

DOI:10.19651/j.cnki.emt.2212042

基于模糊 RBF 神经网络的风电机组变桨控制研究 *

陈德海^{1,2} 陈志文¹ 李明¹ 赖正贵¹ 李志远¹

(1.江西理工大学电气工程与自动化学院 赣州 341000; 2.中国科学院赣江创新研究院 赣州 341000)

摘要:针对大型风力发电机变桨控制受外部干扰和参数变化大、造成输出功率不稳定的问题,提出一种智能控制的算法,在 RBF 神经网络基础上增加模糊算法,利用模糊 RBF 神经网络实时在线调整 PID 参数。当实际风速偏离额定风速时,科学调整风机桨距角,使风机所获得的空气动力转矩发生变化,从而在额定功率附近保持风力机输出功率的相对稳定。据此搭建了风电机组各模块的数学模型,并在 MATLAB/Simulink 上搭建了仿真模块。实验结果表明:基于上述的方法控制效果相比传统 PID 控制和常规 RBF 神经网络 PID 控制,响应更快、风能利用系数性能超调更小、功率输出更稳定,更有利风力发电机组的系统稳定性。

关键词:风力发电机;变桨控制;RBF;模糊 RBF 神经网络

中图分类号: TM614 文献标识码: A 国家标准学科分类代码: 510.8

Research on wind turbine pitch control based on fuzzy RBF neural network

Chen Dehai^{1,2} Chen Zhiwen¹ Li Ming¹ Lai Zhenggui¹ Li Zhiyuan¹

(1. School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou 341000, China;

2. Ganjiang Innovation Research Institute, Chinese Academy of Sciences, Ganzhou 341000, China)

Abstract: The variable pitch control of wind turbine is subject to external interference and large parameter changes, resulting in unstable output power, this paper introduces an intelligent control algorithm, adds a fuzzy algorithm on the basis of RBF neural network, and uses fuzzy RBF neural network control to adjust the PID parameters online and in real time. When the actual wind speed is higher than the rated wind speed adjust the blade pitch angle of the fan to change the aerodynamic torque obtained by the fan, make the fan output power stable near the rated power. In this paper, the mathematical model of each module of the fan is established, and the corresponding simulation model is established in the MATLAB/Simulink. According to the experimental results, the control effect based on the above method is better than traditional PID control and conventional RBF neural network PID control, with faster response, less overshoot of wind energy utilization coefficient performance, more stable power output, and more conducive to the system stability of wind turbine.

Keywords: wind turbine; variable pitch control; RBF; fuzzy RBF neural network

0 引言

风能是一种可再生能源,是安全、生态的^[1]。变桨距风力发电机组因其对风能的利用效率高而普遍被应用在发电领域。在风机运行过程中,当自然风速比风机额定风速快时,要保证风机安全运行不超载,就需要通过风机控制倾角,使风机输出功率恢复到额定功率附近并减少其波动值^[2-3]。当前,针对风电机组的变桨控制,已经有了不少调节策略, Venkaiah 等^[4-5]提出了基于模糊算法的变桨距调节。Colombo 等^[6]提出了一种滑模控制方法对桨距角进行

控制,并证明了其收敛性。由于 PID 控制算法在工程控制中具有很高的实用性,因此许多的研究人员采用 PID 独立变桨距控制算法,但是当等效参数测量不准确或发生变化时,传统的 PID 性能相对不稳定,所以研究人员通常使用其他算法与 PID 相结合。陈广华等^[7]提出了模糊 PID 控制方法,设计出了自适应模糊 PID 控制器来调节桨距角,通过模糊控制算法对 PID 参数完成自整定。郭鹏^[8]不仅运用了模糊 PID 控制方法,还在此基础上增加了一种对风速进行调节的模糊前馈方式。田猛等^[9]设计了一个径向基函数(radial basis function, RBF)神经网络 PID 变桨距控制

收稿日期:2022-11-11

* 基金项目:国家自然科学基金(61763015)项目资助

器,此控制器是通过神经网络自学习和参数自适应对 PID 控制器的 3 个参数进行修正。闫学勤等^[10]设计了一种改进型准比例积分谐振的变桨控制器,让变桨距角变化更加精准,但却使得桨距角的调整次数过多。苑晨阳等^[11]利用人工蜂群算法对 PID 参数进行整定,但在应用过程中容易参数模型难以获取,局限性大。易成宏等^[12]设计出一个 RBF 神经网络的风力机变桨滑模控制研究,滑模变结构造成的桨距角变化振动的问题由于神经网络控制的加入而得到了明显改善。

得益于上述各种方法的启示,本文在 RBF 神经网络 PID 控制上加入了模糊算法,将模糊权值和模糊输入信号结合神经网络,设计出模糊 RBF 神经网络 PID 的控制系统来调节桨距角,最后在软件 MATLAB/Simulink 上进行了仿真实验,并将其与传统 PID 控制系统和 RBF 神经网络 PID 控制进行了对比实验,证明本文提出的控制方法在各参数上的表现都优于另外两种控制方法,改进效果良好,桨距角变化更迅速、震荡更小,输出功率更加稳定、超调量更小。

1 风力发电机组变桨控制原理

1.1 风力机建模

当风通过风轮时,风的力量会作用于风轮,使得风轮产生力矩,从而风产生的能量就转化为了风轮的动能,图 1 为风通过叶轮的流体体积变化图,其中 SV_1 为进入叶轮前的流体体积,SV 为经过叶轮时的流体体积, SV_2 为通过叶轮后的流体体积。流体体积动能为:

$$E = \frac{1}{2} SV^3 \quad (1)$$

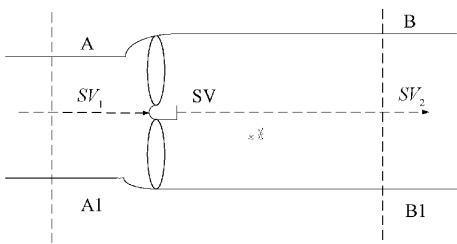


图 1 风经过风轮流体体积

根据 Euler 定律^[13]可知,风轮机所受到的力为:

$$F = \rho SV(V_1 - V_2) \quad (2)$$

式中: ρ 为空气密度,单位为 kg/m^3 。

风力机吸收的功率为:

$$P = Fv = \rho SV^2(V_1 - V_2) \quad (3)$$

最终通过推导得出风力机最大输入功率的值为:

$$P_{\max} = \frac{8}{27} \rho SV_1^3 \quad (4)$$

由贝兹(Betz)气动理论,通过式(1)和(4)可以得到,风力机的最大功率系数为:

$$C_p = \frac{P_{\max}}{E} = \frac{\frac{8}{27} \rho SV_1^3}{\frac{1}{2} \rho SV^3} = \frac{16}{27} \approx 0.593 \quad (5)$$

由此可知,风力机从风轮获取的功率最多也只有全部风能总量的 59%。剩下的能量有一部分在转换中消耗掉,另一部分则以游风的形式存储于风轮机下,也可以理解为风能留在尾流里变成了旋转动能。这说明了当自然风经过风力机时所提供的风力机的能量并不能全部转化,另一方面,获取的能量多少是由风能利用系数 C_p 所决定的,其相关数学模型公式为:

$$\left\{ \begin{array}{l} P_m = \frac{1}{2} \rho \pi C_p(\lambda, \beta) R^2 v_m^3 \\ C_p(\lambda, \beta) = 0.22 \left(\frac{116}{\lambda_i} - 0.4\beta - 5 \right) e^{-21.5/\lambda_i} \\ \frac{1}{\lambda_i} = \frac{1}{\lambda + 0.08\beta} + \frac{0.035}{\beta^3 + 1} \\ \lambda = \frac{\omega_r R}{v_m} \end{array} \right. \quad (6)$$

式中: P_m 为风轮捕获的功率; ρ 为空气的密度单位为 kg/m^3 ; v_m 为风速; ω_r 为风轮转速; λ 为叶尖速比; $C_p(\lambda, \beta)$ 为风能利用系数; β 为叶片桨距角; R 为风轮半径。图 2 是风能利用率系数 C_p 、叶尖速比 λ 、桨距角 β 三者的联系图。

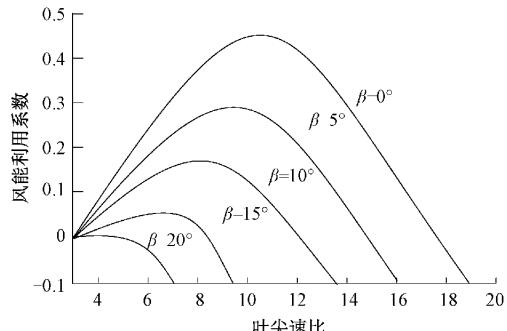


图 2 C_p 、叶尖速比以及 β 之间关系图

由图可得,在叶尖速比 λ 为一定数值的时候,桨距角 β 越小,风能利用系数的值就越大,当其为 0 度时利用率最高,同样的桨距角越大,风能利用率越小。因此,当风速比额定风速更低的时候,只需使得桨距角 β 为 0° 即可,当风速比额定风速更高时,就要调整桨距角角度使其变大,则风能利用系数变小,对风力发电机从风能中获得的能量进行控制,从而让风力发电机的输出功率稳定在额定功率附近而不过高。

1.2 传动系统建模

本文使用的风力发电机组是非直驱式的,式(7)为靠近风轮一侧低速轴的动力学模型,式(8)为在靠近发电机一侧的高速轴的动力学模型。

$$J_r \frac{d\omega}{dt} = T_r - T_D - \gamma T_m \quad (7)$$

$$J_r \frac{d\omega_g}{dt} = T_m - T_e \quad (8)$$

式中: J_r 为风轮的转动惯量; ω 为风轮转速; T_D 为系统阻力矩, $T_D = a + \frac{b}{\omega} + c\omega$, a, b, c 为常数; T_m 为转矩; γ 为齿轮箱增速比, $\gamma = \frac{\omega_g}{\omega}$, ω_g 为发电机转速。

通过式(7)和式(8)推导可知, 风力发电机组中传动系统总方程为:

$$(J_r + \gamma^2 J_g) \frac{d\omega}{dt} = T_r - T_D - \gamma T_e \quad (9)$$

1.3 发电机系统模型

发电机系统模型中所讨论的异步发电机被假定为理想发电机, 也就是忽略了铁磁饱和、磁滞、定子和转子齿槽效应以及涡流的影响^[8]。在发电机中, 三相定子绕组对称, 每个相位的磁动势和磁密度在气隙中产生一个正弦分布。而转子是一个对称的多相绕组, 每相也产生一个正弦分布的磁场气隙中的磁力和磁密度, 发电机的数学模型可以简化为:

$$\begin{cases} T_c = \frac{p_n m_1 U_1 r_2'}{(p_n m_g - w_c) \left[\left(r_1 - \frac{C_1 r_2' w_c}{p_n w_g - w_c} \right)^2 + (x_1 + C_1 x_2')^2 \right]} \\ P = T_c w_g \end{cases} \quad (10)$$

式中: P_n 是发电机极对数, m_1 是相数; U_1 为电网电压; C_1 为修正系数; w_c 为发电机同步转速; r_1 为定子绕组的电阻, x_1 为定子绕组的阻抗; r_2' 为归算后转子绕组的电阻; x_2' 为归算后转子绕组的电抗。

2 基于模糊 RBF 神经网络 PID 的控制器设计

2.1 模糊 RBF 神经网络结构

首先, 模糊 RBF 神经网络结构是通过 RBF 神经网络和模糊控制两者相结合而成^[14]。RBF 神经网络作为比较新颖的前馈神经网络之一, 包含了快速的学习速度, 简单的结构以及对任何非线性系统的最佳逼近能力等优点^[15-16]。因此使用 RBF 神经网络对模糊控制算法进行深度学习, 改进模糊控制系统中的模糊规则, 优化其中的隶属度函数, 能够明显的优化系统的整体性能。本文中使用的即是模糊 RBF 神经网络系统来调节风力机的桨距角。图 3 为模糊 RBF 神经网络结构示意图。

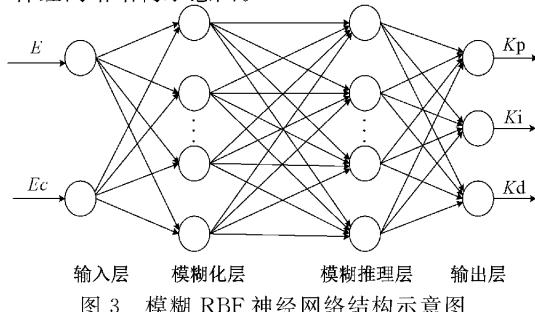


图 3 模糊 RBF 神经网络结构示意图

文章所设计的模糊 RBF 神经网络结构是两输入三输出的四层拓扑结构, 分别由第一层输入层、第二层模糊化层、第三层模糊推理层以及第四层输出层组成。分述如下:

1) 输入层。输入的信号偏差 E 和偏差变化率 E_c 与各个节点相连接, 不进行数据的特殊处理, 主要功能是把输入传递至下一层。函数表示为:

$$f_1(i, j) = I_1(i, j) = X_i \quad (11)$$

2) 模糊化层。将输入变量 E 和 E_c 进行模糊化整定, 设定模糊控制范围的相关参数, 确定偏差 E 、偏差率 E_c 、比例 K_p 、积分 K_i 和微分 K_d 的模糊数域。然后计算输入分量的隶属函数大小, 此处假设其为高斯基函数, 则有:

$$f_2(i, j) = \exp(I_2(i, j)), j = 1, 2, \dots, B \quad (12)$$

$$I_1(i, j) = \frac{(f_1(i, j) - c_{ji})^2}{2\sigma_{ij}^2} \quad (13)$$

式中: c_{ji} 为高斯型隶属函数的均值, σ_{ij} 为高斯型隶属函数的宽度值。其中: $i = 1, 2$; $j = 1, 2, 3, \dots, n$

3) 模糊推理层。该层设定了相对应的模糊规则, 并与模糊化层相连接以适应模糊规则的相对应, 它的每个节点都等同于一条规则。其函数表达式如下:

$$f_3(l) = I_3(l) = \prod_{i=1}^2 f_2(i, l) \quad (l = 1, 2, \dots, B^2) \quad (14)$$

式中: $s = s(l, i)$, S 由 i 和 l 两者共同决定的, 且 $s \in (1, 2, \dots, B)$, $s(l, i)$ 则由以下规则决定:

当 $l \bmod B = 0$ 时, $s(l, 1) = B, s(l, 2) = [(l - l \bmod B)/B]$ 。

$$\text{当 } l \bmod B \neq 0 \text{ 时, } s(l, i) = \begin{cases} l \bmod B, & i = 1 \\ [(l - l \bmod B)/B] + 1, & i = 2 \end{cases}$$

4) 输出层。该层功能是输出前面两层结构整定后的 K_p, K_i 和 K_d 这 3 个参数, 其函数表达式为:

$$f_4(m) = I_4(m) = \sum_{l=1}^{n^2} f_3(l) w_{lm} \quad (15)$$

$$\Delta k_m = f_4(m) = \frac{I_4(m)}{\sum_{l=1}^{n^2} f_3(l)}, \quad (m = p, i, d) \quad (16)$$

式中: m 为输出层节点数量; w_{lm} 为输出权重。

2.2 模糊 RBF 神经网络 PID 控制学习算法与控制系统设计

增量 PID 控制器:

$$i_q(k) = i_q(k-1) + [k_p(k-1) + \Delta k_p][e(k) - e(k-1)] + [k_i(k-1) + \Delta k_i]e(k) + [k_d(k-1) + \Delta k_d][e(k) - 2e(k-1) + e(k-2)] \quad (17)$$

系统的性能指标函数为:

$$E(k) = \frac{1}{2} e^2(k) \quad (18)$$

系统里的参数调节是通过梯度下降法来进行在线调节的, 其函数表达式为:

$$x(k) = x(k-1) - \eta \frac{\partial E}{\partial x} + \alpha \Delta x(k-1) \quad (19)$$

式中: η 为学习速率; α 为动量因子; x 为每个要改变的参数, 其中包括权重 w_{lm} 、隶属度函数中心值 c_{ij} 与宽度值 σ_{ij} 。

由式(11)~(16)可得:

$$\frac{\partial E}{\partial w_{lm}} = -e(k) \frac{\partial V}{\partial \Delta i_q} \frac{\partial i_q}{\partial k_m} \frac{f_3(l)}{\sum_{x=1}^{n^2} f_3(x)} \quad (20)$$

$$\frac{\partial E}{\partial c_{ij}} = \sum_{m=p,i,d} -e(k) \frac{\partial V}{\partial i_q} \frac{\partial i_q}{\partial \Delta k_m} \frac{\partial f_4(m)}{\partial f_2(i,j)} \frac{\partial f_2(i,j)}{\partial c_{ij}} \quad (21)$$

$$\frac{\partial E}{\partial \sigma_{ij}} = \sum_{m=p,i,d} -e(k) \frac{\partial V}{\partial i_q} \frac{\partial i_q}{\partial \Delta k_m} \frac{\partial f_4(m)}{\partial f_2(i,j)} \frac{\partial f_2(i,j)}{\partial \sigma_{ij}} \quad (22)$$

其中,

$$\frac{\partial i_q}{\partial \Delta k_m} = \begin{cases} e(k) - e(k-1), m = p \\ e(k), m = i \\ e(k) - 2e(k-1) + e(k-2), m = d \end{cases} \quad (23)$$

$$\frac{\partial f_4(m)}{\partial f_2(i,j)} = \frac{1}{\sum_{x=1}^{n^2} f_3(x)} \sum_{l=1}^{n^2} \left(w_{lm} - \frac{1}{\sum_{x=1}^{n^2} f_3(x)} \right) \lambda[l],$$

$$s(l,i)] f_2(\bar{i}, \bar{s}) \quad (24)$$

$$\frac{\partial f_2(i,j)}{\partial c_{ij}} = \frac{f_1(i) - c_{ij}}{\sigma_{ij}^2} f_2(i,j) \quad (25)$$

$$\frac{\partial f_2(i,j)}{\partial \sigma_{ij}} = \frac{(f_1(i) - c_{ij})^2}{\sigma_{ij}^3} f_2(i,j) \quad (26)$$

式中: $\lambda[j, s(l,i)] = \begin{cases} 1, & j = s(l,i) \\ 0, & j \neq s(l,i) \end{cases}$ 。 \bar{i} 表示非 i ; $\bar{s} = s(l,\bar{s})$ 。

上述算法过程中, 由模糊 RBF 神经网络控制初始值, 其中模糊 RBF 神经网络的参数辨识准确度与隐含层的节点数有关, 辨识精度随着节点数的增加而更精准, 但太多反而导致计算成本的提高, 所以本文控制算法中的隐含层节点数设置为 7 个, 这时的算法效果最为理想。学习速率 η 的取值范围为 $[0, 1]$, 当 η 过于小时, 学习效率太低, 当 η 过于

表 1 3MW 风力发电机组参数

参数名称	数值	参数名称	数值
风轮半径 R	47.5 m	发电机极对数 P_n	2
风轮转动惯量 J_r	$6.25 \times 10^5 \text{ kg/m}^2$	电网电压 U	690 V
发电机转动惯量 J_g	15 kg/m^2	齿轮箱轴系比 η	80
额定功率 P^*	3 MW	最大转速标幺值 ω_{max}	1.2 p.u
空气密度 ρ	1.225 kg/m^3	最低转速标幺值 ω_{min}	0.7 p.u
额定风速 V_c	12 m/s	额定转速标幺值 ω_e	1 p.u
切入风速 V_{in}	3 m/s	切出风速 V_{out}	25 m/s

根据变桨控制机制以及上述各参数构建的系统总体仿真模型如图 5 所示。分别由风速模块、模糊 RBF 神经网

大时, 控制系统将不稳定, 会震荡, 故经过多次测试后本文 η_{rbf} 取值为 0.3, η_{pid} 取值为 0.2。动量因子 α 影响网络权重, 本文取其值为 0.05, 网络权重分别设置为 0.3、0.4、0.1。当传统 PID 给各个参数分别为 $K_p = 0.3$, $K_i = 0.1$, $K_d = 0.3$ 时, 此时 PID 控制器控制桨距角震荡较小, 效果为 PID 控制中最好。

模糊 RBF-PID 控制系统原理如图 4 所示。

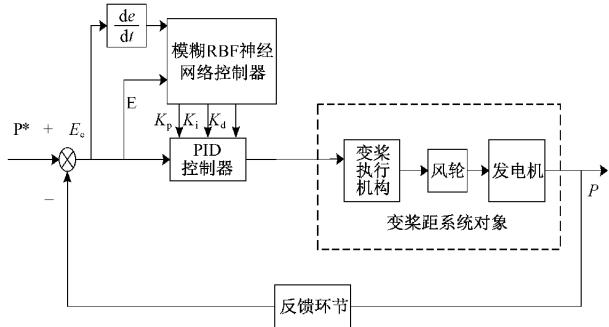


图 4 变桨距控制原理

变桨距控制系统中变桨控制器是模糊 RBF 神经网络与 PID 控制相结合而成的, 即在系统输入风力发电机输出功率误差 E 及其误差变化率 E_s 后, 首先通过 RBF 神经网络对模糊控制进行深度学习, 利用算法改进模糊控制系统中的模糊规则, 优化其中的隶属度函数, 最后传送至输出层, 将计算得到的 PID 控制器的参数变化量 Δk_p 、 Δk_i 和 Δk_d 同时输出, 实现对 PID 控制器的各个参数的实时在线调整, 从而可以有效地提高系统的整体性能。

3 变桨控制仿真模型与结果

3.1 仿真模型

通过分析风力发电机组变桨控制原理以及模糊 RBF 神经网络 PID 控制学习算法, 本文在仿真软件 MATLAB/Simulink 上搭建了额定功率为 3 MW 的风力机各个模块的仿真模型, 由于该额定功率数值比较大, 为了方便模糊 RBF 神经网络 PID 控制器控制和后续各类计算, 故采用整体缩放的方法将额定功率标准化, 具体的各仿真参数如表 1 所示。

根据变桨控制机制以及上述各参数构建的系统总体仿真模型如图 5 所示。分别由风速模块、模糊 RBF 神经网

络 PID 控制模块、风机模型、传动系统模型、发电机模型组成, 并有传统 PID 控制与 RBF-PID 控制与其对比。使用

风速模拟器模拟风速,将额定功率与输出功率整定后输入变桨控制器并计算出桨距角值,把桨距角值与风速、转速

输入到风机模型中,从而计算得到风机功率,最后经过发电机轴传动系统将其传送到发电机进行计算。

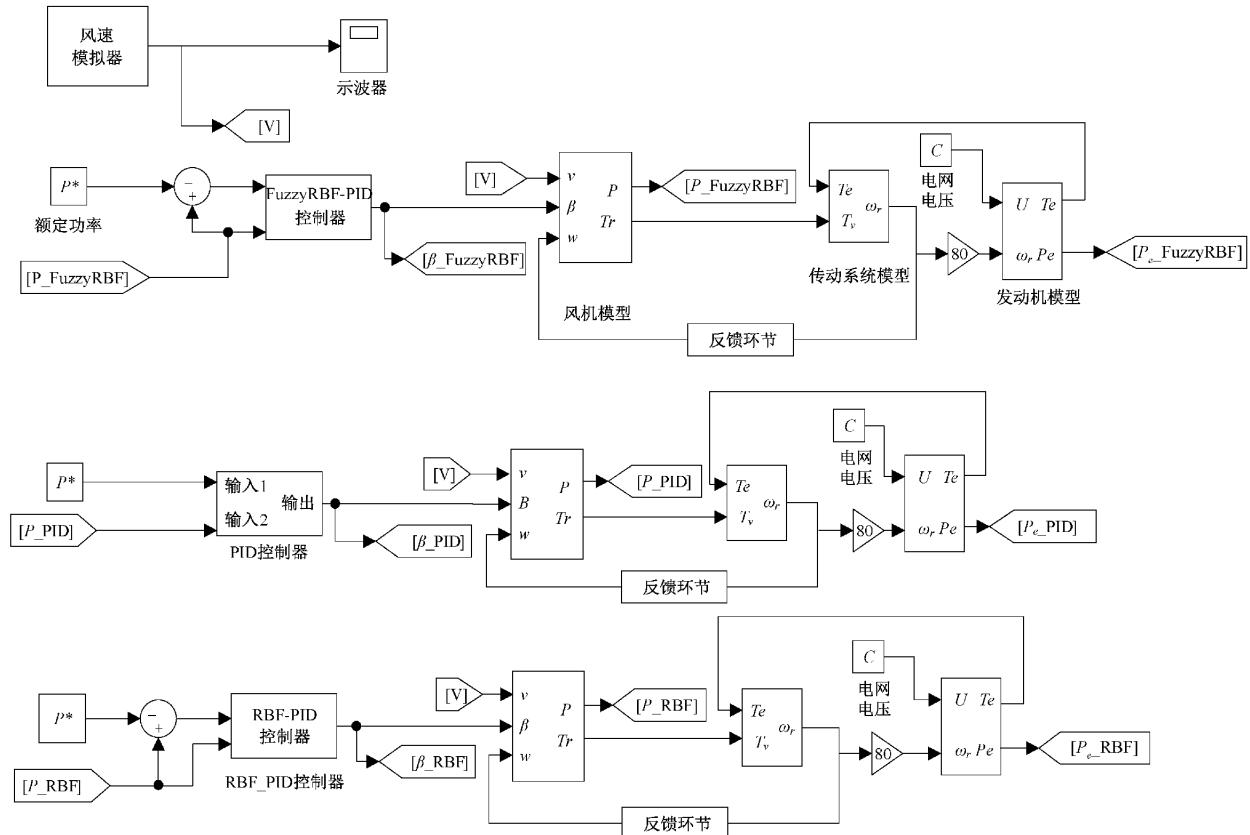


图 5 系统仿真模型

3.2 实验结果与分析

实验搭建的风力机仿真模型额定功率为 3 MW,分别模拟风速在低于额定风速的状态和在高于额定风速的状态,风速示意图如图 6 所示。

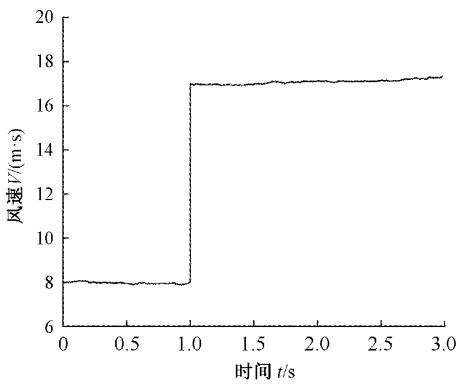


图 6 风速示意图

由前文分析可得,当经过风力机的风速小于风力机的额定风速时,此时只需要调节桨距角为 0° ,便能使得输出功率最大化输出,本文主要研究当切入风速高于额定风速时的情景,为了让输出功率在额定功率附近保持稳定,需要风机系统转换到最大功率跟踪模式,利用所设计的桨距

角控制模块调节桨距角,进而使得功率稳定。将本文提出的模糊 RBF 神经网络 PID 控制系统分别与传统 PID 控制系统和 RBF 神经网络 PID 控制系统进行仿真结果对比,在 MATLAB/Simulink 软件中进行仿真得到不同控制下的各仿真结果,如图 7~10 所示。

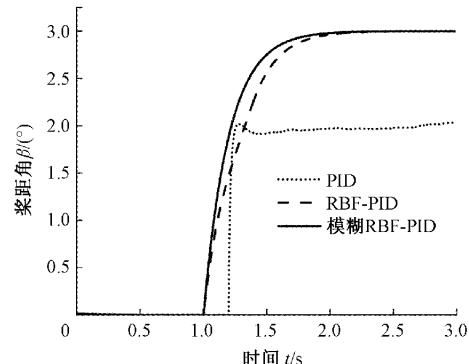


图 7 桨距角变化曲线

图 7 为桨距角变化对比图,由图可知,传统 PID 控制桨距角响应较慢,在风速变化后的 1.2 s 时才发生改变,在稳定下来后也一直有震荡;RBF-PID 控制和模糊 RBF-PID 控制桨距角响应迅速,当 1 s 时风速改变时可以及时作出

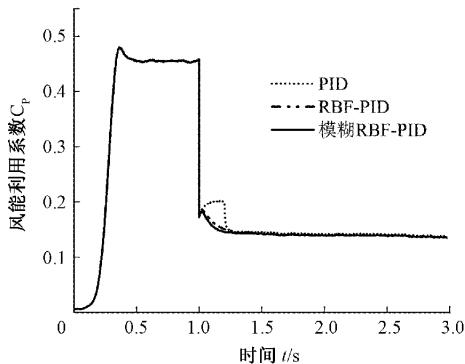


图 8 风能利用系数变化曲线

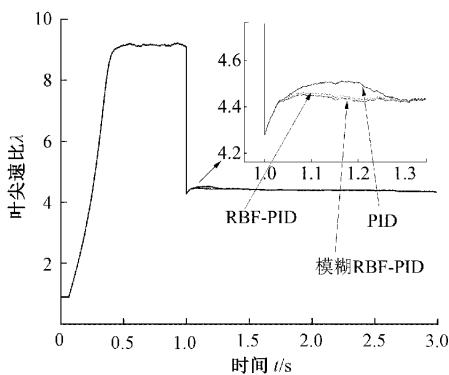


图 9 叶尖速比变化曲线

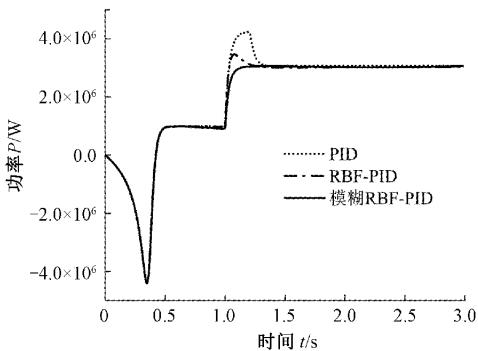


图 10 风力发电机输出功率

反应,且到达稳定后波动较小,其中 RBF-PID 控制到达稳定时间为 2.25 s,模糊 RBF-PID 控制到达稳定时间为 2 s,综上,模糊 RBF-PID 控制的桨距角变化效果为三者最好。图 8 为风能利用系数对比图,在风速没有达到额定风速时,3 种控制风能利用系数均为 0.453,在风速改变后,PID 控制超调最大,为 0.060,达到稳定的时间为 1.35 s;RBF-PID 控制超调较小,为 0.035,达到稳定的时间为 1.3 s;模糊 RBF-PID 控制超调最小,为 0.030,达到稳定的时间为 1.25 s,效果为三者间最优。图 9 为叶尖速比对比图,在风速改变后到达稳定的过程中,PID 控制超调量为 0.060,RBF-PID 控制超调量为 0.015,模糊 RBF-PID 控制超调量为 0.010。图 10 为风力发电机输出功率对比图,传统 PID 控制的功率超调率为 25%,RBF-PID 控制超调率为 12%,

模糊 RBF-PID 控制超调率为 2%,在到达稳定的时间上,三者分别为 1.4、1.35、1.25 s,由此可知,本文控制算法相比于传统 PID 控制和 RBF-PID 控制,在减少输出功率的超调和波动上效果更加优越,能够让输出功率稳定在额定功率附近,满足风力发电机组对功率稳定控制的基本要求。

4 结 论

针对大型风力发电机组变桨距控制系统问题,提出了一种模糊 RBF 神经网络控制算法,在额定功率为 3 MW 的风力机上设计了一种模糊 RBF 神经网络 PID 控制器来控制桨距角,解决了在风速高于额定风速时风力发电机输出功率波动大、可能超载的问题,使其稳定在额定功率附近。

模糊 RBF 神经网络 PID 控制系统不仅拥有一般模糊控制的优点,还拥有神经网络的自学习能力,它的内部参数可以不断优化,从而使系统克服非线性和时变性,满足系统动态和稳定的特点。仿真结果也表明了这一方法的优越性,该控制系统动、静态性能较好,鲁棒性强,减少了桨距角和输出功率的超调量和波动性,可以稳定的输出功率,比传统 PID 控制和 RBF 神经网络 PID 控制有更好的控制效果。根据文章方法的特点和设计思路,将其应用到更大功率的海上风力发电机变桨控制中,更能发挥其优势,这为风力发电大型化的发展趋势提供了一种相应技术支持。

参考文献

- [1] 王林富,许丹枫,赵湖珊,等.直驱永磁风力发电系统建模与仿真方法研究[J].电子测量技术,2019,42(20):44-50.
- [2] ZHANG Q, CHEN Z, CHENG M. Proportional resonant individual pitch control for mitigation of wind turbines loads[J]. IET Renewable Power Generation, 2013,7(3):191-200.
- [3] 李继超,胡文婷,陈超波,等.基于自抗扰控制的风电机组限功率算法研究[J].国外电子测量技术,2022,41(5):118-123.
- [4] VENKAIAH P, SARKAR B K. Hydraulically actuated horizontal axis wind turbine pitch control by model free adaptive controller[J]. Renewable Energy, 2020, 147:55-68.
- [5] 刘德.基于模糊算法的风力发电机变速变桨控制系统研究[D].南京:南京信息工程大学,2018.
- [6] COLOMBO L, CORRADINI ML, IPPOLITI G, et al. Pitch angle control of a wind turbine operating above the rated wind speed: A sliding mode control approach[J]. ISA Transactions, 2020,96:95-102.
- [7] 陈广华,张健,张坤婷,等.中小型风电机组变桨距控制算法研究[J].北京交通大学学报,2019,43(4):

- 102-108.
- [8] 郭鹏. 模糊前馈与模糊 PID 结合的风力发电机组变桨距控制[J]. 中国电机工程学报, 2010, 30(8): 123-128.
- [9] 田猛, 周腊吾, 陈浩, 等. 风电机组 RBF 神经网络 PID 独立变桨控制研究[J]. 电力电子技术, 2015, 49(12): 70-72.
- [10] 同学勤, 王维庆, 王海云. 基于 IQPI-R 的风力机独立变桨距控制策略研究[J]. 太阳能学报, 2020, 41(10): 229-235.
- [11] 苑晨阳, 李静, 陈健云, 等. 大型风电机组变桨距 ABC-PID 控制研究[J]. 太阳能学报, 2019, 40(10): 3002-3008.
- [12] 易成宏, 孙长乐, 孙启童, 等. 基于 RBF 补偿滑模变桨控制的风力机叶片颤振抑制[J]. 山东科技大学学报(自然科学版), 2021, 40(4): 109-117.
- [13] ANCA D. Centralised power control of wind farm with doubly fed induction generators[J]. Renewable Energy, 2006, 31(7).
- [14] 朱敏, 赵聪聪, 臧昭宇. 基于改进型模糊神经网络 PID 阀位控制研究[J]. 现代制造工程, 2022(1): 125-131.
- [15] 霍建霖, 袁园, 张镭. 基于 RBF 神经网络滑模控制的双尾鳍机器鱼[J]. 电子测量技术, 2022, 45(18): 86-90.
- [16] 赵岩, 周秦源, 邵念锋, 等. 基于 RBF 神经网络模糊 PID 控制的电液伺服系统[J]. 机电工程, 2022, 39(2): 244-249.

作者简介

陈德海, 副教授, 博士, 硕士生导师, 主要研究方向为风力发电技术。
E-mail: dhchen22@gia.cas.cn