

基于神经网络的双馈风电机组转速PID控制仿真

童菲¹, 晁勤², 袁铁江², 李玉军³

(1. 华为技术有限公司, 广东 深圳 518129; 2. 新疆大学电气工程学院, 新疆 乌鲁木齐 830008;
3. 西安理工大学自动化学院, 陕西 西安 710048)

摘要: 为了提高双馈风电机组的转速控制性能, 采用了基于BP神经网络的PID控制方案和基于RBF神经网络辨识的PID控制方案, 在推导出双馈风电机组暂态电势恒定情况下随风速变化的二阶转速调节模型基础上, 分别编制仿真程序, 对风电机组转速控制进行了跟踪仿真分析。针对上述两种方案的缺陷, 提出了基于RBF网络辨识的单神经元网络PID控制和基于RBF网络辨识的BP神经网络PID控制两种改进控制方案, 达到了优化风电机组转速控制性能的目的。

关键词: 人工神经网络; PID控制; 双馈风电机组转速控制; BP网络; RBF网络

ANN-PID control and simulation for rotating speed control of doubly-fed generator

TONG Fei¹, CHAO Qin², YUAN Tie-jiang², LI Yu-jun²

(1. Huawei Technology Co., Ltd, Shenzhen 518129, China; 2. Faculty of Electrical Engineering, Xinjiang University, Urumchi 830008, China; 3. Faculty of Automatization, Xi'an University of Technology, Xi'an 710048, China)

Abstract: For improving the quality of rotating speed control of doubly-fed generator, BPNN(back propagation neural network) PID controller and RBFNN (radial basis function neural network) PID control schemes are investigated in the paper. On the basis of building the second-order rotating speed control model of doubly-fed generator with variable wind speed and constant transient voltage, the simulation programs are programmed respectively and applied into the model to simulate rotating speed control of the generators. To avoid defects of these two schemes above, neuro element PID controller based on RBFNN identification and BPNN PID controller based on RBFNN identification are brought forward which has obtained satisfied control effects.

This project is supported by National Natural Science Foundation of China(No.50667002) and Key Item of Xinjiang Education Department(No.XJEDU2008I62).

Key words: ANN; PID control; doubly-fed generator rotating speed control; back propagation neural network (BPNN); radial basis function neural network(RBFNN)

中图分类号: TM743 文献标识码: A 文章编号: 1674-3415(2009)19-0014-05

0 引言

近年来, 随着人工神经网络研究的进展, 神经网络越来越多地应用于控制领域的各个方面。从过程控制、机器人控制、生产制造、模式识别直到决策支持都有许多应用神经网络的例子。而目前, 风能作为一种绿色可再生能源, 风能发电日趋受到世界各国的普遍重视。在此大环境下, 本文将神经网络与传统PID控制器结合起来, 通过它们的有机结

合来取长补短, 构成新型控制器, 将其应用于目前的热门能源产业风力发电上, 来实现提高双馈异步风电机组的转速控制性能。

1 双馈风力发电机组数学建模方法

变速恒频双馈风电机组的动态控制模块结构如图1所示, 本文主要针对风速变化通过桨距角控制模块控制风力机和双馈异步发电机的输出转速, 假定双馈风电机组暂态电势恒定, 因此变频器模型及转子电气控制部分模型不考虑, 简化后数学模型主要环节包括: 风速模型、风力机模型、异步发电机模型、桨距角控制系统模型。其中风速模型共分为

基金项目: 国家自然科学基金项目(50667002); 新疆教育厅重点项目(XJEDU2008I62)

基本风, 阵风, 渐变风和随机风四种^[1,2], 其数学表达式略。

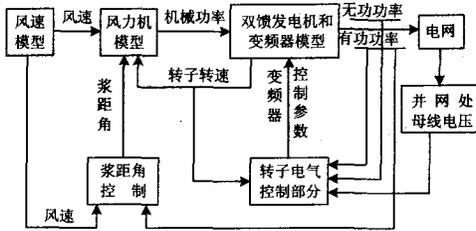


图1 双馈风电机组控制模型结构简图

Fig.1 Doubly-fed generator control model structure

1.1 风力机数学模型^[3]

风力机转矩模型为

$$M_w = \frac{1}{2} \pi \rho C_p R^3 \frac{V_w^2 \Omega_N}{\lambda P_N} \times 10^{-3} = \frac{P_w \Omega_N}{\Omega P_N} \times 10^{-3} \quad (1)$$

其中: M_w 为风力机叶片转矩; ρ 为空气密度; R 为叶片半径; V_w 为作用于叶片的风速; $\lambda = \Omega R / V_w$ 为叶尖速比; $\Omega = 2\pi n / 60$ 为叶片机械角速度; Ω_N 为风力机额定机械角速度; P_N 为风力机额定功率; C_p 为风能转换系数, 反映了风力机叶片捕获风能的能力, 是叶尖速比和叶片桨距角 β 的非线性函数, 本文采用如下的拟合函数:

$$C_p = c_1 (c_2 - c_3 \beta - c_4 \beta^\alpha - c_5) e^{-c_6 \lambda} \quad (2)$$

其中: $c_1 = 0.5$, $c_2 = 1.5V_w / \Omega$, $c_3 = 0$, $c_4 = 0.22$, $c_5 = 6.15$, $c_6 = 0.21V_w / \Omega$, $\alpha = 2$ 。

风力机传动部分模型为:

$$\frac{dM_m}{dt} = \frac{1}{T_w} (M_w - M_m) \quad (3)$$

式中: M_m , M_w 分别为发电机轴上的机械转矩和风力机的机械转矩; T_w 为风力机惯性时间常数。

1.2 双馈异步发电机数学模型^[4]

双馈异步发电机采用忽略定子绕组暂态的机电暂态模型。由于本文主要研究转速变化时的调节规律, 当不考虑定子绕组暂态电势 E' 变化时, 也就是暂态电势 E' 恒定时, 双馈异步发电机模型为:

$$T_j \frac{ds}{dt} = (M_E - M_m) \quad (4)$$

其中: T_j 为转子惯性时间常数; s 为双馈异步发电机的滑差 $s = (\omega_0 - \omega_r) / \omega_0$; ω_0 为定子磁场旋转角速度, ω_r 为转子旋转角速度; M_E , M_m 分别为发电机的电磁转矩和输入机械转矩。

1.3 桨距角控制数学模型

经过简化推导可得变桨距机构数学模型为:

$$\frac{d\beta}{dt} = \frac{1}{T_\beta} (\beta_{ref} - \beta) \quad (5)$$

式中: T_β 为时间常数, β_{ref} 为参考桨距角。

1.4 双馈风电机组转速控制数学模型

将式(4)对 t 作微分后, 与式(3)、式(5)联立整理得

$$T_j \frac{d^2 s}{dt^2} + T_j \frac{ds}{dt} = \frac{dM_E}{dt} + \frac{M_E}{T_w} - \frac{M_w}{T_w} \quad (6)$$

由电磁转矩公式

$$M_E = \frac{2M_{E_{max}}}{s_{LJ} + \frac{s_{LJ}}{s}} \left(\frac{U}{U_c} \right)^2 \quad (7)$$

式中: s_{LJ} 为临界滑差, U , U_c 分别为机端实际电压和机端额定电压, 因为 s 远小于 1, 且 $s_{LJ} \gg s$, 所以

$$M_E \approx \frac{2M_{E_{max}}}{s_{LJ}} \left(\frac{U}{U_c} \right)^2 = \frac{2M_{E_{max}}}{s_{LJ}} \left(\frac{U}{U_c} \right)^2 \cdot s \quad (8)$$

将其代入式(6), 且由 n 阶后向差分定义 $\nabla^n f(k) = \nabla^{n-1} f(k) - \nabla^{n-1} f(k-1)$ 代入后整理得:

$$\left[T_j + \left(\frac{T_j}{T_w} - \frac{2M_{E_{max}}}{s_{LJ}} \right) \left(\frac{U}{U_c} \right)^2 - \frac{2M_{E_{max}}}{T_w s_{LJ}} \left(\frac{U}{U_c} \right)^2 \right] \cdot s(k) + \left[- \left(\frac{T_j}{T_w} - 2 \frac{M_{E_{max}}}{s_{LJ}} \right) \left(\frac{U}{U_c} \right)^2 - 2T_j \right] \cdot s(k-1) + T_j \cdot s(k-2) = \frac{M_w}{T_w} \quad (9)$$

以 750 kW 变速恒频风电机组为例, 各项参数值为: 风力机桨叶半径 $R=24.2$ m; 空气密度 $\rho=1.29$ kg/m³; 叶尖速比 $\lambda = \Omega R / V_w = 56.4 / V_w$; 当额定风速为 8 m/s 时, 风力机额定机械角速度 $\Omega_N = 159$ rad/min; 叶片机械角速度 $\Omega = 2\pi n / 60 = 2.33$ rad/min; 风力机额定功率 $P_N = 750$ kW; 齿轮箱额定功率 $P_w = 825$ kW; 发电机转动部分惯性时间常数 $T_j = 7.1$ s, 风力机与发电机之间机械传动部分时间常数 $T_w = 0.5$ s。发电机额定滑差 $s_{LJ} = 1.33\%$; 机端额定电压 $U_c = 690$ V; 机端实际电压 $U = 690$ V; 发电机最大电磁转矩 $M_{E_{max}} = 1.282$ (均为标么值)。

将各值代入式(2), 求得风能转换系数为:

$$C_p = 0.065V_w - 0.00074\beta^2 - 0.0207 \quad (10)$$

由桨距角模型式(5)可得:

$$\beta = \beta_{ref} - T_\beta \frac{d\beta}{dt} \quad (11)$$

式中: 令 $T_\beta = 1$ s, $\beta_{ref} = 10$, 且将各参数代入式(1), 和(9)后, 整理后得到风电机组模型为:

$$-557s(k) + 164.382s(k-1) + 7.1s(k-2) = 1.4 \times 10^{-5} V_w^4 - \left[1.246 \times 10^{-5} - 3.2 \times 10^{-7} \frac{d\beta}{dt} + 1.6 \times 10^{-7} \left(\frac{d\beta}{dt} \right)^2 \right] V_w^2 \quad (12)$$

式(12)中 V_w 为风速,是风电机组的输入变量,而 β 则相当于控制量 u ,等式右边项中 V_w 即相当于输入风速信号,本文中输入指令给定阶跃信号时,模拟输入阵风;输入指令给定斜坡信号时,模拟输入渐变风;输入指令给定随机正弦信号时,模拟输入随机风。对式(12)方程右边项作后向差分,整理和近似代入后得双馈风力发电机组转速控制模型为:

$$s(k) = 0.295s(k-1) - 0.0127s(k-2) + 0.18u(k-1) + 0.2u(k-2) \quad (13)$$

2 基于多种神经网络整定的 PID 控制器在双馈风电机组转速控制上的应用^[5]

针对基于BPNN(BP神经网络)的PID控制方案和基于RBFNN辨识的PID控制方案以及改进后的基于RBFNN辨识的单神经元NN PID控制和基于RBFNN辨识的BPNN PID控制方案,分别编程实现了双馈风电机组的转速控制。算法流程图限于篇幅略。

2.1 阵风输入时各神经网络PID控制器仿真

当输入阵风时,输入指令为 $rin(k) = 1.0$ 。

(1) BP神经网络PID控制器^[6]

BP网络结构选3-5-3,学习速率 $\eta = 0.2$,惯性系数 $\alpha = 0.4$ 。加权系数初始值为 $[-0.5, 0.5]$ 上的随机值。采样时间为6s,跟踪结果图2可知,BPNN有着全局学习神经网络的缺点,上升时间较长,学习速度较慢,但几乎无超调量。

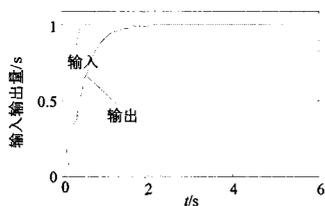


图2 BPNN滑差跟踪曲线
Fig.2 BPNN slip tracking curve

(2) RBF辨识的神经网络PID控制器^[7]

RBF网络结构选4-5-1。权向量初始值设为10,网络中心矢量取30,网络基宽矢量取40。积分、微分、比例学习速率为 $\eta_p = 1, \eta_i = 1, \eta_d = 1$ 。

采样时间为3s,由图3可知RBFNN控制精度高,快速响应性较好,参数实现了自整定,但在开始的1s左右,超调量略大,且振荡次数多。

(3) 基于RBF神经网络辨识的单神经元网络PID控制器

RBF网络结构选4-5-1,权向量初始值设为 $[-1,1]$

上的随机值,网络中心矢量取0.1,网络基宽矢量取30。 k_p, k_i, k_d 初始值分别为-20, 160, 55,比例、积分、微分学习速率为 $\eta_p = 0.9, \eta_i = 0.9, \eta_d = 0.4$ 。采样时间为6s,由图4可知,跟踪曲线超调量很大,且在约11s的时间内会有较小程度的振荡,这种不稳定性在风电机组转速控制实际应用中可能会产生问题。

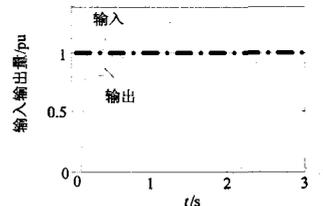


图3 RBFNN滑差跟踪曲线
Fig.3 RBFNN slip tracking curve

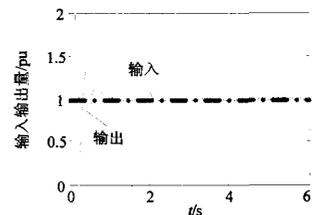


图4 滑差跟踪曲线
Fig.4 Slip tracking curve

(4) 基于RBF神经网络辨识的BP神经网络PID控制

RBF网络结构选4-5-1,权向量初始值设为 $[-1,1]$ 上的随机值,网络中心矢量取0.1,网络基宽矢量取30。BP网络结构选3-5-3,加权系数初始值为 $[-0.5,0.5]$ 上的随机值。采样时间为6s,参数变化图6说明参数自适应调整,很快稳定在最优值。跟踪结果图5和BPNN PID控制器跟踪曲线图2相比较,快速性明显提高,且保持了BPNN超调量很小的优点,减小了风电对电网造成频率雪崩和低频振荡的发生几率。

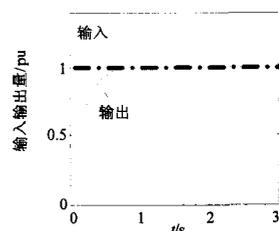


图5 滑差跟踪曲线
Fig.5 Slip tracking curve

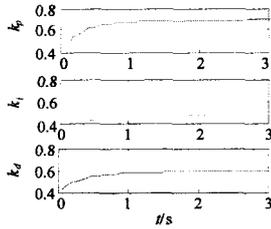


图 6 PID 参数自适应整定曲线

Fig.6 Adaptive PID parameter tuning curve

2.2 渐变风输入时各神经网络 PID 控制器仿真

输入渐变风, 输入指令为斜坡信号 $rin(k) = 0.01k$ 。

(1) BP 神经网络 PID 控制器

采样时间为 6 s, 跟踪效果及误差曲线如图 7 和图 8 所示, 可知该种控制器准确性不佳, 误差逐渐增加。

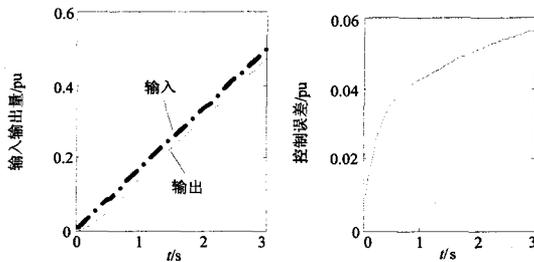


图 7 滑差跟踪曲线

Fig.7 Slip tracking curve

图 8 误差曲线

Fig.8 Error curve

(2) RBF 辨识的神经网络 PID 控制器

采样时间为 6 s, 跟踪效果及误差曲线如图 9 和图 10 所示, 跟踪曲线稳定后其误差比 BPNN 略小, 保持在 0.026 左右, 准确性优于 BPNN。

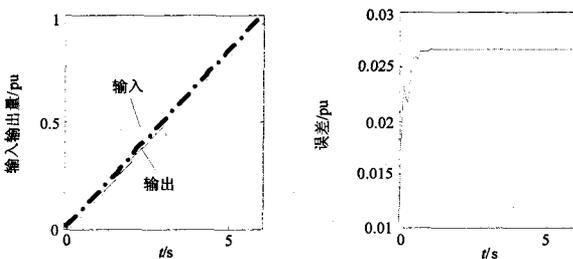


图 9 滑差跟踪曲线

Fig.9 Slip tracking curve

图 10 误差曲线

Fig.10 Error curve

(3) 基于 RBF 神经网络辨识的单神经元网络 PID 控制器

采样时间为 6 s, 跟踪效果和误差曲线如图 11 和图 12 所示。改进后的 ANN-PID 控制器误差值很

小, 几乎为零, 明显优于其他类型 ANN-PID。

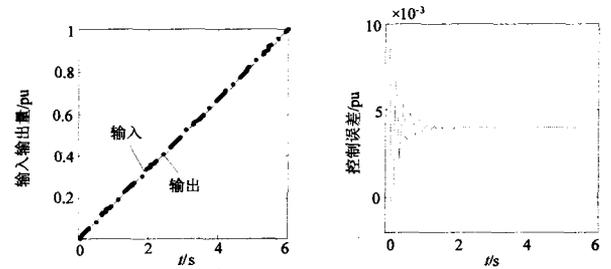


图 11 滑差跟踪曲线

Fig.11 Slip tracking curve

图 12 误差曲线

Fig.12 Error curve

(4) 基于 RBF 神经网络辨识的 BP 神经网络 PID 控制

采样时间为 3 s, 图 13 和图 14 所示跟踪和误差曲线和图 7 中 BPNN PID 控制器及图 11 中 RBFNN PID 控制器跟踪曲线相比较, 误差值呈下降趋势。

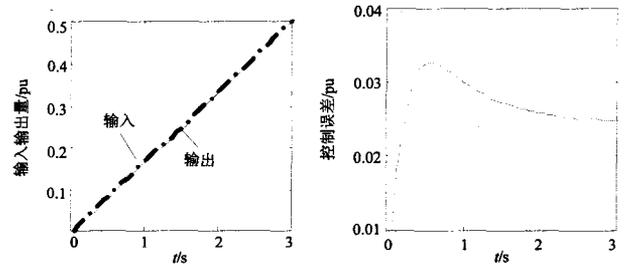


图 13 滑差跟踪曲线

Fig.13 Slip tracking curve

图 14 误差曲线

Fig.14 Error curve

2.3 随机风输入时各神经网络 PID 控制器仿真

当输入随机风, 输入指令为正弦信号 $rin(k) = 2 * \sin(0.01 * p_i * k)$, 参考模型指令信号为 $yrou(k) = 0.2 * yrou(k-1) + 0.6 * rin(k)$ 。

(1) BP 神经网络 PID 控制器

采样时间为 30 s, 跟踪效果如图 15 所示, 其误差值较大。

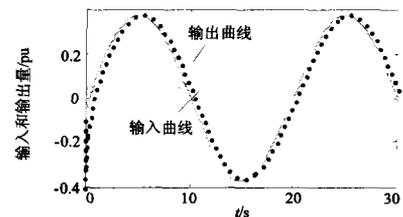


图 15 滑差跟踪曲线

Fig.15 Slip tracking curve

(2) RBF 辨识的神经网络 PID 控制器

采样时间为 18 s, 跟踪效果如图 16 所示。其误差值变小。

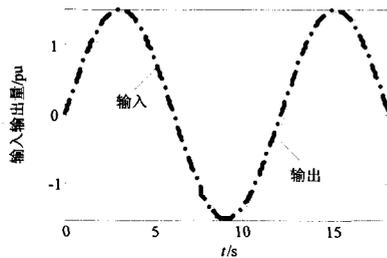


图 16 滑差跟踪曲线
Fig.16 Slip tracking curve

(3) 基于 RBF 神经网络辨识的单神经元网络 PID 控制器

采样时间为 18 s, 跟踪曲线如图 17 所示, 其稳定后误差值较小, 具有较好的准确性。

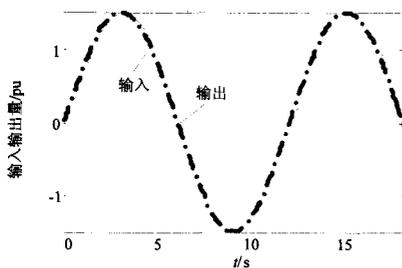


图 17 滑差跟踪曲线
Fig.17 Slip tracking curve

(4) 基于 RBF 神经网络辨识的 BP 神经网络 PID 控制

采样时间为 18 s, 跟踪效果如图 18 所示, 其误差值相对较小, 对电力网的频率质量影响小。

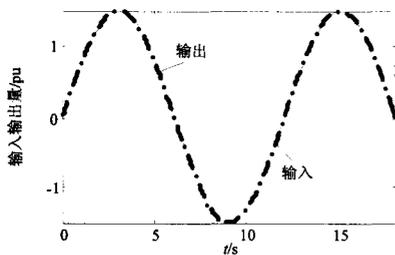


图 18 滑差跟踪曲线
Fig.18 Slip tracking curve

3 结束语

本文在推导出了双馈异步风力发电机组转速控制模型基础上, 提出了一些基于神经网络对其进行 PID 整定控制其转速的方法。

首先提出了基于 BP 算法的 PID 参数整定方法。通过仿真, 揭示了这种控制结构在学习训练中, 反应比较“迟钝”, 调节时间长, 对跟踪渐变风和随机风的跟踪误差较大。而对于 RBF 网络辨识的 PID

控制器仿真后, 和 BPNN 比较可知: 在输入阵风时, 快速响应时间短, 快速性较好, 但超调量略大, 且振荡次数较多; 输入渐变风时和随机风时, 误差比 BPNN 小, 准确性优于 BPNN。

最后将 RBF 网络作为辨识器, 单神经元和 BPNN 作为控制器分别进行复合 PID 控制双馈风力发电机组的转速, 仿真结果表明, 改进后控制精度高, 效果好, 参数实现了自整定, 转速瞬态调整率小和稳定时间短, 克服了常规控制器所不能避免的一些弊端, 提高了控制效果。

参考文献

- [1] Slootweg J G Wind Power Modeling and Impact on Power System Dynamics,PHD Thesis [D]. Ridderprint Offset drukkerij B.V. Ridderkerk, Netherlands:123-130.
- [2] WU Xue-guang, et al. Application of Models of the Wind Energy Conversion System to Wind Power Dynamic Analysis[A]. in: Proceedings POWERCON '98. International Conference on Power System Technology [C]. 1998.1406 -1411.
- [3] 闫广新, 吐尔逊, 晁勤. 交流励磁双馈风力发电机组的稳定性仿真分析[J].继电器, 2007, 35 (14) :7-9. YAN Guang-xin, Tuerxun, CHAO Qin. Analysis of Simulation of Stability of AC Excited Double-fed Wind Generator[J]. Relay,2007, 35 (14) :7-9.
- [4] 李光中, 肖强晖, 张文飞. 双馈电机数学模型及其应用[J]. 微电机, 2002, 35 (3): 18-20. LI Guang-zhong, XIAO Qiang-hui, ZHANG Wen-fei. Mathematical Model of Double-fed Motor and Applications, 2002, 35 (3): 18-20.
- [5] 刘金琨. 先进 PID 控制及 MATLAB 仿真(第 2 版)[M]. 北京:电子工业出版社, 2004.87-96. LIU Jin-kun. Advanced PID Control and MATLAB Simulation[M].Beijing: Publishing House of Electronics Industry, 2004.87-96.
- [6] 朱海峰, 李伟, 张林. 基于 BP 神经网络整定的 PID 控制[J]. 动力学与控制学报, 2005, 3(4) :93-96. ZHU Hai-feng, LI Wei, ZHANG Lin. PID Control Based on BP Neural Network[J]. Journal of Dynamics and Control, 2005, 3(4):93-96.
- [7] 林嘉宇, 刘莹. RBF 神经网络的梯度下降法中的学习步长优化[J]. 信号处理, 2002, 18(1) :43-48. LIN Jia-yu, LIU Ying. Learning Rate Refining for Gradient Descent Method of RBF Neural Networks[J].Signal Processing,2002,18(1):43-48.

收稿日期: 2008-08-22; 修回日期: 2008-10-18

作者简介:

童菲(1986-), 女, 学士, 助理工程师, 主要研究方向为控制理论与控制工程;

晁勤(1959-), 女, 教授, 博士生导师, 主要研究方向为电力系统综合自动化及风力发电技术与教学; E-mail:cqtdx@163.com

袁铁江(1975-), 男, 博士, 讲师, 主要研究方向为风电并网技术。