

# 船舶发电机组转速神经网络模型参考自适应控制研究<sup>①</sup>

张 威<sup>②</sup> 施伟锋 许丽霞

(上海海事大学电气自动化系 上海 201306)

**摘要** 将基于神经网络的模型参考自适应控制(NNMRAC)作为控制策略用于研究船舶发电机组的时变与非线性转速控制,以提高控制质量。研究中建立了船舶发电机组二阶传递函数模型,模型参考自适应控制的神经网络辨识器与控制器均采用多层前馈拓扑结构,网络训练采用量化共轭梯度反向传播优化学习算法。学习完成的神经网络模型参考自适应控制器与 PID 控制器并行作用于船舶发电机组,仿真数据表明船舶发电机组转速控制系统的调速快速性得到了提高、灵敏度得到了改善。

**关键词** 船舶发电机组, 神经网络, 模型参考自适应控制(MRAC), 转速控制, 量化共轭梯度算法

## 0 引言

模型参考自适应控制(model-reference adaptive control, MRAC)由美国麻省理工学院的 Witark 教授于 1958 年提出,其基本结构包括参考模型、反馈控制器和预处理环节三部分<sup>[1]</sup>,参考模型提供被控对象运行的标准。基于神经网络的模型参考自适应控制(neural network-based MRAC, NNMRAC)是一种综合了神经网络与模型参考自适应控制的优点控制策略,对非线性系统被控对象控制有效果,已被用于交流传动系统控制<sup>[2]</sup>、感应电机转速估计<sup>[3]</sup>、转速辨识<sup>[4]</sup>、无速度传感器的矢量控制<sup>[5]</sup>及电力系统稳定器控制<sup>[6]</sup>。

船舶发电机组转速的变化直接影响到船舶电力系统频率的稳定性。相对于陆上电力系统,全电船电力系统推进电机负荷单机额定功率大于发电机单机额定容量,推进电机重载负荷随机变化且连续作用于发电机组控制系统,因而对船舶发电机组转速的控制要求较高。针对这种情况,本项目开展了将神经网络模型参考自适应控制(NNMRAC)策略应用于船舶发电机组转速控制的研究,控制系统仿真结果表明,船舶发电机组采用 NNMRAC 与 PID 并行控制转速的方法提高了控制质量,调速的快速性和灵敏度均得到了改善。

## 1 船舶发电机组转速模型建立

目前船舶发电机组转速控制研究中的柴油机采用二阶环节加延时环节<sup>[7]</sup>进行建模,输出量通过积分得到转矩,转矩输出与转速测量值相乘得到机械功率,同步发电机在这个机械功率的驱动下,带动同步发电机转动发出电功率<sup>[8]</sup>。研究中的延迟时间为<sup>[9]</sup>0.024s,即  $G_\tau(s) = e^{-0.024s}$  (其中 s 是拉普拉斯算子),因此,油门执行器及柴油原动机的传递函数  $G_a(s)$  如下式所示:

$$G_a(s) = \frac{0.25s + 1}{s(0.009s + 1)(0.0384s + 1)} e^{-0.024s} \quad (1)$$

在对同步发电机组的输入机械功率  $P_m$  与输出转速  $\omega$  的研究中,通过对机械功率输入单位阶跃信号,得到相应的转速输出响应;根据瞬态响应数据及二阶传递函数多项式、超调量和过渡过程时间公式<sup>[10]</sup>,如式

$$G(s) = \omega_n^2 / (s^2 + 2\xi\omega_n + \omega_n^2) \quad (2)$$

$$M_p = e^{-\pi\xi\sqrt{1-\xi^2}}, \quad (0 \leq \xi < 1) \quad (3)$$

$$t_s = 4.6/\xi\omega_n, \quad (\Delta = 5\%) \quad (4)$$

所示,可得同步发电机机械功率  $P_m$  与转速  $\omega$  如式

<sup>①</sup> 高等学校博士学科点专项科研基金(20123121110003)和上海海事大学研究生创新基金(2014ycx056)资助项目。

<sup>②</sup> 女,1987 年生,博士生;研究方向:电力系统优化与控制;联系人,E-mail: viweizhang@163.com  
(收稿日期:2014-07-03)

$$G(s) = 25/(s^2 + 6s + 25) \quad (5)$$

所示的二阶传递函数模型,其中  $\xi = 0.6, \omega_n = 5$ 。

因此,由油门执行器、柴油原动机及同步发电机构成的船舶发电机组控制广义被控对象可由下式表示:

$$G_p(s) = G_a(s)G(s) = \frac{25(0.25s + 1)e^{-0.024s}}{s(s^2 + 6s + 25)(0.009s + 1)(0.0384s + 1)} \quad (6)$$

## 2 神经网络模型参考自适应 PID 并行控制

### 2.1 神经网络模型参考自适应 PID 并行控制结构

船舶发电机组转速神经网络模型参考自适应控制(NNMRAC)与 PID 并行控制系统结构如图 1 所示。船舶发电机组转速控制系统由 NNMRAC 与 PID 并行控制调速器、油门执行器、柴油原动机及同步发电机组成。船舶发电机组转速控制是通过改变柴油原动机供油量使船舶发电机组转速稳定。

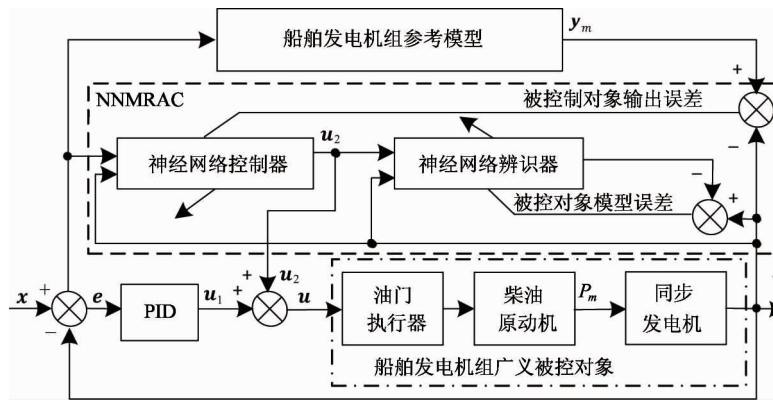


图 1 船舶发电机组转速 NNMRAC 与 PID 并行控制结构

图 1 所示的并行控制系统输入转速参考值  $x$  是发电机组期望转速输出,系统转速输出  $y$  是电机实际转速。在并行控制中,NNMRAC 与 PID 并行控制并非 PID 控制器的简单重复,它的控制对象逆模型中包含被控对象的信息。NNMRAC 控制器通过对 PID 控制下转速控制过程的离线学习进行神经网络权值调整获得相应的控制性能,对 PID 控制研究的目的是为 NNMRAC 控制器学习提供数据样本,对比分析控制器性能及增强系统的稳定性、抑制扰动<sup>[11]</sup>。船舶发电机组转速 NNMRAC 主要包括被控对象神经网络辨识和神经网络控制器生成。

### 2.2 神经网络拓扑结构与算法

如图 1 所示的神经网络辨识器及控制器采用多层前馈拓扑结构,该结构以离线学习方式进行神经网络权值调整。神经网络辨识器通过对船舶发电机组控制广义被控对象进行辨识,并通过神经网络控制器权值调整,实现船舶发电机组的转速 NNMRAC,使得船舶发电机组的转速输出与参考模型输出相一致。神经网络辨识器和神经网络控制器输入层函数为

$$O_j^{(1)} = x(j), j = 1, 2, \dots, M \quad (7)$$

网络隐含层的输出为

$$O_i^{(2)}(k) = f\left(\sum_{j=0}^M \omega_{ij}^{(2)} O_j^{(1)}\right), i = 1, \dots, Q \quad (8)$$

隐含层神经元的激活函数为双曲正切传输函数

$$f(x) = (1 - e^{-2x}) / (1 + e^{-2x}) \quad (9)$$

网络输出层的输出为

$$O_l^{(3)}(k) = g\left(\sum_{j=0}^Q w_{lj}^{(3)} O_j^{(2)}(k)\right), l = 1, \dots, N \quad (10)$$

式中:上角标(1)、(2)、(3)分别表示输入层、隐含层和输出层。

输出层的神经元激活函数为线性传输函数

$$g(x) = x \quad (11)$$

网络的性能指标函数为  $E(k) = E[(e^2(k))]$ ,按照梯度下降法修正网络权值,各层权值按递推式

$$x(k+1) = x(k) - \alpha g(k) \quad (12)$$

计算。式中:  $x(k)$  为第  $k$  次迭代各层之间的连接权向量;  $g(k) = \partial E(k) / \partial x(k)$  为第  $k$  次迭代的神经网络输出误差对各权值向量的梯度向量; 负号表示梯度的反方向,即梯度的最速下降方向;  $\alpha$  为学习速率。

### 2.3 神经网络学习算法

由于船舶发电机组转速 NNMRAc 的神经网络应用了神经网络的逼近能力,逼近的实质是神经网络权值优化,可用动态反传算法来训练神经网络。基本的反向传播优化算法是最速下降反传算法,主要有 Levenberg-Marguardt 算法和量化共轭梯度法。Levenberg-Marguardt 算法计算速度快,但对较复杂的神经网络进行训练或进行神经网络辨识时,常选用量化共轭梯度法。研究采用量化共轭梯度算法,相应的算法如下<sup>[12]</sup>:

(1) 初始化权值矩阵  $\mathbf{w}(0)$ 。二次项  $\mathbf{E}''(\mathbf{w}_k)$  系数  $0 < \sigma \leq 10^{-4}$ , Hessian 矩阵调整系数  $0 < \lambda \leq 10^{-6}$ ,  $\bar{\lambda}_1 = 0$ , 初始梯度向量  $\mathbf{p}(0) = \mathbf{r}(0) = -\mathbf{E}'(\mathbf{w}(0))$ , success = true。

(2) 计算二次项  $\mathbf{E}''(\mathbf{w}_k)$  参数。 $\sigma_k = \sigma / |\mathbf{E}'(\mathbf{w}(k))|$ ,  $\mathbf{S}_k = (\mathbf{E}'(\mathbf{w}_k + \sigma_k \mathbf{p}_k - \mathbf{E}'(\mathbf{w}_k))) / \sigma_k$ ,  $\delta_k = \mathbf{p}_k^T \mathbf{S}_k$ 。

(3) 计算  $\sigma_k$ : $\sigma_k = \sigma_k + (\lambda_k - \bar{\lambda}_k) |\mathbf{p}_k|^2$ 。

(4) 如果  $\sigma_k \leq 0$  使 Hessian 矩阵正定,则有: $\bar{\lambda}_k = 2(\lambda_k - \sigma_k / |\mathbf{p}_k|^2)$ ,  $\sigma_k = -\sigma_k + \lambda_k |\mathbf{p}_k|^2$ ,  $\lambda_k = \bar{\lambda}_k$ 。

(5) 计算迭代步长: $\mu_k = \mathbf{p}_k^T \mathbf{r}_k$ ,  $\alpha_k = \mu_k / \delta_k$ 。

(6) 计算调整参数  $\Delta_k$ : $\Delta_k = 2\sigma_k [\mathbf{E}(\mathbf{w}_k) - \mathbf{E}(\mathbf{w}_k + \alpha_k \mathbf{p}_k)] / \mu_k^2$ 。

(7) 如果  $\Delta_k \geq 0$ , 则有: $\mathbf{w}_{k+1} = \mathbf{w}_k + \alpha_k \mathbf{p}_k$ ,  $\mathbf{r}_{k+1} = -\mathbf{E}'(\mathbf{w}(k+1))$ ,  $\bar{\lambda}_k = 0$ , success = true;

若 mod( $k$ , N) = 0, 则  $k = k + 1$ ,  $\mathbf{p}_{k+1} = \mathbf{r}_{k+1}$ , 反之,  $\beta_k = (|\mathbf{r}_{k+1}|^2 - \mathbf{r}_{k+1}^T \mathbf{r}_k) / \mu_k$ ,  $\mathbf{p}_{k+1} = \mathbf{r}_{k+1} + \beta_k \mathbf{p}_k$ ;

若  $\Delta_k \geq 0.75$ , 则  $\lambda_k = 0.25 \lambda_k$ , 反之,  $\lambda_b = \lambda_k$ , success = false。

(8) 若  $\Delta_k < 0.25$ , 则有: $\lambda_k = \lambda_k + (\delta_k(1 - \Delta_k) / |\mathbf{p}_k|^2)$ 。

(9) 如果最速梯度下降矢量  $\mathbf{r}_k \neq 0$ , 则  $k = k + 1$ , 返回步骤(2)。反之,终止计算,返回权值矩阵  $\mathbf{w}_{k+1}$ 。

### 2.4 神经网络学习算法

船舶发电机组转速控制广义被控对象的神经网络辨识是通过神经网络辨识器运用量化共轭梯度学习算法进行网络训练,获得广义被控对象的神经网络表达形式。

考虑系统动态因素的神经网络辨识器,即将输入  $\mathbf{u}$ 、输出  $\mathbf{y}$  及其时间延迟信号输入到神经网络辨

识器,神经网络辨识器的输出与被控对象的实际输出的误差作为神经网络学习的输入,调节神经网络权值。其非线性离散动态特性由式

$$\begin{aligned} \mathbf{y}(k+1) &= f(\mathbf{y}(k), \dots, \mathbf{y}(k-n+1), \mathbf{u}(k), \\ &\quad \mathbf{u}(k-1), \dots, \mathbf{u}(k-m+1)) \end{aligned} \quad (13)$$

进行描述。当前  $k+1$  时刻的系统输出依赖于过去时刻的  $n$  个输出值和过去时刻的  $m$  个控制值。比较直观的一种建模方法是选择神经网络的输入输出结构与系统的结构一致,记  $\mathbf{y}_N$  为神经网络输出,则

$$\begin{aligned} \mathbf{y}_N(k+1) &= \tilde{f}(\mathbf{y}(k), \dots, \mathbf{y}(k-n+1), \mathbf{u}(k), \\ &\quad \mathbf{u}(k-1), \dots, \mathbf{u}(k-m+1)) \end{aligned} \quad (14)$$

其中  $\tilde{f}$  为神经网络的输入输出非线性映射,网络的输入包括实际系统的输出过去值  $\mathbf{y}(k)$ ,  $\mathbf{y}(k-1)$ ,  $\dots$ ,  $\mathbf{y}(k-n+1)$ , 使得神经网络辨识器通过学习逼近被控对象,满足  $\|\mathbf{y}_N - \mathbf{y}\| \leq \varepsilon$ 。其中,  $\varepsilon > 0$  可预先由辨识准则给定。误差准则函数的泛化表示如下:

$$E(k) = \sum_{k=1}^M f[e(k)] \quad (15)$$

式中,  $f(\cdot)$  有不同的选择,这里选用平方函数:

$$f[(e(k))] = e^2(k) \quad (16)$$

其中,  $e(k)$  是误差,区间为  $[0, M]$ , 是辨识模型的输出与被测系统的输出之差。 $e(k) = 0$  说明辨识模型能够描述被控对象特性。

### 2.5 NNMRAc 控制器

在完成对船舶发电机组控制广义被控对象的神经网络辨识器训练后,进行 NNMRAc 控制器的训练。神经网络控制器的输入为转速参考  $\mathbf{x}$  和实际转速  $\mathbf{y}$ , 神经网络控制器根据参考模型输出  $\mathbf{y}_m$  与实际转速输出  $\mathbf{y}$  的偏差进行学习,调整神经网络权值,产生控制信号,使实际转速趋于参考模型输出。

设神经网络控制器方程为

$$\mathbf{u}(k) = g(\mathbf{x}(k), \mathbf{y}(k), \mathbf{y}_m(k), \mathbf{W}) \quad (17)$$

式中,  $\mathbf{y}_m(k)$  为参考模型转速输出,  $\mathbf{W}$  为神经网络控制器的权值与阈值矩阵。

NNMRAc 控制器结构如图 2 所示。神经网络控制器的输入包含了延迟参考输入  $\mathbf{x}(k)$ 、延迟系统输出  $\mathbf{y}(k)$  和延迟参考模型输出  $\mathbf{y}_m(k)$ , 输出量为  $\mathbf{u}(k)$ 。隐含层、输出层神经元的激活函数分别采用双曲正切传输函数和线性函数。

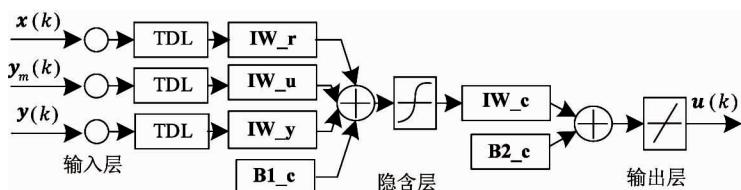


图 2 NNMRAc 控制器结构图

### 3 船舶发电机组转速 NNMRAc 与 PID 并行控制仿真

控制仿真中,隐含层神经元数目根据经验并通过仿真实验分析确定,神经网络辨识器及神经网络控制器隐含层神经元数目分别确定为 10 个和 13 个。

#### 3.1 NNMRAc 训练结果

根据所选用的神经网络多层前馈拓扑结构及 NNMRAc 控制器的工作原理,将量化共轭梯度算法用于神经网络的训练。在进行 NNMRAc 控制器的训练过程中,为使被控对象得到充分激励输入随机

阶跃信号,训练完成后可得如图 3 所示的神经网络辨识器训练结果,均方误差绝对值小于 0.02;神经网络控制器训练结果及神经网络权值,分别如图 4 和表 1 所示。

#### 3.2 船舶发电机组转速 NNMRAc 与 PID 并行控制仿真结果

结合图 1 所示船舶发电机组转速 NNMRAc 与 PID 并行控制系统结构图,将训练完成后的 NNMRAc 控制器用于船舶发电机组转速控制。对比分析在 PID 控制器参数相同的情况下,船舶发电机组在 PID 控制下和在 NNMRAc 与 PID 并行控制作用下的调速性能。船舶发电机组转速给定发生阶跃变化时控制系统的响应如图 5 所示。

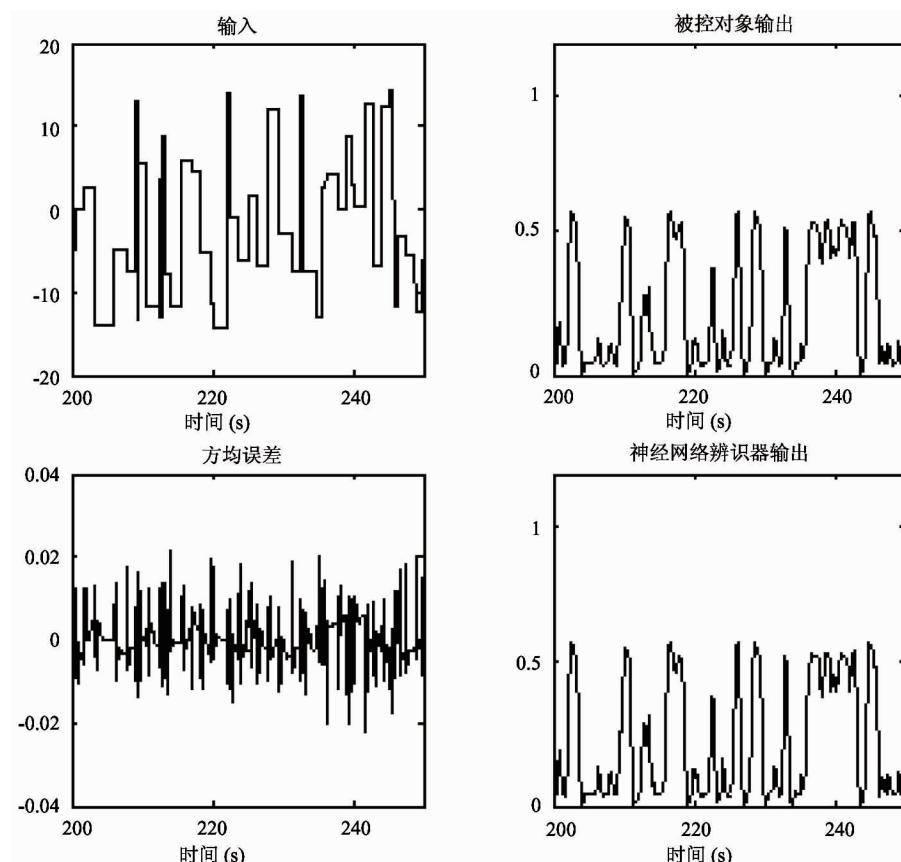


图 3 神经网络辨识器训练结果

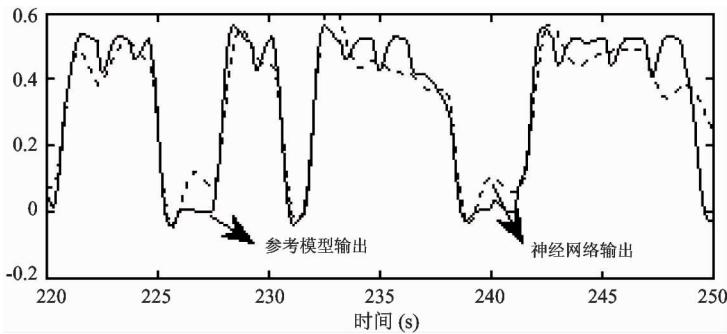


图4 神经网络控制器训练结果

表1 神经网络控制器权值数据

名称	权值
IW_y	$[ -0.0695, 0.1588, 0.1866, 0.2938, 0.5887, 0.7406, -0.7983, -0.7385, 0.3279, -0.6811, -0.23049, -0.0710, 0.5992; -0.5088, 0.1228, 0.3855, -0.4432, -0.0407, -0.5634, 0.7974, 1.7237, -0.3468, -1.2147, 0.5269, 0.5645, -0.0046 ]^T$
IW_u	$[ -0.2843, 0.2225, -0.3522, -0.1493, -0.3803, -0.2261, 0.1494, -0.0796, -0.2803, 0.4749, 0.1580, -0.2739, 0.0639 ]^T$
IW_r	$[ 0.4314, -0.2344, -1.4050, -2.3594, 0.6358, -1.4406, 1.0064, 1.3486, 1.3865, -1.1719, -1.7066, 2.1271, -0.9425; 2.2354, 0.5400, 1.6814, 1.8030, -1.5309, 1.8957, -1.0194, 0.1747, -1.233, -1.0789, 0.3107, 1.3922, 1.6296 ]^T$
IW_c	$[ -0.0233, 1.0344, -0.5683, -1.5456, 0.1560, -2.0763, 1.9708, 2.3198, -0.2061, -2.4005, -0.1835, 0.4736, -0.1763 ]$
B1_c	$[ 2.5275; -2.0107; -1.5658; 0.26305; 0.7290; -0.0930; -0.2053; -0.2300; 0.8061; -2.2873; -1.7047; -2.1495; 2.3049 ]$
B2_c	-0.9188

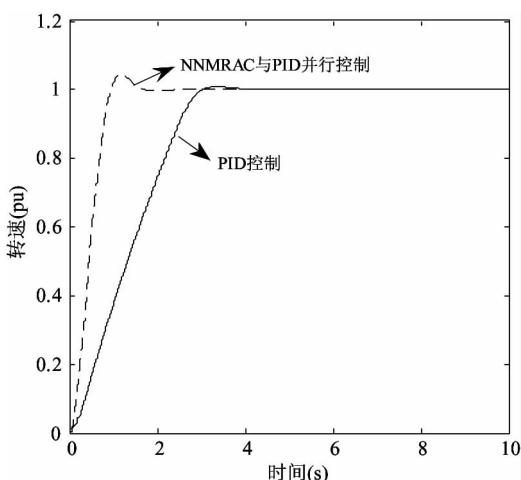


图5 船舶发电机组转速给定阶跃变化响应曲线

由图5所示的船舶发电机组转速给定阶跃变化响应曲线(纵轴转速(pu, per unit)表示转速标么值)可知,船舶发电机组转速给定发生阶跃变化时,

在PID控制器作用下,阶跃响应无超调,过渡时间为4.2s;在NNMRAC与PID并行控制作用下,转速上升阶段曲线斜率较PID控制器作用时大,峰值时间为1.14s,超调量为4.5%,过渡时间为1.8s。对比分析仿真结果,可得在NNMRAC控制器的作用下,提高了船舶发电机组转速控制阶跃响应的快速性,改善了转速响应灵敏度,体现了NNMRAC具有的学习能力及自适应能力。

为了进一步研究NNMRAC与PID并行控制作用下,船舶发电机组的转速调节性能,分别对船舶发电机组在5s至6s进行突加35%负载和油门执行器在5s至6s发生白噪声扰动情况下的转速进行了仿真分析,结果如图6、图7所示。

由图6所示的船舶发电机组突加35%负载转速曲线可知,在PID控制器和NNMRAC与PID控制器并行作用下的转速波动幅度均达2%,但在故障切除后的过渡过程中,在PID控制器作用下的转速

有超调,且过渡时间长于 NNMRAc 与 PID 并行控制作用下的过渡时间。由仿真结果可知,NNMRAc 提高了船舶发电机组转速响应的快速性,调速系统的灵敏度有所改善。

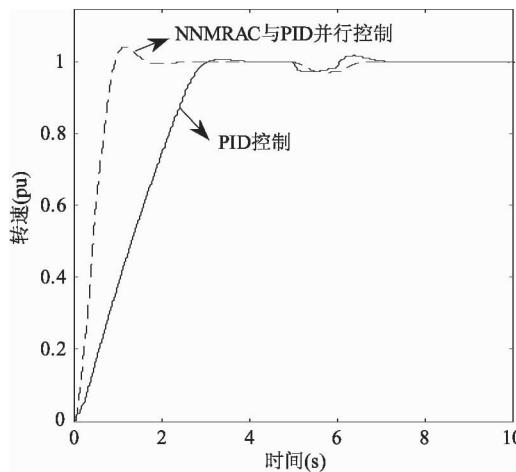


图 6 船舶发电机组突加 35% 负载转速曲线

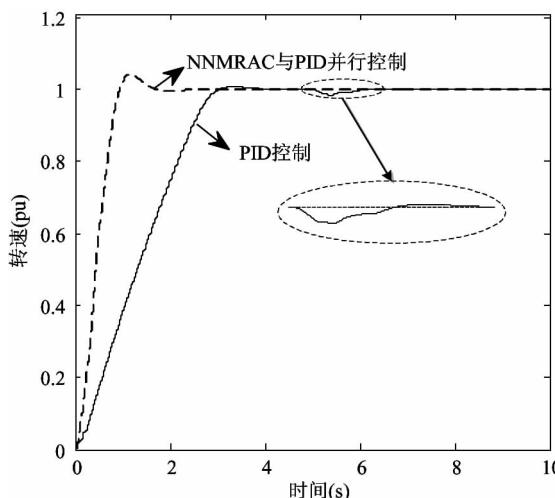


图 7 船舶发电机油门执行器白噪声扰动下转速曲线

由图 7 所示的船舶发电机油门执行器白噪声扰动情况下的转速曲线可知,油门执行器在白噪声干扰时,在 PID 控制器作用下发电机转速发生了波动响应,波动幅度达 2%,故障切除后,经过 1.5s 的调整过程转速恢复到额定转速;在 NNMRAc 与 PID 并行控制作用下的船舶发电机转速无转速波动,体现了 NNMRAc 控制的鲁棒性。

## 4 结 论

针对船舶电力系统中发电机组转速变化影响电

力系统的频率稳定问题,本文将神经网络模型参考自适应控制(NNMRAc)策略应用于船舶发电机组转速控制。NNMRAc 通过对船舶发电机组广义被控对象的神经网络辨识获得控制器算法,实施控制。仿真结果表明,NNMRAc 与 PID 并行控制,能够使发电机的转速输出跟踪给定的参考模型的转速变化而达到控制的目的,提高了船舶发电机组转速阶跃响应的快速性,改善了调速系统的灵敏度。

## 参 考 文 献

- [1] Whitaker H P, Yamron J, Kezer A. Design of model-reference adaptive control systems for aircraft. Report R-164, Cambridge: MIT Press, 1958
- [2] 汪镭,周国兴,吴启迪.参数在线跟踪的交流传动系统双神经网络模型参考自适应控制.中国电机工程学报,2001, 21(8):114-119
- [3] 王丙元,冯辉.基于定子电流的模型参考自适应感应电机转速估计.电机与控制学报,2013, 17(9):48-56
- [4] 王庆龙,张兴,张崇巍.永磁同步电机矢量控制双滑模模型参考自适应系统转速辨识.中国电机工程学报,2014, 34(6):97-102
- [5] 尹忠刚,刘静,钟彦儒等.基于双参数模型参考自适应的感应电机无速度传感器矢量控制低速性能.电工技术学报,2012, 27(7):127-130
- [6] Zhang S, Luo F L. An improved simple adaptive control applied to power system stabilizer. *IEEE Transactions on Power Electronics*, 2009, 24(2): 369-375
- [7] 郁能灵,王鹏,倪明杰.大型船舶电力系统关键技术与应用.北京:科学出版社,2012
- [8] 施伟峰,许晓彦.船舶电力系统建模与控制.北京:电子工业出版社,2012
- [9] Yeager K E, Willis J R. Modeling of emergency diesel generators in an 800 megawatt nuclear power plant. *IEEE Transactions on Energy Conversion*, 1993, 8 (3): 433-441
- [10] Franklin G F, Powell J D, Emami-Naeini A. *Feedback Control of Dynamics Systems*. New Jersey: Addison-Wesley, 2004. 139-140
- [11] 施伟峰.船舶柴油发电机转速人工神经网络控制.上海海事大学学报,2006, 27(3):79-83
- [12] Møller M F. A scaled conjugate gradient algorithm for fast supervised learning. *Neural networks*, 1993, 6(4): 525-533

# Neural network based model reference adaptive control of the speed of a marine generator set

Zhang Wei, Shi Weifeng, Xu Lixia

(Department of Electrical Automation, Shanghai Maritime University, Shanghai 201306)

## Abstract

The neural network based model reference adaptive control (NNMRAC) was used as a control tactics to investigate the control of the nonlinear, time-varying rotation speed of a marine generator set to achieve the better control quality. In this study, a second-order transfer function model was established for the diesel generator set. The multilayer feed-forward topological structure was adopted in both the neural network identifier and controller of the model reference adaptive control (MRAC). The scaled conjugate gradient back-propagation algorithm was used to optimize the performance of the learning algorithm. After the learning process, the NNMRAC controller and the conventional PID controller conducted their parallel control for the marine generator set. The simulation results showed that both the rapidity and sensitivity of the speed control system of the marine generator set were all improved.

**Key words:** marine generator set, neural network, model reference adaptive control (MRAC), speed control, scaled conjugate gradient algorithm