

DOI: 10.19783/j.cnki.pspc.250085

# 考虑出力连续波动的虚拟同步机自适应惯量阻尼控制策略

梁展豪<sup>1</sup>, 曾君<sup>1</sup>, 刘俊峰<sup>2</sup>

(1. 华南理工大学电力学院, 广东 广州 510641; 2. 华南理工大学自动化科学与工程学院, 广东 广州 510641)

**摘要:** 应用虚拟同步机(virtual synchronous generator, VSG)技术的可再生能源发生出力波动时, 通过自适应惯量阻尼控制可以抑制由VSG固有动态响应特性导致的输出功率、频率附加振荡。但现有的基于径向基函数(radial basis function, RBF)的VSG自适应控制策略控制灵活性不足且参数配置复杂, 难以在出力连续波动下有效抑制输出功率、频率振荡。针对这一问题, 提出了一种基于粒子群优化(particle swarm optimization, PSO)算法优化RBF神经网络的VSG自适应惯量阻尼控制策略。首先, 对VSG进行小信号建模, 确定虚拟惯量、虚拟阻尼的取值范围并设定稳态惯量。然后, 利用RBF神经网络对VSG角频率与虚拟惯量、虚拟阻尼之间的关系进行拟合, 并引入 $J$ 惯性因子项扩展RBF神经网络的控制维度。进一步, 通过改进PSO对RBF神经网络超参数进行优化配置, 提高RBF神经网络的拟合及泛化能力, 使其在面临复杂的功率、频率波动时能够进行自适应惯量阻尼调节。最后, 搭建VSG并网模型, 在出力突变、出力连续波动、不同电网条件3种工况下验证了所提控制策略的可行性及优越性。**关键词:** 虚拟同步机; 出力连续波动; 径向基函数; 粒子群优化; 自适应惯量阻尼控制

## Adaptive inertia damping control strategy for virtual synchronous generators considering continuous output fluctuations

LIANG Zhanhao<sup>1</sup>, ZENG Jun<sup>1</sup>, LIU Junfeng<sup>2</sup>

(1. School of Electric Power Engineering, South China University of Technology, Guangzhou 510641, China;

2. School of Automation Science and Engineering, South China University of Technology, Guangzhou 510641, China)

**Abstract:** When renewable energy sources using virtual synchronous generator (VSG) technology experience output fluctuations, adaptive inertia damping control can suppress the additional oscillations in output power and frequency caused by the inherent dynamic response of the VSG. However, existing VSG adaptive control strategies based on radial basis function (RBF) lack control flexibility and involve complex parameter configuration, making them ineffective at restraining output power and frequency oscillations under continuous output fluctuations. To address this issue, a VSG adaptive inertia damping control strategy is proposed, in which particle swarm optimization (PSO) is used to optimize the RBF neural network. First, a small-signal model of the VSG is established, the range of values for virtual inertia and virtual damping are determined, and the steady-state inertia is set. Then, an RBF neural network is utilized to fit the relationship between the VSG's angular frequency and its virtual inertia and damping, and a  $J$ -inertia factor is introduced to expand the control dimension of the RBF neural network. Furthermore, an improved PSO algorithm is applied to optimize the hyperparameters of the RBF neural network, enhancing its fitting and generalization capability so that it can perform adaptive inertia damping regulation under complex power and frequency fluctuations. Finally, a VSG grid-connected model is established, and the feasibility and superiority of the proposed control strategy are verified under three operating conditions: sudden output change, continuous output fluctuations and different grid conditions.

This work is supported by the National Natural Science Foundation of China (No. 62173418 and No. 52377186).

**Key words:** virtual synchronous generator; continuous output fluctuation; radial basis function; particle swarm optimization; adaptive inertia damping control

## 0 引言

随着大量可再生能源(如光伏、风力发电等)通

过电力电子接口接入电网, 电力系统的惯性逐渐降低, 严重威胁系统的频率稳定<sup>[1-5]</sup>。虚拟同步机(virtual synchronous generator, VSG)技术作为一种有效的解决方案, 通过模拟传统同步发电机的行为特性, 为电力系统提供了所需的惯性和阻尼<sup>[6-9]</sup>。然而, VSG技术在应对可再生能源出力波动时, 由于其固有的动态

基金项目: 国家自然科学基金项目资助(62173418, 52377186);  
广东省自然科学基金项目资助(2024A1515012428)

响应特性,容易使得 VSG 输出功率和频率引入附加的振荡,给系统频率稳定带来了新的挑战<sup>[10]</sup>。

为了抑制 VSG 的附加功率和频率振荡,学者们提出了一系列解决方案,其中,自适应调整 VSG 的虚拟惯量、虚拟阻尼的方法尤为突出。文献[11-12]运用 bang-bang 算法对 VSG 的虚拟惯量进行自适应调节,但 bang-bang 算法输出具有离散特性,虚拟惯量控制精度不高。文献[13]运用 BP 神经网络自适应调整 VSG 的虚拟惯量和虚拟阻尼(后简称“虚拟惯量阻尼”),该方法在控制精度上优于 bang-bang 算法,但 BP 神经网络非线性拟合能力有限、结构复杂,在面对复杂工况时泛化能力差且计算开销较大。文献[14]提出了一种基于数据的积分强化学习方法(integral reinforcement learning, IRL)来学习频率变化率与虚拟惯量间的非线性关系,在复杂工况下的泛化能力显著提升,但该方法对数据依赖性强。文献[15]将径向基函数(radial basis function, RBF)神经网络应用到虚拟惯量实时调整领域。得益于 RBF 非线性拟合能力强、结构简单的优势,该方法能很好地拟合频率和虚拟惯量间的非线性关系,计算量小且对数据依赖性弱。然而,该算法泛化能力不强,在面临可再生能源出力连续波动时可能会发生梯度消失现象而引起严重振荡,且没有对 RBF 神经网络的学习率、惯性参数等众多超参数的设计原则进行分析。文献[16]提出一种基于最优阻尼比的 VSG 虚拟惯量阻尼自适应(也可称为“自适应惯量阻尼”)调节策略,并与虚拟惯量自适应调节进行了对比研究。该算法的泛化能力有所提升,但依然存在出力连续波动时算法不收敛的情况。

以上文献中的 VSG 自适应惯量阻尼控制策略普遍存在着一个问题:算法的拟合性能和泛化性能有限,难以应对可再生能源出力连续且随机波动的复杂工况。针对这一问题,目前主要的解决思路为改进控制算法架构,扩展控制维度。文献[17]将模糊控制与 bang-bang 算法相结合以自适应调节惯量,文献[18]则将模糊推理与神经网络相结合,模糊控制的引入可以增强算法的自适应性和稳定性,但模糊函数和隶属函数只能基于经验设计。文献[19]建立了分数阶 VSG 模型并引入了可调参数增加系统自由度,并与基于 RBF 神经网络的自适应惯量阻尼控制相结合,改善了系统的动态响应特性,但对建模精度要求较高。文献[20]运用 2-5-3 结构的 RBF 神经网络,通过引入了阻尼补偿量这一额外的控制维度提升算法的控制灵活性,建模工作量小,但神经网络的结构变得更为复杂,降低了实时控制中算法的效率。

控制维度的增加提升了算法的拟合能力和泛化能力,但也对算法参数的设置提出了更高的要求。人工设置算法参数不仅过程繁琐且难以达到理想的优化效果,因而有必要引入优化算法对算法参数进行优化配置。粒子群优化(particle swarm optimization, PSO)是一种基于群体智能的优化算法,凭借简单易实现的特点和良好的全局搜索能力在函数优化<sup>[21]</sup>、信号处理<sup>[22]</sup>和机器学习等领域得到了广泛应用。针对本文的控制器算法参数优化配置问题,PSO 相比其他优化算法展现出收敛速度快的独特优势,对控制器计算资源的要求较低。然而,PSO 的一个显著缺陷是其容易陷入局部最优解,致使实际优化效果不够理想<sup>[23]</sup>。

基于上述研究及分析,为了提高算法的拟合能力和泛化能力以应对出力连续波动,本文设计了一种基于改进 PSO 优化 RBF 神经网络的 VSG 自适应惯量阻尼控制策略。首先,建立了 VSG 的小信号模型,根据小信号模型确定虚拟惯量、虚拟阻尼的取值范围并设定 VSG 稳态惯量以明确自适应惯量阻尼控制的调节边界。其次,搭建了基于 RBF 神经网络的自适应惯量阻尼控制策略并引入了  $J$  惯性因子项,避免了梯度消失现象的发生,从而提高了控制算法在面对出力连续波动的灵活性。然后,设计基于改进 PSO 的 RBF 神经网络超参数优化方法,利用 logistic 混沌映射进行种群初始化,并设计新的适应度函数,提高了 PSO 的全局寻优能力及收敛精度,并形成了一套基于改进 PSO 优化 RBF 神经网络的自适应惯量阻尼控制方案;最后,在 MATLAB/Simulink 平台搭建了 VSG 并网模型,对出力突变、出力连续波动及不同电网条件工况下所提控制策略的有效性和优越性进行了验证。

## 1 VSG 模型

### 1.1 基于改进 PSO 优化 RBF 神经网络的 VSG 控制原理

基于改进 PSO 优化 RBF 神经网络的 VSG 主电路及控制回路结构如图 1 所示。新能源单元通过直流电容、逆变器、滤波器经公共耦合点(point of common coupling, PCC)接入电网。VSG 的控制回路包含基础控制部分和改进部分两部分。基础控制部分通过测量 PCC 处的电压电流计算输出功率,并输入到 VSG 控制环节得到参考电势和参考相位,经虚拟阻抗控制得到参考电压并输入到电压电流双环控制和脉宽调制(pulse width modulation, PWM)环节生成逆变器的控制信号。

改进部分主要由改进 PSO 优化算法和 RBF 神

经网络两部分构成。改进 PSO 优化算法获取 VSG 角频率以计算适应度函数, 基于此对 RBF 神经网络的 4 个超参数(学习率  $\eta$ 、惯性系数  $\alpha$ 、 $J$  惯性系数  $\alpha_J$ 、权值限制值  $w_{lim}$ )进行离线优化配置。RBF 神经网络以 VSG 角频率变化率和角频率偏差为输入, 通过拟合角频率与虚拟惯量阻尼间非线性关系, 实时生成 VSG 控制环节中虚拟惯量阻尼。

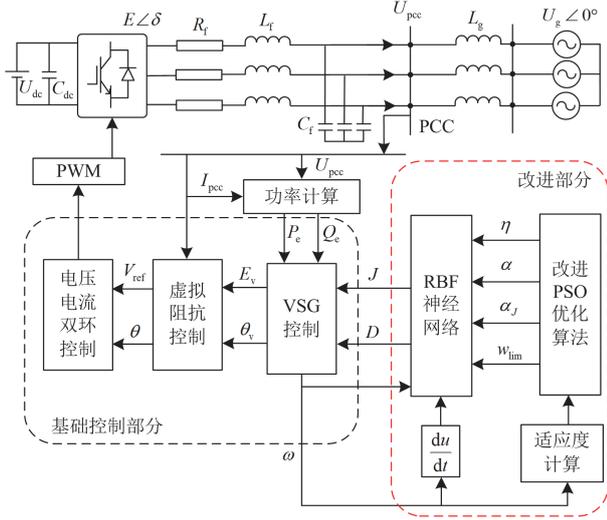


图 1 基于改进 PSO 优化 RBF 神经网络的 VSG 主电路及控制回路结构

Fig. 1 VSG main circuit and control loop structure based on improved PSO optimized RBF neural network

为简化分析, 忽略滤波电容及滤波电阻的影响, 图 1 的主电路结构对应的 VSG 输出有功、无功功率计算方程如式(1)所示。

$$\begin{cases} P_e = \frac{3EU_g \sin \delta}{X} \\ Q_e = \frac{3E(E - U_g \cos \delta)}{X} \end{cases} \quad (1)$$

式中:  $P_e$ 、 $Q_e$  分别为 VSG 输出有功功率和无功功率;  $X$  代表滤波电抗和电网电抗的和;  $E \angle \delta$  为 VSG 输出电动势;  $U_g \angle 0^\circ$  为参考电压。

图 2 为 VSG 控制环节结构图, 有功频率环节和无功电压环节的动态方程分别如式(2)和式(3)所示。

$$J \frac{d\omega}{dt} = \frac{P_{ref} - P_e}{\omega_N} - D_p (\omega - \omega_N) \quad (2)$$

式中:  $J$  为虚拟惯量;  $P_{ref}$  为有功指令;  $D_p$  为虚拟阻尼;  $\omega$  为 VSG 角频率;  $\omega_N$  为同步角频率。

$$K_q \frac{dE_v}{dt} = Q_{ref} - Q_e - D_q (U_{pcc} - U_N) \quad (3)$$

式中:  $K_q$  为无功电压惯性系数;  $E_v$  为 VSG 参考电

动势幅值;  $Q_{ref}$  为无功指令;  $D_q$  为无功电压下垂系数;  $U_{pcc}$  为 PCC 电压;  $U_N$  为 PCC 参考电压。

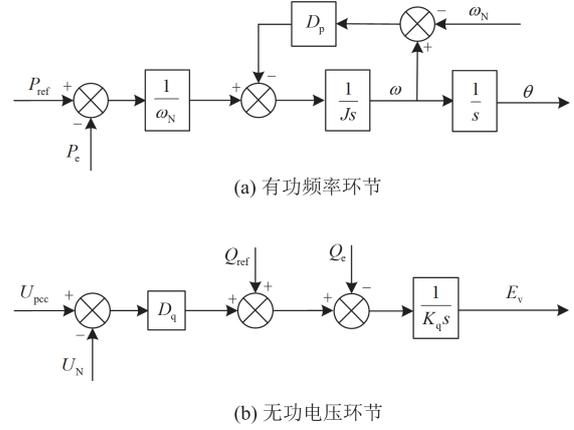


图 2 VSG 控制环节结构

Fig. 2 Control circuit of VSG

其中, 有功频率环节是影响 VSG 输出功率、频率振荡的主要环节。而有功频率环节与无功电压环节间的耦合可以通过虚拟阻抗控制消除, 为简化分析, 直接忽略有功、无功功率的耦合。基于此, 结合式(1)和式(2)得到 VSG 输出有功功率与有功指令的开环传递函数  $G_{VSG}(s)$ , 如式(4)所示。

$$G_{VSG}(s) = \frac{K_{pf}}{\omega_N s (Js + D_p)} \quad (4)$$

式中:  $K_{pf} = 3E_s U_g \cos \delta_s / X$ , 其中  $E_s \angle \delta_s$  为 VSG 稳态输出电动势。

由式(4)可得 VSG 有功频率环节的闭环传递函数  $G(s)$  为

$$G(s) = \frac{K_{pf}}{J\omega_N s^2 + D_p \omega_N s + K_{pf}} \quad (5)$$

由式(5)可知, VSG 有功频率环节的闭环系统是一个典型二阶系统, 对应的自然振荡频率  $\xi$  和阻尼比  $\omega_n$  如式(6)所示。

$$\begin{cases} \xi = \frac{D_p}{2} \sqrt{\frac{\omega_N}{JK_{pf}}} \\ \omega_n = \sqrt{\frac{K_{pf}}{J\omega_N}} \end{cases} \quad (6)$$

## 1.2 惯量阻尼取值范围分析

本文所采用 VSG 模型参数如表 1 所示。基于 VSG 小信号模型, 从惯性响应能力、系统稳定性及动态性能三方面要求出发, 确定虚拟惯量、虚拟阻尼的取值范围并设定 VSG 稳态惯量。

表 1 VSG 模型参数设置

Table 1 Model parameter settings of VSG

参数	描述	数值	参数	描述	数值
$U_{dc}$	直流电压	750 V	$L_g$	电网电感	1.5 mH
$U_g$	电网电压	220 V	$E_s$	输出电动势幅值	226 V
$S_N$	额定容量	10 kW	$\delta_s$	输出电动势相角	0.05
$f_N$	额定频率	50 Hz	$C_{dc}$	直流电容	100 $\mu$ H
$L_f$	滤波电感	0.6 mH	$C_f$	滤波电容	10 $\mu$ H

针对 VSG 的惯性响应能力, GB/T38983.1(后简称“标准”)要求 VSG 惯性时间常数  $T_j$  宜小于等于 12 s,  $T_j$  表达式为

$$T_j = \frac{J\omega_N^2}{S_N} \leq 12 \text{ s} \quad (7)$$

由式(7)可得  $J \leq 1.2 \text{ kg} \cdot \text{m}^2$ , 为保证功率或频率突变时 VSG 能迅速提供功率, 同时避免转动惯量过大带来的系统振荡, 设 VSG 稳态惯量  $J_s = 0.3 \text{ kg} \cdot \text{m}^2$ .

针对系统稳定性, 一般要求开环穿越频率  $\omega_{co}$  不大于同步频率  $\omega_N$  的 10%, 以消除线路阻抗谐振的影响, 另外,  $\omega_{co}$  应不大于  $D/J$ , 确保穿越时的斜率是 20 dB/decade<sup>[24]</sup>, 总结如下:

$$\begin{cases} \omega_{co} \leq 0.1\omega_N \\ \omega_{co} \leq D/J \end{cases} \quad (8)$$

开环传递函数在穿越频率处的环路增益幅值等于 1, 即有

$$|G_{VSG}(j\omega_{co})| = 1 \quad (9)$$

由式(4)、式(9)可得

$$J = \frac{D_p}{\omega_{co}} \sqrt{\left(\frac{K_{pf}}{\omega_{co}\omega_N D_p}\right)^2 - 1} \quad (10)$$

虚拟惯量的取值应为大于 0 的实数, 故式(10)根号中表达式应大于 0, 可得

$$\omega_{co} \leq \frac{K_{pf}}{\omega_N D_p} \triangleq \omega_{co \max} \quad (11)$$

针对系统快速性, 一方面, 设计系统为欠阻尼系统来保证系数响应的快速性, 即取阻尼比  $\xi < 1$ 。另一方面, 标准要求 VSG 的响应调节时间  $t_p$  不大于 1 s。

$$t_p = \frac{4.4}{\xi\omega_n} \leq 1 \text{ s} \quad (12)$$

综合前面分析, 可以得到虚拟惯量、虚拟阻尼的取值范围如图 3 所示。可以看出, 虚拟惯量取值范围为  $0.044 \text{ kg} \cdot \text{m}^2 \leq J \leq 1.2 \text{ kg} \cdot \text{m}^2$ , 虚拟阻尼取值范围为  $11.1 \text{ N} \cdot \text{s}/\text{rad} \leq D \leq 58.0 \text{ N} \cdot \text{s}/\text{rad}$ , 阴影区

域为虚拟惯量、虚拟阻尼取值可行域。

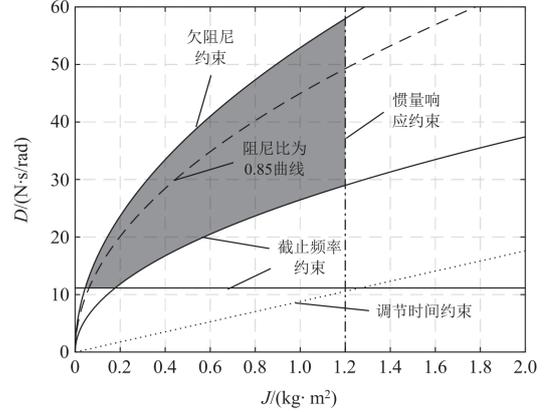


图 3 虚拟惯量、虚拟阻尼取值范围

Fig. 3 Range of virtual inertia and virtual damping

## 2 VSG 自适应惯量阻尼控制策略

### 2.1 RBF 神经网络

RBF 神经网络仅包含一个非线性隐藏层和一个线性输出层, 具有结构简单、非线性映射能力强、训练效率高等特点, 能够很好地在线拟合 VSG 角频率与虚拟惯量之间的非线性关系。本文采用输入层-隐藏层-输出层节点数为 2-5-1 的 RBF 神经网络结构。

输入变量为角频率变化率  $d\omega/dt$  和角频率偏差  $\Delta\omega$ , 经过标幺化处理后接入到 5 个隐藏层(隐藏层采用的基函数为高斯函数), 隐藏层神经元的输出如式(13)所示。

$$h_j = \exp\left(-\frac{\|\bar{\mathbf{x}} - \bar{\mathbf{c}}_j\|^2}{\sigma_j^2}\right), j = 1, 2, \dots, 5 \quad (13)$$

式中:  $h_j$  表示第  $j$  个隐藏层神经元的输出;  $\bar{\mathbf{x}}$  表示经过标幺化处理的输入层向量;  $\bar{\mathbf{c}}_j$ 、 $\sigma_j$  分别代表高斯基函数的中心点向量和宽度。 $\bar{\mathbf{x}}$  中元素的变化范围为  $[-1, 1]$  且在 0 左右波动, 因此选取  $\bar{\mathbf{c}}_j = [0, 0]$  ( $j = 1, 2, \dots, 5$ ), 使得高斯基函数对输入的变化更加敏感; 选取  $\sigma_j = 1$  ( $j = 1, 2, \dots, 5$ ), 以确保高斯基函数能覆盖并精确反映输入数据的特征。

输出层输入  $y$  是对所有隐藏层神经元的加权和, 如式(14)所示。

$$y = \sum_{j=1}^5 w_j \cdot h_j \quad (14)$$

式中:  $w_j$  表示连接第  $j$  个隐藏层神经元与输出层的连接权值。

为了使 RBF 神经网络的输出符合虚拟惯量的物理意义, 在输出节点上加入 Sigmoid 激活函数。

$$J = \frac{ue^y}{e^y + e^{-y}} \quad (15)$$

式中:  $u$  为虚拟惯量的上限值。

选取 VSG 角频率的均方误差  $E(k)$  作为 RBF 神经网络的损失函数, 如式(16)所示。

$$E(k) = \frac{1}{2} (\omega_N - \omega(k))^2 \quad (16)$$

式中:  $\omega(k)$  表示第  $k$  时刻的 VSG 角频率。

RBF 神经网络的权值更新采用梯度下降法, 为了提高神经网络的收敛速度, 本文加入了惯性环节, 权值更新公式如式(17)所示。

$$\Delta w_j(k) = -\eta \frac{\partial E(k)}{\partial w_j(k)} + \alpha \Delta w_j(k-1) \quad (17)$$

其中:

$$\frac{\partial E(k)}{\partial w_j(k)} = \frac{\partial E(k)}{\partial \omega(k)} \cdot \frac{\partial \omega(k)}{\partial J(k)} \cdot \frac{\partial J(k)}{\partial y(k)} \cdot \frac{\partial y(k)}{\partial w_j(k)} \quad (18)$$

式中:  $\eta$  和  $\alpha$  分别代表网络的学习率和惯性系数;  $J(k)$  表示该时刻的虚拟惯量;  $y(k)$  表示该时刻输出层输入值。

由式(15)可得, 当输出层输入过大时有  $\partial J(k)/\partial y(k) \approx 0$ , 由式(18)可得  $\partial E(k)/\partial w_j(k) \approx 0$ , 即 RBF 神经网络发生了梯度消失的现象, 无法正常进行权值更新, 严重影响神经网络的拟合能力和泛化能力, 因而需要限制输出层输入范围。

首先, 设置权值限制范围如式(19)所示, 合理设置权值限制值  $w_{lim}$  可以加强算法的鲁棒性, 避免算法在特定输入下的极端响应。

$$-w_{lim} \leq w_j \leq w_{lim}, j=1, 2, \dots, m, w_{lim} > 0 \quad (19)$$

另外, 对输出层输入进行标么化处理, 如式(20)所示。

$$y' = \frac{y}{y_N} \quad (20)$$

式中:  $y'$  表示标么化处理后的输出层输入变量;  $y_N$  表示输出层输入变量的基准值。Sigmoid 激活函数如图 4 所示。若选取基准值  $y_N$  过大, 输入在经过 Sigmoid 函数时易陷入其线性区域内, 数据表达能力变差; 若选取基准值  $y_N$  过小, 输入在经过 Sigmoid 函数时易陷入到其饱和区域, 标么化对梯度消失的限制作用不大。因此, 选取  $y_N = 2.5w_{lim}$ , 容易得到标么化处理后的输入范围为  $[-2, 2]$ , 可以在保持 Sigmoid 函数非线性表达能力的同时尽量减少梯度消失现象发生的可能。

然而, 尽管通过权值限制和标么化处理限制了输出层输入的大小, 当超参数选取不当(如学习率设置过大)或波动过大时, 仍可能发生梯度消失现象,

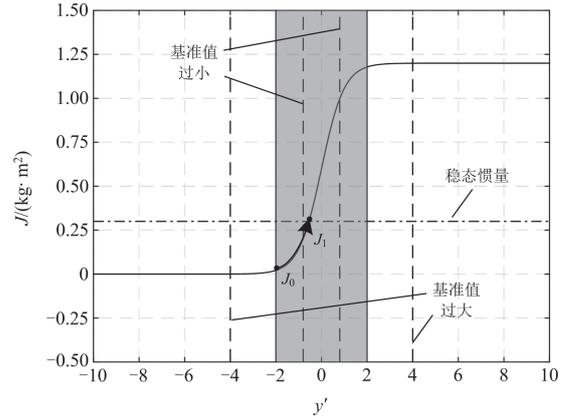


图 4 Sigmoid 激活函数

Fig. 4 Sigmoid activation function

导致控制系统无法针对角频率变化率和角频率偏差的变化及时进行虚拟惯量阻尼的自适应调整; 另一方面, 在自适应惯量阻尼控制这一具体场景中, 在频率波动开始后的初始阶段, 需要惯量迅速增大到较高的水平以防止频率的急剧变化<sup>[25]</sup>。

结合上述问题及需求, 提出在权值更新式(17)中加入一项  $J$  惯性因子项, 权值更新公式调整为

$$\Delta w_j(k) = -\eta \frac{\partial E(k)}{\partial w_j(k)} + \alpha \Delta w_j(k-1) + \Delta w_j(k) \quad (21)$$

$$\Delta w_j(k) = \begin{cases} \alpha_J (J_s - J(k)), & J < J_s \\ 0, & J \geq J_s \end{cases} \quad (22)$$

式中:  $J(k)$  表示这一时刻的虚拟惯量值;  $J_s$  为设定的稳态惯量。

图 4 展示了加入  $J$  惯性因子项的作用。当发生出力连续波动时, 若上一次出力波动较大, 使得稳定后虚拟惯量取值偏低(处于  $J_0$  位置), 若不添加  $J$  惯性因子项, 当发生下一次较小出力波动时, 惯量难以迅速提升到一个较高的位置, 甚至由于进入了 Sigmoid 激活函数的饱和区域而发生梯度消失现象, 导致 RBF 神经网络无法及时做出响应, 虚拟惯量一直维持在较低的水平。加入  $J$  惯性因子项后, 虚拟惯量在波动后能够自动恢复到设定的稳态惯量水平(处于  $J_1$  位置), 保证下一次波动时能迅速做出响应。

上述改进在几乎不增加神经网络复杂度的同时提升了神经网络的拟合能力和泛化能力, 但也不可避免地增加了需要整定的算法参数数量。合理地设置 RBF 神经网络的超参数对控制算法起到关键作用, 因而需要引入优化算法对神经网络的超参数进行优化配置。采用改进 PSO 离线优化超参数既不会增加神经网络的复杂度, 又能极大地提升 RBF 神经网络的控制效果。

## 2.2 改进 PSO 优化算法

PSO 是一种基于群体智能的优化算法, 通过模拟粒子在解空间中的移动和相互之间的信息交流, 逐步逼近最优解。令 PSO 包含  $n_p$  个粒子, 在  $d$  维空间内进行搜索, 粒子的位置和速度表达式为

$$\begin{cases} \bar{x}_i(k) = (x_{i,1}(k), x_{i,2}(k), \dots, x_{i,d}(k)) \\ \bar{v}_i(k) = (v_{i,1}(k), v_{i,2}(k), \dots, v_{i,d}(k)) \end{cases}, i=1, 2, \dots, n_p \quad (23)$$

式中:  $\bar{x}_i(k)$ 、 $\bar{v}_i(k)$  分别表示第  $i$  个粒子在第  $k$  次迭代时所处位置和速度。

粒子搜寻过程位置和速度更新表达式如式(24)所示。

$$\begin{cases} \bar{x}_i(k+1) = \bar{x}_i(k) + \bar{v}_i(k+1) \\ \bar{v}_i(k+1) = \omega_p \bar{v}_i(k) + c_1 r_1 (\bar{y}_{best,i}(k) - \bar{x}_i(k)) + \\ c_2 r_2 (\bar{y}_{gbest}(k) - \bar{x}_i(k)) \end{cases} \quad (24)$$

式中:  $\omega_p$  表示位置权重因子;  $c_1$ 、 $c_2$  分别表示个体学习因子和社会学习因子;  $r_1$ 、 $r_2$  表示 0 到 1 的随机数;  $\bar{y}_{best,i}$  表示第  $i$  个粒子当前个体最优位置;  $\bar{y}_{gbest}$  表示当前群体最优位置。

PSO 是一种发展成熟的优化算法, 其标准流程此处不再赘述。算法主要参数设置为: 最大迭代次数  $N = 50$ , 粒子数量设置为  $n_p = 20$ , 位置权重因子  $\omega_p$  从 0.9 线性递减到 0.2,  $c_1$ 、 $c_2$  均选为 2。

值得注意的是, PSO 算法的初始化对其精度存在较大影响, 解空间不均匀的初始粒子分布不利于算法的前期收敛, 会导致算法陷入局部最优。研究表明, 以混沌映射替代传统随机数生成器来生成随机数, 可以提高算法的效率<sup>[26-27]</sup>。因此, 本文采用 logistic 映射初始化种群的方法改进 PSO 算法。

首先, 随机生成一个初始值  $x_{i,1}(0) \in (0,1)$ 。然后, 运用 logistic 映射生成第一个粒子为

$$x_{i,j+1}(0) = \lambda x_{i,j}(0)(1 - x_{i,j}(0)), j = 1, 2, \dots, d-1 \quad (25)$$

式中:  $\lambda$  为混沌映射系数, 决定映射的混沌程度, 取  $\lambda = 4$  使得映射处于完全混沌状态。

由于生成的混沌序列在 (0,1) 范围内, 需要将其线性变换至解空间, 得到第一个粒子为

$$x_{i,j}(0) = x_{L,j} + x_{i,j}(0) \cdot (x_{U,j} - x_{L,j}), j = 1, 2, \dots, d \quad (26)$$

式中:  $x_{U,j}$ 、 $x_{L,j}$  分别表示解空间第  $j$  维度的上限值和下限值。

然后, 基于这一粒子运用一维混沌 logistic 映射迭代生成其他粒子, 如式(27)所示。

$$\begin{aligned} x_{i+1,j}(0) &= \lambda x_{i,j}(0)(1 - x_{i,j}(0)), \\ i &= 1, 2, \dots, n_p - 1, j = 1, 2, \dots, d \end{aligned} \quad (27)$$

根据前面构建的粒子, 可以构成种群的初始化矩阵  $\mathbf{P}$  为

$$\mathbf{P} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1d} \\ x_{21} & x_{22} & \dots & x_{2d} \\ \vdots & \vdots & & \vdots \\ x_{n_p,1} & x_{n_p,2} & \dots & x_{n_p,d} \end{bmatrix} \quad (28)$$

此外, 传统的 PSO 算法通常采用均方误差 (mean squared error, MSE) 作为适应度函数, VSG 时域曲线中各采样点角频率  $\omega_i$  的 MSE 表达式为

$$f_{MSE} = \frac{1}{n} \sum_{i=1}^n [\omega_i - \omega_N]^2 \quad (29)$$

尽管 MSE 是一种常用的评估指标, 但其无法充分反映在工程实际中所关注的频率性能, 以 MSE 为适应度函数优化得到 RBF 神经网络超参数, 实际频率动态响应性能不够理想。因此, 有必要设计一个综合考虑频率指标的适应度函数, 以更准确地评估和优化 RBF 神经网络的性能。所设计的适应度函数表达式如式(30)所示。

$$f_{fit} = a_1 \cdot f_{MAE} + a_2 \cdot f_{RoCoF \max} + a_3 \cdot \Delta f_{\max} \quad (30)$$

式中:  $f_{MAE}$  表示频率绝对平均误差;  $f_{RoCoF \max}$  表示最大频率变化率;  $\Delta f_{\max}$  表示最大频率偏差; 三者均采用了标幺值以统一量纲;  $a_1$ 、 $a_2$ 、 $a_3$  分别代表三者的权重因子, 反映函数中每个项的相对重要性。

需要说明的是, 粒子适应度函数计算所依据的频率响应曲线来源于: 粒子位置对应的一组神经网络超参数输入到 RBF 神经网络, 然后基于该 RBF 神经网络控制的 VSG 并网模型(模型参数如表 1)在设定的随机出力连续波动工况下的频率响应曲线。

为了验证所提出改进粒子群优化(improved particle swarm optimization, IPSO)算法的优越性, 选取了收敛速度快、计算量小的传统 PSO 算法和两种抗早熟收敛能力强、善于处理复杂问题的新型智能优化算法: 麻雀搜索算法(sparrow search algorithm, SSA)<sup>[28]</sup>、冠豪猪优化算法(crested porcupine optimizer, CPO)<sup>[29]</sup>进行对比分析。本文对比了 4 种算法对 RBF 神经网络超参数优化配置问题的优化效果。图 5 为 4 种算法 80 次迭代的适应度值  $f_{fit}$  随迭代步数  $n_{iter}$  的变化曲线, 图 6 对 4 种算法的适应度最小值  $f_{fit \min}$  和收敛迭代步数  $n_{iter \max}$  进行了对比分析。

可以看出, 所提出的改进粒子群算法经过 11~16 次迭代即可收敛, 优于 SSA 和 CPO, 继承了传统 PSO 收敛速度快的优点。另外, logistic 混沌映射初始化种群克服了传统随机初始化种群带来的初始粒子分布不均问题, 有助于算法在早期探索更多潜在解区域, 避免算法陷入局部最优, 最终适应度收敛结果稳定且低至 0.786, 在 4 种算法中最优。

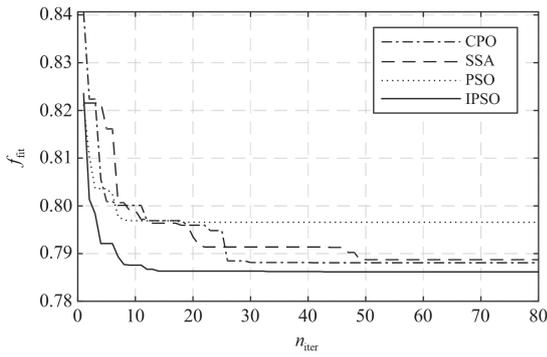


图 5 不同算法的适应度变化曲线

Fig. 5 Fitness variation curves of different algorithms

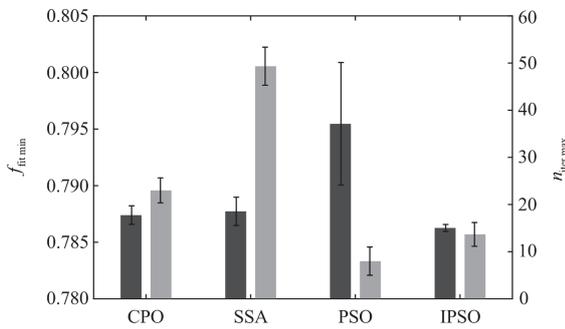


图 6 不同算法的适应度最小值和收敛迭代步数

Fig. 6 Minimum fitness and iterations for convergence of different algorithms

### 2.3 基于改进 PSO 优化 RBF 神经网络的 VSG 自适应惯量阻尼控制方案

综合上述研究, 形成了一套完善的基于改进 PSO

优化 RBF 神经网络的 VSG 自适应惯量阻尼控制方案。图 7 为算法流程图, 算法思路如下: 首先, 从 VSG 控制环节提取 VSG 角频率变化率和角频率偏差; 其次, 采用改进粒子群算法对学习率、惯性系数、 $J$  惯性系数、权值限制值等超参数进行优化, 并输出最优超参数到 RBF 神经网络; 然后, RBF 神经网络对 VSG 角频率与虚拟惯量间非线性关系进行拟合, 动态生成当前时刻的虚拟惯量, 与此同时, 按式(31)确定当前时刻固定阻尼比下虚拟阻尼(固定阻尼比运行曲线如图 3 所示); 最后, 结合虚拟惯量与虚拟阻尼的预设范围, 对两者进行合理限制后输出。

$$D_p = \frac{1}{2\zeta_s} \sqrt{\frac{\omega_N}{JK_{pf}}} \quad (31)$$

式中:  $\zeta_s$  为选取的固定阻尼比, 本文选取  $\zeta_s = 0.85$ , 以兼顾系统稳定性和响应速度。

### 3 仿真实验及结果分析

在 MATLAB/Simulink 平台搭建了 VSG 并网模型, 其模型参数如表 1 所示。对所提基于改进 PSO 优化 RBF 神经网络的 VSG 自适应惯量阻尼控制策略(简称 IPSO-RBF)在出力突变、出力连续波动、不同电网条件 3 种典型工况下的可行性进行评估, 并与取虚拟惯量  $J = 0.5 \text{ kg} \cdot \text{m}^2$  的固定惯量控制(简称 fixed-J)和传统 RBF 自适应惯量阻尼控制(简称 RBF)两种控制策略的控制效果进行对比分析, 验证所提自适应惯量阻尼控制策略的优越性。

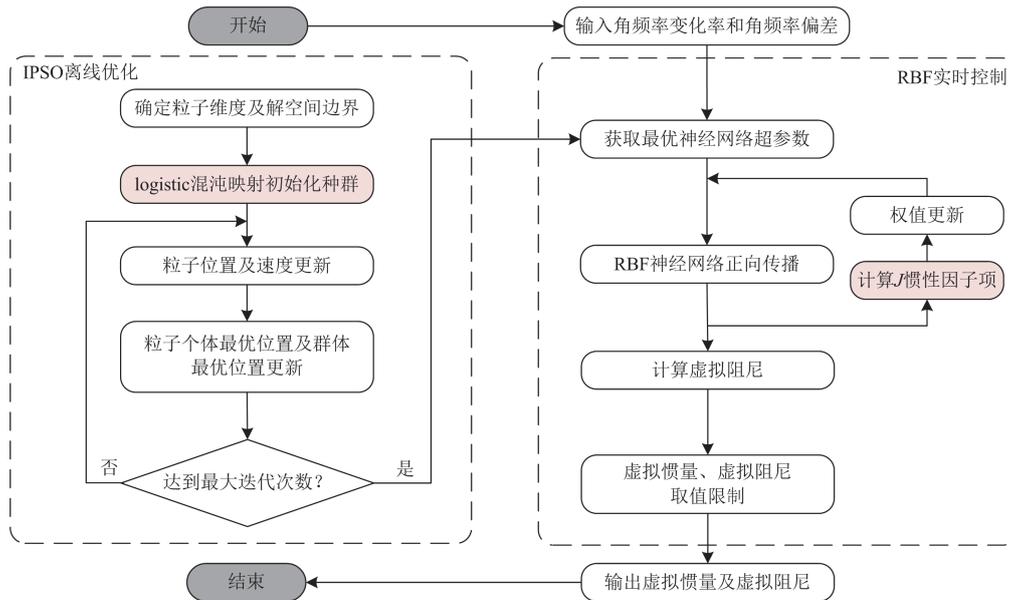


图 7 基于改进 PSO 优化 RBF 神经网络的自适应惯量阻尼控制算法流程图

Fig. 7 Flow chart of adaptive inertial damping control algorithm based on improved PSO optimized RBF neural network

### 3.1 出力突变

设置仿真时长为 0.6 s，初始状态 VSG 有功指令为 10 kW，在 0.2 s 时有功指令突增到 20 kW，图 8 为采用 IPSO-RBF 控制的 VSG 的 PCC 电压电流波形。采用 IPSO-RBF 控制的 VSG 在面对出力突变时表现出良好的电压电流外特性。其中，PCC 电压  $U_{pcc}$  几乎不受影响，保持稳定；PCC 电流  $I_{pcc}$  则能够迅速恢复至稳态。

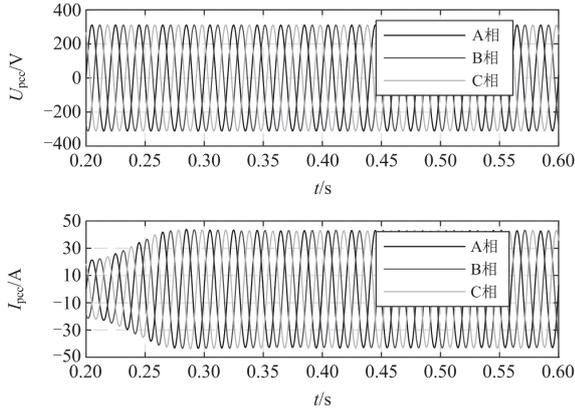


图 8 PCC 处电压电流波形

Fig. 8 Voltage and current waveforms at PCC

出力突变后 IPSO-RBF 控制与 RBF 控制的虚拟惯量、虚拟阻尼曲线如图 9 所示。

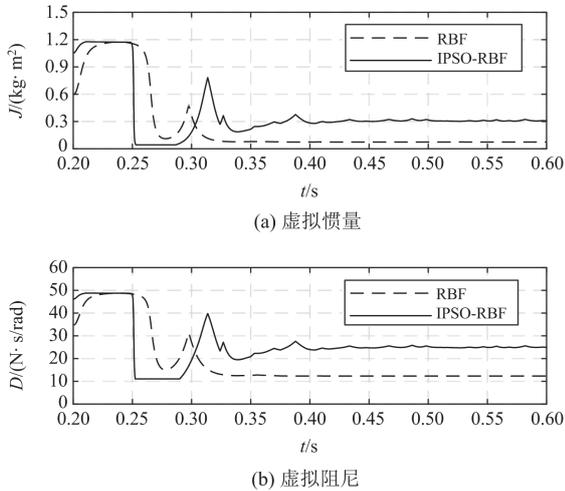


图 9 不同算法的虚拟惯量、虚拟阻尼曲线

Fig. 9 Virtual inertia and virtual damping curves for different algorithms

可以看出，两种控制策略下 VSG 的虚拟惯量、虚拟阻尼均能保持在设定的限制范围内。相较于 RBF 控制，IPSO-RBF 控制在频率波动期间表现出更灵活且迅速的虚拟惯量阻尼调节能力，这是因为 IPSO-RBF 控制通过改进 PSO 对神经网络超参数的

优化提高了算法的拟合能力。在频率稳定后 IPSO-RBF 控制在添加的  $J$  惯性因子项作用下可以恢复到设定的稳态惯量水平，为应对下一次波动做准备。

图 10、图 11、表 2 对比了 3 种控制方案在出力突变时的功率及频率响应性能。

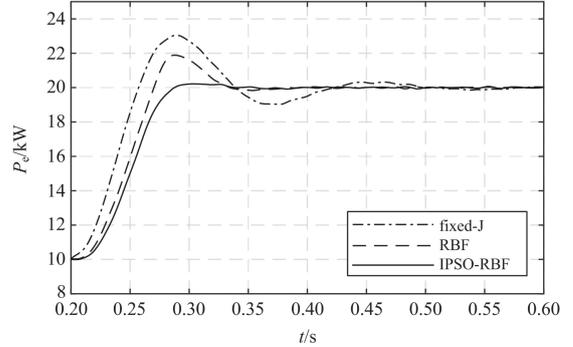


图 10 不同算法的功率曲线

Fig. 10 Power curves of different algorithms

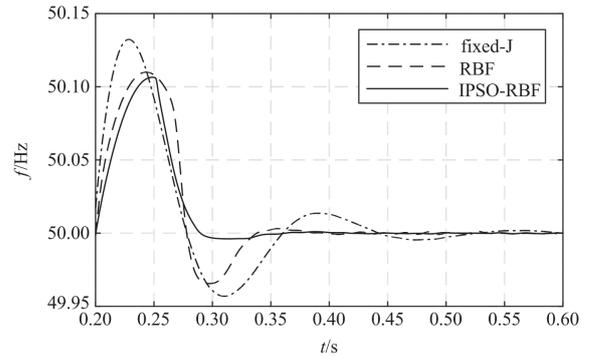


图 11 不同算法的频率曲线

Fig. 11 Frequency curves of different algorithms

表 2 不同算法性能指标

Table 2 Performance indicators of different algorithms					
组别	$f_{MAE}/\text{Hz}$	$\Delta f_{\max}/\text{Hz}$	$f_{\text{RoCoF max}}/(\text{Hz/s})$	$\Delta P_{\max}/\text{kW}$	$t_s/\text{s}$
fixed-J	0.024	0.132	7.436	3.06	0.18
RBF	0.019	0.110	6.295	1.89	0.11
IPSO-RBF	0.014	0.107	4.195	0.22	0.07

由图 10、图 11 和表 2 可以得到以下结论：

1) IPSO-RBF 控制的最大功率偏差  $\Delta P_{\max}$  为 0.22 kW，小于 RBF 控制的 1.89 kW 和 fixed-J 控制的 3.06 kW，功率稳定时间  $t_s$  为 0.07 s，小于 RBF 控制的 0.11 s 和 fixed-J 控制的 0.18 s，说明 IPSO-RBF 控制可以在减小功率超调的同时提高功率响应速度，控制策略的精度更高。

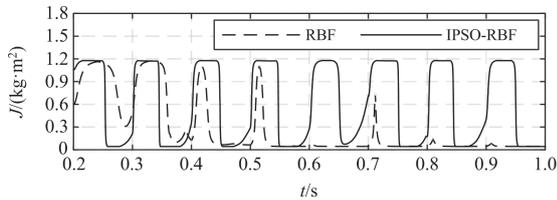
2) IPSO-RBF 控制下最大频率偏差  $\Delta f_{\max}$  为 0.107 Hz，小于 RBF 控制的 0.110 Hz 和 fixed-J 控制

的 0.132 Hz, IPSO-RBF 控制下最大频率变化率  $f_{\text{RoCoF max}}$  为 4.195 Hz/s, 低于 RBF 控制的 6.295 Hz/s 和 fixed-J 控制的 7.436 Hz/s, 说明 IPSO-RBF 控制具备高惯量带来的频率偏差小、频率变化率低的优势; IPSO-RBF 控制下频率绝对平均误差  $f_{\text{MAE}}$  为 0.014 Hz, 小于 RBF 控制的 0.019 Hz 和 fixed-J 控制的 0.024 Hz, 说明 IPSO-RBF 控制具备低惯量的响应速度快的优势。上述分析说明, IPSO-RBF 控制通过灵活迅速的虚拟惯量阻尼自适应调整, 同时具备高惯量和低惯量在频率响应中的优势, 相比 RBF 控制和 fixed-J 控制具有更好的频率响应性能。

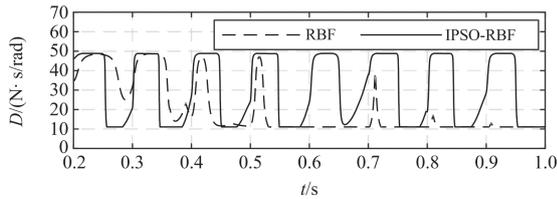
### 3.2 出力连续波动

设置仿真时长为 1 s, 初始状态 VSG 有功指令为 10 kW, 从 0.2 s 开始有功指令连续随机波动。

出力连续波动期间 IPSO-RBF 控制与 RBF 控制的自适应虚拟惯量、虚拟阻尼曲线如图 12 所示。可以看出, 在面对出力的连续波动时, RBF 控制时虚拟惯量、虚拟阻尼无法及时响应, 面对某些波动甚至无法进行虚拟惯量、虚拟阻尼的自适应调整, 惯量阻尼一直维持在极低水平。这是因为 RBF 控制存在着激活函数饱和的风险, 当发生较大出力波动时就会导致控制算法发生梯度消失现象以致算法不收敛。



(a) 虚拟惯量



(b) 虚拟阻尼

图 12 不同算法的虚拟惯量、虚拟阻尼曲线

Fig. 12 Virtual inertia and virtual damping curves for different algorithms

IPSO-RBF 控制在权值更新公式中引入了  $J$  惯性因子项, 使得虚拟惯量可以在波动后自动恢复到稳态惯量, 从而脱离激活函数饱和区域。另外, 通过改进 PSO 算法对神经网络超参数的优化配置, 不仅进一步抑制了梯度消失现象发生的可能, 还赋予了该控制算法出色的虚拟惯性阻尼自适应调节能力。因此, IPSO-RBF 控制在面对复杂的出力连续

波动工况时具备良好的控制性能和稳定性。

图 13、图 14、表 3 对比了 3 种控制方案在出力连续波动时的功率及频率响应性能。

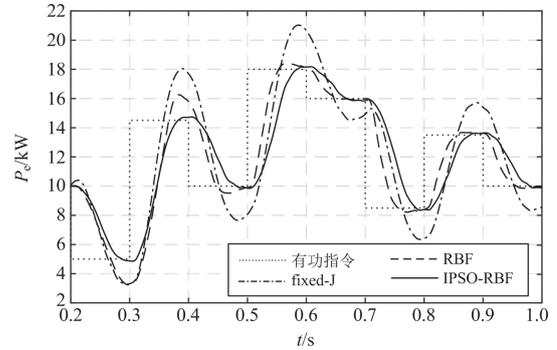


图 13 不同算法的功率曲线

Fig. 13 Power curves of different algorithms

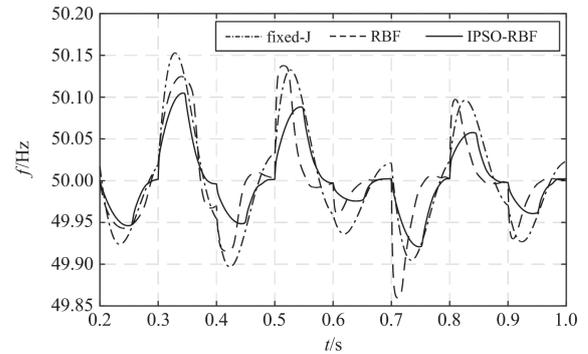


图 14 不同算法的频率曲线

Fig. 14 Frequency curves of different algorithms

表 3 不同算法频率性能指标

Table 3 Frequency performance indicators of different algorithms

组别	$f_{\text{MAE}}/\text{Hz}$	$\Delta f_{\text{max}}/\text{Hz}$	$f_{\text{RoCoF max}}/(\text{Hz/s})$
fixed-J	0.053	0.153	8.521
RBF	0.038	0.138	16.480
IPSO-RBF	0.031	0.105	6.305

由图 13、图 14 和表 3 可以得到以下结论:

1) 由图 13 可以直观看出: 在出力连续波动时, IPSO-RBF 控制和 RBF 控制相比 fixed-J 控制都能起到减小功率波动的作用, 相较于 RBF 控制, IPSO-RBF 控制的功率响应性能更为优越。

2) RBF 控制的频率绝对平均误差和最大频率偏差分别为 0.038 Hz 和 0.138 Hz, 相对 fixed-J 控制的 0.053 Hz 和 0.153 Hz 有较明显的改善, 但 RBF 控制的最大频率变化率为 16.480 Hz/s, 反而远高于 fixed-J 控制的 8.521 Hz/s。由图 14 还可以看出, RBF

控制在面对出力连续波动导致的每次频率波动(除初次波动外)时,在波动初始阶段都会有极大的频率变化率,这是因为 RBF 控制经历初次波动后惯量维持在极低水平,在面对后续波动时响应无法迅速恢复到惯量较高水平,导致波动初始阶段频率变化率过大。而 IPSO-RBF 控制面对出力连续波动时仍能灵活且迅速地进行虚拟惯量阻尼调节,使得三大频率性能指标都得到了有效改善,频率绝对平均误差、最大频率偏差、最大频率变化率分别为 0.031 Hz、0.105 Hz、6.305 Hz/s,相对 RBF 控制分别降低了 18.4%、23.9%、61.7%,相对 fixed-J 控制分别降低了 41.5%、31.4%、26.0%。

### 3.3 不同电网条件

3.1 节分析了所提自适应惯量阻尼控制策略在短路比(short circuit ratio, SCR)等于 15 的电网条件下的运行表现。为了进一步验证所提控制策略的有效性,设置了短路比  $K_{SCR} = 3$  和  $K_{SCR} = 35$  的电网条件进行试验,并设置初始状态 VSG 有功指令为 10 kW, 0.5 s 时有功指令突增到 20 kW。

图 15、图 16、表 4 和表 5 对比了 IPSO-RBF 控制、RBF 控制和 fixed-J 控制在不同电网条件下的功率及频率响应性能,可以得到以下结论:

1) 由图 15、表 4 可以看出,  $K_{SCR} = 3$  的弱电网

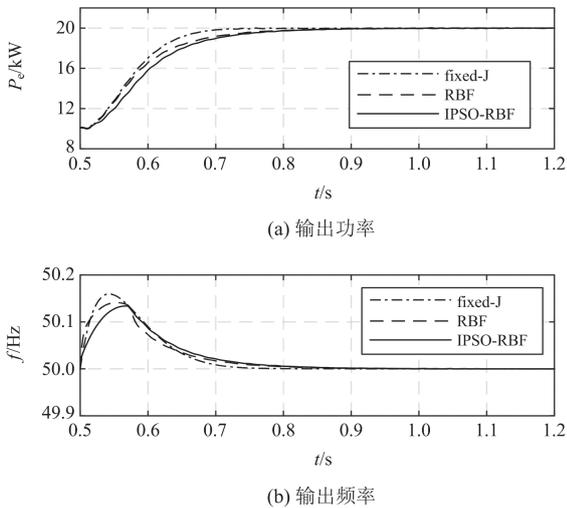


图 15  $K_{SCR} = 3$  时功率及频率曲线

Fig. 15 Power and frequency curves at  $K_{SCR} = 3$

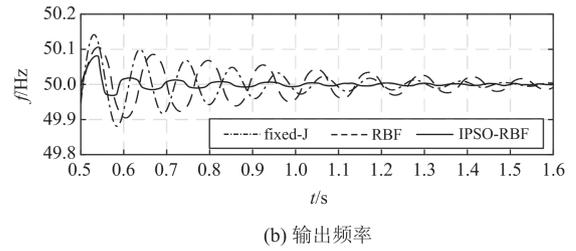
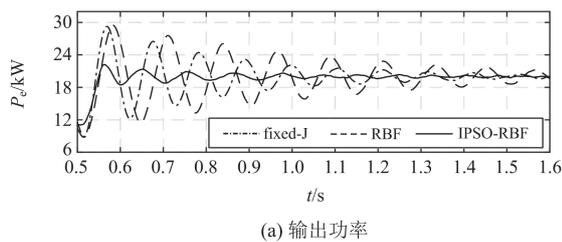


图 16  $K_{SCR} = 35$  时功率及频率曲线

Fig. 16 Power and frequency curves at  $K_{SCR} = 35$

表 4  $K_{SCR} = 3$  时性能指标

Table 4 Performance indicators at  $K_{SCR} = 3$

组别	$f_{MAE}/\text{Hz}$	$\Delta f_{\max}/\text{Hz}$	$f_{\text{RoCoF max}}/(\text{Hz/s})$	$\Delta P_{\max}/\text{kW}$	$t_s/\text{s}$
fixed-J	0.024	0.160	8.305	0.03	0.15
RBF	0.024	0.141	11.128	0.01	0.18
IPSO-RBF	0.024	0.134	6.185	0.01	0.20

表 5  $K_{SCR} = 35$  时性能指标

Table 5 Performance indicators at  $K_{SCR} = 35$

组别	$f_{MAE}/\text{Hz}$	$\Delta f_{\max}/\text{Hz}$	$f_{\text{RoCoF max}}/(\text{Hz/s})$	$\Delta P_{\max}/\text{kW}$	$t_s/\text{s}$
fixed-J	0.038	0.142	10.110	9.25	0.65
RBF	0.045	0.106	6.722	9.48	1.02
IPSO-RBF	0.011	0.081	4.260	2.21	0.22

条件下 VSG 控制稳定性较强,但受到扰动时表现出频率超调大、频率变化率高的特点。相比 RBF 控制和 fixed-J 控制, IPSO-RBF 控制最大频率偏差分别减小了 0.019 Hz 和 0.026 Hz,最大频率变化率分别降低了 4.943 Hz/s 和 2.120 Hz/s,有效抑制了弱电网条件下的出力突变扰动所导致的频率振荡。

2) 由图 16、表 5 可以看出,在  $K_{SCR} = 35$  的强电网条件下系统受到扰动时, VSG 控制表现出剧烈且持续的功率及频率振荡,而 IPSO-RBF 控制相比 RBF 控制和 fixed-J 控制,功率稳定时间分别减少了 0.80 s 和 0.43 s,证明 IPSO-RBF 控制能更快地抑制振荡并使系统恢复到稳定状态。

由上述结论可以得知,所提出的自适应惯量阻尼控制策略在弱电网和强电网条件下均能有效抑制 VSG 输出功率及频率振荡,为解决 VSG 控制在强、弱电网下的振荡问题提供了可靠的方案。

## 4 结论

本文针对现有的基于 RBF 神经网络的 VSG 自适应控制策略存在控制不够灵活且参数配置困难,难以对可再生能源出力连续波动下的功率、频率振荡进行有效抑制的问题,提出了一种基于改进 PSO 优化 RBF 神经网络的虚拟同步机自适应惯量阻尼控制策略,得到了如下结论:

1) 基于 VSG 小信号建模, 综合考量系统的惯性响应能力、系统稳定性及快速性, 确定了虚拟惯量、虚拟阻尼的取值范围并设定了 VSG 稳态惯量, 明确了自适应惯量阻尼控制的调节边界。

2) 与传统 PSO 和新型智能优化算法 SSA、CPO 进行对比, 证明所提改进 PSO 算法应用于本文的 RBF 神经网络超参数优化问题时不会陷入局部最优, 适应度收敛结果稳定且优于其他 3 种算法。

3) 与固定惯量控制和传统 RBF 控制进行对比, 验证了所提出的自适应惯量阻尼控制策略在出力突变、出力连续波动、不同电网条件 3 种典型工况下均具备更优的功率和频率动态响应性能。

所提出的自适应惯量阻尼控制策略能够对可再生能源出力连续波动下功率、频率振荡进行有效的抑制, 对促进可再生能源消纳、推动电力系统电力电子化具有参考意义。

#### 参考文献

- [1] 李军徽, 冯喜超, 严干贵, 等. 高风电渗透率下的电力系统调频研究综述[J]. 电力系统保护与控制, 2018, 46(2): 163-170.  
LI Junhui, FENG Xichao, YAN Gangui, et al. Survey on frequency regulation technology in high wind penetration power system[J]. Power System Protection and Control, 2018, 46(2): 163-170.
- [2] 孙华东, 王宝财, 李文锋, 等. 高比例电力电子电力系统频率响应的惯量体系研究[J]. 中国电机工程学报, 2020, 40(16): 5179-5191.  
SUN Huadong, WANG Baocai, LI Wenfeng, et al. Research on inertia system of frequency response for power system with high penetration electronics[J]. Proceedings of the CSEE, 2020, 40(16): 5179-5191.
- [3] 朱介北, 王云逸, 仲悟之, 等. 基于超级电容的新能源惯量-阻尼-电抗综合模拟控制方案[J]. 电力系统保护与控制, 2023, 51(19): 135-143.  
ZHU Jiebei, WANG Yunyi, ZHONG Wuzhi, et al. Composite inertia-damping-impedance emulation control scheme for renewable energy sources based on supercapacitor[J]. Power System Protection and Control, 2023, 51(19): 135-143.
- [4] 刘学成, 杨军, 申锦鹏, 等. 基于系统动力学模型的电力系统等效惯量时空演变趋势研究[J]. 全球能源互联网, 2024, 7(5): 579-590.  
LIU Xuecheng, YANG Jun, SHEN Jinpeng, et al. Analysis of spatiotemporal evolution trend of equivalent inertia in power system based on system dynamics model[J]. Journal of Global Energy Interconnection, 2024, 7(5): 579-590.
- [5] 李逸欣, 吴伟杰, 张伊宁, 等. 大规模新能源接入的电力系统惯量缺失机理及惯量水平评估[J]. 南方能源建设, 2024, 11(5): 132-139.  
LI Yixin, WU Weijie, ZHANG Yining, et al. Mechanism of inertia loss and evaluation of inertia level in power systems with large scale new energy access[J]. Southern Energy Construction, 2024, 11(5): 132-139.
- [6] 曹炜, 钦焕乘, 陆建忠, 等. 新型电力系统下虚拟同步机的定位和应用前景展望[J]. 电力系统自动化, 2023, 47(4): 190-207.  
CAO Wei, QIN Huancheng, LU Jianzhong, et al. Orientation and application prospect of virtual synchronous generator in new power system[J]. Automation of Electric Power Systems, 2023, 47(4): 190-207.
- [7] CHEEMA K M. A comprehensive review of virtual synchronous generator[EB/OL]. [2025-03-05]. <https://doi.org/10.1016/j.ijepes.2020.106006>
- [8] 孙佳航, 王小华, 黄景光, 等. 基于MPC-VSG的孤岛微电网频率和电压动态稳定控制策略[J]. 中国电力, 2023, 56(6): 51-60, 81.  
SUN Jiahang, WANG Xiaohua, HUANG Jingguang, et al. MPC-VSG based control strategy for dynamic stability of frequency and voltage in islanded microgrid[J]. Electric Power, 2023, 56(6): 51-60, 81.
- [9] 白文远, 庄国峰, 罗雪梅, 等. 基于动态阻尼增强的VSG并联系统功率振荡抑制方法[J]. 智慧电力, 2024, 52(11): 16-22, 113.  
BAI Wenyuan, ZHUANG Guofeng, LUO Xuemei, et al. Power oscillation suppression method for VSG parallel system based on dynamic damping enhancement[J]. Smart Power, 2024, 52(11): 16-22, 113.
- [10] 李雪萍, 王自力, 陈燕东, 等. 基于虚拟惯量模糊自适应的新能源逆变器频率主动支撑策略[J]. 电力系统保护与控制, 2024, 52(20): 25-37.  
LI Xueping, WANG Zili, CHEN Yandong, et al. Active frequency support strategy for new energy inverters based on virtual inertia fuzzy adaptive control[J]. Power System Protection and Control, 2024, 52(20): 25-37.
- [11] LI Jin, WEN Buying, WANG Huaiyuan. Adaptive virtual inertia control strategy of VSG for micro-grid based on improved bang-bang control strategy[J]. IEEE Access, 2019, 7: 39509-39514.
- [12] ELWAKIL M M, ZOGHABY H M E, SHARAF S M, et al. Adaptive virtual synchronous generator control using optimized bang-bang for islanded microgrid stability improvement[EB/OL]. [2025-03-05]. <https://doi.org/10.1186/s41601-023-00333-7>

- [13] MIR A S, SENROY N. Self-tuning neural predictive control scheme for ultrabattery to emulate a virtual synchronous machine in autonomous power systems[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(1): 136-147.
- [14] LIU Peng, BI Yuxuan, LIU Chong. Data-based intelligent frequency control of VSG via adaptive virtual inertia emulation[J]. IEEE Systems Journal, 2022, 16(3): 3917-3926.
- [15] 杨旭红, 姚凤军, 郝鹏飞, 等. 基于改进型RBF神经网络的VSG转动惯量自适应控制[J]. 电测与仪表, 2021, 58(2): 112-117.  
YANG Xuhong, YAO Fengjun, HAO Pengfei, et al. Adaptive inertia control for VSG based on improved RBF neural network[J]. Electrical Measurement & Instrumentation, 2021, 58(2): 112-117.
- [16] YAO Fengjun, ZHAO Jinbin, LI Xiangjun, et al. RBF neural network based virtual synchronous generator control with improved frequency stability[J]. IEEE Transactions on Industrial Informatics, 2021, 17(6): 4014-4024.
- [17] MENTESIDI K, GARDE R, AGUADO M, et al. Implementation of a fuzzy logic controller for virtual inertia emulation[C] // 2015 International Symposium on Smart Electric Distribution Systems and Technologies (EDST), September 8-11, 2015, Vienna, Austria: 606-611.
- [18] OSHEBA D S M, OSHEBA S M, NAZIH A, et al. Performance enhancement of PV system using VSG with ANFIS controller[J]. Electrical Engineering, 2023, 105(5): 2523-2537.
- [19] 张赞宁, 郭钟仁, 张磊. 基于RBF神经网络的分数阶虚拟同步机控制策略[J/OL]. 电力系统及其自动化学报: 1-7[2025-01-17]. <https://doi.org/10.19635/j.cnki.csu-epsa.001536>  
ZHANG Yunning, GUO Zhongren, ZHANG Lei. Fractional-order virtual synchronous generator control strategy based on RBF neural networks[J/OL]. Proceedings of the CSU-EPSA: 1-7[2025-01-17]. <https://doi.org/10.19635/j.cnki.csu-epsa.001536>
- [20] 张子星, 赵晋斌, 曾志伟, 等. 基于RBF的VSG虚拟惯量和动态阻尼补偿自适应控制[J]. 电力系统保护与控制, 2024, 52(2): 155-164.  
ZHANG Zixing, ZHAO Jinbin, ZENG Zhiwei, et al. VSG virtual inertia and dynamic damping compensation adaptive control based on RBF[J]. Power System Protection and Control, 2024, 52(2): 155-164.
- [21] PAN Hui, WANG Ling, LIU Bo. Particle swarm optimization for function optimization in noisy environment[J]. Applied Mathematics and Computation, 2006, 181(2): 908-919.
- [22] ABABNEH J I, BATAINEH M H. Linear phase FIR filter design using particle swarm optimization and genetic algorithms[J]. Digital Signal Processing, 2008, 18(4): 657-668.
- [23] JORDEHI A R. Enhanced leader PSO (ELPSO): a new PSO variant for solving global optimisation problems[J]. Applied Soft Computing, 2015, 26: 401-417.
- [24] CHEN Junru, O'DONNELL T. Parameter constraints for virtual synchronous generator considering stability[J]. IEEE Transactions on Power Systems, 2019, 34(3): 2479-2481.
- [25] 陈杰, 程静, 王维庆, 等. 应用多参数协同自适应方法的虚拟同步发电机控制策略[J]. 电力系统保护与控制, 2024, 52(23): 74-85.  
CHEN Jie, CHENG Jing, WANG Weiqing, et al. Control strategy for a virtual synchronous generator using a multi-parameter cooperative adaptive method[J]. Power System Protection and Control, 2024, 52(23): 74-85.
- [26] ZHAO Qiang, LI Changwei, ZHU Dong, et al. Coverage optimization of wireless sensor networks using combinations of PSO and chaos optimization[J]. Electronics, 2022, 11(6).
- [27] COELHO L D S, LEE C. Solving economic load dispatch problems in power systems using chaotic and Gaussian particle swarm optimization approaches[J]. International Journal of Electrical Power & Energy Systems, 2008, 30(5): 297-307.
- [28] XUE Jiankai, SHEN Bo. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [29] ABDEL-BASSET M, MOHAMED R, ABOUHAUWASH M. Crested porcupine optimizer: a new nature-inspired metaheuristic[EB/OL]. [2025-03-05]. <https://doi.org/10.1016/j.knosys.2023.111257>

收稿日期: 2025-01-20; 修回日期: 2025-06-04

作者简介:

梁展豪(2001—), 男, 博士研究生, 研究方向为新能源系统并网控制; E-mail: 202311082974@mail.scut.edu.cn

曾君(1979—), 女, 博士, 教授, 研究方向为微电网能量管理、功率变换及电力电子装置以及可再生能源发电系统; E-mail: junzeng@scut.edu.cn

刘俊峰(1978—), 男, 博士, 教授, 研究方向为分布式发电系统中的控制与电力电子技术、综合能源网络中的协调控制与优化。E-mail: aujfliu@scut.edu.cn

(编辑 魏小丽)