

DOI:10.12158/j.2096-3203.2020.05.023

基于 RBF 神经网络的智能负载控制策略研究

叶泰然¹, 王婷², 吕捷¹, 吴薛红¹, 周杨¹, 马刚¹

(1. 南京师范大学电气与自动化工程学院, 江苏 南京 210023;

2. 国网冀北电力科学研究院(华北电力科学研究院有限责任公司), 北京 100045)

摘要:传统用于电力弹簧(ES)控制的PI控制器调节性能较差,且控制方法中未考虑非关键负载突然变化的问题,为解决该问题,根据ES的数学模型和控制电路提出了一种基于径向基函数(RBF)神经网络的智能负载控制方法。利用RBF神经网络算法弥补传统PI控制器参数固定即无法更改的缺点,通过对控制器参数的实时在线调整来减少智能负载失稳情况,确保系统母线电压稳定。在Matlab/Simulink仿真环境中进行仿真验证,结果表明,与传统PI控制相比,文中所提控制策略下的智能负载对关键负载两端电压的调节性能更优。因此,在基于RBF神经网络的PI新型控制策略下的智能负载具有更好的鲁棒性和系统控制能力。

关键词:智能负载;径向基函数(RBF)神经网络算法;电压控制;PI控制器;电力弹簧

中图分类号:TM732

文献标志码:A

文章编号:2096-3203(2020)05-0162-07

0 引言

随着可再生能源的发展和煤炭等传统能源储量持续减少,全球燃料结构发生了巨大的变化^[1-2]。分布式发电(distributed generation, DG)是连接到配电网的可再生能源发电单元,是可再生能源发电的重要方式之一^[3]。大量DG接入配电网后,可以有效减少供电网络的输电电量,提高供电可靠性,减少电力损耗。但是,由于风能和太阳能的随机性强,DG的输出功率具有很大的波动性,因此,大量DG的接入对有源配电网的电压有很大影响,甚至可能严重损害电力系统的稳定运行^[4]。

目前,为解决电网电压波动问题,主要有2种技术方案:无功补偿技术和储能技术^[5-7]。无功补偿是应用最广泛的技术,但该技术采用大容量集中安装方式,不能有效满足DG接入的应用场景^[8]。储能技术如电池的电流容量通常很小,大量的安装不仅投资成本太高而且处理时还会对环境造成不良影响^[9]。

针对上述问题,文献[10]于2012年9月首次提出了电力弹簧(electric spring, ES)的概念,其与非关键负载串联组成智能负载。ES可以实现可再生能源发电波动的缓冲,并在稳定电网主电压方面发挥作用。ES颠覆了传统的电力系统中电力生产由负载需求决定的运行模式,使电网负荷所消耗的电能够随可再生发电量的变化而变化,从而保证临界负荷的电压稳定性。文献[11]建立了ES的动态

仿真模型;文献[12]将ES与静止同步补偿器(static synchronous compensator, STATCOM)进行比较,以强调ES具有更好的稳定性和灵活性;文献[13]介绍了用于实现无功补偿和电压控制的ES实际电路设计和基本控制结构;文献[14]验证了ES在降低电网的储能能力方面的有效性;文献[15]提出基于下垂控制来稳定控制电网中的多个ES的策略;文献[16]验证了ES在三相电源系统中抑制功率不平衡方面的有效性。目前的研究中用于ES控制调节性能的方法还需要进一步优化^[11],同时,在传统的ES控制方法中,例如在电加热器的待机模式和加热模式的改变中,并没有考虑非关键负载的突然变化。

针对上述问题,文中提出一种基于径向基函数(radial basis function, RBF)神经网络的智能负载控制方法,使得智能负载在非关键负载变化时具有更好的调节效果,同时保持稳定的调节性能。首先,分析了智能负载的基本原理和存在的问题;其次,通过RBF神经网络实时调整PI控制器参数,建立了智能负载的自适应控制方法;最后,基于Matlab/Simulink软件建立的仿真模型,验证了该自适应控制方法的可行性和有效性。

1 智能负载原理及其建模

将ES与一个非关键负载 Z_{NCL} 串联组成智能负载,再与关键负载 Z_{CL} 等并联,组成智能负载电路结构如图1所示。

图1中,将ES与 Z_{NCL} 的串联组合称为智能负载; U_{ref} 为智能负载两端应该维持不变的母线电压; U_{ES} 为ES两端电压; U'_{NCL} 为 Z_{NCL} 两端电压; U_{SL} 为 Z_{CL}

收稿日期:2020-03-23;修回日期:2020-04-19

基金项目:国家自然科学基金资助项目(51607093)

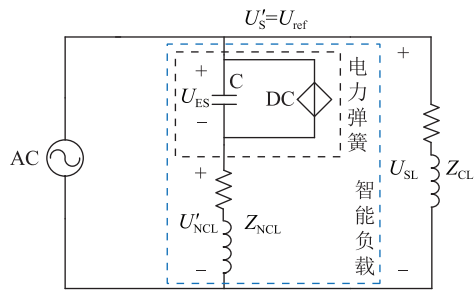


图1 智能负载电路结构

Fig.1 Structure of intelligent load circuit

两端电压, U'_S 为智能负载两端电压。由电路关系可知, 智能负载上的电压向量为:

$$U'_S = U_{SL} = U_{ES} + U'_{NCL} \quad (1)$$

式(1)表明, 可以通过控制 U'_{NCL} 跟随 U_{SL} 的变化, 将 U_{SL} 的电压波动转移到 Z_{NCL} 上, 从而使 U_{SL} 保持恒定, 即 U'_S 保持恒定。智能负载的 3 种不同工作模型的相量关系如图 2 所示。




图2 智能负载运行状态的向量图

Fig.2 Vector diagram of intelligent load operation state

智能负载的内部主电路结构如图 3 所示。输入端接入直流电源 DC, 其两端电压为 U_{dc} ; 输出端接入滤波电路, 其中逆变器输出电压为 U_a ; 滤波电路采用的是低通滤波, L_F 为电感感抗值, 其流过电流为 I_F ; C_F 为电容容抗值, 其流过的电流为 I_C , 两端电压为 U_{ES} ; R_{NCL} 为非关键负载电阻值, 其两端电压为 U_{NCL} ; U_S 为电网电压。

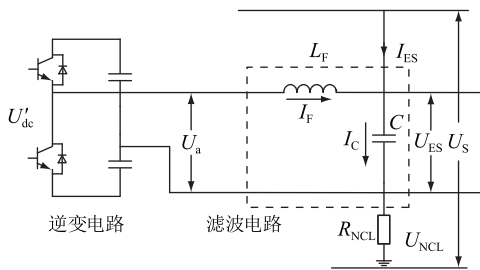


图3 智能负载主电路

Fig.3 Main circuit of intelligent load

图 3 中, 在逆变器的交流侧运用基尔霍夫电压 (KVL) 和电流 (KCL) 定律可得如下表达式 (文中规定电压和电流为关联参考方向):

$$\begin{cases} U_S = U_{ES} + R_{NCL} I_{ES} \\ I_{ES} + I_F = I_C \end{cases} \quad (2)$$

由电容和电压、电感和电流的关系可得:

$$\begin{cases} U_F = L_F \frac{dI_F}{dt} \\ I_C = C_F \frac{dU_{ES}}{dt} \end{cases} \quad (3)$$

逆变电路的输出电压 U_a 为:

$$U_a = L_F \frac{dI_F}{dt} + U_{ES} = \frac{U_{dc}}{2} P - \frac{U_{dc}}{2} \bar{P} \quad (4)$$

式中: P 为逆变器开关管驱动信号; U_{dc} 为逆变器的直流链路电压。

通过傅里叶分解原理可知, 逆变器的输出电压波形包含高频分量和基波分量, 所以 U_a 为:

$$U_a(t) = U_{1a}(t) + \sum_{n=1}^{\infty} a_n \cos \frac{2\pi n t}{T_s} + b_n \sin \frac{2\pi n t}{T_s} \quad (5)$$

式中: T_s 为采样时间; n 为谐波阶数。

对式(5)两端取周期 T_s 内平均值, 可得逆变器输出电压 U_a 的平均值为:

$$\begin{aligned} \bar{U}_a(t) &= \sum_{n=1}^{\infty} a_n \cos \frac{2\pi n t}{T_s} \frac{1}{T_s} \int_0^{T_s} U_{1a}(\tau) d\tau + \\ &\quad \sum_{n=1}^{\infty} b_n \sin \frac{2\pi n t}{T_s} \end{aligned} \quad (6)$$

式(6)的第一项为在时间 T_s 内低频分量 (频率为 50 Hz) 的平均值, 第二项为高频分量平均值。

将式(4)代入式(6), 可得:

$$\begin{aligned} L_F \frac{dI_F}{dt} &= \frac{1}{T_s} \int_0^{T_s} U_{1a}(\tau) d\tau - U_{ES} + \\ &\quad \sum_{n=1}^{\infty} \left(a_n \frac{2\pi n t}{T_s} \right) + b_n \sin \frac{2\pi n t}{T_s} \end{aligned} \quad (7)$$

经过低通滤波后, 滤除高频分量, 可进一步简化式(7)得:

$$L_F \frac{dI_F}{dt} = \frac{1}{T_s} \int_0^{T_s} U_{1a}(\tau) d\tau - U_{ES} \quad (8)$$

逆变器输出的基频电压为:

$$U_{1a}(t) = \frac{U_{dc}}{2} m \quad (9)$$

其中, m 为电压调制系数, 具体数值为:

$$m = M \sin(100\pi t + \theta) \quad (10)$$

综上所述, 智能负载主电路的数学模型可以表示为:

$$\begin{cases} \frac{dI_F}{dt} = -\frac{R_F}{L_F} I_F + \frac{U_{dc}}{2} \frac{m}{L_F} - \frac{1}{L_F} U_{ES} \\ \frac{dU_{ES}}{dt} = \frac{1}{C_F} I_F + U_S \frac{1}{R_{NCL} C_F} - \frac{1}{R_{NCL} C_F} U_{ES} \\ \frac{dU_{dc}}{dt} = \frac{R_F}{C_1 + C_1} \frac{I_F^2}{U_{dc}} \end{cases} \quad (11)$$

2 基于 RBF 的智能负载自适应控制

2.1 RBF 神经网络原理

RBF 神经网络由 J.Moody 和 C.Darken 在 1980 年提出, Broomhead 和 Lowe 在神经网络的设计中率先使用了 RBF^[17]。RBF 是一类特殊的函数, 其特征是响应速度随着离中心点的距离单调减小或增加, 是具有单个隐藏层的前馈三层网络, RBF 神经网络是一个本地近似网络。事实证明, RBF 网络具有以任意精度近似逼近任何连续函数的能力^[18]。

RBF 网络是三层前馈神经网络, 从输入到输出的映射是非线性的, 但是从隐藏层到输出层的映射是线性的, 学习速度大大提高, 避免了局部极小化的问题。文中的 RBF 网络配置如图 4 所示, 在 RBF 神经网络的结构中, 第一层 U 是网络的输入向量, 第二层(隐藏层)的神经元通过 RBF 激活, 第三层为输出层, 代表比例控制系数 k_p , 积分控制系数 k_i 。




图 4 RBF 神经网络拓扑结构

Fig.4 RBF neural network topology

2.2 基于 RBF 的控制器设计

在 ES 的传统 PI 控制基础上^[17-20], 通过 RBF 模型对 PI 控制参数进行动态调节, 实现 PI 自适应控制的目的。由于文中被控对象在实际过程中为多变量、非线性, 采用固定参数的调节方式无法满足非线性的拟合。然而神经网络能以任意精度逼近任意非线性函数, 能够辨识文中被控制对象, 从而获得简单的控制模型。采用 RBF 能够较好地模拟这种非线性的情况, 具有全局最优且训练快速简单的优点, 其控制框图如图 5 所示, 其中, B2B-ES 为 ES 设备。

图 5 中, 主要控制系统有 2 部分组成, 其一是传统的 PI 控制器, 通过改变 k_p, k_i 参数值, 直接以闭环反馈方式对 B2B-ES 的输出进行调节控制, 进而完善控制器调节性能; 其二是 RBF 神经网络控制器, 控制器本身接收来自被控对象的误差量, 通过闭环反馈直接控制自身权重系数的变化, 输出局部最优解 $(\Delta k_p, \Delta k_i)$, 并传输给传统 PI 控制器, 实




图 5 基于 RBF 的智能负载自适应控制结构

Fig.5 Structure of intelligent load adaptive control based on RBF

现 PI 控制器参数的自适应调节, 改善系统动态调节性能。此处, $U_{SREF}(k)$ 为母线电压有效值的参考量; $y_m(k)$ 为经过 RBF 控制器辨识后的输出电压; $\Delta k_p, \Delta k_i$ 为 RBF 模型实时控制的参数变化量。

RBF-PI 控制器可以采用增量型 PI 控制, 其控制误差为:

$$e(k) = U_{SREF}(k) - y(k) \quad (12)$$

控制器输出:

$$u(k) = k_p e(k) + k_i \sum_{j=0}^k e(j) \quad (13)$$

增量型 PI 控制算法为:

$$\Delta u(k) = k_p (e(k) - e(k-1)) + k_i e(k) \quad (14)$$

PI 控制器的 2 个输入为:

$$\begin{cases} x(1) = e(k) - e(k-1) \\ x(2) = e(k) \end{cases} \quad (15)$$

神经网络性能指标衡量函数为:

$$E(k) = \frac{1}{2} e^2(k) \quad (16)$$

基于 RBF 神经网络的自学习能力, 网络可以自适应整定 PI 的 2 个参数。其中, 各个参数的变化量按照梯度下降法原则刷新, 结果如式(17)所示。

$$\begin{cases} \Delta k_p = -\eta_p \frac{\partial E}{\partial k_p} = -\eta_p \frac{\partial E}{\partial y} \\ \frac{\partial y}{\partial u} \frac{\partial u}{\partial k_p} = \eta_p e(k) \frac{\partial y}{\partial u} x(1) \\ \Delta k_i = -\eta_i \frac{\partial E}{\partial k_i} = -\eta_i \frac{\partial E}{\partial y} \\ \frac{\partial y}{\partial u} \frac{\partial u}{\partial k_i} = \eta_i e(k) \frac{\partial y}{\partial u} x(2) \end{cases} \quad (17)$$

其中, 每次迭代是沿着负梯度的方向搜索, $\Delta k_p, \Delta k_i$ 为实时参数调节变化量, 参与完成 PI 控制器参数在线自适应变化。

综上所述, RBF 神经网络整定 PI 参数法的主要原理是通过自适应方法, 持续不断地在线修正 PI 控制器的 $\Delta k_p, \Delta k_i$ 参数。采用改进的 RBF 控制算法的 PI 参数向量为:

$$\begin{pmatrix} k_p(k) \\ k_i(k) \end{pmatrix} = \begin{pmatrix} \Delta k_p(k) + k_p(k-1) \\ \Delta k_i(k) + k_i(k-1) \end{pmatrix} \quad (18)$$

式中: k_p, k_i 为修正后输送给传统PI控制器的参数。

3 仿真验证

3.1 仿真参数

含有智能负载的配电网仿真测试系统结构如图6所示。为了验证上述控制方法对智能负载调节性能改善作用,对智能负载的配置做出优化,由原先的一个ES配置一个负载优化为一个ES串联一个负载簇。




图6 含有智能负载的简化配电网仿真测试系统结构

Fig.6 Structure of simplified distribution network simulation test system with intelligent load

系统额定三相电压380 V,额定频率50 Hz。配电网内的发电单元DG、线路、负载、及智能负载单元的相关参数如表1所示,智能负载的控制电路单元相关参数如表2所示。

表1 RBF-PI控制单元仿真参数配置

Table 1 Simulation parameter configuration of RBF-PI control unit

控制器	参数	数值
PI 控制器	比例控制系数 k_p	50
	积分控制系数 k_i	10
	学习速率 η_{pid}	0.2
	微分控制系数 k_d	0
	信号模式	离散型
	采样时间 T_s/ms	10
RBF 控制器	隐层节点数 m	7
	学习速率 η_{rbf}	0.3
	惯性系数 α	0.05
网络权重 (w_1, w_2, w_3)		(0.3, 0.4, 0.1)

3.2 算例分析

文中分别从分布式电源功率变化、关键负载两端母线电压的变动以及非关键负载变动时产生的电压波动等方面来验证所提的智能负载及自适应PI控制方法的有效性。

3.2.1 分布式电源功率发生变化时实验算例

在本实验算例仿真中,仿真时间为25 s。分布式电源的功率变化情况如图7所示,用来模拟光伏发电系统中某一逆变单元损坏而导致的功率骤变情况。图7中,当 $t=5$ s时,系统某一逆变单元发生

表2 线路及电力弹簧仿真参数配置

Table 2 Configuration of circuit and ES simulation parameters

	参数	数值
线路阻抗参数	感抗 $L/(\text{mH}\cdot\text{km}^{-1})$	1.24
	电阻 $R/(\Omega\cdot\text{km}^{-1})$	0.1
负载参数	Z_1/Ω	30
	Z_2/Ω	20
	Z_4/Ω	10
	Z_5/Ω	5
ES 单元参数	低通滤波器电感 L_f/mH	5
	低通滤波器电容 $C_f/\mu\text{F}$	13.2
	ES 直流侧电压 V_{dc}/V	400
	ES 直流侧电容 $C_d/\mu\text{F}$	6 800
	脉冲宽度调制 波形频率 f_s/kHz	20

故障而导致功率发生骤变。当不接入智能负载时, Z_2 处电压状况如图8所示。图9为当ES在5 s时接入,在采用经典PI控制策略和文中所提的自适应PI控制策略2种情况下 Z_2 两端的电压状况。




图7 分布式电源的功率波动

Fig.7 Power fluctuations of distributed power sources




图8 算例1中未接入智能负载时
负载 Z_2 处的电压波形 U_s

Fig.8 Voltage waveform of U_s of load Z_2 when the intelligent load is not connected in example 1

通过图7和图8的对比分析可以得出, Z_2 处的母线电压随着分布式电源出力的变化而改变,且变化趋势大致相同,此时负载两端电压最大为221 V,最小为216 V,系统电压具有较大波动性,严重影响了系统稳定与安全。

由图9可知,在智能负载接入电网后,系统电压 U_s 得到了有效的控制。除此以外,通过比较2段波




图9 算例1中接入智能负载时
负载 Z_2 处的电压波形 U_s

Fig.9 Voltage waveform of U_s of load Z_2 when the intelligent load is connected in example 1

形得出,相较于传统的PI控制方法,自适应PI控制方法调节效果更好。

3.2.2 非关键负载发生变化实验案例

设分布式电源的输出功率恒定不变,仿真时间为25 s,且在仿真期间,智能负载始终接于电路中。非关键负载 Z_2 初始值为 10Ω ,并且在 $t=5 \text{ s}, 10 \text{ s}, 15 \text{ s}$ 时切换负载,分别在传统PI控制和自适应PI控制2种情况进行仿真测试。

(1) 非关键负载 Z_5 逐渐增大。图10展示了当 Z_5 由 10Ω 增大时,采用传统PI和所提自适应PI控制方法时负载 Z_6 两端母线电压的波形。由图10中2段波形的对比可以发现,2种控制方法都能抑制由于负载变化导致的电压波动,但是,文中所提自适应PI控制具有更好的调节性能。使用传统PI控制下的电压恢复时间约为2 s左右,而使用自适应PI控制下的电压恢复时间则减小至0.5 s左右,约为原时间的1/4,这足以证明自适应PI控制的优越性。




图10 PI控制下的 U_s 波形

Fig.10 Voltage waveform of U_s under PI control

(2) 非关键负载 Z_5 逐渐减小。从图11的2种PI控制器的输出图中可以发现,在非关键负载变化过大时,传统PI控制器会出现振荡现象,这也直接导致了 Z_4 两端电压产生的巨大振荡。因此可以得出结论,传统PI控制器调节性能不如自适应PI控制器。文中所提出的自适应PI控制方法很好地抑

制了这一现象,确保整个系统在允许电压范围内运行。




图11 PI控制器输出信号

Fig.11 Output signal of PI controller

图12为 $t=5 \text{ s}$ 时,非关键负载 Z_5 从 10Ω 变小的情况下采用传统PI控制和文中所提的自适应PI控制时负载 Z_4 两端的电压波形。可以发现,当非关键负载出现较大变化时,电压会发生剧烈振荡,从而导致系统无法满足在规定电压下运行的要求,当系统长时间运行在这种电压情况下时,会产生无法想象的严重后果。而通过文中自适应PI控制方法,可以有效抑制由于负载变化而引起的电压波动,从而确保系统可以在允许电压下安全稳定运行。




图12 非关键负载逐渐减小情况下PI控制下的 U_s 波形

Fig.12 Voltage waveform of U_s under PI control with NC load decreasing gradually

4 结语

针对基于RBF神经网络的PI新型控制策略下的智能负载在电力系统中的工作原理及工作特性,初步建立其仿真模型并设计基本控制结构。利用RBF的自学习能力,以受扰动的系统电压与系统额定电压之间的差值为输入,通过PI控制器实时在线调节 k_p, k_i 数值,从而进一步提高智能负载在提高系统稳定性方面的能力。通过Matlab/Simulink进行仿真验证,得到在系统发生大扰动后,与传统PI控制下的智能负载相比,自适应PI控制下的智能负载响应速度更快,稳态误差更小且恢复稳态的速度有所提升,因此基于RBF神经网络的PI新型控制策略下的智能负载有更好的鲁棒性和系统控制能力。

参考文献:

- [1] 刘吉臻. 大规模新能源电力安全高效利用基础问题[J]. 中国电机工程学报, 2013, 33(16): 1-8.
LIU Jizhen. Basic issues of safe and efficient utilization of large-scale new energy power[J]. Journal of China Electrical Engineering, 2013, 33(16): 1-8.
- [2] 崔晓利. 中国能源大数据报告(2018)[R]. 中电传媒·能源情报研究中心, 2018.
CUI Xiaoli. China energy big data report (2018) [R]. CLP Media Energy Intelligence Research Center, 2018.
- [3] 《中共中央关于制定国民经济和社会发展第十三个五年规划的建议》[C]//行政权力结构视角的金融监管体制改革研究. 中国经济改革研究基金会, 2016:2.
《Suggestions of the CPC Central Committee on formulating the 13th five year plan for national economic and social development》[C]//Research on the Reform of Financial Regulatory System from the Perspective of Administrative Power Structure. China Economic Reform Research Foundation, 2016:2.
- [4] 国家能源局. 太阳能发展“十三五”规划[Z]. 2016.
National Energy Administration. 13th Five-Year-Plan for solar energy development[Z]. 2016.
- [5] 潘军, 吴红斌, 许道强, 等. 光伏/电动汽车/负荷博弈的屋顶光伏容量优化[J]. 电力系统自动化, 2019, 43(1): 186-197.
PAN Jun, WU Hongbin, XU Daoqiang, et al. The roof photovoltaic capacity optimization of in photovoltaic/electric vehicle/load game[J]. Automation of Electric Power Systems, 2019, 43(1): 186-197.
- [6] 袁军, 李波, 刘志凯, 等. 基于虚拟仪器技术的电动汽车充电桩综合测试系统[J]. 浙江电力, 2018, 37(6): 36-41.
YUAN Jun, LI Bo, LIU Zhikai, et al. Integrated testing system of electric vehicles charging pile based on virtual instrument technology[J]. Zhejiang Electric Power, 2018, 37(6): 36-41.
- [7] 谢宝江, 陈桑红, 陈轶玮, 等. 基于CPT的电动汽车无线充电技术研究[J]. 浙江电力, 2018, 37(7): 26-30.
XIE Baojiang, CHEN Sanghong, CHEN Yiwei, et al. Research on wireless charging technology of electric vehicles based on CPT[J]. Zhejiang Electric Power, 2018, 37(7): 26-30.
- [8] 200万千瓦:我国用户光伏累计装机量[J]. 中国电力企业管理, 2018(3): 7.
2 million kilowatts: cumulative installed capacity of domestic photovoltaic [J]. China Power Enterprise Management, 2018(3): 7.
- [9] “十三五”国家战略性新兴产业发展规划[J]. 中国产经, 2016(12): 95-97.
“13th-Five-Year” national strategic emerging industry development plan[J]. China Industry and Economy, 2016(12): 95-97.
- [10] HUI S Y, LEE C K, WU F F. Electric springs—a new smart grid technology[J]. IEEE Transactions on Smart Grid, 2012, 3(3): 1552-1561.
- [11] CHUADHURI N R, LEE C K, CHUADHURI B, et al. Dynamic modeling of electric springs[J]. IEEE Transactions on Smart Grid, 2014, 5(5): 2450-2458.
- [12] LUO X, AKHTAR Z, LEE C K, et al. Distributed voltage control with electric springs: comparison with STATCOM [J]. IEEE Transactions on Smart Grid, 2015, 6(1): 209-219.
- [13] LEE C K, CHAUDHURI B, HUI S Y. Hardware and control implementation of electric springs for stabilizing future smart grid with intermittent renewable energy sources [J]. IEEE Journal of Emerging & Selected Topics in Power Electronics, 2013, 1(1): 18-27.
- [14] LEE C K, HUI S Y. Reduction of energy storage requirements in future smart grid using electric springs[J]. IEEE Transactions on Smart Grid, 2013, 4(3): 1282-1288.
- [15] LEE C K, CHUADHURI N, CHUADHURI B, et al. Droop control of distributed electric springs for stabilizing future power grid[J]. IEEE Transactions on Smart Grid, 2013, 4(3): 1558-1566.
- [16] YAN S, TAN S C, LEE C K, et al. Electric springs for reduction power imbalance in three-phase power system[J]. IEEE Trans Power Electron, 2015, 30(7): 3601-3609.
- [17] CHEN Y, MA G, XU G, et al. Restraining the demand side power fluctuation of active distribution network using 0°/180° phase controlled electric spring[J]. Journal of Electrical and Computer Engineering, 2018, 18(3): 1-13.
- [18] 徐谷超. 基于电力弹簧的有源配电网电压稳定控制研究[D]. 南京: 南京师范大学, 2018.
XU Guchao. Research on voltage stability control of active distribution network based on power spring[D]. Nanjing: Nanjing Normal University, 2018.
- [19] 程明, 王青松, 张建忠. 电力弹簧理论分析与控制器设计[J]. 中国电机工程学报, 2015, 35(20): 2436-2444.
CHENG Ming, WANG Qingsong, ZHANG Jianzhong. Theoretical analysis and controller design of power spring [J]. Proceedings of the CSEE, 2015, 35(20): 2436-2444.
- [20] LIANG L, HOU Y H, HILL D J, et al. Enhancing resilience of microgrids with electric springs [J]. IEEE Transactions on Smart Grid, 2018, 9(3): 2235-2247.

作者简介:



叶泰然

叶泰然(1998),男,本科在读,研究方向为电气工程及其自动化(E-mail: 547671903@qq.com);

王婷(1989),女,硕士,工程师,从事分布式发电技术、家庭能量管理相关工作;

吕捷(1994),女,硕士在读,研究方向为分布式发电技术、家庭能量管理。

Intelligent load control strategy based on RBF neural network

YE Tairan¹, WANG Ting², LYU Jie¹, WU Xuehong¹, ZHOU Yang¹, MA Gang¹

(1. School of Electrical and Automation Engineering, Nanjing Normal University, Nanjing 210023, China; 0

2. State Grid Jibei Electric Power Research Institute (North China Electric

Power Research Institute Co., Ltd.), Beijing 100045, China)

Abstract: Aiming at the problem that the traditional PI controller used for the control of electric springs has poor adjustment performance and the control method does not take into account the sudden changes of non-critical loads, a smart load control method is proposed based on RBF neural network of the network on the basis of the mathematical model and control circuit of electric spring. The RBF neural network algorithm is used to make up for the shortcomings of the traditional PI controller that the parameters are fixed and cannot be changed. The real-time online adjustment of the controller parameters reduces the intelligent load instability and ensures the stability of the system bus voltage. Simulation verification in the simulation environment of Matlab/Simulink shows that, compared with traditional PI control, the intelligent load under the proposed control strategy has better performance in regulating the system. Therefore, the smart load under the new PI control strategy based on RBF neural network has better robustness and system control capability.

Keywords: intelligent load; radial basis function (RBF) neural network algorithm; voltage control; PI controller; electric springs

(编辑 钱悦)

(上接第 161 页)

Generation of typical sequential joint output scenarios of wind power based on Copula function

TANG Xianghua¹, LI Qiushi¹, HOU Ligang¹, CHEN Changming², LIU Shengyuan³, LIN Zhenzhi³

(1. Haimen Power Supply Company of State Grid Jiangsu Electric Power Co., Ltd., Haimen

226100, China; 2. Polytechnic Institute, Zhejiang University, Hangzhou 310027, China;

3. School of Electrical Engineering, Zhejiang University, Hangzhou 310027, China)

Abstract: Typical scenarios generating is one of methods for dealing with uncertainty of wind and PV outputs in power system planning and operation. However, the differences among output distribution functions at different times are not considered by the existing generation methods for typical scenarios. Given this background, in view of the uncertainty and correlation of outputs for distributed renewable energy generation, the differences among outputs' distribution functions at different times are considered innovatively, the Copula function is used to establish the joint output model for multi-wind farm time-series. A large number of initial scenario sets are generated by probability sampling and splicing from the Copula model, and *K*-means clustering algorithm is used for reducing scenarios and generating typical joint output scenarios. Case studies show that the typical joint output scenarios of wind power are consistent with the correlation among wind power output and the differences among outputs' distribution functions at different times. The output scenarios of multiple wind farms in the same area can be generated by the proposed algorithm with higher accuracy, which can guide the optimal operation of power systems more effectively.

Keywords: scenario generation; scenario reduction; Copula function; joint output of wind power; goodness of fit

(编辑 方晶)