

基于局部递归线性 NF 模型智能非线性识别系统设计

侯贤敏, 汪松玉, 张建军, 吕海燕

(河南农业大学 信息与管理科学学院, 郑州 450002)

摘要: 主要研究了智能非线性识别技术在绕组建模中的设计; 首先分析了模糊神经 (NF) 建模的相关属性, 针对绕组建模系统所需要的控制性能, 为了改善其控制性能, 实现可靠的容错系统, 提出一种新的基于模糊神经网络 NF 的模拟模型, 将该模型应用到基于递归的局部线性模糊神经网络 (RLLNF), 该网络通过局部的线性模型树 (LOLIMOT) 训练, 设计出一种改进的基于树的增量学习算法; 最后设置时间间隔在 220 s 和 225 s 之间的实际的绕组过程, 通过仿真实验结果表明, 将提出的 NF 模型与其他已知智能算法, 即多层感知器 (MLP) 等进行比较, 所设计的系统更具有可行性与高效性。

关键词: 非线性系统识别; 递归局部线性模糊神经网络 (RLLNF); 局部线性模型树 (LOLIMOT); 神经网络 (NN); 工业绕组过程

Intelligent Non-linear Modeling of an Industrial Winding Process Using Recurrent Neuro-fuzzy Networks

Hou Xianmin, Wang Songyu, Zhang Jianjun, Lv Haiyan

(College of Information and Management Science, Henan Agricultural University, Zhengzhou 450002, China)

Abstract: This study deals with the neuro-fuzzy (NF) modeling of a real industrial winding process in which the acquired NF model can be exploited to improve control performance and achieve a robust fault-tolerant system. A new simulator model is proposed for a winding process using non-linear identification based on a recurrent local linear neuro-fuzzy (RLLNF) network trained by local linear model tree (LOLIMOT), which is an incremental tree-based learning algorithm. The proposed NF models are compared with other known intelligent identifiers, namely multilayer perceptron (MLP) and radial basis function (RBF). Experimental results show the effectiveness of our proposed NF modeling approach.

Key words: non-linear system identification; recurrent local linear neuro-fuzzy (RLLNF) network; local linear model tree (LOLIMOT); neural network (NN); industrial winding process

0 引言

如今, 随着时代的发展, 科技的进步, 物理过程建模已成为控制理论及应用领域内最具吸引力、最具挑战性的一个方向之一。时常会存在一些因素使常规建模过程变得繁琐且耗时, 如果缺乏有关系统精确与正式的理解或者存在高度的不确定性, 则甚至可能会产生意想不到的结果。然而, 提取一个工业绕组过程的模型似乎是基于模型的控制和诊断试验所必需的^[1]。因此, 在本文中, 数据驱动的建模方法而不是分析方法将被应用以找出一种准确和可靠的工业绕组过程模型^[2]。

显而易见的是, 目前尚无相关研究是针对于处理基于软计算技术的绕组过程的智能非线性建模。就我们所知, 现存研究中没有尝试将模糊神经 (NF) 建模应用于工业绕组过程领域。神经网络模型的主要缺点是因为他们通常被认为是黑盒性质的。事实上, NF 建模可以视为一种灰色模型, 它是处于神经网络与定性模糊模型两者交叉位置的。最常见的 NF 系统基于

两种类型的模糊模型, 即 TS (数据驱动) 和知识驱动, 二者均与神经网络学习算法相结合。当模型的精确度要求较高时, TS 型 NF 模型是主要选择。

1 绕组过程分析

上文中介绍的绕组工厂是 Web 输送系统中经常遇到的主要子系统。使用基于理论的方法, 比如胡克方程是一个复杂的任务。为了克服这些问题, 本文提出了基于工业绕组过程的非线性模型^[3]。

本文结合的案例研究是工业的绕组过程测试设置。图 1 显示了绕组过程的整体结构, 多变量和耦合系统的组成与过程参数。绕组的主要作用是过程的控制 Web 运送, 以避免摩擦和滑动的影响。绕组机主要由 3 个直流电机驱动的卷筒组成, 可以表示为 M_1 、 M_2 和 M_3 ; 加上卷轴和一种塑料条的齿轮减速装置等。其中: 电机 M_1 对应退卷, M_3 对应倒带卷轴, M_2 对应牵引卷轴。电机 M_2 (Ω_2) 以及 (T_1 、 T_3) 之间的卷轴的角速度分别采用电机转速和张力求来表示。

每个电机是由局部控制器驱动的。转矩控制实现于电动机 M_1 和 M_3 , 速度控制实现于电机 M_2 。重要进程参数由传感器采样送至监控系统等。

在此过程中出现的参数变化是由于平仑盘半径变化。这种非量化卷筒半径的变化显著的修改了系统整体过程的动态行

收稿日期: 2014-01-20; 修回日期: 2014-03-01。

基金项目: 河南省教育厅科学技术研究重点项目 (13B110057)。

作者简介: 侯贤敏 (1981-), 女, 河南开封人, 硕士, 讲师, 主要从事概率论与数理统计方向的研究。

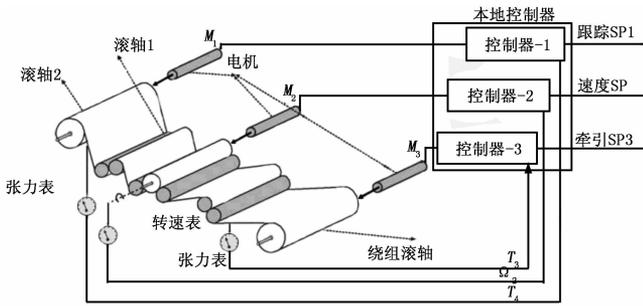


图 1 工业绕组过程的整体结构

为。因此，由于绕组过程遭受的这些失控因素影响，这种过程类型是建模、识别及控制中的挑战性因素。若要准确描述绕组过程，相应重要的输入和输出变量如表 1 所示。

表 1 绕组过程中的输入和输出变量

变量类别	变量名	变量描述
输入	S_1	卷轴 1 角速度
	S_2	卷轴 2 角速度
	S_3	卷轴 3 角速度
	RI_1	M_1 电流
	RI_2	M_2 电流
输出	T_1	卷轴 1&2 张力
	T_3	卷轴 2&3 张力

2 基于工业绕组过程的智能非线性建模

当物理系统中的线性方法建模无法得到令人满意的结果时，非线性系统将体现自身价值。因此，在本节中，作者将针对基于局部线性神经模糊 (RLLNF) 技术的非线性的过程和动态绕组过程进行描述。

2.1 模型数据预处理

数据预处理方法需要从现有的实验数据中提取有效的数据。真实数据的峰值平滑处理在前期处理阶段非常重要。为了实现这些目标，实际数据通过 0.3 Hz 带宽的一阶数字低通滤波器。从信号处理的角度来看，一个合适的筛选器不应改变或影响原始信号形状，而只是消除噪音和干扰信号。^[4]此外，由于输入和输出的数据具有不同的范围，筛选器可能会产生数据错误并导致系统识别失败。数据规范化必须作为数据挖掘系统辨识的关键步骤。实验证明使用数据规范化将获取更准确更有价值的模拟结果。原始信号 S 可以映射到 S_n 的归一化信号，过程如下所示：

$$S_n = \frac{S - S_{\min}}{S_{\max} - S_{\min}} \quad (1)$$

式中， S_{\max} 和 S_{\min} 分别对应 S 的最大和最小值。

2.2 递归局部线性模糊神经网络

为了建立一个绕组过程的非线性仿真模型，需要利用到 RLLNF 网络和一个局部线性模型树 (LOLIMOT) 算法来为网络寻找最佳的结构和参数。基于 LOLIMOT 算法训练的 RLLNF 模型具有很多优点，包括：局部估计带来的低计算成本、对噪声干扰的鲁棒性、高精度、快速培训、较高的评价能力和在线适应性等。RLLNF 网络的结构如图 2 所示。

每个神经元实现局部线性模型 (LLM) 和相关联的模糊有效性函数，以确定其有效性的区域。LLNF 模型具有与 TS

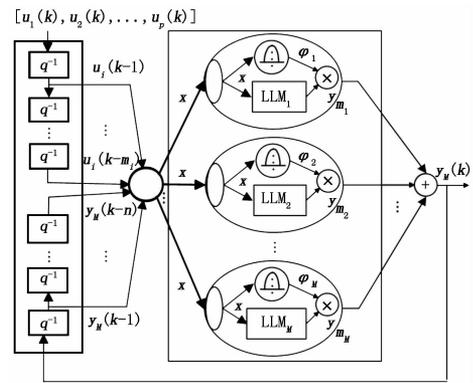


图 2 RLLNF 网络的结构

模型基本相同的解释，那就是：其中每个神经元表示一个模糊规则、有效性函数表示规则前提、而 LLMs 表示规则结果。若要创建一个仿真模型，延迟的进程输入和 LLNF 模型输出的历史样品被加入模型作为输入参数。因此，对于递归的 (动态) LLNF 网络模型，其输入可以定义如下：

$$x = \begin{bmatrix} u_1(k-1), \dots, u_1(k-m_1), u_2(k-1), \dots, u_2(k-m_2), \dots, \\ u_p(k-1), \dots, u_p(k-m_p), u_M(k-1), \dots, u_M(k-n) \end{bmatrix}^T \quad (2)$$

式中， n 与 m_i ($i=1, 2, \dots, p$) 分别是 i 的分母和分子命令输入。相应的，参数 j 对应的规则后果 w_j 可表示为：

$$w_j = [b_{j11}, b_{j12}, \dots, b_{j1m_1}, \dots, a_{j1}, \dots, a_{jn}]^T \quad (3)$$

这些参数估计均通过加权最小二乘法 (WLS) 获得。因此，模型的全局输出可以作为所有 LLMs 输出的加权求和来计算，过程可如下所示：

$$y_M(k) = \sum_{j=1}^M \sum_{i=1}^p \left[\begin{aligned} & b_{ji1} u_i(k-1) + b_{ji2} u_i(k-2) + \\ & \dots + b_{jim_i} u_i(k-m_i) - \\ & a_{ji} y_M(k-1) - \\ & \dots - a_{jn} y_M(k-n) + \zeta_j \end{aligned} \right] * \bar{w}_j(x) \quad (4)$$

式中， b 和 a_m 分别表示分母和分子对应系数、 ζ_j 是 LLM_j 偏移量， $\varphi_j(x)$ 是操作点依赖加权因素。换句话说，不同的 LLMs 对应的网络是相同的，利用了其有效性函数。x 上的有效性函数通常选择作为正常化的高斯分布，所以它们形成一个统一的分区：

$$\sum_{j=1}^M \varphi_j(x) = 1 \quad (5)$$

在轴正交高斯分布中，有效性函数定义为：

$$\varphi_j(x) = \frac{\mu_j(x)}{\sum_{j=1}^M \mu_j(x)} \quad (6)$$

因此， $\mu_j(x)$ 可以设定为：

$$\mu_j(x) = \exp \left\{ -\frac{1}{2} \left[\left(\frac{x_1 - c_{j1}}{\sigma_{j1}} \right)^2 + \dots + \left(\frac{x_D - c_{jD}}{\sigma_{jD}} \right)^2 \right] \right\} \quad (7)$$

式中， D 是 LLNF 模型中输入通道的总数； c 和 σ 分别为中心坐标和个体标准差。

局部线性建模方法基于分而治之的策略。复杂的绕组过程模型分为较小的子模型，然后通过应用分段线性模型分别加以

解决。这种模型的成功使用最重要的因素是最初的复杂问题的划分策略。这是由一种名为 LOLIMOT 的算法来决定的。LOLIMOT 算法由一个外部循环(确定规则前提结构)和一个内部嵌套循环(规则结果参数优化)。这种循环可以概括成 5 个步骤^[5], 如下所示。

- (1) 开始, 首先初始化单个 LLM, 这是基于最小二乘估计的整个输入空间全局优化参数;
- (2) 找到表现最差的 LLM, 例如, 有着最大的局部损失函数;
- (3) 将 (2) 中所选的最差模型(神经元)进一步划分。此神经元的验证立方体用轴正交的拆分成两部分^[6]。该动作在所有层面进行, 并为每个拆分执行以下 4 个步骤:
 - ① 为两个超矩形构建多维模糊隶属度函数;
 - ② 构建有效性函数;
 - ③ 为两个新生成局部线性神经元的规则后续参数做局部优化;
 - ④ 计算当前的整体模型对应的全局损失函数。
- (4) 找到最佳模型(第 3 步中的最佳替代品), 并递增神经元数量: $M \rightarrow M+1$ 。
- (5) 测试收敛性。

2.3 多层反馈神经网络

多层反馈神经网络对于工厂的基于数据的建模是十分适用的, 因为其一般函数逼近能力很强^[7]。一种适合 MISO 的 MLP 神经网络的体系结构如图 3 所示。此网络有一个非线性隐藏层, 具有 L 切线双曲激活函数。输出层也有一个线性斜率为 1 的神经元激活函数^[8]。

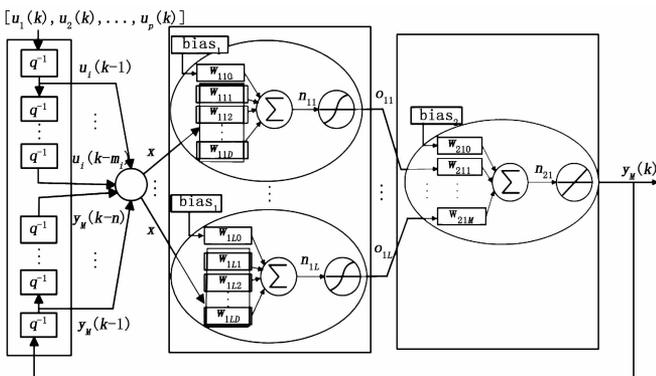


图 3 MLP 网络的结构

本文应用 LM 算法来更新 MLP 网络参数, 因为它具有以下优点: 比 GD 方法更快的收敛速度、具有比 GN 法更高的鲁棒性^[9]。LM 算法更新多层反馈神经网络参数的规则可描述如下:

$$\begin{cases} W_{n+1} = W_n + \Delta W \\ \Delta W = - (J^T(W)J(W) + \mu I)^{-1} (J^T(W)e) \end{cases} \quad (8)$$

式中, e 是误差函数; J 是雅可比矩阵; μ 是标量, 使得 LM 更接近于 GD 或 GN; W 包含网络的权重, 定义如下:

$$W = [\omega_{110}, \omega_{111}, \dots, \omega_{11L}, \dots, \omega_{21M}] \quad (8)$$

关于前馈多层神经网络, 需要注意带有一个隐藏层的网络对于大多数逼近任务是足够的。多层可以提供更好的适应性, 但训练的要求时间较长^[10]。

3 实验设计与结果分析

3.1 评价指标建立

为了评估本文所建模型的性能, 我们应用均方误差 (MSE) 和方差占 (VAF) 等概念。MSE 被定义为:

$$MSE = \frac{1}{Q} \sum_{N=1}^Q (y_p(N) - y_m(N))^2 \quad (9)$$

方差占百分值也用来测量本文所建模型的性能:

$$VAF = 1 - \frac{\text{cov}(y_p - y_m)}{\text{cov}(y_p)} \times 100\% \quad (10)$$

式中, $\text{cov}(\cdot)$ 表示各自向量的协方差。

LLNF 和神经网络模型的最关键的关注是神经元, 数目应尽可能小。本文中所述所有网络神经元数目均基于 MSE 曲线。一类典型的 MLP 网络 MSE 曲线如图 4 所示。

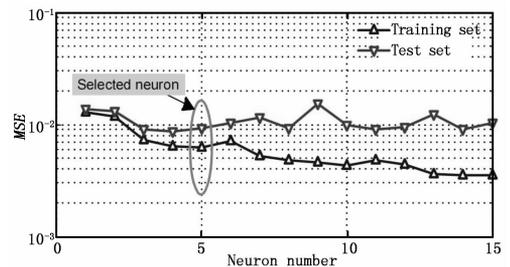


图 4 一类典型的 MLP 网络 MSE 曲线

在这方面, 理想的神经元数量是由增加的神经元数量决定, 直到更多的神经元对于试验数据 MSE 的减少并没有重大的影响。随着神经元数量从 1 到 5 的增加, 培训和测试数据集的 MSE 值下降。当隐藏神经元的数量超过 5, 试验数据中的 MSE 没有明显的改善。因此, 有 5 个隐藏的神经元感知器网络的选择是基于 MSE 曲线的。因此, 对于其他网络, 即 LLNF 执行相同的过程来选择最佳的神经元数。

图 5 和 6 显示的是 NF、MLP 等模型的反应, 以及实际绕组过程中卷轴 1 和 2 (T_1) 和卷轴 2 和 3 (T_3) 之间的紧密程度。NF 模型能够最好地跟踪绕组过程的相应产出。其他模型各自均存在一些问题, 特别是在一些时间间隔中存在。这种情况下可以观察到 220 s 和 225 s 之间的时间间隔中的实际的绕组过程 (T_3) 的第二个输出。据图可知。系统被 RLLNF 模型有效跟踪, 而其他智能模型, 即 MLP, 有一些跟踪问题, 尤其是在时间间隔的一组内的系统响应的波动(例如, [235、245] s)。LSE 线性模型则存在严重的跟踪问题, 尤其是与大

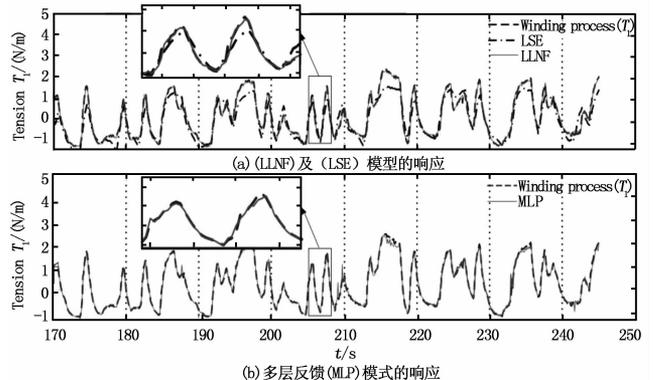


图 5 卷轴 1 和 2 之间 web 张力模型建模性能比较

震级的系统反应。根据上述分析可知，由于 *LSE* 是线性系统的最优建模方法，可以断定本文所述工业绕组过程属于非线性系统类别。

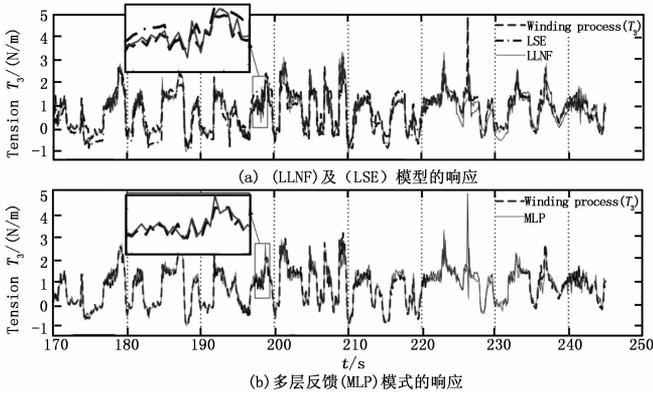


图 6 卷轴 2 和 3 之间 web 张力模型建模性能比较

3.2 实验结果分析

如表 2 所示，基于设置的模型精度标准的基础上，不同绕组机模型实现的准确结果一目了然。考虑到所取得的 *MSE* 和 *VAF* 值，本文提出的 *RLLNF* 模型获得了绕组过程的几乎整个非线性模拟与其他建模方法比较的最高精度。此外，需要注意表 2 中提交的非线性网络的神经元数目，其中 *RLLNF* 网络的神经元（规则）数目很大，原因就在于 *LOLIMOT* 算法突出的快速训练和评价能力。

表 2 绕组过程的线性和非线性模型精度结果

<i>LSE-T₁</i>	—	0.124 7	0.135 9	87.306 2	86.740 6
<i>MLP-T₁</i>	12	8.93e-4	8.61e-4	98.474 6	98.675 2
<i>LLNF-T₁</i>	20	1.44e-4	7.72e-4	99.691 5	98.823 4
<i>LSE-T₃</i>	—	0.254 7	0.243 0	75.231 3	73.985 5
<i>MLP-T₃</i>	5	9.27e-4	1.10e-3	93.531 7	89.905 2
<i>LLNF-T₃</i>	25	8.86e-4	1.10e-3	94.086 5	92.272 1

表 2 中的值是近似的。*LSE* 为最小平方误差；*MLP* 为多层感知器；*LLNF* 为局部线性神经模糊；*MSE* 为均方误差；*VAF* 为方差占。

本文所示的所有非线性仿真模型可能不需要真正绕组厂输出数据，而只是输入模型相关参数，也可以模拟出相关的工业

绕组过程属性。该智能仿真模型的配备使得模拟和设计基于模型的控制，用来针对整个经营范围的非线性绕组系统变为可能。此外，局部线性模型中的策略也可以成功的被应用于 *NF* 模拟器模型的构建等。

4 结束语

本文将基于 *RLLNF* 方法的非线性仿真模型应用到实际工业绕组过程中，其中，数据的建模、噪音消除、数据规范化和顺序选择至关重要。首先对数据进行预处理并取得丰富的数据集，将本文提出的 *NF* 模型与其他已知智能算法，即多层感知器 (*MLP*) 等进行比较，相关实验结果验证了本文提出算法的可行性与高效性。实验的结果表明，本文提出的 *NF* 模型展示除了最高精度。此外，通过线性和非线性建模方法之间的比较证明了绕组过程是一个非线性系统。应用此 *LLNF* 仿真模型开发绕组过程中基于模型的故障诊断和容错控制系统是今后的深入研究方向。

参考文献:

- [1] 彭金柱, 王耀南, 王 杰, 等. 基于递归模糊神经网络的机器人鲁棒 H_∞ 跟踪控制 [J]. 控制理论与应用, 2010, 27 (9): 1145-1151.
- [2] 李艳东, 王宗义, 朱 玲, 等. 基于递归模糊神经网络的移动机器人滑模控制 [J]. 吉林大学学报: 工学版, 2011, 41 (6): 1731-1737.
- [3] 李国勇, 刘 鹏. 一种递归模糊神经网络的广义预测控制方法 [J]. 太原理工大学学报, 2012, 43 (1): 11-15.
- [4] 陈向坚, 白 越, 续志军, 等. 基于自结构动态递归模糊神经网络的无人机姿态控制 [J]. 计算机应用研究, 2011, 28 (9): 3387-3389.
- [5] 张 瑶. 基于动态递归模糊神经网络的微生物发酵过程软测量方法研究 [D]. 镇江: 江苏大学, 2010.
- [6] 张平均, 蒋新华. 基于动态递归模糊神经网络的共振频率自适应反推控制 [J]. 信息与控制, 2011, 40 (1): 21-25.
- [7] Banadaki H D, Nozari H A, Kakahaji H. Nonlinear simulator model identification of a walking beam furnace using recurrent local linear neuro-fuzzy network [J]. Int. J. Control automation, 2011, 4 (4): 123-134.
- [8] 王 暑, 杨晓京. 基于模糊神经网络的烟叶烘烤温湿度监控系统研究 [J]. 计算机测量与控制, 2009, 17 (2): 342-344.

(上接第 1489 页)

红外传感器的闸机人体识别技术，设计了红外传感器的结构布局，采用事件识别标志分析和区域分析相结合的复合识别方法，对 4 种常见的闸机通行事件进行了分析，并开展了实验研究。实验结果表明：基于多红外传感器的闸机人体识别技术能够有效地识别闸机通行的多种事件，减少了数据量，简化了识别算法，提高了运算速度，具有较好的工程应用前景。

参考文献:

- [1] 赵瑞宇, 孙首群, 等. 高铁闸机智能监控系统中的行人检测算法研究 [J]. 计算机应用与软件, 2013, 30 (3): 85-88.

- [2] 朱小柯. 基于特征融合和支持向量机的步态识别算法研究 [D]. 开封: 河南大学, 2010.
- [3] 曲 日, 鲍彦和, 任长明. 城市轨道交通中闸机事件识别技术 [J]. 中国铁道科学, 2006, 27 (4): 112-118.
- [4] 张 娜. 城市轨道交通系统的闸机中图像处理与识别技术 [D]. 天津: 天津大学, 2006.
- [5] 牛国柱, 宋 哲, 李文文. 轨道交通闸机系统中的人体识别技术 [J]. 城市轨道交通研究, 2012, (1): 29-32.
- [6] 牟总斌. 基于人体头肩部与步态检测的闸机通行逻辑 [J]. 城市轨道交通研究, 2008, (8): 36-39.
- [7] 李建省, 张美凤. 地铁闸机控制系统中人体识别技术的研究与应用 [J]. 电气传动自动化, 2008, 30 (1): 22-24.