

文章编号: 1001-0920(2007)10-1125-04

基于动态递归模糊神经网络的水轮发电机组建模

罗南华^{1,2}, 王伟³

(1. 东北大学 信息科学与工程学院, 沈阳 110004; 2. 长春工程学院 能源动力学院, 长春 130012; 3. 大连理工大学 信息与控制研究中心, 辽宁 大连 116024)

摘要: 针对水轮发电机组的复杂动态特征, 提出一种新的动态递归模糊神经网络结构, 并将其应用于解决水轮发电机组的建模问题. 通过在网络规则层引入乘积运算, 使得复杂模糊规则容易提取, 模糊推理功能易于实现. 在网络隐层中引入局部递归单元, 该方法能克服基于反向误差传播的静态网络辨识动态系统的局限性, 提高辨识水轮发电机组动态特性的准确性. 通过与其他智能方法的仿真比较, 验证了所提出方法的有效性.

关键词: 水轮发电机组; 动态递归; 模糊神经网络; 动态反向传播学习算法

中图分类号: TM312

文献标识码: A

Modelling for hydroelectric generating unit based on dynamic recurrent fuzzy neural network

LUO Nan-hua^{1,2}, WANG Wei³

(1. School of Information Science and Engineering, Northeastern University, Shenyang 110004, China; 2. Department of Energy Source, Changchun Institute of Technology, Changchun 130012, China; 3. Research Center of Information and Control, Dalian University of Technology, Dalian 116024, China. Correspondent: LUO Nan-hua, E-mail: luonanhua@hotmail.com)

Abstract: Aiming at complex dynamic characteristics of the hydroelectric generating unit, a novel dynamic recurrent fuzzy neural network is proposed, which is used to model the hydroelectric generating unit. The fuzzy inference function is realized easily by using a product operation in the network. Introducing local recurrent units to hidden layer, the proposed method can overcome the limit of using back-propagation-based static network methods and accurately identify the dynamic characteristics of the hydroelectric generating unit. Comparing with the traditional methods, the effectiveness of the proposed method is verified.

Key words: Hydroelectric generating unit; Dynamic recurrent; Fuzzy neural network; Dynamic back propagation algorithm

1 引言

水轮机调节系统作为调节电网频率的主要环节, 是典型的高阶非线性、时变、非最小相位环节的复杂系统, 并且具有多种运行工况. 当水头、负荷、转速等量偏离各工况下的额定工作点时, 模型的参数会发生变化. 对于水轮机调节系统存在的非线性, 传统建模方法较难对其进行确切的描述, 实际中通常用额定工况点附近的线性化模型来近似描述. 这样会造成很大的辨识误差, 从而造成机组运行的不稳定^[1].

不少学者利用神经网络方法对水轮发电机组辨

识问题进行研究. 文献[2]的研究结果表明, 神经网络具有良好的映射性能及较强的容错性; [3]针对多层前向神经网络, 运用递推预报误差 (RPE) 算法对水轮发电机组进行非线性建模; [4]采用 BP 神经网络模型表达水轮机的非线性特性, 解决了插值法的导数不连续问题. 近年来, 模糊神经网络已成为研究的热点. 文献[5]采用基于模糊参考集的自适应网络 ANFIS 方法, 实现了低水头水电站的非线性、多变量控制; [6]针对具有复杂动态特性和不确定性的水轮发电机组, 提出一种直接自适应模糊控制方法; [7]根据水力机组可分段线性化的特性, 提出了水力

收稿日期: 2006-07-06; 修回日期: 2006-08-25.

基金项目: 国家杰出青年基金项目 (69825106); 东北电力集团科研项目 (99AQ-09).

作者简介: 罗南华 (1963—), 男, 吉林省吉林市人, 副教授, 博士生, 从事智能控制、自适应控制的研究; 王伟 (1955—), 男, 辽宁鞍山人, 教授, 博士生导师, 从事模型预测控制、智能控制等研究.

机组的简易模糊语言模型,并将反馈控制的思想引入系统辨识.在上述一系列研究中,人们主要是利用神经网络的逼近特性表达非线性系统的能力和自适应学习的功能,解决水轮发电机组特性辨识问题.

事实上,三层前馈神经网络能以任意精度逼近任何连续的非线性函数映射.然而,上述大多数方法采用静态网络,描述动态系统有其局限性^[8].为了提高动态系统的辨识精度,研究具有动态特性的模糊神经网络更具实际意义^[9,10].

本文针对水轮发电机组的复杂非线性及时变特性特征,提出一种新的动态递归模糊神经网络(DRFNN)结构,并应用于水轮发电机组建模问题.新的网络结构在规则层中采用了乘积运算的方式,保证每条规则的激活度 $w_j(k) \leq 1$,便于模糊推理功能的实现;通过在规则层引入单位延迟单元,使静态网络具有动态特性;网络在 k 时刻每条规则的激活度不仅包括由当前输入计算得出的激活度值,而且包括前一时刻所有规则激活度值的贡献,因此提高了网络辨识的准确性,可以较好地完成水轮发电机组的动态辨识.通过与BP网络方法的仿真比较,验证了所提出方法的有效性和准确性.

2 动态递归模糊神经网络(DRFNN)

单输入单输出DRFNN网络拓扑结构如图1所示.网络由5层组成:

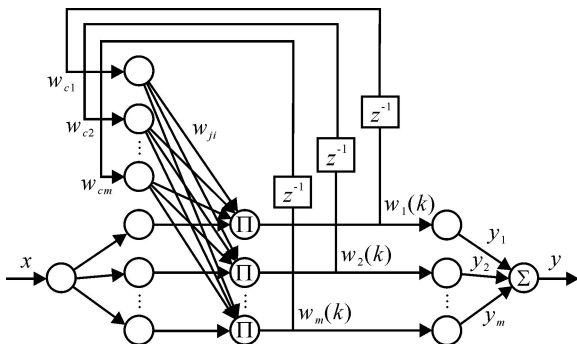


图1 动态递归模糊神经网络结构

第1层为输入层,此层的节点直接与输入向量 x 相连,将输入值传送到下一层.

第2层为模糊化层,每个节点代表一个语言变量值,如 S_2, S_1, C_E, B_1, B_2 等,其作用是计算输入量属于各语言变量值模糊集合的隶属度函数.根据具体问题选择输入隶属度函数为高斯函数

$$\mu^j = \exp\left[-\left(\frac{x(k) - x_j}{j}\right)^2\right]. \quad (1)$$

其中: x_j 和 j 分别表示第 j 个隶属函数的中心和宽度, $x(k)$ 为第 k 时刻网络的输入, $j = 1, 2, \dots, m, m$ 为 x 的模糊分割数.

第3层为规则层,每个结点代表一条模糊规则,

其作用是匹配模糊规则的前件,计算出每条规则的激活度 $w_j(k)$.在此层中引入递归层,根据图1所示的网络结构,有

$$w_j(k) = \left[\prod_{i=1}^m w_{ci}(k) W_{ji} \right] \exp\left[-\left(\frac{x(k) - x_j}{j}\right)^2\right]. \quad (2)$$

其中: W_{ji} 为由递归层第 j 个节点到规则层第 i 个节点的连接权, $w_{ci}(k)$ 是递归层中第 i 个节点的激活度,即

$$w_{ci}(k) = w_i(k-1), i = 1, 2, \dots, m. \quad (3)$$

式(2)和(3)说明:由于在网络结构中引入递归层,网络在 k 时刻每条规则的激活度 $w_j(k)$ 不仅包括由当前输入计算得出的激活度值 μ^j ,而且包括前一时刻各激活度 $\prod_{i=1}^m w_i(k-1)$ 值的贡献,因此加强了网络辨识的准确性,并使静态网络具有了动态特性.

与其他动态递归网络不同的是(参见文献[9]),本文提出在规则层中采用乘积运算的方式,既有效地保证每条规则的激活度 $0 < w_j(k) \leq 1$,又便于实际中模糊推理功能的实现,提取的模糊规则模式易于操作人员的理解.

第4层为解模糊化层,实现模糊结论的解模糊化运算.本层中每个节点的激活度定义为

$$\phi = 1 / \prod_{i=1}^m w_i(k), \quad (4)$$

则该层第 i 个节点的输出为

$$\bar{w}_i(k) = \phi w_i(k). \quad (5)$$

第5层为输出层,网络在 k 时刻的输出为

$$y(k) = \prod_{i=1}^m \tilde{y}_i(k) \bar{w}_i(k) = \prod_{i=1}^m \tilde{y}_i(k) w_i(k) / \prod_{i=1}^m w_i(k), \quad (6)$$

其中 $\tilde{y}_i(k)$ 为 k 时刻第 i 条模糊规则的结论.

3 DRFNN学习算法

模糊分割数一经确定,则需要学习的网络参数有4个,分别为递归层到规则层的连接权 W_{ji} ,输入量隶属函数的中心 x_j 和宽度 j ,隐层到输出层的连接权值 \tilde{y}_i (即规则结论).

采用均方误差(MSE)定义目标函数

$$\text{MSE} = \frac{1}{N} \sum_{k=1}^N E_p(k). \quad (7)$$

其中: N 为样本数, $E_p(k)$ 为每次迭代后的瞬时平方误差,定义为

$$E_p(k) = \frac{1}{2} (y_d(k) - y(k))^2, \quad (8)$$

式中 $y_d(k)$ 和 $y(k)$ 分别为 t 时刻辨识对象的实际样

本输出和 DRFNN 输出.

由式(2)和(3)可知

$$w_{cj}(k) = w_j(k-1) = \left[\prod_{i=1}^m w_{ai}(k-1) W_{ji} \right] \exp \left[- \left(\frac{x(k-1) - x_i}{j} \right)^2 \right]. \quad (9)$$

式(9)说明 $w_{cj}(k)$ 依赖于过去不同时刻的连接权,即 $w_{cj}(k)$ 是一个动态递推过程.因此可将相应的BP算法称为动态BP算法.

各参数的调整均采用梯度下降法,以寻找使目标函数 E_p 最小化的参数向量.具体的参数调整学习算法分述如下:

3.1 递归层到规则层的连接权值 w_{ji} 的调整

$$W_{ji}(k+1) = W_{ji}(k) - w \frac{\partial E_p}{\partial W_{ji}} \Big|_k, \quad (10)$$

其中 w 为学习率系数.学习率系数大则算法收敛速度较快,但容易产生振荡;学习率系数小可以减缓振荡,但收敛速度较慢,因而其选择原则要根据实际确定.利用链式规则求导,有

$$\frac{\partial E_p}{\partial W_{ji}} = \frac{\partial E_p}{\partial y(k)} \frac{\partial y(k)}{\partial w_j(k)} \frac{\partial w_j(k)}{\partial W_{ji}}. \quad (11)$$

由式(8)求导得

$$\frac{\partial E_p}{\partial y(k)} = - (y_d(k) - y(k)); \quad (12)$$

由式(6)求导得

$$\frac{\partial y(k)}{\partial w_j(k)} = \frac{\tilde{y}_i(k) - y(k)}{\prod_{i=1}^m w_i(k)}; \quad (13)$$

由式(2)和(9)求导得

$$\frac{\partial w_j(k)}{\partial W_{ji}} = \left[\prod_{n=1}^m w_n(k-1) W_{jn} \right] \exp \left[- \left(\frac{x(k) - x_i}{j} \right)^2 \right] \times \left(\frac{1}{W_{ji}} + \frac{1}{w_j(k-1)} \frac{\partial w_j(k-1)}{\partial W_{ji}} \right). \quad (14)$$

这便构成了梯度 $\partial w_j / \partial W_{ji}$ 的动态递推关系,与沿时间反向传播的学习算法类似.由式(12)~(14)可得到式(11).

3.2 输入量隶属函数中心 x_j 的调整

$$x_j(k+1) = x_j(k) - x \frac{\partial E_p}{\partial x_j} \Big|_k, \quad (15)$$

其中 x 为学习率系数,选择原则同前.根据链式规则求导,有

$$\frac{\partial E_p}{\partial x_j} = \frac{\partial E_p}{\partial y(k)} \frac{\partial y(k)}{\partial w_j(k)} \frac{\partial w_j(k)}{\partial x_j}. \quad (16)$$

由式(2)和(9)求导得

$$\frac{\partial w_j(k)}{\partial x_j} = \left[\prod_{i=1}^m w_i(k-1) W_{ji} \right] \exp \left[- \left(\frac{x(k) - x_i}{j} \right)^2 \right] \times \left[2 \left(\frac{x(k) - x_i}{j} \right) + \frac{1}{w_j(k-1)} \frac{\partial w_j(k-1)}{\partial x_j} \right]. \quad (17)$$

可知式(17)也是梯度 $\partial w_j(k) / \partial x_j$ 的动态递推关系.由式(12),(13),(17)可得式(16)

3.3 输入量隶属函数宽度 j 的调整

$$j(k+1) = j(k) - \frac{\partial E_p}{\partial j} \Big|_k, \quad (18)$$

其中 $\frac{\partial E_p}{\partial j}$ 为学习率系数.根据链式规则求导,有

$$\frac{\partial E_p}{\partial j} = \frac{\partial E_p}{\partial y(k)} \frac{\partial y(k)}{\partial w_j(k)} \frac{\partial w_j(k)}{\partial j}. \quad (19)$$

由式(9)求导得

$$\frac{\partial w_j(k)}{\partial j} = \left[\prod_{i=1}^m w_i(k-1) W_{ji} \right] \exp \left[- \left(\frac{x(k) - x_i}{j} \right)^2 \right] \times \left[2 \frac{(x(k) - x_i)^2}{j^3} + \frac{1}{w_j(k-1)} \frac{\partial w_j(k-1)}{\partial j} \right]. \quad (20)$$

式(20)为梯度 $\partial w_j(k) / \partial j$ 的动态递推关系.由式(12),(13)和(20)可得式(19).

3.4 隐层到输出层的连接权 \tilde{y}_i 的调整

$$\tilde{y}_i(k+1) = \tilde{y}_i(k) - \tilde{y} \frac{\partial E_p}{\partial \tilde{y}_i} \Big|_k, \quad (21)$$

其中 \tilde{y} 为学习率系数.根据链式规则求导,有

$$\frac{\partial E_p}{\partial \tilde{y}_i} = \frac{\partial E_p}{\partial y(k)} \frac{\partial y(k)}{\partial \tilde{y}_i(k)}. \quad (22)$$

由式(6)求导得

$$\frac{\partial y(k)}{\partial \tilde{y}_i(k)} = w_i(k) \prod_{i=1}^m w_i(k). \quad (23)$$

由式(12)和(23)可得式(22).

4 水轮发电机组的动态模糊神经网络模型

为了验证本文提出的 DRFNN 的有效性,由某电站的实际数据中采集 240 个样本数据,其中 120 个作为训练数据,另 120 个作为测试数据.机组在不同工况下模型参数变化很大,只采集某一工况下的数据进行训练所得模型适应性很差,因此应选取不同工况下的典型数据作为训练样本.

选择 W_{ji} 和 \tilde{y}_j 分别为 $[0,1]$ 一致分布的随机数,输入量的初始隶属函数为高斯型函数.学习算法经 25 次迭代后,均方误差快速收敛到一个较小的值 8.402×10^{-4} .

DRFNN 网络的训练结果如图 2 所示.从图 2 可以看出,在线辨识水轮机特性时,通过控制量 $u(k)$ 和输出量 $y(k)$ 能精确地辨识水轮机组输出 $y(k+1)$,辨识误差可达 10^{-4} 数量级,说明设计的 DRFNN 网络具有良好的辨识能力.

经过训练的输入变量隶属度函数如图 3 所示.

为说明本文提出方法的优点,与 BP 网络作了辨识结果比较.选用 20 个隐层结点,使用 120 个训练样本学习 BP 网络,共进行 100 次迭代,仿真结果




图2 DRFNN网络训练结果






图3 调整后的隶属函数

如图4所示.由图4可见,在隐层结点数和学习率系数相同的前提下,BP网络是否收敛与初始权值的选择有很大的关系,而且在样本数据变化较大的区域,辨识精度较差.本文提出的方法基本不受初始状态的影响,用于辨识具有非最小相位特性的水轮发电机组时,准确性可以得到保证.



(a) 第1组BP网络



(b) 第2组BP网络

图4 不同BP网络初始权值的训练结果

5 结论

本文提出一种新型的DRFNN网络,它既有模糊推理系统的推理功能,又有神经网络的训练学习功能.将二者的优势结合起来,能克服单纯神经网络

的黑箱特性,具有一定的透明度.本文通过仿真验证了DRFNN比一般BP神经网络训练快,训练次数也大为减少,克服了局部最优的问题.使用DRFNN网络可建立较精确的水电机组输入输出模型,解决了水电机组在实际运行中存在的非线性问题.另外,所提出的新型网络结构也便于实现模糊规则,提取的模糊规则模式易于操作人员的理解,而且具有模型学习参数少、收敛速度快、鲁棒性强等特点.

参考文献(References)

- [1] Xu Fang-tong, Li Yong-hua, Cheng Qi-juan. Study of the modeling of hydroturbine generating set [C]. Int IEEE/ IAS Conf on Industrial Automation and Control: Emerging Technologies. Taipei, 1995: 644-647.
- [2] 景雷, 叶鲁卿, 周泰经. 水轮发电机组的神经网络可辨识性研究[J]. 水电能源科学, 1997, 15(2): 17-23. (Jing Lei, Ye Lu-qing, Zhou Tai-jing. Study of neural network identifiability for hydroelectric generating unit [J]. Hydro-electric Energy, 1997, 15(2): 17-23.)
- [3] 陈启卷, 徐枋同. 水轮发电机神经网络非线性建模研究[J]. 水利学报, 1997, 10(1): 62-65. (Chen Qi-juan, Xu Fang-tong. Research on modeling hydro turbine generating set by using neural networks [J]. J of Hydraulic Power, 1997, 10(1): 62-65.)
- [4] 程远楚, 叶鲁卿, 蔡维由. 水轮机特性的神经网络建模[J]. 华中科技大学学报, 2003, 31(6): 68-70. (Cheng Yuan-chu, Ye Lu-qing, Cai Wei-you. Modeling of hydro-turbine hill chart by neural network [J]. J of Huazhong University of Science and Technology, 2003, 31(6): 68-70.)
- [5] Zhang Jian-ming, Wang Shu-qing. Direct adaptive fuzzy controller for hydraulic turbine generators [C]. Proc of the 3rd World Congress on Intelligent Control and Automation. Hefei, 2000: 1762-1766.
- [6] Djukanovic M B, Calovic M S, Vesovic B V, et al. Neuro-fuzzy controller of low head hydropower plants using adaptive network based fuzzy inference system [J]. IEEE Trans on Energy Conversion, 1997, 12(4): 375-381.
- [7] 孙昀, 沈祖谟. 基于模糊神经网络的水力机组模型辨识[J]. 河海大学学报, 2000, 28(2): 69-73. (Sun Yun, Shen Zu-yi. A turbine identification model based on fuzzy neural network [J]. J of Hehai University, 2000, 28(2): 69-73.)
- [8] Lin C H, Chou W D, Lin F J. Adaptive hybrid control using a recurrent neural network for a linear synchronous motor servo-drive system [J]. Control Theory and Applications, 2001, 148(2): 156-168.

(下转第1133页)

间得到 M 点和 E 点,从 M 点和 E 点可看出汽车交通事故的发展趋势.图 4 中曲线表明汽车交通事故必定发生,若在 M 点提醒驾驶员,便可避免交通事故的发生.

根据国外的分析,在汽车交通事故发生之前 5 s 左右提醒驾驶员采取措施,能避免 80% 的交通事故.所以这种事故混沌理论的提出,为减少事故的发生提供了理论基础.

6 结 语

本文根据事故对初始条件的敏感性和事故长期不可预测性,提出一种新型的事故混沌理论.为了验证事故混沌理论,采用人-机-环境系统工程理论、模糊故障树和混沌理论分析汽车交通事故的特性,利用预测尺度为 0.026 s 的混沌相空间预测模型来预测交通事故的发生,提前提醒驾驶员采取措施,这样可避免大量交通事故的发生.通过实验验证了事故混沌理论是有效的,具有广泛的应用价值.

这种事故混沌理论仅是一种分析方法.将它与混沌控制、混沌同步、混沌优化以及其他智能算法等相结合,可以形成一种事故混沌理论,这是需要继续研究的课题.它的实现和推广将为现有的事故预防和控制提供一种良好的理论基础,并可应用于矿井、交通、航天等领域,为人民生命安全和国家财产安全提供保障.

参考文献(References)

- [1] 袁昌明,崔晓君.事故预测模型的建立与应用[J].中国计量学院学报,2004,15(4):314-316.
(Yuan Chang-ming, Cui Xiao-jun. Establishment and application of an accident prediction model [J]. J of China Jiliang University, 2004, 15(4): 314-316.)
- [2] 周维新.交通事故灰色预测模型的研究[J].西安公路交通大学学报,2000,20(2):73-75.
(Zhou Wei-xin. Study on the forecast model of traffic accidents with grey theory [J]. J of Xi'an Highway University, 2000, 20(2): 73-75.)
- [3] Feng H Q, Suzuki K, Gabbar H A. Application of grey prediction model on safety target value[C]. Progress in Safety Science and Technology. Shanghai, 2005, 5: 16-20.
- [4] Noy Y I. Human factors in modern traffic systems[J]. Ergonomics, 1997, 40(10): 1016-1024.
- [5] Wang W H, Cao Q, Liu D M. Analyze and assessment of driver's operation reliability[J]. Vehicle Transportation Research, 1994, 16(4): 207-212.
- [6] Singer D. A fuzzy set approach to fault tree and reliability analysis[J]. Fuzzy Sets and Systems, 1990, 34(2): 145-155.
- [7] Weber D P. Fuzzy fault tree analysis[C]. IEEE World Congress on Computational Intelligence. Orlando, 1994, 3: 1899-1904.
- [8] Tarko A, Tracz M. Accident prediction models for signalized crosswalks[J]. Safety Science, 1995, 19(3-4): 110-118.
- [9] 王宏伟,马广富.基于模糊模型的混沌时间序列预测[J].物理学报,2004,53(10):3293-3297.
(Wang Hong-wei, Ma Guang-fu. Prediction of chaotic time series based on fuzzy model [J]. Acta Physica Sinica, 2004, 53(10): 3293-3297.)
- [10] 张化光,王智良,黄伟.混沌系统的控制理论[M].沈阳:东北大学出版社,2003.
(Zhang Hua-guang, Wang Zhi-liang, Huang Wei. Control theory of chaos system [M]. Shenyang: Northeastern University Press, 2003.)
- [11] Grassberger P, Procaccia J. Dimension and entropies of strange attractors from a fluctuating dynamics approach[J]. Physica D, 1984, 13(1): 189-208.
- [12] 岳毅宏,韩文秀.混沌系统可预测尺度研究[J].系统工程理论与实践,2003,23(1):91-95.
(Yue Yi-hong, Han Wen-xiu. Study on the predictable size of chaotic systems [J]. Systems Engineering Theory and Practice, 2003, 23(1): 91-95.)

(上接第 1128 页)

- [9] 张友旺.基于动态递归模糊神经网络的动态系统辨识[J].中南工业大学学报,2003,34(3):277-280.
(Zhang You-wang. Identification of dynamic system based on dynamic fuzzy neural network [J]. J of Center South University Technology, 2003, 34(3): 277-280.)
- [10] Lee Ching-hung, Teng Ching-cheng. Identification and control of dynamic systems using recurrent fuzzy neural networks[J]. IEEE Trans on Fuzzy Systems, 2000, 8(4): 349-366.