海英, 沈益涛, 罗雨航. 基于改进深度置信网络的智能电网暂态安全状态感知[J]. 电力系统保护与控制, 2022, 50(5):171-177.
- LI Haiying, SHEN Yitao, LUO Yuhang. Transient security situational awareness of smart grids based on an improved deep belief network[J]. Power System Protection and Control, 2022, 50(5):171-177.
- [25] 国家市场监督管理总局, 国家标准化管理委员会. 电力系统安全稳定计算规范: GB/T 40581—2021[S]. 北京: 中国标准出版社, 2021.

#### 作者简介:

张梦琪(1998—), 女, 硕士研究生, 主要研究方向为新能源电力系统(**E-mail**: zhangmengqi612@163.com);

李永刚(1967—), 男, 教授, 博士研究生导师, 通信作者, 主要研究方向为新能源电力系统和大型电机故障诊断(**E-mail**: lygzxm0@163.com)。

(编辑 任思思)

## Adaptive adjustment method for control parameters of grid-forming inverter based on DBN-ELM

ZHANG Mengqi<sup>1</sup>, LI Yonggang<sup>1</sup>, SUN Geng<sup>2</sup>, WU Binyuan<sup>1</sup>, LIU Qiyu<sup>1</sup>, ZHANG Chi<sup>1</sup>

(1. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Baoding 071003, China;

2. Fuxin Power Supply Subsidiary Company of State Grid Liaoning Electric Power Co., Ltd., Fuxin 123000, China)

**Abstract:** In the “double-high” power system, the grid impedance exhibits a wide range of time-varying characteristics. The grid-forming control parameters of grid-forming inverter lack the adaptive adjustment ability, resulting in the risk of instability. To solve this problem, an adaptive adjustment method for control parameters of grid-forming inverters based on deep belief network and extreme learning machine is proposed. A closed-loop pole mapping model is established and the mapping relationship between control parameters and key poles is trained by using the deep architecture. Then, the corresponding key poles are predicted by the trained closed-loop pole mapping model, and the control parameters of the grid-forming inverter are identified when the key poles are closest to the reference poles. By adjusting the control parameters adaptively, the system can keep track the reference poles when the grid impedance changes, and realize the adaptive stability control. It is shown by both theoretical analysis and simulative results that the proposed method can realize the adaptive adjustment of control parameters, and effectively improve the adaptability of the grid-forming inverter to the changes of the grid impedance.

**Key words:** grid-forming inverter; adaptive adjustment; deep belief network-extreme learning machine; complex vector modeling; grid impedance

附录 A

对于一个双输入双输出的系统，dq 坐标系下系统模型可表示为：

$$\begin{bmatrix} y_d \\ y_q \end{bmatrix} = \underbrace{\begin{bmatrix} G_{dd}(s) & G_{dq}(s) \\ G_{qd}(s) & G_{qq}(s) \end{bmatrix}}_{G_{dqm}} \begin{bmatrix} x_d \\ x_q \end{bmatrix} \quad (A1)$$

式中： $x_{dq}$  和  $y_{dq}$  分别表示 dq 坐标系下系统的输入和输出； $G_{dqm}$  为系统传递函数矩阵。

对于 dq 坐标系中的信号  $y_{dq}$ ，可以得到复矢量坐标系下对应的复信号  $y_{dq\pm}$  为：

$$\begin{bmatrix} y_{dq+} \\ y_{dq-} \end{bmatrix} = \underbrace{\begin{bmatrix} 1 & j \\ 1 & -j \end{bmatrix}}_{T} \begin{bmatrix} y_d \\ y_q \end{bmatrix} \quad (A2)$$

式中： $y_{dq+}$  和  $y_{dq-}$  分别为复信号  $y_{dq\pm}$  的正频率信号和负频率信号； $T$  为变换矩阵。

相应的复矢量模型可以表示为：

$$\begin{bmatrix} y_{dq+} \\ y_{dq-} \end{bmatrix} = \underbrace{\begin{bmatrix} G_{dq+}(s) & G_{dq-}(s) \\ \bar{G}_{dq-}(s) & \bar{G}_{dq+}(s) \end{bmatrix}}_{G_{dq\pm}(s)} \begin{bmatrix} x_{dq+} \\ x_{dq-} \end{bmatrix} \quad (A3)$$

$$\begin{cases} G_{dq+}(s) = \frac{G_{dd}(s) + G_{qq}(s)}{2} + j \frac{G_{qd}(s) - G_{dq}(s)}{2} \\ G_{dq-}(s) = \frac{G_{dd}(s) - G_{qq}(s)}{2} + j \frac{G_{qd}(s) + G_{dq}(s)}{2} \end{cases}$$

式中： $x_{dq\pm}$  和  $y_{dq\pm}$  分别为  $x_{dq}$  和  $y_{dq}$  的复矢量形式； $G_{dq\pm}(s)$  为复传递函数， $\bar{G}_{dq\pm}(s)$  为其复共轭。

当系统对称时有：

$$\begin{cases} G_d(s) = G_{dd}(s) = G_{qq}(s) \\ G_q(s) = G_{qd}(s) = -G_{dq}(s) \end{cases} \quad (A4)$$

此时，dq 坐标系下系统模型可表示为：

$$\begin{bmatrix} y_d \\ y_q \end{bmatrix} = \begin{bmatrix} G_d(s) & -G_q(s) \\ G_q(s) & G_d(s) \end{bmatrix} \begin{bmatrix} x_d \\ x_q \end{bmatrix} \quad (A5)$$

相应的复矢量模型可以表示为：

$$\begin{cases} G_{dq+}(s) = G_d(s) + jG_q(s) \\ G_{dq-}(s) = 0 \end{cases} \quad (A6)$$

此时，双输入双输出系统可以通过复矢量的表达方法将其表征为单输入单输出的系统。

附录 B

受控源的虚拟阻抗特性如图 B1 所示。由图 B1 (a) 和图 B1 (b) 可知，根据欧姆定律和叠加定理，自电流控制电压源可等效为串联阻抗，自电压控制电流源可等效为并联导纳。图 B1 (c) 为外部电压控制的电压源的等效阻抗推导过程图。根据框图变换、欧姆定律、叠加定理、诺顿定理

和戴维南定理，逐步推导出其并联形式的阻抗。

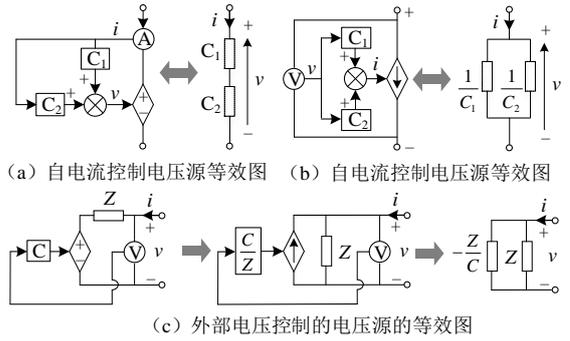


图 B1 受控源的等效虚拟阻抗

Fig.B1 Equivalent virtual impedance of a controlled source

附录 C

构网型并网逆变器本质是一个受控电压源，采用电流内环和电压外环双比例-积分 (proportional integral, PI) 调节器的控制方法。电流内环的作用是并网电流跟踪指令电流，实现逆变器的高功率因数并网；电压外环的作用是稳定直流侧电压。构网型并网逆变器电流控制回路形成的等效输出阻抗描述其外部动态特性，其推导过程如图 C1 (a) 所示。图中： $L_f$  为构网型并网逆变器滤波电感； $\omega$  为实际角频率 (rad/s)； $G_{Pli}$  为电流控制 PI 调节器传递函数； $Z_{Pli}$  为电流控制 PI 调节器的等效阻抗； $Z_{CDi}$  为电流控制负虚拟阻抗。 $Z_{Pli}$ 、 $Z_{CDi}$  和  $G_i$  的表达式分别如式(C1)–(C3) 所示。

$$Z_{Pli} = G_{Pli} = k_{pi} + \frac{k_{ii}}{s} \quad (C1)$$

$$Z_{CDi} = -j\omega L_f \quad (C2)$$

$$G_i = \frac{Z_{Pli}}{Z_{loopi}} \quad (C3)$$

式中： $k_{pi}$  为电流调节器比例系数； $k_{ii}$  为电流调节器积分系数。

从图 1 可以看出，构网型并网逆变器中电压控制为电流控制提供给定电流  $i_{Ldq}^*$ ，因此其电压控制回路形成的等效输出阻抗可在电流等效输出阻抗的基础上进行进一步推导，其推导过程如图 C1 (b) 所示。图中： $C_f$  为构网型并网逆变器滤波电容； $G_{Piv}$  为电压控制 PI 调节器； $Z_{Piv}$  为电压控制 PI 调节器的等效阻抗； $Z_{CDv}$  为电压控制负虚拟阻抗。 $Z_{Piv}$ 、 $Z_{CDv}$  和  $G_v$  的表达式如式(C4)–(C6)所示。

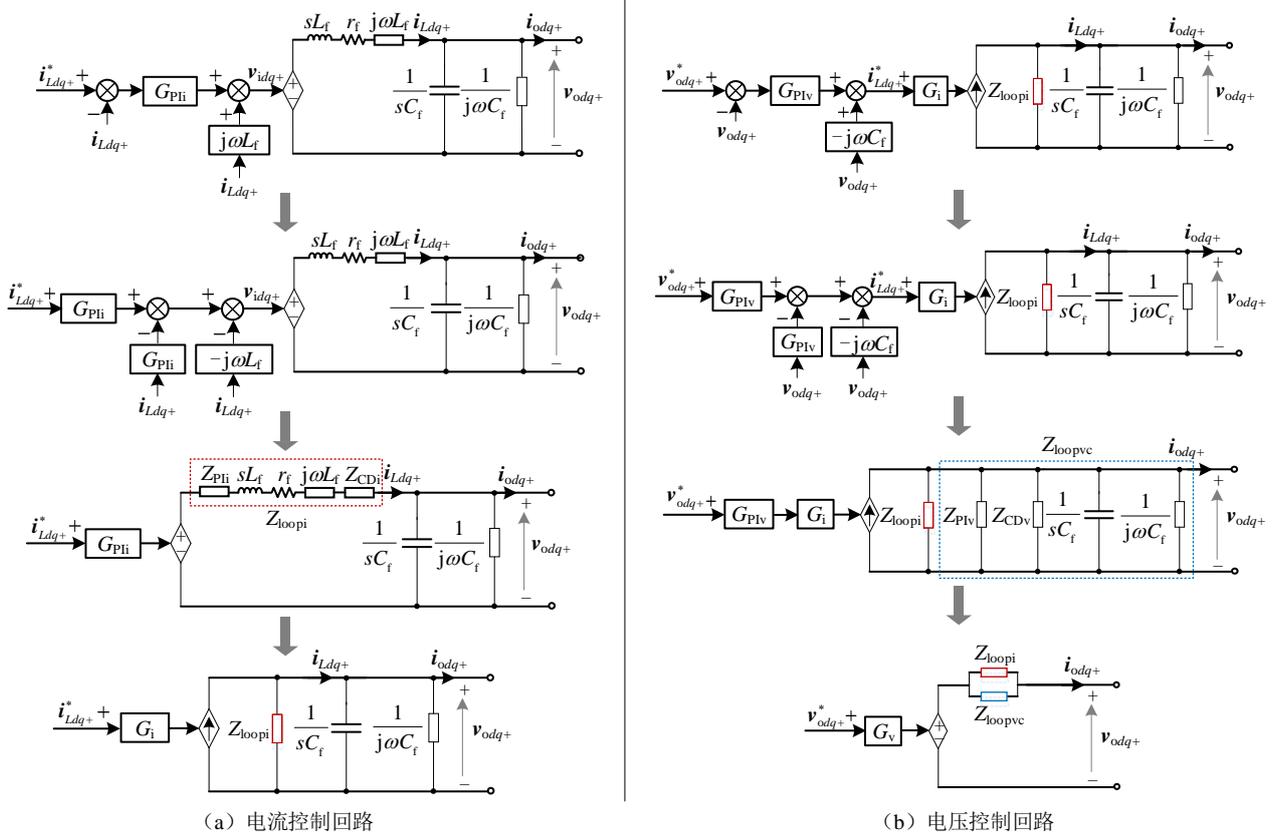


图 C1 构网型并网逆变器控制回路等效虚拟阻抗推导

Fig.C1 Derivation of equivalent virtual impedance of control loop for grid-forming inverter

$$Z_{PIV} = G_{PIV} = k_{pv} + \frac{k_{iv}}{s} \quad (C4)$$

$$Z_{CDV} = -j\omega C_f \quad (C5)$$

$$G_v = \frac{Z_{loopi} // Z_{loopvc}}{Z_{PIV}} \quad (C6)$$

式中： $k_{pv}$  为电压调节器比例系数； $k_{iv}$  为电压调节器积分系数。

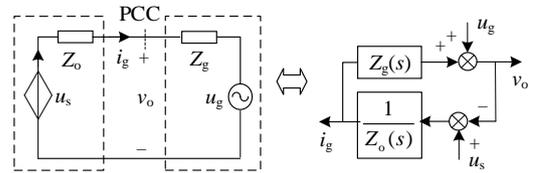


图 D2 构网型并网逆变器系统的戴维南等效电路及其等效控制框图

Fig.D2 Thevenin equivalent circuit of grid-forming inverter system and its equivalent control block diagram

表 D1 构网型并网逆变器参数

Table D1 Parameter of grid-forming inverter

参数	数值	参数	数值
额定电压 $U_N/kV$	23	$m_{PF}$	0.05
额定容量 $S_N/(MV \cdot A)$	100	$\omega_f(rad/s)$	$2\pi \times 15$
基波频率 $f_1/Hz$	50	$k_{pv}$	0.1
$L_f$	0.05	$k_{iv}$	1000
$C_f$	0.02	$k_{pi}$	0.5
$r_f$	0.05	$k_{ii}$	350

附录 D

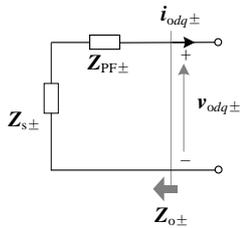


图 D1 考虑功率下垂控制构网型并网逆变器阻抗电路模型

Fig.D1 Impedance circuit model of grid-forming inverter considering power drooping control

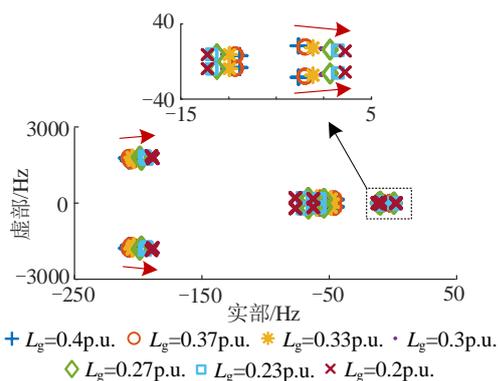


图 D3 电网阻抗变化时系统闭环极点结果

Fig.D3 Results of closed-loop poles when impedance of power network changes

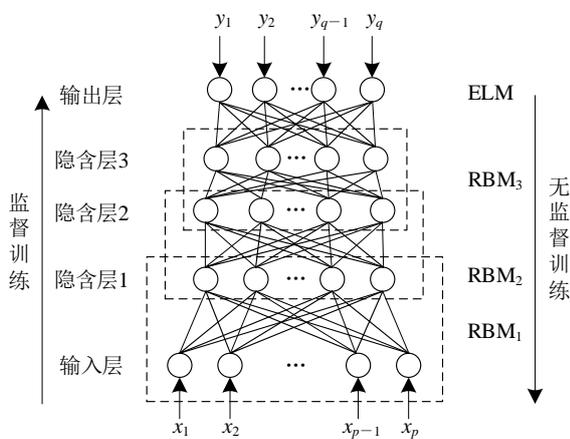


图 D4 DBN-ELM 模型结构

Fig.D4 Structure of DBN-ELM model

附录 E

RBM 是一种包括可见层和隐含层的 2 层神经网络。前一个 RBM 的隐含层作为下一个 RBM 的可见层，依次堆叠，其在训练过程中主要采用对比散度算法。设定可见层神经元状态为  $v$ ，隐含层神经元状态为  $h$ ，则在给定的状态  $(v, h)$  时，RBM 的能量函数定义为：

$$E(v, h|\theta) = -\sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i w_{ij} h_j \quad (E1)$$

式中： $\theta = \{a_i, w_{ij}, b_j\}$  表示 RBM 的各类参数 ( $i=1, 2, \dots, n; j=1, 2, \dots, m$ )； $n$  和  $m$  分别为一个 RBM 包含的可见层  $v_i$  和隐含层  $h_j$  的数目； $v_i$  和  $a_i$  分别为第  $i$  个可见层的状态和偏置； $h_j$  和  $b_j$  分别为第  $j$  个隐含层的状态和偏置； $w_{ij}$  为第  $i$  个可见层以及第  $j$  个隐含层二者之间的连接权重。

通过能量函数，可以得到模型可见层和隐含层的联合概率分布函数，即：

$$P_j(v, h|\theta) = \frac{1}{Z(\theta)} e^{-E(v, h|\theta)} \quad (E2)$$

式中： $Z(\theta) = \sum e^{-E(v, h|\theta)}$ ，称为归一化因子。

在 RBM 中，同一层的神经元无连接，相邻层的神经元全连接，所以当给定可见层节点的状态时，各个隐含层节点的激活状态之间是相互独立的。 $P_h(h_j=1|v)$ 、 $P_v(v_i=1|h)$  分别为给定可见（隐含）节点状态时，第  $j(i)$  个隐含（可见）层神经元的激活概率，定义式为：

$$P_h(h_j=1|v) = g\left(b_j + \sum_{i=1}^n v_i w_{ij}\right) \quad (E3)$$

$$P_v(v_i=1|h) = g\left(a_i + \sum_{j=1}^m w_{ij} h_j\right) \quad (E4)$$

式中： $g(\cdot)$  表示 sigmod 激活函数，用于限定神经元输出振幅。

参数  $w_{ij}$  可以按照式(E5)进行更新：

$$w_{ij} = \rho w_{ij} + \chi (<v_i h_j>_{\text{data}} - <v_i h_j>_{\text{model}}) \quad (E5)$$

式中： $\rho$  为动量； $\chi$  为学习率； $<v_i h_j>_{\text{data}}$  为数据分布的期望； $<v_i h_j>_{\text{model}}$  为 RBM 模型定义的期望。

$a_i$  和  $b_j$  也可以通过类似的方式进行更新调整。

模型训练的理想结果是模型任意输出节点的输出值能够零误差地逼近  $l$  个样本的实际值，即 ELM 的输出满足：

$$\begin{cases} y'_{ir} = \sum_{j=1}^{n_h} u_{j,r} g(\mathbf{W} \cdot \mathbf{X}_i + b_j) \\ \sum_{i=1}^l |y_{ir} - y'_{ir}| = 0 \end{cases} \quad (E6)$$

式中： $i=1, 2, \dots, l; r=1, 2, 3, 4$ ； $y'_{ir}$  为第  $i$  个样本模型的第  $r$  个输出节点的预测值； $u_{j,r}$  为第  $j$  层隐含层第  $r$  个输出节点的权重； $n_h$  为隐含层节点数； $g(\cdot)$  表示 sigmod 激活函数； $\mathbf{W}$  为输入层与隐含层神经元间的连接权重； $\mathbf{X}_i$  为第  $i$  个输入样本； $b_j$  为第  $j$  层隐含层的偏置值； $y_{ir}$  为第  $i$  个样本模型的第  $r$  个输出节点的实际值。

将式(E6)改写为矩阵形式，如式(E7)所示。

$$\mathbf{UH} = \mathbf{Y}' \quad (E7)$$

式中： $\mathbf{U}$  为权重矩阵； $\mathbf{H}$  为模型隐含层输出矩阵； $\mathbf{Y}'$  为输出矩阵。

设 DBN-ELM 模型结构隐含层数为  $d$ 。根据 ELM 算法，第  $d-1$  个隐含层到第  $d$  个隐含层的权重和偏置可以随机初始化，并得到唯一的输出矩阵  $\mathbf{H}$ 。根据期望输出  $\mathbf{Y}'$  将 DBN-ELM 的训练问题最终转化成了求解线性系统，则存在最优输出权值  $\mathbf{U}^*$ ：

$$\mathbf{U}^* = \mathbf{H}^+ \mathbf{Y}' \quad (E8)$$

式中： $\mathbf{H}^+$  表示矩阵  $\mathbf{H}$  的 Moore-Penrose 广义逆，根据  $\mathbf{H}^+ = (\mathbf{H}\mathbf{H}^T)^{-1} \mathbf{H}$  进行求解。

DBN 的学习训练过程可以划分为预训练和微调 2 个阶段。RBM 堆叠网络通过无监督训练将输入的高维特征重构融合成低维特征，利用贪心无监督学习算法由下至上逐层对整个 DBN 模型参数进行初始化。由于贪心算法无法使整个网络参数达到最优，故需要进入微调阶段优化整个网络的参数。第二阶段为微调阶段，ELM 有监督地对网络空间的相关参数进行进一步优化和调整，自顶向下微调整个模型，使模型性能更优。这种先无监督学习后监督学习的两步走模式，使 DBN 在训练数据不足的半监督学习任务中有很好的表现。

附录 F

F1 遗传算法优化 DBN-ELM 模型

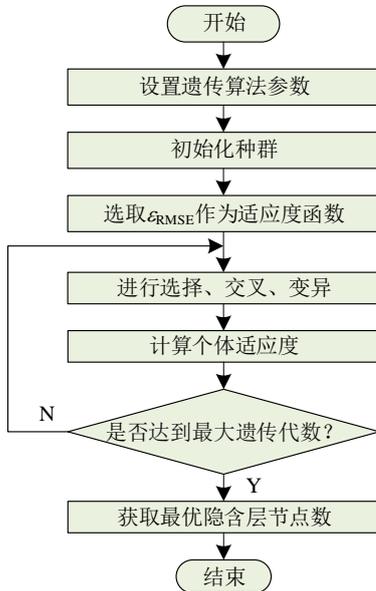


图 F1 遗传算法流程图

Fig.F1 Flowchart of genetic algorithm

采用遗传算法对 DBN-ELM 模型的优化步骤如下。

1) 待确定的遗传算法基本参数包括：遗传算法的最大遗传代数、种群大小、个体长度、代沟、交叉概率和变异概率。

2) DBN-ELM 的隐含层各层节点数与种群中的个体相对应，采用实数进行编码。

3) 通过式(F1)计算 DBN-ELM 模型得到的预测值和真实值间的  $\epsilon_{RMSE}$ ，该误差的大小反映了所建模型的优劣。因此选取  $\epsilon_{RMSE}$  作为适应度值。

$\epsilon_{RMSE}$  的表达式为：

$$\epsilon_{RMSE} = \sqrt{\frac{1}{L} \sum_{i=1}^L (y_{ir} - y'_{ir})^2} \quad (F1)$$

式中： $L$  为数据长度； $y_{ir}$ 、 $y'_{ir}$  分别为实际值、表

示预测值。

4) 选择、交叉和变异分别采用轮盘赌法、多点交叉和随机选取变异点的方法。

5) 终止条件是指是否到达最大遗传代数。

F2 控制参数搜索算法流程

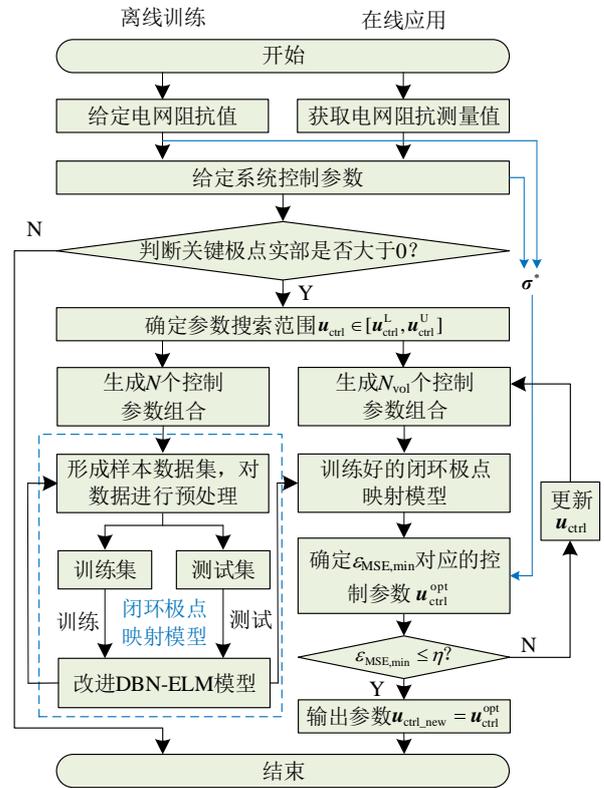


图 F2 控制参数搜索算法流程图

Fig.F2 Flowchart of control parameter search algorithm

附录 G

以寻找一元二次函数  $f_e = e^2$  在  $[-8,6]$  范围内的极小值为例，对式(12)所示的参数上、下限更新方法的有效性进行验证。图 G1 为参数上、下限的更新过程，第  $k+1$  次更新时的上、下限如式(G1)所示。

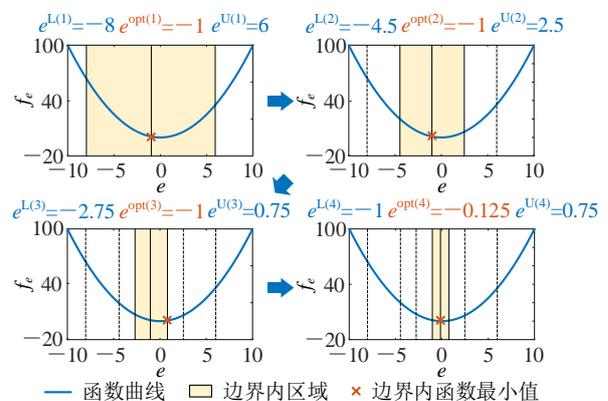


图 G1 参数上、下限更新过程图

Fig.G1 Diagram of upper and lower parameter boundary update process

$$\begin{cases} e^{L(k+1)} = \frac{1}{2}(e^{\text{opt}(k)} + e^{L(k)}) \\ e^{U(k+1)} = \frac{1}{2}(e^{\text{opt}(k)} + e^{U(k)}) \end{cases} \quad (\text{G1})$$

从图 G1 可以看出, 参数上、下限更新后得到的极小值接近原点, 证明了参数上、下限更新的有效性。该方法可以推广到多参数的情况, 其搜索区域将变为一个超平面。

附录 H

表 H1 训练样本集参数

Table H1 Parameters for training sample set

参数	数值
$u_{in}$ 维度	6×500
$u_{ctrl}$	$[m_{PF} \ k_{pv} \ k_{iv} \ k_{pi} \ k_{ii}]^T$
$u_{ctrl}^*$	$[0.05 \ 0.1 \ 500 \ 0.5 \ 1000]^T$
$u_{in}^U$	$[0.2 \ 0.5 \ 2000 \ 2 \ 3000 \ 1]^T$
$u_{in}^L$	$[0.02 \ 0.05 \ 200 \ 0.2 \ 300 \ 0.1]^T$
$y_{out}$ 维度	4×500

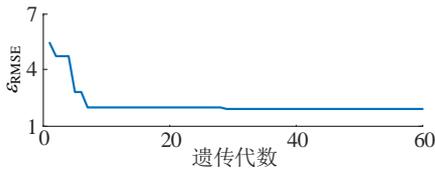


图 H1 遗传算法寻优结果

Fig.H1 Optimization results of genetic algorithm

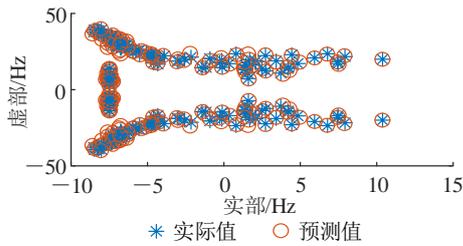


图 H2 测试集预测结果图

Fig.H2 Results of prediction for test set

表 H2 基于不同算法模型所预测后的评价指标

Table H2 Evaluation indexes predicted by different algorithm models

模型	$\epsilon_{RMSE}$	$\epsilon_{MAPE}/\%$	$t/s$
改进 DBN-ELM	1.93	3.64	0.82
DBN-ELM	2.70	7.85	0.97
DBN	3.41	9.21	1.06
ELM	4.84	13.91	1.12
BPNN	5.80	12.88	2.31

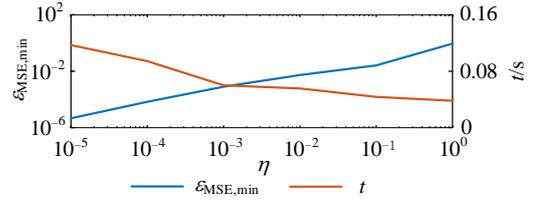
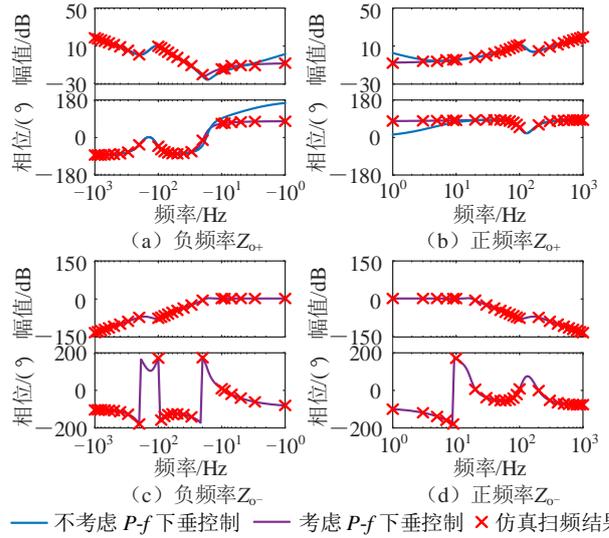


图 H3 不同容差下  $\epsilon_{MSE,min}$  和  $t$  的变化趋势

Fig.H3 Trends of  $\epsilon_{MSE,min}$  and  $t$  under different tolerances



— 不考虑  $P-f$  下垂控制 — 考虑  $P-f$  下垂控制 × 仿真扫频结果

图 H4 复矢量阻抗电路模型的理论曲线和仿真结果

Fig.H4 Theoretical curve and simulative results of complex vector impedance circuit model