DOI: 10.7641/CTA.2017.70239

# 基于深度自适应动态规划的 孤岛主动配电网发电控制与优化一体化算法

殷林飞1,余 涛1<sup>†</sup>,张泽宇<sup>2</sup>,张孝顺<sup>1</sup>

(1. 华南理工大学 电力学院,广东 广州 510640; 2. 中国电建集团 中南勘测设计研究院有限公司,湖南 长沙 410014)

**摘要**:随着多种分布式新能源的并网,如风电与光伏发电、生物质能发电、储能与电动汽车等,传统情况下孤岛 配电网的发电控制方法已很难达到高品质频率稳定控制的要求.为解决此问题,本文提出了一种新颖的深度自适 应动态规划算法.该算法将自适应动态规划算法中的神经网络替换为机器学习领域中的深度神经网络,并在其中 添加深度模型预测网络.所提算法能一次性完成传统模式下"发电控制算法+指令优化分配算法"共同完成的工 作.最后,为验证深度自适应动态规划算法的鲁棒性,设计了多种配电网的仿真实验,即正常情况、"即插即用"启 停机情况、通讯故障情况、全天扰动仿真情况、变拓扑结构的孤岛配网情况和变参数模型的仿真,设置的总仿真时 长达25年.仿真结果验证了所设计的深度自适应动态规划算法有效性、可行性与强鲁棒性.

关键词: 主动配电网; 发电控制; 优化控制; 深度学习; 自适应动态规划

**引用格式**: 殷林飞, 余涛, 张泽宇, 等. 基于深度自适应动态规划的孤岛主动配电网发电控制与优化一体化算法. 控制理论与应用, 2018, 35(2): 169 – 183

中图分类号: TM734 文献标识码: A

## Deep adaptive dynamic programming based integration algorithm for generation control and optimization of islanded active distribution network

YIN Lin-fei<sup>1</sup>, YU Tao<sup>1†</sup>, ZHANG Ze-yu<sup>2</sup>, ZHANG Xiao-shun<sup>1</sup>

School of Electric Power, South China University of Technology, Guangzhou Guangdong 510640, China;
 Power China Zhongnan Engineering Co Ltd, Changsha Hunan 410014, China)

**Abstract:** With the development of many distributed generations (DGs) (e.g. wind power and photovoltaic power, biomass energy, energy storage device and plug in hybrid electric vehicle (PHEV)), the traditional methods for generation control of isolated island power grids cannot meet the requirements of frequency stability. This paper proposes deep adaptive dynamic programming (DADP) algorithm to solve this problem. Replacing neural network (NN) in adaptive dynamic programming (ADP) algorithm by the deep neural network (DNN) in the field of machine learning (ML), and adding deep model forecast neural network in, the proposed DADP algorithm is designed. Generation commands, which are achieved by the algorithms of both generation control and generation command dispatch in the traditional way, are obtained by the proposed DADP algorithm. Finally, to verify the robustness of the proposed DADP algorithm, many simulations for isolated island micro-gird are simulated, for instance, the normal isolated island situation, plug and play situation, communication failure situation, all-day disturbance situation, time-varying topology situation and systemic internal parameters varying situation, and the duration of all these simulations is configured as long as 25 years. The effectiveness, feasibility and strong robustness of the proposed DADP algorithm are verified by the simulation results.

**Key words:** active distribution network; generation control; optimization control; deep learning; adaptive dynamic programming (ADP)

**Citation:** YIN Linfei, YU Tao, ZHANG Zeyu, et al. Deep adaptive dynamic programming based integration algorithm for generation control and optimization of islanded active distribution network. *Control Theory & Applications*, 2018, 35(2): 169 – 183

收稿日期: 2017-04-10; 录用日期: 2017-09-08.

<sup>&</sup>lt;sup>†</sup>通讯作者. E-mail: taoyu1@scut.edu.cn; Tel.: +86 13002088518.

本文责任编委: 邹云.

国家自然科学基金项目(51177051, 51477055), 国家重点基础研究 "973" 项目(2013CB228205)资助.

Supported by the National Natural Science Foundation of China (51177051, 51477055) and the National Key Basic Research Program of China ("973" Program) (2013CB228205).

#### 1 引言(Introduction)

随着人类对可再生新能源利用率的不断提高,分 布式电源(distributed generation, DG)<sup>[1]</sup>如小水电、风 电 (wind power)<sup>[2]</sup>、光伏发电 (photovoltaic power, PV)<sup>[3]</sup>、生物质发电及电动汽车(plug in hybrid electric vehicle, PHEV)<sup>[4]</sup>不断接入配电网, 配电网的供电方 式已经开始发生逆转,从主网被动受电的配电网已经 逐步过渡为主动供电配电网, 配电网在分布式电源支 撑下独立运行的能力不断变强[5]. 一方面, 电网可接 入分布式电源的多元化及间歇性新能源随机性的变 大导致配电网电能质量控制的难度变大[6]. 而另一方 面,智能主动配电网的发展要求配电网在输电网发生 严重故障时,能主动解列为孤岛小配电网自律稳定运 行[7]. 近年来, 如何有效地提升含多种新能源的孤岛 配网稳定控制的水平已成为国内外电力工作者关心 的一个技术难题[8]. 而且针对各种微电源稳定运行, 更需电力电子装置的支持[9-11].

而孤岛配电网的稳定主要包含电压稳定、功角稳定和频率稳定<sup>[12]</sup>.其中控制频率稳定的主要目的有: 1)维持电网发电有功功率与负荷功率的实时平衡;2)维持电网频率在规定范围内(如配电网频率偏差不超过±0.2 Hz).为控制电网的有功功率的平衡和电网频率的稳定,一般根据电网对负荷的不同时间尺度的预测值由时间尺度长的算法(如机组组合(unit commitment, UC)和经济调度(economic dispatch, ED)对机组发电功率做出预控制<sup>[13]</sup>.再通过时间尺度较短的自动发电控制(automatic generation control, AGC)和发电功率分配 (generation command dispatch, GCD)组合控制,以期减小频率偏差且平衡有功功率.

针对多种新能源组成的微网(micro-grid, MG)中 的二次调频(secondary frequency regulation, SFR)问 题,目前国内外学者研究的算法一般可分为两类.一 类为AGC控制算法,如传统的PID算法<sup>[14-15]</sup>、滑模控 制算法(sliding mode control, SMC)<sup>[16]</sup>、自抗扰控制 算法(active disturbance rejection control, ADRC)<sup>[17]</sup>、 分数阶PID算法(fractional order PID, FOPID)<sup>[18]</sup>、模 糊控制(fuzzy)<sup>[15]</sup>、强化学习系列的Q学习算 法<sup>[19-21]</sup>、Q(λ)学习算法<sup>[22]</sup>、R(λ)学习<sup>[23]</sup>等,此类算 法一般将整个微网作为单区域进行计算发电指令,再 由固定比例(proportional)分配给各可控的微电源.另 一类算法为GCD优化算法,如经典的遗传算法(genetic algorithm, GA)、二次规划 (quadratic)、灰狼算法 (gray wolf optimizer, GWO)<sup>[23-25]</sup>、固定比例算法、粒 子群算法(particle swarm optimization, PSO)<sup>[26]</sup>、飞蛾 扑火算法(moth-flame optimization, MFO)<sup>[27]</sup>、鲸鱼优 化算法(whale optimization algorithm, WOA)<sup>[28]</sup>、蚁狮 算法(ant lion optimizer, ALO)<sup>[29]</sup>、蜻蜓算法(dragonfly algorithm, DA)<sup>[30]</sup>、群搜索算法 (group search optimizer, GSO)<sup>[31]</sup>、鸡群搜索算法(chicken swarm optimization, CSO)<sup>[32]</sup>、正弦余弦算法(sine cosine algorithm, SCA)<sup>[33]</sup>等<sup>[34-36]</sup>,此类算法一般采用经典的PID控制 算法作为发电控制指令算法,然后采用此类优化算法 将发电指令分配到各微电源,且一般以发电成本最小 为目标.此两类算法有一定的优点,如控制算法与优 化算法进行分开,可分别进行设计不同的算法,但也 存在两算法如何配合使用的问题,其中的控制算法以 控制频率偏差最小为控制目标,而优化分配算法以发 电成本最小为优化目标,此两者结合的效果会使频率 偏差变大且发电成本变大,从而导致发电控制的性能 较差,会因算法的精度提高而导致实际计算时间超过 发电指令允许的最长时间.

针对上述发电控制算法与优化分配算法结合使用的缺点,本文设计了一种"一体式"的控制算法.该算法能一次性输出多个微电源的发电指令,从而兼顾频率偏差和发电成本的目标.此算法依托自适应动态规划算法(adaptive dynamic programming, ADP)为框架,将其中的两个神经网络(neural network, NN)替换为深度神经网络(deep neural network, DNN),且添加深度模型预测网络,从而命名为:深度自适应动态规划算法(deep adaptive dynamic programming, DADP).所提DADP算法中的框架为ADP算法,ADP算法的在线更新能力强,能较好地应对各种随机的外部扰动带来的影响<sup>[37-38]</sup>.且所提DADP算法中存在3个深度学习的网络<sup>[39-41]</sup>,提升了原本ADP算法的学习与对系统的预测能力.因深度神经网络的加入,所提DADP算法具有以下优点:

 与已有的强化学习系列算法相比(文献[19-21] 中的强化学习系列算法预训练时间从10000s到 40000s不等),所需预学习时间(即离线训练时间)较 短(只需9600s);

2) 与己有的功率优化分配算法相比(如PSO算法 某次其实际计算时间超过80 s), 在使用过程中所需实 际计算时间短(小于0.2 s), 避免了实际计算时间超出 所允许的指令周期的问题(指令周期时间为4 s);

3) 避免了因控制算法与优化算法配合使用从而 导致的性能较差的问题,能"一体式"输出各机组的 发电功率指令;

4) 通过大规模复杂变参数的仿真验证, 与其他多种算法相比, 所提DADP算法具有强鲁棒性.

为验证所提算法的鲁棒性,设计了复杂的大规模 仿真实验,如孤岛配电网的正常情况仿真、"即插即 用"启停机仿真、通讯故障仿真、全天候扰动仿真、时 变拓扑结构的仿真与系统内部参数的仿真,且将ADP 算法和DADP算法与156种传统"发电控制算法与发 电指令优化分配算法"结合的算法进行对比,仿真时 设定的总仿真时长为25.155年.

# 2 孤岛配电网模型(Model of islanded active distribution network)

分3个部分来分析孤岛配电网的模型,即其结构、 发电控制模型和发电指令分配优化模型.

#### 孤岛配电网的结构和AGC模型(Structure 2.1 and AGC models of islanded active distribution network (ADN))

本文的基本AGC模型采用文[35]的模型,该模型 既包含多种中小型分布式能源(如小水电、风电、生物 质能等),又包含几种较典型的微网结构(如柴油-风、 微燃-光伏、燃料电池-光伏等组合类型)的智能配电 网信息物理模型,如图1所示.图中小水电机组、柴油 发电机、燃料电池、生物质能发电机组、微型燃气轮 机和飞轮储能等各机组的相关参数如表1和表2所示.



图 1 智能配电网信息物理模型图 Fig. 1 Cyber-physical model of smart distribution grid

表1 AGC机组相关参数 Table 1 Parameters of AGC units

区博	机组	$\Delta P_{\mathrm{G}i}^{\mathrm{max}}$	$\Delta P_{\mathrm{G}i}^{\mathrm{min}}$	$a_i$ /	$b_i$ /	$c_i$ /
	1/ ⊌≈⊥⊥	/kW	/kW	$(\${\cdot}h^{-1})$	$(\${\cdot}h^{-1})$	$(\cdot h^{-1})$
配电网	H1	250	-250	0.0001	0.0346	8.5957
配电网	H2	150	-150	0.0001	0.0335	8.0643
配电网	H3	150	-150	0.0001	0.0335	8.0643
配电网	H4	100	-100	0.0001	0.0314	7.6248
配电网	H5	100	-100	0.0001	0.0314	7.6248
配电网	BE6	200	-200	0.0004	0.0656	8.7657
配电网	BE7	200	-200	0.0004	0.0656	8.7657
微网1	MT8	100	-100	0.0002	0.1088	5.2164
微网1	MT9	100	-100	0.0002	0.1088	5.2164
微网1	MT10	150	-150	0.0002	0.1164	5.4976
微网1	MT11	150	-150	0.0002	0.1164	5.4976
微网2	MT12	150	-150	0.0002	0.1164	5.4976
微网2	MT13	150	-150	0.0002	0.1164	5.4976
微网2	FC14	150	-150	0.0003	0.1189	3.5442
微网2	FC15	150	-150	0.0003	0.1189	3.5442
微网3	DS16	120	-120	0.0004	0.2348	10.9952
微网3	DS17	120	-120	0.0004	0.2348	10.9952
微网3	DS18	120	-120	0.0004	0.2348	10.9952
微网3	DS19	120	-120	0.0004	0.2348	10.9952

	表	2	各机组参数取值表
--	---	---	----------

	Table 2 Para	meters of units	
参数	机组	含义	取值
$T_{\rm P}$	小水电机组	辅助阀和伺服 电动机时间常数	0.05 s
$K_{\rm g}$	小水电机组	伺服增益	5
$T_{\rm G}$	小水电机组	主伺服时间常数	0.2 s
$R_{\rm P}$	小水电机组	永久下降率	0.04
$R_{\mathrm{T}}$	小水电机组	暂时下降率	0.4
$T_{\rm R}$	小水电机组	复位时间	5.0 s
$F_{\rm HP}$	微型燃气轮机	HP级占HP, IP和 LP级功率部分	0.3
$T_{\rm RH}$	微型燃气轮机	再热器的时间常数	6.0 s
$T_{\mathrm{M}}$	微型燃气轮机发动机	机械启动时间常数	12 s
$T_{\rm f1}$	燃料电池	反应时间常数1	9.205 s
$T_{\rm f2}$	燃料电池	反应时间常数2	10.056 s
$T_{\rm bt}$	生物质能发电机	汽轮机时间常数	0.08 s
$T_{\rm bg}$	生物质能发电机	发电机时间常数	10 s
$T_{\rm br}$	生物质能发电机	调速器时间常数	0.3 s
$T_{\rm dt}$	柴油发电机汽轮机	时间常数	0.025 s
$T_{\rm dg}$	柴油发电机	发电机时间常数	8 s
$T_{\rm dr}$	柴油发电机	调速器时间常数	3 s
$K_{\rm f}$	飞轮储能	飞轮常数	0.003333

此外,考虑到AGC调节过程中,光伏发电与风电均 不参与调频,可将其模型进行简化,并以扰动负负荷 的形式并入系统.通过模拟全天光照强度的变化,模 拟光伏出力模型;而风电模型则采用有限带宽白噪声 模拟的随机风作为风电出力(假定切入风速为3 m/s, 切除风速为20 m/s,额定风速为11 m/s),其发电功率 曲线如图2所示.而典型的负荷扰动功率曲线如图3所 示.



图 2 风电与光伏发电功率曲线







### 2.2 孤岛配电网的GCD优化模型(GCD optimiza-

tion models of islanded active distribution network)

当已计算出AGC的发电指令时,需要将发电指令 分配给孤岛电网中的每个发电机组,而目前实际分配 过程是按照机组额定总功率的比例进行分配.实际上, 按一定比例分配功率指令,不一定是最优(发电成本最 小)的效果,此时,可采用优化分配算法进行优化分配 结果,一般GCD可以按照经济调度常用的发电成本来 进行优化,其发电成本为

$$C_i(P_{G_i}) = a_i P_{G_i}^2 + b_i P_{G_i} + c_i,$$
(1)

式中:  $P_{G_i}$ 表示第i台机组的出力;  $C_i(\cdot)$ 表示第i台机组的发电成本;  $a_i, b_i, c_i$ 分别表示第i台机组发电成本的各次系数. 即此函数为功率分配优化算法的目标函数.

因此,AGC功率分配后各台机组的发电成本将变为

$$C_i(P_{\mathrm{G}i,\mathrm{actual}}) = C_i(P_{\mathrm{G}i,\mathrm{plan}} + \Delta P_{\mathrm{G}i}) = \alpha_i \Delta P_{\mathrm{G}i}^2 + \beta_i \Delta P_{\mathrm{G}i} + \gamma_i,$$
(2)

式中:  $P_{Gi,actual}$ 为第i台机组的实际发电功率;  $P_{Gi,plan}$ 为第i台机组的计划发电功率;  $\Delta P_{Gi}$ 为第i台 机组的AGC调节功率;  $\alpha_i$ ,  $\beta_i$ ,  $\gamma_i$ 分别为考虑发生功率 扰动后第i台机组发电成本的各次动态系数, 其中

$$\begin{cases} \alpha_i = a_i, \\ \beta_i = 2a_i P_{\mathrm{G}i,\mathrm{plan}} + b_i, \\ \gamma_i = a_i P_{\mathrm{G}i,\mathrm{plan}}^2 + b_i P_{\mathrm{G}i,\mathrm{plan}} + c_i. \end{cases}$$
(3)

如系统有n台AGC机组,其GCD的优化目标函数可描述为

$$\min C_{\text{total}} = \sum_{i=1}^{n} (\alpha_i \Delta P_{\text{G}i}^2 + \beta_i \Delta P_{\text{G}i} + \gamma_i),$$
  
s.t. 
$$\begin{cases} \Delta P_{\Sigma} - \sum_{i=1}^{n} \Delta P_{\text{G}i} = 0, \\ \Delta P_{\text{G}i}^{\min} \leqslant \Delta P_{\text{G}i} \leqslant \Delta P_{\text{G}i}, \end{cases}$$
(4)

式中:  $C_{\text{total}}$ 表示发电实际总成本,本文把 $C_{\text{total}}$ 取为 AGC功率分配的目标函数;  $\Delta P_{\Sigma}$ 表示AGC跟踪的总 功率指令;  $\Delta P_{G_i}^{\min}$ 和 $\Delta P_{G_i}^{\max}$ 分别表示机组i的最小和 最大可调容量.

# **3** 深度自适应动态规划算法(Deep adaptive dynamic programming)

### 3.1 DADP的结构(Structure of DADP)

DADP算法由ADP算法改进而来,并作为同时考虑"发电控制与功率分配优化"的智能发电控制算法. ADP的结构示意图如图4所示. 其中, ADP为控制和优化算法部分,在图中的智能体里面发挥着控制和优化的作用. 而ADP智能体又包含评价网络和执行网络, 其控制框图类似于强化学习.







ADP一般可通过两个神经网络对执行函数和评价 函数逼近,执行函数将为获得最大的奖励而选择对应 的输出.其ADP算法中的两个网络在处理相对简单的 问题时,也可用函数逼近的方式实现.采用函数逼近 的方式实现时,与强化学习经典算法-Q学习极其相 似,而采用神经网络实现时,其收敛速度快于Q学习的 收敛速度,其加速收敛的过程如图5所示.但在处理相 对较为复杂的非线性最小相位的问题时,利用普通神 经网络不能完全胜任,因此,本文应采用深度学习对 其改进.



第2期



所设计的深度自适应动态规划算法,采用ADP算 法作为框架,添加深度模型预测网络,并将ADP算法 中的神经网络替换为深度神经网络.所设计DADP算 法结构如图6所示.列出图6中3个网络的输入与输出 如表3所示.





传统ADP算法,能随着系统的变化而动态更新策略,但依赖于系统的变化而学习,对系统的主动认知不够.深度模型预测网络的加入,增强了对系统的预测能力,且在线不断更新学习的结果,能对系统的长

期的与短期的变化进行学习,提高对系统的认知能力, 使得其对系统的控制效果得到了提升.

表	3	3个深度	と网络1	的输入	、输出表
---	---	------	------	-----	------

Table 3	Inputs and	outputs	of deep	neural	networks
14010 0	inparts and	o arep ares	01 <b>60</b> 00		

输入	输出
动作集、状态	下一时刻状态
下一时刻状态	评价值
评价值、动作集、状态	动作输出
	输入 动作集、状态 下一时刻状态 评价值、动作集、状态

#### 3.2 DADP中的深度神经网络(DNNs of DADP)

深度神经网络DNN采用深层次的神经网络作为基础,将多个受限波尔兹曼机(restricted Boltzmann machine, RBM)堆叠,在训练DNN时,采用无监督的逐层贪心训练方法(逐层进行训练).在离线训练完成之后,可采用有监督的学习对网络进行边训练边利用.在假定所有可见和隐含单元均为二值变量(只能取0或1).即 $i, j, v_i, h_j \in \{0, 1\}$ .基于能量定义的RBM系统的能量定义为

$$E(\boldsymbol{v}, \boldsymbol{h}|\boldsymbol{\theta}) = -\sum_{i=1}^{n} a_{i}v_{i} - \sum_{j=1}^{m} b_{j}h_{j} - \sum_{i=1}^{n} \sum_{j=1}^{m} v_{i}W_{ij}h_{j}, \quad (5)$$

式中: *W<sub>ij</sub>*为链接权重, *a<sub>i</sub>*, *b<sub>j</sub>*分别为可见元*i*和隐元*j* 的偏置. 此时的(*v*, *h*)的联合概率分布为

$$P(\boldsymbol{v}, \boldsymbol{h} | \boldsymbol{\theta}) = \frac{e^{-E(\boldsymbol{v}, \boldsymbol{h} | \boldsymbol{\theta})}}{Z(\boldsymbol{\theta})}, \qquad (6)$$

式中归一化因子(配分函数)为 $Z(\theta) = \sum_{v,h} e^{-E(v,h|\theta)}$ .

RBM的层间有连接层内无连接的结构决定了各个隐元的激活条件是独立的.其激活概率为

$$P(h_j = 1 | \boldsymbol{v}, \boldsymbol{\theta}) = \sigma(b_j + \sum_i v_i W_{ij}), \qquad (7)$$

式中sigmoid激活函数为 $\sigma(x) = \frac{1}{1 + e^{-x}}$ . 各个可见元的激活概率为

$$P(v_i = 1 | \boldsymbol{h}, \boldsymbol{\theta}) = \sigma(a_i + \sum_j h_j W_{ij}).$$
(8)

动作的概率转换为

$$a = \begin{cases} k_{\rm p} \ln(2p), & p < 0.5, \\ -k_{\rm p} \ln[2(1-p)], & p \ge 0.5, \end{cases}$$
(9)

式中kp为动作概率因子,而概率的状态转换为

$$p = \begin{cases} e^{\frac{s}{2k_s}}, & s < 0, \\ 1 - e^{-\frac{s}{2k_s}}, & s \ge 0, \end{cases}$$
(10)

式中ks为概率的状态转换因子.

# **3.3** 训练方法与样本获取 (Training methods and sample acquisition)

对于深度自适应动态规划算法而言,初始情况下, 深度神经网络几乎无预测能力,因此,训练的样本对 于DADP算法至关重要.为获取具有正确的引导作用的动作指令, 需选择控制和优化效果较好的算法获取 样本.进行离线训练时, 深度神经网络需一层一层进 行训练, 之后在线运行时, 可将新的数据作为样本进 行在线微调训练.

针对发电控制问题,若采用控制算法与功率分配

优化算法进行控制与优化,并将控制算法产生的指令 进行成比例的缩放,从而获取不同功率指令下机组分 配的情况,且将其分配的结果输入各个机组,进而得 到"下一时刻"的系统的状态,即下一时刻的频率偏 差,得到的数据均可作为样本,特别是深度模型预测 网络的样本,其过程如图7所示.



图 7 样本产生示意图

Fig. 7 Diagram of sample generation

离线训练时,选择控制效果较优的算法的数据进行"预学习".投入运行的基于DADP算法设计的控制器以在线信息作为数据,不断地更新学习,对系统的预测与控制能力将不断提升,避免了组合式算法因组合而耦合度不高导致控制性能差的问题.

#### 3.4 设计基于DADP算法的微网控制器(Controller for ADN based on DADP)

设计基于DADP算法的孤岛智能配电网智能发电控制器的执行流程如图8所示.



图 8 基于DADP算法的微网控制器

Fig. 8 Islanded smart distribution grid controller based on DADP algorithm

从图8中可以看出,产生动作指令的模块所产生的 动作为矩阵,不同于强化学习中的动作集,动作集是 动作向量,而此时为的矩阵,其中为机组数,是为每个 机组产生的指令数.此处的可进行拓展,即对其他算 法仿真结果的数据的动作进行拓展,以一定比例对动 作进行拓展,以增加深度模型预测神经网络对系统本 身的认知,提高所提算法对系统的预测能力.依据对 模型的预测和对预测出的状态的评价,选择评价值高 的评价值对应的动作作为输出.

### 4 算例仿真(Simulations)

所有算例均在CPU为i7-2760QM@2.40 GHz内存 为16 GB系统为Windows 10 Enterprise 64位的笔记本 上运行,所用软件版本为MATLAB R2016b,以下算例 中算法的实际计算时间均以此配置的笔记本为准.所 有算例中的传统"组合式"算法实际计算时间的统 计均为优化算法实际计算时间的统计,不计控制算法 的实际计算时间("组合式"算法的控制算法实际计 算时间远小于其优化算法的实际计算时间,可忽略不 计),而ADP算法和所提DADP算法的实际计算时间是 一体的实际计算时间,相当于"控制算法+优化算 法"时间的总和.

#### 4.1 仿真算法(Algorithms for simulations)

所有算例均以图1所示的孤岛智能配电网模型为基础,包含一个配电网和3个微网,可调机组19台,总可调容量2760 kW,不可调机组看作负负荷扰动处理.

本文所仿真的算法与仿真对象表如表4所示.

	14010	Bonnan	is and sojeen (es
_	ADP算法, A	DDP算法	仿真对象与仿真时
	控制算法	优化分配算法	设置的仿真时长/s
	固定参数PID	CCC	无故障的基本仿真,1200
	固定参数SMC	二次规划	即插即用启停机, 2400
Ī	固定参数–ADRC	GA	通讯故障, 3600
Ē	固定参数FOPID	GWO	全天扰动仿真,86400
	自适应PID	固定比例	变拓扑结构仿真, 12000
	自适应-SMC	PSO	变参数模型仿真, 1200×(4 <sup>6</sup> )
	自适应–ADRC	MFO	
	自适应FOPID	WOA	
	Fuzzy	ALO	
	Q学习	DA	
	$Q(\lambda)$ 学习	GSO	
	$R(\lambda)$ 学习	CSO	
	· · · ·	SCA	

;	表 4	昇法与	对象	.衣	
Table 4	Alg	orithms	and	obiec	tives

表4中 "CCC" 为作者在文[35,42]中提出的一致 性协同控制算法 (collaborative consensus control, CCC). 此CCC优化算法属于分布式算法, 当发电控制 算法与CCC算法进行组合式控制时, 该CCC算法所用 的分布式通讯情况如图1中的蓝色虚线所示. 而本文 其他组合式算法、ADP算法和所提DADP算法均在集 中式通讯下完成.

表4"控制算法"一列中的"自适应-PID"是指变参数的PID算法,与固定参数的PID算法相对;"自适应-SMC"是指变参数的SMC算法;该列中其他"自适应"亦然.

从表4可以看出,由"发电控制算法+优化分配算法"共同完成"控制优化"的算法有12×13=156种,与ADP算法和所提DADP算法共158种"控制优化" 算法.从"仿真对象与仿真时设置的仿真时长"一列中可以看出共建立6种仿真对象、每种仿真对象在仿 真时设置的仿真时长不尽相同,特别是系统内部参数 发生变化的情况下,每种算法在仿真时设置的仿 真时长为56.89天.每种算法均在这6个仿真对象中进 行仿真,因此,所有算法在所有仿真对象中设置的总 仿真时长为((12×13+2)×(1200+2400+3600+ 86400+12000+1200×(4<sup>6</sup>)))/(365×24×3600)s, 即 25.155年(每年按365天计算,在Simulink仿真中 设定的仿真时长).所有算例在PC机上开启12个窗口 并行运行,计算机实际所需计算时间共45天,共产生 166 GB的数据文件.

所提DADP算法中的深度模型预测网络、深度评价网络和深度执行网络均为6层每层20个神经元的深度网络(经过多次测试仿真对比,发现此层数和神经元参数较优),离线训练的次数为1000次.

所需离线训练的实际计算时间为9600 s, 而文 [19-21]中强化学习系列算法所需离线训练的计算时 间(在文献中被称为"预训练"时间)为10000 s 到 40000 s不等.以下章节中比较的是在线运行的实际计 算时间.仿真结果中"PSO"算法一栏对应的"实际 计算时间均值(s)"一列中的0.4302 s, 是功率分配算 法为PSO算法情况下的实际计算时间的平均值.

以下章节为各仿真对象的仿真结果展示.

#### 4.2 无故障的基本仿真(Basic situation)

首先,将所有本文中的158种算法在所有微电网都 并网且无故障的情况下进行仿真,在仿真时设置的仿 真时长为1200 s. 绘制"控制+优化"156种算法中控 制性能最优算法、ADP算法与所提DADP算法的频率 偏差的曲线如图9(a)所示.对控制与优化算法分别 统计发电成本、算法实际计算时间与收敛步数如图 9(b)-9(c)所示.所提算法DADP 算法的离线训练和在 线训练的曲线如图9(d)-9(f)所示.







图9中的"Quad"为二次规划函数(内部采用内 点法计算),"PROP"为固定比例算法,"A-"为自 适应算子,如其中"A-PID"为自适应PID算法.

从图9(a)中能看出, DADP算法的控制效果比其

他"控制+优化"组合的156种算法中最优效果好, 且DADP算法比ADP算法性能改善较多.在前300 s, ADP算法的方向正确,但是其精度不够,导致其曲 线波动较大,因此需对其继续进行训练.而DADP算 法由于深度神经网络和对系统预测的深度神经网络 的加入,其控制效果优于ADP算法.

从图9(b)-9(c)中看出, ADP算法和DADP算法的 控制性能统计的最大与最小值基本一致, 算法性能 比传统"发电控制+发电功率优化"的性能更稳定. 且从图9(b)-9(c)中能看出:与ADP算法对比, DADP 算法虽然计算步数与ADP算法的计算步数一致, 且 在远小于发电指令周期(4 s)的情况下, 其频率偏差 Δ*f*和发电费用均比ADP算法小. 且能看出, 通过深 度神经网络改进的自适应动态规划算法能够进行输 出多个机组的指令, 无需另外的优化算法的配合, 减少了实际计算时间, 加速了收敛过程.

图9(d)和图9(e)分别展示了DADP算法在离线训 练时的误差分布图和误差均方差迭代图.图9(f)对 比了ADP算法和DADP算法在线训练过程中对频率 偏差控制的收敛曲线,图中显示DADP算法对系统 的控制效果优于ADP算法.

(a) 频率偏差曲线图

**4.3** "即插即用" 启停机仿真(Plug and play situation)

为模拟微网电网的"即插即用"性能,采用微电网的启停机进行模拟.如在仿真为0s时,微电源MT11与FC14为关闭状态,MT12为开启状态. 1200s时,将MT11与FC14开启,将MT12关闭.每个算法在仿真时设置的仿真时长均为2400s.仿真结果如图与图9(a)-(c)所示趋势一致,在此不赘示,从而得出DADP算法在解决"即插即用"启停机问题时,均优于其他算法,此仿真能模拟不同机组的组合情况或机组故障无法发出功率的情况,且从图中能看出ADP算法不够稳定.

## **4.4** "通讯故障" 仿真(Communication failure situation)

若在通讯故障时,通讯故障的微电源均只参与 "一次调频",不参与二次调频.设计在不同时刻的 通讯故障情况的算例如表5所示.当通讯故障时,故





Fig. 10 Results of communication failures situation

# **4.5** 全天扰动仿真(All-day long disturbance situation)

采用典型的负荷扰动(风电和光伏发电如图2所 示,负荷扰动如图3所示)进行全天候的仿真,每个算 障机组保持之前获取到的发电指令进行发电,包括与CCC算法组合式算法亦是如此,即该机组不参与通讯.

表 5 通讯故障情况表

Table 5 Communication failures situation

时刻/s	通讯	故障的微	[电源
0~1200	MT12	MT13	FC15
$1200 \sim 2400$	MT10	MT11	MT12
2400~3600	MT12	DS17	DS19

此算例中每个算法进行仿真3600 s, 仿真结果图 10所示, 对于不同算法的收敛步数、频率偏差、实际 计算时间和发电成本的统计结果类似于基本仿真情 况, 在此不赘示.

从图10能看出, ADP算法的收敛范围太大, 甚至 超出了频率的标准要求. 而DADP 算法不仅能够控 制频率偏差最小. 发电费用统计与图9(b)和图9(c) 趋势一致, 以最经济的方式提供较高的电能质量.



----- ADP算法 — DADP算法

法进行仿真24 h. 其结果如图9所示结果趋势一致. 因此,从全天扰动的仿真看来,所提DADP算法的稳 定性最强,不仅所需的实际计算时间少,而且能有 较高的电能质量.

# **4.6** 变拓扑结构仿真(Time-varying topology situation)

为验证DADP算法在智能微网的拓扑结构变化时,甚至有电源进行启动时的鲁棒性能,设计了变 拓扑结构的微电网.假定变拓扑结构的所有微电网 工28个,在不同的时刻形成不同的微网,其拓扑结 构变化时,微电源的启停情况如图11(a)所示.电源 的参数表如表6所示.该算例进行仿真12000 s,分10 个不同的拓扑结构,仿真结果如图11(b)-(c)所示.

变拓扑结构的仿真结果的不同控制算法和不同 优化算法的对比图与以上仿真类似,再次不赘示. 图11"各电源的启停情况图"中的白色表示此电源 退出微网,从而配电网拓扑结构发生变化,此仿真 验证了所提DADP算法在拓扑结构发生变化时具有 较强的鲁棒性.

第2期

# **4.7** 系统内部参数变化仿真(Systemic internal parameters varying situation)

选取基本微网的结构(其结构见图1,参数见表1),设计系统内部参数发生变化的仿真算例.系统内部参数可变范围太多,选取其中6个参数进行变化.因此,假定系统内部参数可变化的范围如表7所示,参数变化共有4<sup>6</sup>种可能的组合,每个组合在仿真时设置的仿真时长为1200s,即每种算法仿真1200×4<sup>6</sup>s = 4915200s = 56.89天.采用158种算法对比的仿真结果如图12所示.

表 6 电源的参数表 Table 6 Parameters of AGC units

도난	- - - - - - - - - - - - - - - - - - -	$\Delta P_{\mathrm{G}i}^{\mathrm{max}}$	$\Delta P_{\mathrm{G}i}^{\mathrm{min}}$	$a_i$ /	$b_i$ /	$c_i$ /
区域	机组	/kW	/kW	$(\${\cdot}h^{-1})$	$(\${\cdot}h^{-1})$	$(\${\cdot}h^{-1})$
配电网	H1	250	-250	0.0001	0.0346	8.5957
配电网	H2	150	-150	0.0001	0.0335	8.0643
配电网	H3	150	-150	0.0001	0.0335	8.0643
配电网	H4	100	-100	0.0001	0.0314	7.6248
配电网	H5	100	-100	0.0001	0.0314	7.6248
配电网	BE6	200	-200	0.0004	0.0656	8.7657
配电网	BE7	200	-200	0.0004	0.0656	8.7657
配电网	H8	100	-100	0.0001	0.0346	7.5248
配电网	BE9	200	200	0.0004	0.0656	7.7657
微网1	MT10	100	-100	0.0002	0.1088	5.2164
微网1	MT11	100	-100	0.0002	0.1088	5.2164
微网1	MT12	150	-150	0.0002	0.1164	5.4976
微网1	MT13	150	-150	0.0002	0.1164	5.4976
微网1	MT14	150	-150	0.0002	0.1164	5.3976
微网1	MT15	150	-150	0.0002	0.1164	5.1976
微网2	MT16	150	-150	0.0002	0.1164	5.4976
微网2	MT17	150	-150	0.0002	0.1164	5.4976
微网2	FC18	150	-150	0.0003	0.1189	3.5442
微网2	FC19	150	-150	0.0003	0.1189	3.5442
微网2	FC20	200	-200	0.0003	0.1189	3.1442
微网2	FC21	200	-200	0.0003	0.1189	3.2442
微网2	FC22	200	-200	0.0003	0.1189	4.5242
微网3	DS23	120	-120	0.0004	0.2348	10.9952
微网3	DS24	120	-120	0.0004	0.2348	10.9952
微网3	DS25	120	-120	0.0004	0.2348	10.9952
微网3	DS26	120	-120	0.0004	0.2348	10.9952
微网3	DS27	120	-120	0.0004	0.2328	10.9952
微网3	DS28	120	-120	0.0004	0.2328	10.9952





(b) 不同优化算法的统计结果



Fig. 12 Results of varied systemic internal parameters

表	7	系统	内音	『参数	可i	先范	围君	ŧ
-						$\sim$ $\sim$		-

Table 7 Ranges of systemic internal parameters

参数	参	数取	(值范E	围 / s
H1的二次调频时延	2	3	4.5	5.5
BE6的二次调频时延	4	6	8	10
H8的二次调频时延	3	5	8	12
MT10二次调频时延	2	4	5	6
MT14的二次调频时延	2	4	6	8
MT16的二次调频时延	3	5	7	9

图12(a)和12(b)为统计箱形图, 红色加号(+)为异常点, 红色横线为中分点, 黑色横线为上下边缘线 (数据的除异常外的最大最小值), 蓝色框为上、下四分点所在位置(75%, 25%).

从图12(a)和12(b)中的"计算时间"统计情况可 以看出,某些组合式算法会导致其实际计算时间超 过自动发电指令时间(4 s).

从图12能看出, ADP算法在具有大量在线学习 过程中, 其效果优于其他较多组合式算法, 且与 DADP算法的控制效果较为接近.

从图 12 中能看出,特别是从 12(c) 中能看出, DADP算法在保证频率偏差 $\Delta f$ 为最小的情况下,发 电成本和所需实际计算时间最小.因此,能验证所 提DADP算法在系统内部参数变化时仍然具有强鲁 棒性,无需强化学习系列算法中的系统内部参数发 生变化时的重新预学习(训练).

### 4.8 上述所有算例的统计情况(Simulation results)

将上述所有算法的仿真算例的结果进行统计, 形成统计表如表8所示.表中也展示了在大量仿真 对比下,ADP"一体式"算法相对于其他组合式算 法的控制效果,其频率偏差小于组合式算法,但因 其精度不够高,其控制性能弱于对其改进的算法(所 提DADP算法).从表8能看出:

对比算法	发电成本平均	实际计算	收敛步数	频率偏差 $ \Delta f $
	值/( $(\cdot h^{-1})$ )	时间均值/s	平均值/步	平均值/Hz
PID	114346.2471	0.0968	37.57	0.1579
SMC	119760.5607	0.0731	76.13	0.3487
ADRC	123520.5751	0.0810	41.37	0.9931
FOPID	117977.3682	0.0772	49.37	0.3134
A-PID	116162.7808	0.0754	39.36	0.2363
A-SMC	118424.9519	0.0782	53.22	0.2805
A-ADRC	117176.1223	0.0779	54.91	0.2961
A-FOPID	116961.5691	0.0772	43.60	0.2625
Fuzzy	114565.9263	0.0745	35.62	0.1680
Q学习	115043.3969	0.0750	66.94	0.2100
$Q(\lambda)$ 学习	114923.5256	0.0753	66.77	0.2101
$R(\lambda)$ 学习	116170.9556	0.0756	64.48	0.2487
CCC	113688.5332	0.0022	394.76	0.2871
二次规划	115079.3377	0.0050	7.61	0.4499
GA	115584.9879	0.1164	8.00	0.3297
GWO	118921.7885	0.0113	27.44	0.3118
固定比例	114984.2230	$9.4 \times 10^{-6}$	2.00	0.1889
PSO	113822.3790	0.4302	3.06	0.1840
MFO	118600.9489	0.0067	24.77	0.3745
WOA	117436.5432	0.0058	25.13	0.2937
ALO	117916.7883	0.0947	27.64	0.3021
DA	118780.8924	0.2955	23.24	0.2788
GSO	120858.7915	0.0272	100.00	0.3728
CSO	118620.6617	0.0143	21.17	0.3397
SCA	117824.2693	0.0059	16.95	0.3227
ADP算法	118088.4203	0.0155	2.00	0.1413
DADP算法	116024.1953	0.0174	2.00	0.0106

表 8 仿真算例结果统计表

Table 8 Statistic results of simulations

1) 针对主动配电网的"一体化"发电控制问题, 所提DADP算法在所有算例中获得的频率偏差最小;

2) 与其他算法相比,所提DADP算法所需的计 算步数极少,且其实际计算时间少,即所设计的"一 体化"算法满足自动发电指令周期的要求;

3) 因深度神经网络的加入,针对主动配电网的 "一体化"发电控制问题,所提DADP算法控制性 能比ADP算法的控制性能好;

4) 针对主动配电网的"一体化"发电控制问题, 所设计的DADP算法训练方法有效,能可靠地解决 系统拓扑结构变化和系统内部参数发生较大变化给 系统带来的影响,具有强鲁棒性;

5) 所提DADP算法能"一体式"输出孤岛配电 网各机组的发电指令,能有效取代传统"发电控 制+控制指令分配"的功能,具有在线更新能力,所 需实际计算时间短,收敛性强,适合作为孤岛配网 的二次调频控制策略.

### 5 结论(Conclusions)

本文将具有较强预测能力的深度神经网络融入 到ADP算法中,在此基础上添加深度模型预测网络, 针对孤岛配电网提出了一种发电控制与控制指令在 线优化"一体"算法DADP.本文搭建了复杂的孤岛 配电网模型,并在此基础上设计了较为完整的复杂 工况下配电网仿真,特别是的系统拓扑、开启停及 参数变化的大规模仿真;最后通过总仿真时长 为25.155年的仿真,与其他156种组合算法的对比, 所提DADP算法具有可行性、有效性和鲁棒性.

所提DADP算法实现了"发电控制算法与优化 分配算法"配合使用的功能.且其效果优于配合使 用的效果,虽其采用其中一种组合算法的结果进行 离线训练,但其通过离线与在线的学习,不断增强 了对系统的预测能力,进而做出了更好的决策,从 而获得了更好的控制效果,避免了"控制算法+优化 算法"组合算法的缺点.

### 参考文献(References):

- LI Bin, ZHU Jing, LI Peijie, et al. Island partition of distribution network with unreliable distributed generatos [J]. Automation of Electric Power Systems, 2015, 39(8): 59-65.
   (李滨, 祝靖, 李佩杰, 等. 含非可靠分布式电源的配电网孤岛划分 [J]. 电力系统自动化, 2015, 39(8): 59-65.)
- [2] HE Chengming, WANG Hongtao, WEI Zhongkang, et al. Distributed coordinated real-time control of wind farm and AGC units [J]. Proceedings of the CSEE, 2015, 35(2): 302 309.
  (何成明, 王洪涛, 韦仲康, 等. 风电场与AGC机组分布式协同实时控制 [J]. 中国电机工程学报, 2015, 35(2): 302 309.)
- [3] GUO X, GUO X. China's photovoltaic power development under policy incentives: a system dynamics analysis [J]. *Energy*, 2015, 93: 589 – 598.
- [4] ZHONG J, HE L, LI C, et al. Coordinated control for large-scale EV charging facilities and energy storage devices participating in frequency regulation [J]. *Applied Energy*, 2014, 123(12): 253 – 262.
- [5] LI Xiulei, GENG Guangfei, JI Yuqi, et al. Intergrated optimal planning of energy storage and demand side response in active power distribution network [J]. *Power System Technology*, 2016, 40(12): 3803 – 3810.

(李秀磊, 耿光飞, 季玉琦, 等. 主动配电网中储能和需求侧响应的联合优化规划 [J]. 电网技术, 2016, 40(12): 3803 – 3810.)

[6] ZUO Weijie, MA Zhao, ZHOU Limei, et al. Grid-connection of distributed photovoltaic generation method based on the power quality health status of distribution system [J]. *Power System Technology*, 2015, 39(12): 3442 – 3448. (左伟杰,马钊,周莉梅,等.基于配电网电能质量健康评估策略的分 布式光伏接入方法 [J].电网技术,2015,39(12):3442-3448.)

 YU Ting, LIU Guangyi, PU Tianjiao, et al. Multiple coordinated optimization control of active distribution network considering flexible load [J]. Automation of Electric Power Systems, 2015, 39(9): 95 – 100.

(于汀, 刘广一, 蒲天骄, 等. 计及柔性负荷的主动配电网多源协调优 化控制 [J]. 电力系统自动化, 2015, 39(9): 95 – 100.)

- [8] LIU Dandan, DUAN Bin, WANG Jun, et al. A multi-agent system for fault self-recovery of distribution systems in active distribution network based on IEC 61850 [J]. Automation of Electric Power Systems, 2015, 39(9): 119-126.
  (刘丹丹, 段斌, 王俊, 等. 基于IEC 61850的主动配电网故障自恢复 多代理系统 [J]. 电力系统自动化, 2015, 39(9): 119-126.)
- [9] XU Shaohua, LI Jianlin, HUI Dong. Stability analysis and control strategy of parallel storage inverter system working under the microgrid's island condition [J]. *High Voltage Engineering*, 2015, 41(10): 3266 3273.
  (徐少华,李建林,惠东.多储能逆变器并联系统在微网孤岛条件下

的稳定性分析及其控制策略 [J]. 高电压技术, 2015, 41(10): 3266-3273.)

- [10] YANG Xiangzhen, SU Jianhui, DING Ming, et al. Voltage control strategies for microgrid with multiple inverters [J]. Proceedings of the CSEE, 2012, 32(7): 7 – 13.
  (杨向真,苏建徽,丁明,等. 面向多逆变器的微电网电压控制策略 [J]. 中国电机工程学报, 2012, 32(7): 7 – 13.)
- [11] LI Zhenkun, ZHOU Weijie, WANG Jianmin, et al. Dynamic islanding method of active power distribution network based on wind-photovoltatic-load curve [J]. Automation of Electric Power Systems, 2016, 40(14): 58 64.
  (李振坤,周伟杰,王坚敏,等. 基于风光荷功率曲线的有源配电网动态孤岛划分方法 [J]. 电力系统自动化, 2016, 40(14): 58 64.)
- [12] LU Q Y, HU W, ZHENG L, et al. Integrated coordinated optimization control of automatic generation control and automatic voltage control in regional power grids [J]. *Energies*, 2012, 5(10): 3817 – 3834.
- [13] QU Junyi, REN Jianwen, ZHOU Ming, et al. Multi-time scale fuzzy chance constrained dynamic economic dispatch model for power system with wind power [J]. *Power System Technology*, 2016, 40(4): 1094 1099.
  (翟俊义, 任建文, 周明, 等. 含风电电力系统的多时间尺度模糊机会)

约束动态经济调度模型 [J]. 电网技术, 2016, 40(4): 1094 – 1099.)

- [14] SAHU R K, PANDA S, YEGIREDDY N K. A novel hybrid DEPS optimized fuzzy PI/PID controller for load frequency control of multiarea interconnected power systems [J]. *Journal of Process Control*, 2014, 24(10): 1596 – 1608.
- [15] SAHU B K, PATI S, MOHANTY P K, et al. Teaching-learning based optimization algorithm based fuzzy-PID controller for automatic generation control of multi-area power system [J]. *Applied Soft Computing*, 2015, 27(C): 240 – 249.
- [16] PREETI D, VEENA S, RAM N. Automatic generation control using disrupted oppositional based gravitational search algorithm optimised sliding mode controller under deregulated environment [J]. *IET Generation, Transmission & Distribution*, 2016, 10(16): 3995 – 4005.
- [17] LIU F, LI Y, CAO Y, et al. A two-layer active disturbance rejection controller design for load frequency control of interconnected power system [J]. *IEEE Transactions on Power Systems*, 2016, 31(4): 3320 – 3321.
- [18] DEBBARMA S, SAIKIA L C, SINHA N. Automatic generation control using two degree of freedom fractional order PID controller [J]. *International Journal of Electrical Power & Energy Systems*, 2014, 58: 120 – 129.
- [19] YU T, ZHOU B, CHAN K W, et al. Stochastic optimal CPS relaxed control methodology for interconnected power systems using

Q-learning method [J]. *Journal of Energy Engineering*, 2010, 137(3): 116 – 129.

[20] YU T, ZHOU B, CHAN K W, et al. Stochastic optimal relaxed automatic generation control in non-Markov environment based on multistep, learning [J]. *IEEE Transactions on Power Systems*, 2011, 26(3): 1272 – 1282.

第2期

- [21] YU T, WANG H Z, ZHOU B, et al. Multi-agent correlated equilibrium  $Q(\lambda)$  learning for coordinated smart generation control of interconnected power grids [J]. *IEEE Transactions on Power Systems*, 2015, 30(4): 1669 1679.
- [22] YU T, ZHOU B, CHAN K W, et al. R(λ) imitation learning for automatic generation control of interconnected power grids [J]. Automatica, 2012, 48(9): 2130 – 2136.
- [23] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69(3): 46 – 61.
- [24] MIRJALILI S. How effective is the grey wolf optimizer in training multi-layer perceptrons [J]. *Applied Intelligence*, 2015, 43(1): 150 – 161.
- [25] SAREMI S, MIRJALILI S Z, MIRJALILI S M. Evolutionary population dynamics and grey wolf optimizer [J]. *Neural Computing and Applications*, 2015, 26(5): 1257 – 1263.
- [26] BAHRAMI S, HOOSHMAND R A, PARASTEGARI M. Short term electric load forecasting by wavelet transform and grey model improved by PSO (particle swarm optimization) algorithm [J]. *Energy*, 2014, 72(7): 434 – 442.
- [27] MIRJALILI S. Moth-flame optimization algorithm: a novel natureinspired heuristic paradigm [J]. *Knowledge-Based Systems*, 2015, 89: 228 – 249.
- [28] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51 67.
- [29] MIRJALILI S. The ant lion optimizer [J]. Advances in Engineering Software, 2015, 83(6): 80 – 98.
- [30] MIRJALILI S. Dragonfly algorithm: a new meta-heuristic optimization technique for solving single-objective, discrete, and multiobjective problems [J]. *Neural Computing and Applications*, 2016, 27(4): 1053 – 1073.
- [31] HE S, WU Q H, SAUNDERS J R. A group search optimizer for neural network training [J]. *Lecture Notes in Computer Science*, 2006, 3982: 934 – 943.
- [32] MENG X, LIU Y, GAO X, et al. A new bio-inspired algorithm: chicken swarm optimization [C] //International Conference in Swarm Intelligence. Hefei, China: Springer, 2014.
- [33] MIRJALILI S. SCA: a sine cosine algorithm for solving optimization problems [J]. *Knowledge-Based Systems*, 2016, 96: 120 – 133.
- [34] XIE Pingping, LI Yinghong, LIU Xiaojuan, et al. Optimal PI/PID controller design of AGC based on social learning adaptive bacteria foraging algorithm for interconnected power grids [J]. *Proceedings of*

the CSEE, 2016, 36(20): 5440 - 5448. (谢平平, 李银红, 刘晓娟, 等. 基于社会学习自适应细菌觅食算法的 互联电网 AGC 最优 PI/PID 控制器设计 [J]. 中国电机工程学报, 2016, 36(20): 5440 - 5448.)

- [35] ZHANG Xiaoshun, YU Tao. Virtual generation tribe based collaborative consensus algorithm for dynamic generation dispatch of AGC in interconnected power grids [J]. *Proceedings of the CSEE*, 2015, 35(15): 3750 3759.
  (张孝顺, 余涛. 互联电网AGC功率动态分配的虚拟发电部落协同一致性算法 [J]. 中国电机工程学报, 2015, 35(15): 3750 3759.)
- [36] XI L, ZHANG Z, YANG B, et al. Wolf pack hunting strategy for automatic generation control of an islanding smart distribution network [J]. *Energy Conversion & Management*, 2016, 122: 10 – 24.
- [37] DONG L, TANG Y, HE H, et al. An event-triggered approach for load frequency control with supplementary ADP [J]. *IEEE Transactions on Power Systems*, 2017, 32(1): 581–589.
- [38] LI Xiangjun, ZHANG Jinqiong, HE Yuting, et al. Optimal control method of energy storage system based on adaptive dynamic programming [J]. *Power System Technology*, 2016, 40(5): 1355 1362. (李相俊, 张晶琼, 何字婷, 等. 基于自适应动态规划的储能系统优化 控制方法 [J]. 电网技术, 2016, 40(5): 1355 1362.)
- [39] RAHHAL M M A, BAZI Y, ALHICHRI H, et al. Deep learning approach for active classification of electrocardiogram signals [J]. Information Sciences, 2016, 345(C): 340 – 354.
- [40] MNIH V, KAVUKCUOGLU K, SILVER D, et al. Human-level control through deep reinforcement learning [J]. *Nature*, 2015, 518(7540): 529 – 33.
- [41] SILVER D, HUANG A, MADDISON C J, et al. Mastering the game of Go with deep neural networks and tree search [J]. *Nature*, 2016, 529(7587): 484 – 489.
- [42] ZHANG X, YU T, YANG B, et al. Virtual generation tribe based robust collaborative consensus algorithm for dynamic generation command dispatch optimization of smart grid [J]. *Energy*, 2016, 101: 34 – 51.

作者简介:

**殷林飞** (1990—), 男, 博士研究生, 目前研究方向为智能电网技 术, E-mail: epyinlinfei@mail.scut.edu.cn;

**余 涛** (1974—), 男, 教授, 博士生导师, 目前研究方向为复杂电 力系统的非线性控制理论和仿真, E-mail: taoyu1@scut.edu.cn;

**张泽宇** (1991—), 男, 硕士, 目前研究方向为新能源工程设计, E-mail: 775013627@qq.com;

**张孝顺** (1990—), 男, 博士研究生, 目前研究方向为发电控制技术、无功优化技术, E-mail: 472672671@qq.com.