

DOI:10.3969/j.issn.1001-4551.2017.06.017

# 基于 RBF 神经网络的风力发电机组系统辨识研究<sup>\*</sup>

杨震宇<sup>1</sup>, 王青<sup>1,2</sup>, 魏新刚<sup>1</sup>, 应有<sup>1,2</sup>, 孙勇<sup>1,2</sup>

(1. 浙江运达风电股份有限公司,浙江 杭州 310012;2. 风力发电系统国家重点实验室,浙江 杭州 310012)

**摘要:**针对风力发电机组精确的数学模型难以建立的特点,采用 RBF 神经网络对风电机组进行了系统辨识。通过对风力发电机组转矩环和桨距环的动态过程进行分析,设计了基于 RBF 神经网络算法的风力发电机组转矩环与桨距环的辨识系统,采用 RBF 基函数构成隐含层空间,RBF 参数确定后,非线性映射关系就确定了,将输入矢量直接映射到隐含层空间,对隐含层节点输出进行了线性加权求和,得到了输出层。研究结果表明,进行转矩环辨识时,辨识系统的输入信号为转矩给定,输出信号为发电机转速,辨识结果的误差率为 1%;进行桨距环辨识时,辨识系统的输入信号为桨距角,输出信号为发电机转速,辨识结果的误差率为 3%;采用 RBF 神经网络算法进行系统辨识具有较高的辨识精度和效率。

**关键词:**风力发电机组;RBF 神经网络;辨识

中图分类号:TM315;TK8

文献标志码:A

文章编号:1001-4551(2017)06-0639-05

## Identification of the wind turbine system based on RBF neural network

YANG Zhen-yu<sup>1</sup>, WANG Qing<sup>1,2</sup>, WEI Xin-gang<sup>1</sup>, YING You<sup>1,2</sup>, SUN Yong<sup>1,2</sup>

(1. Zhejiang Windey Co., Ltd., Hangzhou 310012, China; 2. State Key Laboratory of Wind Power System, Hangzhou 310012, China)

**Abstract:** Aiming at the problems of difficult to establish the accurate mathematical model of wind power generation, identification of the wind turbine based on RBF neural network was presented. The dynamic process of the torque loop and the pitch loop was simulated, RBF neural network algorithm was adopted to identification the torque loop and the pitch loop. RBF basis function was adopted to form space. If the hidden layer RBF parameters was determined, the nonlinear mapping relation was determined. The output layer was the hidden layer nodes output linear weighted summation. The result indicate that identification of torque loop, the input is torque, the output is speed, the torque loop error rate is about 1%. Identification of pitch loop, the input is pitch angle, the output is speed, the pitch loop error rate is about 3%. The pitch loop is a very complicated nonlinear model, the model structure is influenced by many aspects, identification result error is bigger than the torque loop identification error, but the error rate is allowed. The algorithm has higher precision and efficiency.

**Key words:** the wind turbine; radi-calbasis function(RBF) neural network; identification

## 0 引言

风力发电机组系统是复杂的非线性时变系统,很难获得系统精确的数学模型。当系统工况发生变化时,常规线性模型控制系统的控制效果会降低,甚至影响整个系统的正常运行。因此,建立系统的精确模型,为优化风电机提供理论基础,具有重要意义。

风力发电机组系统常用的建模方法可分为机理建模方法和非线性系统辨识方法<sup>[1-5]</sup>。采用机理建模方法,即利用各种数学方程来描述风力发电机组系统,在已知风电机固有参数(升力系数,阻力系数,桨叶弦长,安装角等等)的条件下,输入相关参数(风角速度、风速、可调桨距角等),再根据复杂的能量转换和空气动力学原理进行一系列的复杂公式推导和简化条件得

收稿日期:2017-01-13

基金项目:国家科技支撑计划资助项目(2015BAA06B01)

作者简介:杨震宇(1967-),男,浙江杭州人,高级工程师,主要从事风力发电机组应用技术方面的研究. E-mail:yingY@chinawindey.com

到,该方法操作复杂且得到的数学模型由于经过了条件简化,其与实际工况下的模型会有较大差距。随着控制理论的发展,涌现出多种非线性系统辨识方法辨识算法<sup>[6-7]</sup>。JELAVIC 等提出采用模糊逻辑方法进行切换的整机模型辨识方法;同时,VAN DER VEEN 等<sup>[8]</sup>提出一种基于状态空间方法,添加激励信号以消除模型周期性扰动的方法来提高模型的精确性。IRIBAS 等将机组的系统辨识划分为转矩环辨识和桨距环辨识,并分别给出了工程上较易实现的辨识方案。近年来,国内外很多研究学者对风力发电机组的非线性模型辨识进行了研究。将节距角、风速和电机力矩作为输入<sup>[9]</sup>,对额定风速以上运行的风力发电机进行辨识,得到一系列在稳定工作点运行的模型,但该方法主要是得到各个单个稳定工作点的模型,进行全风速段辨识时需添加其他辨识算法;采用动态模糊神经网络进行系统辨识<sup>[10]</sup>,但是两种智能算法结合,虽然克服了传统 BP 神经网络易陷入局部极值的问题,但也增加算法难度。基于 LPV 方法进行风力发电机系统辨识<sup>[11-14]</sup>,该方法获得多个局部工作点,但是该方法全局辨识,在切换工作点时会出现较大偏差,并不能精确地进行全局辨识。

基于以上工作,本研究将采用 RBF 神经网络对风电机组的转矩环和桨距环分别进行辨识。转矩环的输入信号为转矩给定,输出电机转速;桨距环的输入信号为桨距角给定,输出为电机转速。

## 1 RBF 控制算法

### 1.1 RBF 神经网络结构

RBF 神经网络的结构如图 1 所示。

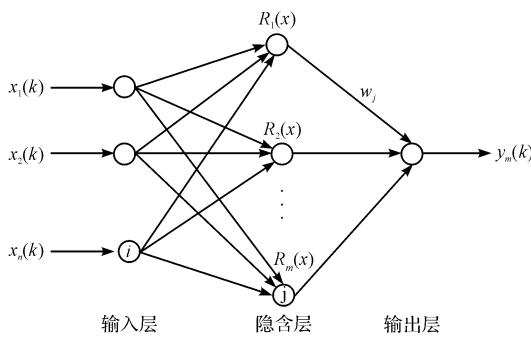


图 1 RBF 神经网络结构图

图注:  $x_1(k), x_2(k), \dots, x_n(k)$ —输入语言变量;  
 $y_m(k)$ —系统的输出量; $R_1(x), R_2(x), \dots, R_m(x)$ —径向函数; $w_j$ —权值; $w_j(k-1)$ —( $k-1$ )时刻第  $j$  个隐含层神经元至输出层神经元的权值<sup>[15]</sup>

RBF 神经网络的输入为:

$$\mathbf{x} = [x_1(k), x_2(k), \dots, x_n(k)]^T = [y(k-1), \dots, y(k-n_y); u(k-1), \dots, u(k-n_u)]^T \quad (1)$$

式中: $n$ —输入节点个数, $n = n_y + n_u + 1$ 。

RBF 神经网络输出为  $y_m(k)$ ;

隐含层的激励函数取高斯基函数,即:

$$R_j(x) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_j\|^2}{2b_j^2}\right) \quad (2)$$

式中: $j = 1, 2, \dots, m$ ; $\mathbf{c}_j$ —第  $j$  个基函数的中心点,且  $\mathbf{c}_j = [c_{j1}, c_{j2}, \dots, c_{jn}]^T$ ; $b_j$ —一个可以自由选择的参数,它决定该基函数围绕中心点的宽度; $m$ —隐含层节点个数。

则激励函数的导数为:

$$\begin{aligned} \frac{\partial R_j(x)}{\partial b_j} &= \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_j\|^2}{b_j^2}\right) \frac{\|\mathbf{x} - \mathbf{c}_j\|^2}{b_j^3} = \\ R_j(x) \frac{\|\mathbf{x} - \mathbf{c}_j\|^2}{b_j^3} & \end{aligned} \quad (3)$$

$$\begin{aligned} \frac{\partial R_j(x)}{\partial c_{ji}} &= \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_j\|^2}{b_j^2}\right) \frac{(x_i - c_{ji})}{b_j^2} = \\ R_j(x) \frac{(x_i - c_{ji})}{b_j^2} & \end{aligned} \quad (4)$$

### 1.2 RBF 神经网络训练过程

(1) 信号前向传播。计算 RBF 神经网络的输出。输入层神经元的输入为  $\mathbf{x} = [x_1(k), x_2(k), \dots, x_n(k)]^T$ ,而由式(2)知,隐含层神经元的输出为:

$$R_j(x(k)) = \exp\left(-\frac{\|\mathbf{x}(k) - \mathbf{c}_j(k-1)\|^2}{2b_j^2(k-1)}\right) \quad (5)$$

输出层神经元的输出为:

$$y_m(k) = \sum_{j=1}^m \omega_j(k-1) R_j(x(k)) \quad (6)$$

用于训练 RBF 网络的误差为:

$$e(k) = y(k) - y_m(k) \quad (7)$$

式中: $y(k)$ —实际输出, $y_m(k)$ —模型输出。

取性能指标为:

$$E(k) = \frac{1}{2} e^2(k) \quad (8)$$

(2) 误差反向传播。采用  $\delta$  学习算法,调整 RBF 网络各层间的权值。

由式(6~7)得:

$$\delta^{(2)} = \frac{\partial E(k)}{\partial y_m(k)} = \frac{\partial E(k)}{\partial e(k)} \frac{\partial e(k)}{\partial y_m(k)} = -e(k) \quad (9)$$

由式(6)和式(9)得:

$$\begin{aligned} \frac{\partial E(k)}{\partial \omega_j(k-1)} &= \frac{\partial E(k)}{\partial y_m(k)} \frac{\partial y_m(k)}{\partial \omega_j(k-1)} = \\ \delta^{(2)} R_j(x(k)) &= -e(k) R_j(x(k)) \end{aligned} \quad (10)$$

则隐含层至输出层的权值  $\omega_j(k)$  的学习算法为:

$$\Delta\omega_j(k) = -\eta \frac{\partial E(k)}{\partial \omega_j(k-1)} = \eta e(k) R_j(x(k)) \quad (11)$$

$$\omega_j(k) = \omega_j(k-1) + \Delta\omega_j(k) + \alpha(\omega_j(k-1) - \omega_j(k-2)) \quad (12)$$

式中: $\eta$ —学习速率, $\eta > 0$ ; $\alpha$ —动量项因子, $\alpha \in [0,1]$ 。

由式(6)和式(9)得:

$$\delta^{(1)} = \frac{\partial E(k)}{\partial R_j(x(k))} = \frac{\partial E(k)}{\partial y_m(k)} \frac{\partial y_m(k)}{\partial R_j(x(k))} = \delta^{(2)} \omega_j(k-1) \quad (13)$$

则由式(3)、式(4)和式(13)得:

$$\begin{aligned} \frac{\partial E(k)}{\partial b_j(k-1)} &= \frac{\partial E(k)}{\partial R_j(x(k))} \frac{\partial R_j(x(k))}{\partial b_j(k-1)} = \\ &- e(k) \omega_j(k-1) R_j(x(k)) \cdot \\ &\frac{\|x(k) - c_j(k-1)\|^2}{b_j^3(k-1)} \end{aligned} \quad (14)$$

$$\begin{aligned} \frac{\partial E(k)}{\partial c_j(k-1)} &= \frac{\partial E(k)}{\partial R_j(x(k))} \frac{\partial R_j(x(k))}{\partial c_j(k-1)} = \\ &- e(k) \omega_j(k-1) R_j(x(k)) \cdot \\ &\frac{x_i(k) - c_{ji}(k-1)}{b_j^2(k-1)} \end{aligned} \quad (15)$$

则 $b_j(k)$ 、 $c_{ji}(k)$ 的学习算法为:

$$\Delta b_j(k) = -\eta \frac{\partial E(k)}{\partial b_j(k-1)} = \eta e(k) \omega_j(k-1) \cdot R_j(x(k)) \frac{x(k) - c_j(k-1)^2}{b_j^3(k-1)} \quad (16)$$

$$b_j(k) = b_j(k-1) + \Delta b_j(k) + \alpha(b_j(k-1) - b_j(k-2)) \quad (17)$$

$$\Delta c_{ji}(k) = -\eta \frac{\partial E(k)}{\partial c_{ji}(k-1)} = \eta e(k) \omega_j(k-1) \cdot R_j(x(k)) \frac{x_i(k) - c_{ji}(k-1)}{b_j^2(k-1)} \quad (18)$$

$$c_{ji}(k) = c_{ji}(k-1) + \Delta c_{ji}(k) + \alpha(c_{ji}(k-1) - c_{ji}(k-2)) \quad (19)$$

RBF神经网络算法的流程图如图2所示。

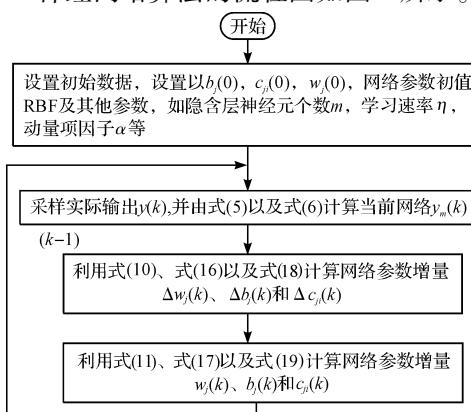


图2 RBF神经网络流程图

## 2 基于RBF的风电机组系统辨识仿真研究及结果分析

本研究主要针对风力发电机组的转矩环和桨距环进行系统辨识。

本研究采用仿真模型为运达风电的1.5 MW风力发电机数据,其主要参数如表1所示。

表1 风力发电机组WD1500-77主要参数表

名称	参数
风轮直径/m	77
桨叶数	3
切入风速/(m·s⁻¹)	3
切出风速/(m·s⁻¹)	25
变速比	104.494
电机惯量/kgm	113
高速轴惯量/kgm	10
低速轴刚度/(Nm·rad⁻¹)	1.2E+08
低速轴惯量kgm	2.3E+05
额定功率kW	1 500
额定电机转矩/kNm	8.715
额定风速/(m·s⁻¹)	11.2
转速范围/(r·min⁻¹)	1 100~1 800

风力发电机组转矩环辨识时,辨识系统输入为转矩信号,输出为转速信号。本研究采用平均风速为8 m/s的湍流风,风波形及转矩信号如图3所示。

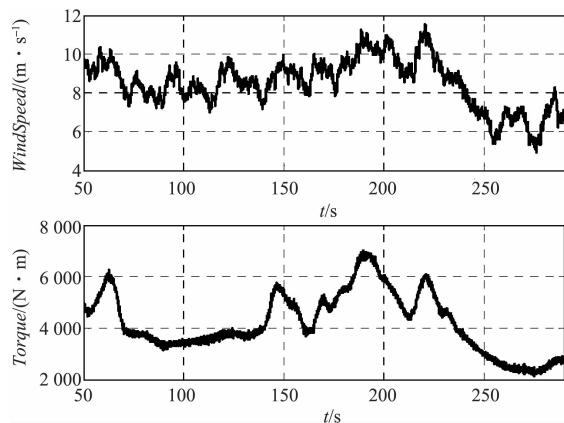


图3 风波形及转矩信号

转矩环实际输出与辨识输出对比波形如图4所示。

桨距环辨识时,辨识系统输入为桨距信号,输出为

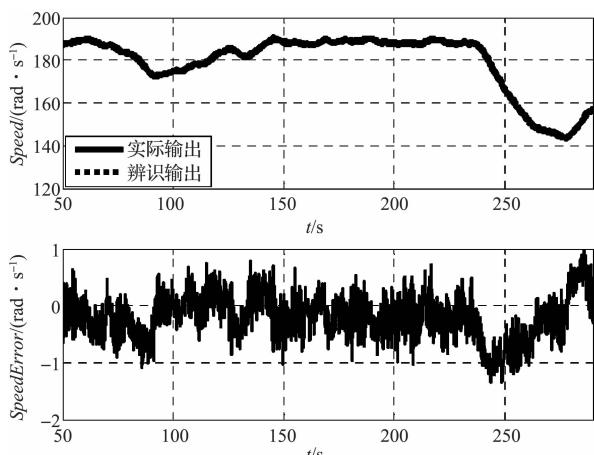


图 4 转矩环实际输出与辨识输出对比波形

转速信号。采用平均风速为 12 m/s 的湍流风, 风波形及桨距角如图 5 所示。

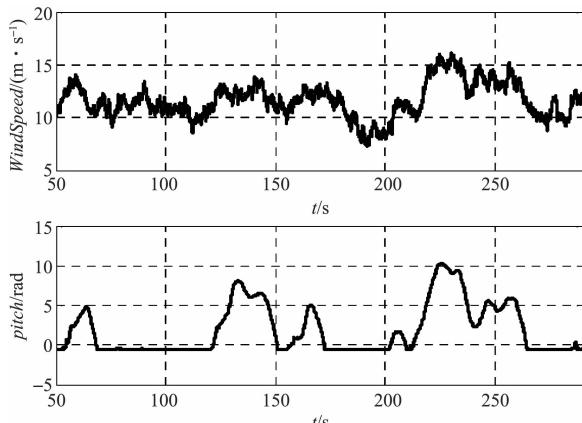


图 5 风波形及桨距角

桨距环实际输出与辨识输出对比波形如图 6 所示。

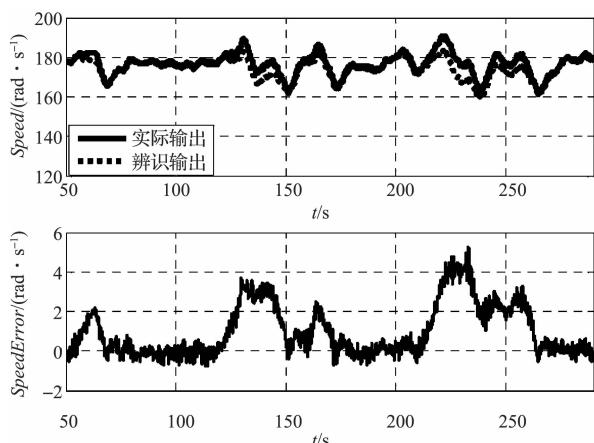


图 6 桨距环实际输出与辨识输出对比波形

由图 4 和图 6 可以看出, 基于 RBF 神经网络辨识的结果与模型实际输出基本一致。采用 RBF 神经网络算法辨识转矩环时, 辨识结果的误差率为 1% 左右; 辨识桨距环时, 辨识结果的误差率为 3% 左右。由于桨距环是极为复杂的非线性模型, 其模型结构受多方面影响, 辨识结果误差比转矩环辨识误差大, 但其误差率也在允许的范围内。

### 3 结束语

本研究通过采用 RBF 神经网络对风力发电机组转矩环和桨距环的动态过程进行辨识研究, 避免了传统建模中需要知道机组参数的弊端。采用智能控制算法, 简化操作。RBF 神经网络控制算法操作步骤简单, 辨识结果精准度高。辨识风力发电机组转矩环和桨距环时, RBF 神经网络的输入信号分别为转矩和桨距角, 输出信号均为发电机转速。仿真研究结果证明了 RBF 神经网络可以快速精准的辨识风力发电机组模型。

#### 参考文献( References ) :

- [1] 陈清丽. 风力发电机组风轮建模及运行特性研究 [D]. 北京: 华北电力大学电气与电子工程学院, 2007.
- [2] HOFFMAN J A. Coupled dynamic analysis of wind energy systems [R]. Paragon: NASA CR 135152, 1977.
- [3] VAN DER VEEN G, VAN WINGERDEN J-W, VERHAEGEN M. Global identification of wind turbines using a hammerstein identification method [J]. *IEEE Transactions on Control Systems Technology*, 2013, 21(4): 1471-1478.
- [4] HAND M M, BALAS M J. Non-linear and linear model based controller design for variable-speed wind turbines [M]. Colorado: National Renewable Energy Laboratory, 1999.
- [5] MENG W, YANG Q, YING Y, et al. Adaptive power acquisition control of variable-speed wind energy conversion systems under inaccurate wind speed measurement [J]. *American Control Conference ( ACC )*, 2013, 37(1): 4271-4276.
- [6] 叶杭治. 风力发电机组的控制技术 [M]. 3 版. 北京: 机械工业出版社, 2015.

( 下转第 658 页 )

#### 本文引用格式:

杨震宇, 王青, 魏新刚, 等. 基于 RBF 神经网络的风力发电机组系统辨识研究 [J]. 机电工程, 2017, 34(6): 639-642, 658.

YANG Zhen-yu, WANG Qing, WEI Xin-gang, et al. Identification of the wind turbine system based on RBF neural network [J]. *Journal of Mechanical & Electrical Engineering*, 2017, 34(6): 639-642, 658.

《机电工程》杂志: <http://www.meeem.com.cn>