

基于模糊认知网络的改进非线性Hebbian算法

陈 宁[†], 王 磊, 彭俊洁, 刘 波, 桂卫华

(中南大学 信息科学与工程学院, 湖南 长沙 410083)

摘要: 针对难以用机理模型准确描述的非线性系统, 研究基于模糊认知网络(fuzzy cognitive networks, FCN)的非线性系统建模和参数辨识问题。首先, 建立非线性系统的具有数值推理和模糊信息表达的模糊认知网络模型, 利用包含节点、权值和反馈的有向图表示系统。其次, 由于模型的精确性取决于权值参数, 提出了一种带终端约束的非线性Hebbian学习算法(nonlinear Hebbian learning, NHL)。该算法在权值的学习过程中引入了FCN模型中节点的系统实际值, 在原更新机制的基础上, 增加了包含反馈值与预测值差值的修正项, 然后归一化得到最终权值迭代公式。该算法具有收敛速度快、学习结果精准等优点, 解决了传统非线性Hebbian算法对初始值依赖性强的缺点。最后将所提出的方法运用到水箱控制系统, 仿真结果说明了基于FCN的非线性Hebbian学习算法的有效性。

关键词: 模糊认知网络; 非线性Hebbian学习算法; 终端约束

中图分类号: TP309 文献标识码: A

Improved nonlinear Hebbian learning algorithm based on fuzzy cognitive networks model

CHEN Ning[†], WANG Lei, PENG Jun-jie, LIU Bo, GUI Wei-hua

(School of Information Science and Engineering, Central South University, Changsha Hunnan 410083, China)

Abstract: Modeling and parameter identification problems based on fuzzy cognitive networks (FCN) is studied for a kind of nonlinear systems which is difficult to accurately modelled by the mechanism. First, fuzzy cognitive networks with numerical reasoning and fuzzy information expression is established. The FCN model can express the system utilizing the directed graph containing nodes, weights, and feedback. Second, due to the precision of the model depends on the weight parameter, a nonlinear Hebbian learning algorithm with terminal constraints is proposed. The algorithm introduces the actual feedback value of system to the process of weight training. Based on the old update mechanism, a correction term with difference between the feedback value and predictive value is increased, then normalized to the final weight iteration formula. This algorithm has the advantages of fast convergence rate, high accuracy. The nonlinear Hebbian algorithm solves the shortcomings of traditional nonlinear Hebbian learning algorithm that initial value is strongly depended. Finally, the proposed method is applied to water tank control system. The simulation results illustrate the nonlinear Hebbian learning algorithm based on FCN is effective.

Key words: fuzzy cognitive networks; nonlinear Hebbian learning; terminal constraint

1 引言(Introduction)

随着生产力日益提升, 现代人类社会系统和工业过程越来越复杂, 具有强非线性、多变量耦合、模糊性等特点, 且各类数据、信息和知识之间的关系难以表达。传统数学机理建模方法^[1]由于对精确机理和对象信息的强依赖性已经不能满足当前需求。模糊认知图(fuzzy cognitive map, FCM)^[2]是一种新型的建模方法, 能够依靠人类的推理过程, 利用包括不确定性和模糊性的描述来处理复杂系统。

FCM是神经网络和模糊逻辑相结合的一种软计算

方法^[3-4], 是由节点、弧和权重组成的有向图。其中, 认知图的顶点称之为概念节点, 代表一个用来描述系统的实体、行为等特性。连接两个概念节点的带符号和权重的弧代表这些概念之间存在的因果关系。各概念状态值的取值范围是[0, 1]或[-1, 1], 权值的取值范围是[-1, 1]。

FCM具有较好的动态特性和学习能力, 在建模、过程分析、决策制定等方面表现出了很强的优越性^[5]。Papageorgiou等提出一种基于数据驱动的非线性FCM动态系统建模方法^[6]。文献[7]利用现有的知识和专家

收稿日期: 2015-10-09; 录用日期: 2016-05-27

[†]通信作者。E-mail: ningchen@csu.edu.cn; Tel.: +86 13875915950。

本文责任编辑: 王伟。

国家自然科学基金创新研究群体科学基金项目(61321003), 国家自然科学基金项目(61673399)资助。

Supported by Foundation for Innovative Research Groups of National Natural Science Foundation of China (61321003) and National Natural Science Foundation of China (61673399).

经验改进了FCM的软计算方法,采用新的构造算法实现复杂系统的建模,并应用在热交换器的加工工业问题上.

传统的FCM也存在一些难以解决的问题,如对专家知识依赖性大、离线模拟系统过程.一旦根据专家经验或获得的数据构造出了认知图并确定了权值,FCM就离线运作.专家的知识可能不准确或者系统在运行过程中发生变化会导致FCM不能正确地反应当前系统的实际状态.

模糊认知网络(fuzzy cognitive networks, FCN)^[8-10]是为了与实际系统保持密切交互描述而对FCM进行的扩展,可以对系统做出更适合的控制和自适应决策. FCN框架包括一个模糊认知图,一个基于系统反馈的更新机制以及整个操作过程中获得知识的存储. FCN只在初始点使用或者完全脱离专家经验,能够解决传统FCM建模方法对专家经验依赖性强的缺点.同时,建立一个动态地模糊规则数据库,保存了系统在不同平衡点处的模型参数.

一个模型的精度很大程度上依赖于其参数的设定,FCN也不例外.类似于神经网络的参数辨识,权值学习是利用一定的机制更新节点之间的因果关系,通过微调初始权值来提高FCN的精确度.近年来,权值学习引起了广大学者关注,多种学习方法得以提出. Dickerson和Kosko提出一个简单的微分Hebbian学习方法算法(differential Hebbian learning, DHL)^[11]. DHL是一个典型的无监督学习方法,但是没有明确的数学计算公式,无法在实际中应用. Papageorgiou等人提出了非线性Hebbian学习法(nonlinear Hebbian learning, NHL)^[12]. koulouriotis等人提出了基于历史数据的遗传算法^[13],通过收集输入/输出数据对来计算FCM模型的权值,由于计算需要多个状态向量序列,该方法在一些领域难以得到应用.文献[14-15]中提出了基于群智能算法的粒子群优化算法(particle swarm optimization, PSO),该算法以人群为基础,通过维护和改造群个体来搜索一个最优位置,PSO学习需要人的知识来指定适当的约束,使得算法的计算效率降低.

传统的Hebbian算法对专家依赖性强,这一致命缺点很大程度上制约了其在FCN中的应用,为了解决这一问题,本文对其进行改进,提出了带终端约束的非线性Hebbian算法.利用概念节点在实际系统中的直接反馈值和节点目标值的约束来学习权值.

2 模糊认知网络(Fuzzy cognitive networks)

FCN建模方法是为了与实际系统保持紧密连接而对FCM进行的扩展,也是一种结合模糊逻辑和神经网络的建模理论.一个非线性系统可以用FCN表示成一个包括节点、权值、带系统反馈的有向图,当有向图取不同初始值和权值时,对应实际系统的不同工况.其

中:用 $C = \{C_1, C_2, \dots, C_n\}$ 表示构成模糊认知图的顶点的概念集合,每一个顶点称之为概念节点,代表系统的特征,如变量、状态、事件、目标等;用 A_i^k 表示节点 C_i 在 k 时刻的状态,它的取值是由系统的实际状态值利用阈值函数转换而来,取值范围为 $[0, 1]$;用 W_{ij} 表示节点 C_i 和节点 C_j 之间的因果影响程度,值域为 $[1, -1]$.如果 $W_{ij} > 0$,则结果概念节点 C_j 的状态正向跟随原因概念节点 C_i 变化;反之,如果 $W_{ij} < 0$,则反向跟随变化;如果 $W_{ij} = 0$,则两个节点之间没有关联.

系统动态行为间的关系都存储于认知图的网络结构和节点间相互影响的因果关系中.每一时刻的节点状态值受该节点上一时刻的状态值取值以及对其有影响节点取值影响.每个时刻的系统状态值可以用下式进行计算^[3]:

$$\mathbf{A}^k = f(\mathbf{A}^{k-1} + \mathbf{A}^{k-1}\mathbf{W}), \quad (1)$$

其中: \mathbf{A}^k 是 k 时刻的状态值矩阵,维数为 $1 \times n$ (n 是系统的概念节点个数); \mathbf{A}^{k-1} 是 $k-1$ 时刻的状态值矩阵,维数为 $1 \times n$; \mathbf{W} 是表示节点之间影响程度的权值矩阵,维数为 $n \times n$; f 是转换函数,用来保证将状态值转换到 $[0, 1]$ 之间,一般选择S型曲线函数,取 $f = 1/(1 + e^{-cx})$.

为了让FCN与实际系统保持密切交互,可以将有向图的状态节点分成控制节点、稳定节点、输出节点和中间节点.控制节点代表实际系统的控制量,稳定节点代表系统中不受其他节点影响但是对其他节点有影响的节点,输出节点代表系统的输出,中间节点是除去前面节点的其他所有节点.根据不同类型节点的特性,对状态值更新机制加以改进,通过引入稳定节点和输出节点的系统反馈值,将更新方程(1)改进为式(2)和式(3).

一般节点的状态值更新为

$$A_i^{k,\text{FCN}} = f(A_i^{k-1,\text{FCN}} + \sum_{i=1, i \neq j}^N A_i^{k-1,\text{FCN}} W_{ji}^{(k-1)}). \quad (2)$$

稳定节点和输出节点的状态值为

$$A_i^{k,\text{FCN}} = A_i^{\text{system}}, \quad (3)$$

其中: $A_i^{k,\text{FCN}}$ 是节点 C_i 在 k 时刻的FCN计算值, $A_i^{k-1,\text{FCN}}$ 是节点 C_i 在 $k-1$ 时刻的FCN计算值, W_{ji} 是节点 C_j 对节点 C_i 的影响权值, f 是转换函数, A_i^{system} 是节点 C_i 的系统实际值,通过在线测量或事先给定.

针对系统的每个平衡点,专家根据知识和经验给出当概念节点与权值初始值时,FCN模型就已经确定.但是由于专家经验局限性,权值的取值可能和实际系统存在一定的差异,这便需要对权值进行学习.

3 权值学习(Weight training)

3.1 非线性Hebbian算法(Nonlinear Hebbian learning)

非线性Hebbian算法(nonlinear Hebbian learning, NHL)是一种无监督权值学习方法^[12]. 选择S型曲线 $f = 1/(1 + e^{-cx})$ 为转换函数, 由专家确定权值初始值, 对初始权值进行迭代更新, 直到满足节点的限制标准. NHL权值更新公式为

$$W_{ji}^k = (1 - \gamma)W_{ji}^{(k-1)} + \eta A_j^{(k-1)} \times A_i^{(k-1)} - \eta W_{ji}^{(k-1)}(A_j^{(k-1)})^2, \quad (4)$$

其中: k 是任意的一个时刻; W_{ji}^k 是节点 C_j 对节点 C_i 在 k 时刻的影响权值; W_{ji}^{k-1} 是节点 C_j 对节点 C_i 在 $k-1$ 时刻的关联程度; $A_j^{(k-1)}$ 是节点 C_j 在 $k-1$ 时刻的状态值; $A_i^{(k-1)}$ 是节点 C_i 在 $k-1$ 时刻的状态值; γ 和 η 是两个很小的正数, 分别代表衰减率和学习率, 通常 $0 < \gamma, \eta < 0.1$.

在式(4)中, 前面两项 $(1 - \gamma)W_{ji}^{(k-1)} + \eta A_j^{(k-1)} \times A_i^{(k-1)}$ 是Hebbian理论的权值修正, 计算模型中节点状态值对权值的修正; 后面一项 $-\eta W_{ji}^{(k-1)}(A_j^{(k-1)})^2$ 是为了保证每一个 W_{ji} 的取值都在 $[-1, 1]$ 范围内.

NHL学习法制定了两个标准函数:

标准 1

$$F_1 = \sqrt{\sum_{i=1}^m (\text{DOC}_i - T_i)^2}, \quad (5)$$

其中: m 是系统输出节点个数; DOC(desired output concept) 是期望输出值, DOC_i 代表计算所得的节点 C_i 的状态值, T_i 是节点 C_i 的期望状态均值. 当 F_1 达到最小值时则认为FCM达到了最终平衡点.

标准 2

$$F_2 = |\text{DOC}_i^{(k+1)} - \text{DOC}_i^k| < e, \quad (6)$$

F_2 是前后两次迭代的结果差的绝对值, 当其小于 0.002 时则认为可以终止迭代.

NHL学习法利用权值关联的原因节点状态值与结果节点状态值对权值进行修正, 没有其他约束条件提高学习效率以及模型准确度, 是一个无监督算法. 由

$$W_{ji}^{k+1} = \frac{(1 - \gamma)W_{ji}^k + \eta A_j^{\text{FCN}} \times A_i^k + \kappa p_i(1 - p_i)A_j^{\text{FCN}}}{\sqrt{\sum_{\substack{j=1 \\ j \neq i}}^n ((1 - \gamma)W_{ji}^k + \eta A_j^{\text{FCN}} \times A_i^{\text{FCN}} + \kappa p_i(1 - p_i)A_j^{\text{FCN}})^2}}, \quad (9)$$

其中: n 是模型节点的个数, 分母包括了与节点 C_i 有关的所有权值.

利用泰勒公式等进行一系列的数学转换, 由于 γ , η 和 κ 取值较小, 泰勒展开式的高阶部分可以省略,

于对专家的依赖性较强, 自主学习能力比较差, 当系统发生变化时, 无法及时跟踪反应, 学习的效率以及准确度都会受到影响.

3.2 带终端约束的NHL(Nonlinear Hebbian learning with terminal constraints)

为了使FCN实时精准的反应系统状态并做出正确的控制, 必须对NHL算法提出改进. 离线学习的模型对系统工况的变化不敏感, 要提高其跟踪能力, 要将权值的学习与系统实际工况相结合. 笔者发现每一次迭代学习得到的状态值作为控制量作用于原系统可以得一个实时值, 可以将其作为学习的目标, 故引进系统实际测量值作为约束来更新FCM的权值, 在NHL的基础上提出带终端约束的非线性Hebbian算法.

NHL算法是利用前一时刻的两个状态值的乘积对他们之间的权值进行修正, 是无方向修正. 带终端约束的非线性Hebbian算法的权值更新引入了系统反馈作为约束, 模型预测值与系统实际的测量值之间的差值作为调整权值的标准. 误差大小直接反应预测值与真实值的差距, 可以实现对权值进行有向修正, 提高了收敛速率, 同时也解决了传统的无监督NHL对专家初始值依赖性强的缺点.

带终端约束的NHL算法将式(4)改进为

$$p_i = A_i^{\text{system}} - \frac{1}{1 + e^{-(A_i^{\text{system}} + \sum_{j=1, j \neq i}^N A_j^{\text{system}} W_{ji})}} = A_i^{\text{system}} - A_i^{\text{FCN}}, \quad (7)$$

$$W_{ji}^{k+1} = (1 - \gamma)W_{ji}^k + \eta A_j^{\text{FCN}} \times A_i^{\text{FCN}} + \kappa p_i(1 - p_i)A_j^{\text{FCN}}, \quad (8)$$

其中: p_i 是节点 C_i 的误差, A_i^{FCN} 是节点 C_i 的FCN计算值, A_j^{FCN} 是节点 C_j 的FCN计算值, A_i^{system} 是节点 C_i 的实时系统测量值, W_{ji}^{k+1} 是节点 C_j 对节点 C_i 在 $k+1$ 时刻的关联程度, W_{ji}^k 是节点 C_j 对节点 C_i 在 k 时刻的关联程度, γ 是衰减系数, η 是学习率, κ 是修正率, 通常 $0 < \gamma, \eta, \kappa < 0.1$.

为了避免 \mathbf{W} 的过度增长, 保证其取的值在 $[-1, 1]$, 要求 \mathbf{W} 的取值满足 $\|\mathbf{W}\| = 1$, 于是在每一步的计算中将式(8)归一化为式(9):

式(9)可以近似简化成

$$\begin{aligned} W_{ji}^{k+1} = & (1 - \gamma)W_{ji}^k + [\eta + \kappa p_i(1 - p_i)]A_j^{\text{FCN}}A_i^{\text{FCN}} + \\ & \kappa p_i(1 - p_i)W_{ji}^kA_j^{\text{FCN}} - \eta W_{ji}^k(A_j^{\text{FCN}})^2. \end{aligned} \quad (10)$$

带终端约束的NHL算法改进结束迭代的标准函数数为:

标准1

$$F_1 = |A_i^{k+1, \text{FCN}} - A_i^{k, \text{FCN}}| < v, \quad (11)$$

其中: $A_i^{k, \text{FCN}}$ 是节点 C_i 在 k 时刻的 FCN 计算值, $A_i^{k-1, \text{FCN}}$ 是节点 C_i 在 $k-1$ 时刻的 FCN 计算值, F_1 是前后两次迭代的结果差的绝对值, 当其小于 0.002 时则认为系统达到了平衡点.

标准2

$$F_2 = |p_i| < e, \quad (12)$$

其中: p_i 是节点 C_i 的误差, 当所有节点的误差都小于阈值时则可以终止迭代, 一般取 $e = 0.001$.

算法1

Step 1 专家根据经验和历史数据给出初始状态值和初始权值;

Step 2 利用式(2)和式(3)计算下一时刻的节点状态值;

Step 3 测量系统值, 将计算所得状态值与实际系统值比较, 根据式(7)计算输出节点的误差; 根据前一个时刻的状态值与当前时刻状态值计算其他节点的误差;

Step 4 判断每一个节点的取值是否满足标准式(11)和式(12). 如果任意一个条件不满足, 跳转到 Step5; 如果全部满足, 则结束更新, 存储最终权值矩阵;

Step 5 利用式(10)对非零权值进行更新, 跳转到 Step2.

由于引进系统的反馈, 带终端约束的NHL在每一次的迭代中都根据实际测量值对权值进行修正, 能快速收敛到准确反映系统的权值, 也解决了非线性Hebbian算法对初始值依赖性强的缺点.

4 仿真分析(Simulation analysis)

4.1 水箱控制过程建模(Modeling of the tank control process)

一个水箱控制过程的系统包括2个水箱、3个开关、1个加热元件和2个温度计. 每个水箱都有一个入水阀和一个出水阀, 且第1个水箱的出水阀是第2个水箱的入水阀. 如图1所示: V1为1号水箱的入水阀, V2为1号水箱的出水阀和2号水箱的入水阀, V3为2号水箱的出水阀.

水箱的工作原理: 水箱1的温度通过调节加热元件控制, 水箱2的温度通过热量传递, 当水箱2温度过低时, 开关2打开, 热水从水箱1流进水箱2, 当水箱1的水位过高时, 打开开关1进水, 当水箱2的水位过高时, 打开开关3放水.

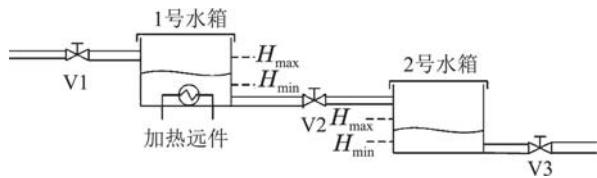


图1 水箱控制过程

Fig. 1 The control process of tanks

水箱控制系统的控制目标有两个: 一是两个水箱的水面高度保持在一定的范围内, 即上限 H_{\max} 和下限 H_{\min} 之间; 二是两个水箱的温度保持在最大值 T_{\max} 和最小值 T_{\min} 之间. 因此, 控制目标是1号水箱液位 H^1 , 2号水箱液位 H^2 , 1号水箱的温度 T^1 , 2号水箱的温度 T^2 . 控制目标的期望区间为

$$\begin{cases} H_{\min}^1 \leq H^1 \leq H_{\max}^1, \\ H_{\min}^2 \leq H^2 \leq H_{\max}^2, \\ T_{\min}^1 \leq T^1 \leq T_{\max}^1, \\ T_{\min}^2 \leq T^2 \leq T_{\max}^2. \end{cases} \quad (13)$$

为了确定描述系统的FCN对象, 必须考虑到系统的变量, 如水箱中液位的高度, 温度的高低; 系统中影响变量的要素, 如阀门的状态.

FCN通过一系列相互有关联的节点来描述一个动态系统. 针对水箱控制过程, 利用专家知识和历史数据, 建立FCN模型如图2所示.

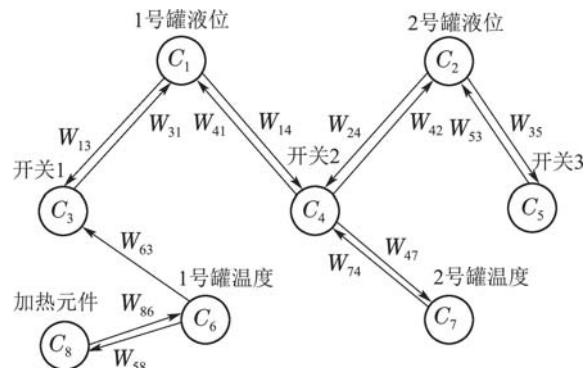


图2 水箱控制过程的FCN模型

Fig. 2 FCN model of the tank control process

该模型中包括的节点为水箱1的液面高度 C_1 , 水箱2的液面高度 C_2 , 开关1的状态 C_3 , 开关2的状态 C_4 , 开关3的状态 C_5 , 水箱1的温度 C_6 , 水箱2的温度 C_7 , 加热元件的状态 C_8 . 模型中每个节点的状态值对应着系统的实际值, 节点间的权值表示节点相互影响程度.

取两个水箱的液面高度和温度作为控制的目标, 即节点1、节点2、节点6和节点7为输出节点. 输出值的目标值代表所模拟系统的期望输出, 在水箱控

制系统中,根据不同的需求,有不同的控制目标,在本次模拟中专家定义目标节点的控制目标为 $ADC_1 = 0.65$, $ADC_2 = 0.775$, $ADC_6 = 0.785$, $ADC_7 = 0.7$,由于实际系统中不可能达到一个完全确定的平衡点,于是将控制目标扩展成一个区间:

$$\begin{cases} 0.55 \leq ADC_1 \leq 0.75, \\ 0.75 \leq ADC_2 \leq 0.8, \\ 0.75 \leq ADC_6 \leq 0.82, \\ 0.65 \leq ADC_7 \leq 0.75. \end{cases} \quad (14)$$

根据历史数据和经验,专家在FCN模型的基础确定权值初始值矩阵为

$$W_0 =$$

$$\begin{bmatrix} 0 & 0 & 0.21 & 0.38 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.70 & 0.60 & 0 & 0 & 0 \\ 0.75 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -0.8 & 0.76 & 0 & 0 & 0 & 0 & 0.09 & 0 \\ 0 & -0.42 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.40 & 0 & 0 & 0 & 0 & 0.53 \\ 0 & 0 & 0 & 0.30 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.60 & 0 & 0 \end{bmatrix}. \quad (15)$$

4.2 仿真结果比较(Comparison of simulation results)

在水箱控制系统的研究中,建立的FCN模型包含8个节点,权值矩阵维数为 8×8 ,专家给定初始状态值 $A_0 = [0.48, 0.57, 0.58, 0.68, 0.59, 0.59, 0.52, 0.58]$,初始值矩阵 W_0 如式(15)所示。本文先后将初值即无权值学习、NHL学习所得权值和用带终端约束的非线性Hebbian算法学习所得权值分别代入系统模型,对达到平衡状态的各节点终值的准确度以及收敛速度进行对比,分析各个算法的优劣。

4.2.1 无权值学习结果(Results without training)

假设模型中节点互连的权重是固定的取初始值 W_0 不变,FCN利用式(1)经过数次状态值迭代后,将

收敛到一个定点,即系统达到稳定。具体如图3所示。

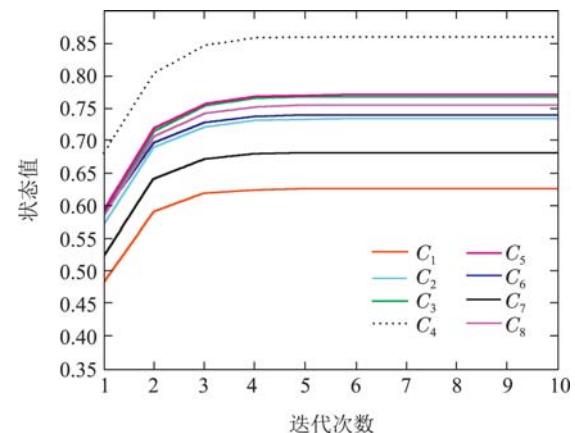


图3 无权值学习的FCN仿真结果

Fig. 3 FCN simulation results without training

没有经过权值学习的FCN模型基于专家给定的初始权值,自主迭代达到平衡点时,各节点状态值取值为

$$\begin{aligned} A^{\text{equil}} = \\ [0.6256, 0.7334, 0.7675, 0.8600, \\ 0.7704, 0.7390, 0.6810, 0.7548], \end{aligned} \quad (16)$$

其中平衡状态的 $A_2 = 0.7334$, $A_6 = 0.7390$,取值明显超出了式(14)中控制目标 ADC_2 , ADC_6 的范围。这表明由于专家知识的局限性和离线运作无法跟随系统的实际变化,无权值学习的FCN模型无法准确模拟系统的实际工况。

4.2.2 NHL学习结果(Results trained by NHL)

没有学习的FCN模型收敛达到的平衡点不符合系统的控制目标,说明由专家指定的初始权值无法精确反应实际系统。

在专家给定初始权值 W_0 的基础上, $\gamma = 0.01$ 取衰减系数, $\eta = 0.04$ 学习率, 利用NHL算法的权值更新公式(4)对初始权值进行迭代学习,直到同时满足NHL的两个标准函数式(5)和式(6)则跳出迭代,得到学习后的权值矩阵为

$$W_{\text{NHL}} = \begin{bmatrix} 0 & 0.022 & 0.244 & 0.413 & 0.039 & 0.04 & 0.035 & 0.041 \\ 0.043 & 0 & 0.045 & 0.721 & 0.617 & 0.046 & 0.039 & 0.047 \\ 0.754 & 0.026 & 0 & 0.055 & 0.047 & 0.049 & 0.042 & 0.05 \\ -0.695 & 0.7052 & 0.054 & 0 & 0.052 & 0.08 & 0.131 & 0.054 \\ 0.045 & -0.381 & 0.047 & 0.052 & 0 & 0.048 & 0.042 & 0.049 \\ 0.044 & 0.027 & 0.429 & 0.051 & 0.044 & 0 & 0.041 & 0.50 \\ 0.041 & 0.024 & 0.042 & 0.335 & 0.04 & 0.04 & 0 & 0.041 \\ 0.045 & 0.027 & 0.047 & 0.052 & 0.044 & 0.428 & 0.042 & 0 \end{bmatrix}. \quad (17)$$

在 \mathbf{W}_{NHL} 中,可以看出,节点影响程度为零的权值在迭代中也会有轻微的改变,变成非零值.将学习完成的权值矩阵 \mathbf{W}_{NHL} 代入FCN模型,取同一初始状态值 \mathbf{A}_0 ,经过8次迭代后,系统达到平衡状态,得到最终状态值的取值为

$$\begin{aligned} \mathbf{A}_{\text{NHL}}^{\text{equil}} = & [0.7056, 0.7657, 0.8217, 0.8965, \\ & 0.8182, 0.8010, 0.7404, 0.8108]. \end{aligned} \quad (18)$$

具体迭代过程如图4所示.

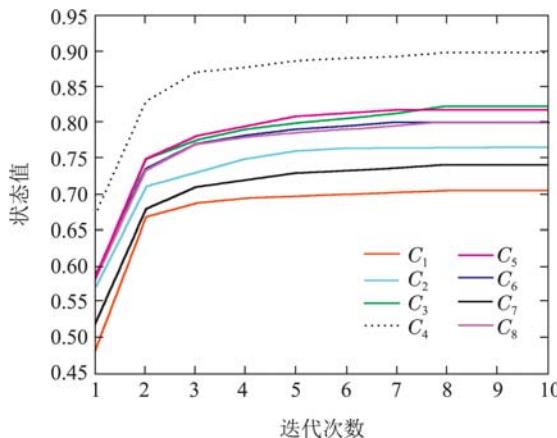


图4 NHL学习后的FCN仿真

Fig. 4 FCN simulation results trained by NHL

由式(18)的结果可以看出,NHL学习后的权值

$$\mathbf{W} = \begin{bmatrix} 0 & 0 & 0.2992 & 0.4109 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.7457 & 0.7804 & 0 & 0 & 0 \\ 0.8954 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -0.8188 & 0.8562 & 0 & 0 & 0 & 0 & 0.2057 & 0 \\ 0 & -0.3883 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.5259 & 0 & 0 & 0 & 0 & 0.7109 \\ 0 & 0 & 0 & 0.3313 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.6072 & 0 & 0 \end{bmatrix}. \quad (20)$$

从式(20)可以看到,在权值矩阵 \mathbf{W} 中,只有初始值非零的权值发生了改变,不会与传统非线性Hebbian算法一样将所有的权值进行调整.将学习完成的权值矩阵 \mathbf{W} 代入FCN模型,模型自主进行状态更新,经过5次迭代后FCN模型能够迅速达到平衡点,当系统达到平衡点时,各个节点状态的值取值为

$$\begin{aligned} \mathbf{A}^{\text{equil}} = & [0.6598, 0.7700, 0.8039, 0.8761, \\ & 0.8028, 0.7792, 0.7086, 0.7938]. \end{aligned} \quad (21)$$

具体过程如图5所示.

\mathbf{W}_{NHL} 能够使FCN模型达到平衡状态时保证所有输出节点 A_1, A_2, A_6, A_7 的取值都满足式(14)中控制目标的范围.说明经过NHL学习后的系统模型,能够让所有都达到目标的期望范围,可以比较准确地模拟系统工况.由此可以得出结论,NHL对FCN模型的权值有一定的修正作用.但是NHL学习法也存在一定的缺点,如收敛速度比较缓慢,精度也不够高,零权值在迭代过程中也会被修改成较小的非零值以及对初始权值依赖性大.

4.2.3 带终端约束的NHL学习结果(Results trained by NHL with terminal constraints)

利用带终端约束的非线性Hebbian算法对权值进行学习.在水箱控制系统的FCN模型中,将节点 C_1, C_2, C_6, C_7 作为带反馈的输出节点,在线将系统的反馈值代入迭代过程,使权值迅速有向收敛到能正确反映系统性质的稳定值.测量得到水箱的实际系统输出值为

$$\begin{aligned} \mathbf{A}_{\text{system}}^{\text{system}} = & [0.6597, 0.7703, 0.8038, 0.8760, \\ & 0.8035, 0.7802, 0.7096, 0.7946]. \end{aligned} \quad (19)$$

利用算法1的更新步骤在线更新修正权值,取衰减系数 $\gamma = 0.01$,学习率 $\eta = 0.02$,修正率 $\kappa = 0.09$.带终端约束的非线性Hebbian算法学习得到的最终权值

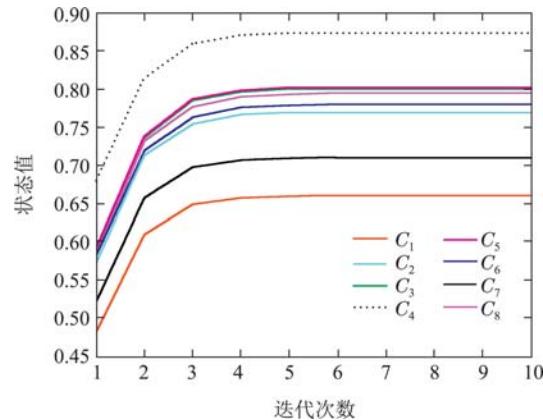


图5 带终端约束的NHL学习后的FCN仿真
Fig. 5 FCN simulation results trained by NHL with terminal constraints

由带终端约束的Hebbian算法的仿真结果式(21)可以看出, 带终端约束的非线性Hebbian算法学习后的FCN模型达到稳态时, 各输出节点的状态终值 A_1, A_2, A_6, A_7 不仅完全满足式(14)中的控制目标区间, 而且非常接近式(19)中的系统测量值。因此, 经过带终端约束的非线性Hebbian算法学习后的系统性能, 比非线性Hebbian算法学习结果只能保证状态值落入期望范围有明显提升, 而且收敛速度也明显加快。

当权值的初始取值发生改变时, NHL由于对初始值的强依赖性, 其学习结果会跟着改变, 导致系统模型发生变化。带终端约束的非线性Hebbian算法引进了系统反馈值, 解决了传统NHL的依赖问题。例如, 初始权值矩阵随机取

$$\mathbf{W}' = \begin{bmatrix} 0 & 0 & 0.2987 & 0.4112 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.7463 & 0.7801 & 0 & 0 & 0 \\ 0.8846 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -0.8098 & 0.8562 & 0 & 0 & 0 & 0 & 0.2056 & 0 \\ 0 & -0.3857 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.5259 & 0 & 0 & 0 & 0 & 0.7107 \\ 0 & 0 & 0 & 0.3313 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.6074 & 0 & 0 \end{bmatrix}. \quad (23)$$

由 \mathbf{W}' 与 \mathbf{W} 的比较可以看出, 当初始权值由式(15)所示的 \mathbf{W}_0 变为式(22)所示的 \mathbf{W}'_0 时, 最终得到的权值矩阵与带终端约束的非线性Hebbian算法在初始权值取 \mathbf{W}_0 时学习所得权值矩阵基本一致。由此可以得出结论, 无论初始权值取值如何, 带终端约束的非线性Hebbian算法可以根据其系统反馈值将权值修正, 克服了传统NHL对初始值依赖性大的缺点。因此, 本文提出的带终端约束的非线性Hebbian算法引入了系统的反馈, 得到的稳态值更加接近期望值, 而且收敛速度比传统NHL明显加快。既提高了收敛效率, 增强了精确度, 又解决了传统Hebbian算法对初始值依赖性大的问题。

5 结论(Conclusions)

通过对非线性系统建模的深入研究, 建立了基于数据和知识的FCN模型, 并提出带终端约束的非线性Hebbian算法对权值进行学习。带终端约束的非线性Hebbian算法将系统反馈引入到权值迭代过程中, 使权值的迭代有监督的向系统真实值不断靠近, 提高了学习质量。基于一个水箱控制过程的FCN模型, 将带终端约束的非线性Hebbian算法与传统NHL算法对比。结果表明, 带终端约束的非线性Hebbian算法收敛速度快, 精确度高而且不依赖

$$\mathbf{W}'_0 =$$

$$\begin{bmatrix} 0 & 0 & 0.45 & 0.83 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.52 & -0.24 & 0 & 0 & 0 \\ 0.15 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -0.4 & 0.60 & 0 & 0 & 0 & 0 & 0.49 & 0 \\ 0 & 0.32 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.13 & 0 & 0 & 0 & 0 & 0.75 \\ 0.1 & 0 & 0 & -0.41 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.2 & 0 & 0 \end{bmatrix}. \quad (22)$$

在初始状态值 A_0 的基础上, 利用带终端约束的非线性Hebbian算法, 根据算法1的步骤进行权值学习, 得到的最终权值为

于专家确定的初始值。因此, 基于FCN带终端约束的非线性Hebbian算法提高了模型精度, 解决了传统NHL的缺点, 并在水箱系统中得以验证。未来会将带终端约束的非线性Hebbian算法在各个领域的更加复杂的系统中进行应用, 同时对FCN模型进一步改进, 使之能够更加灵活反应复杂非线性系统。

参考文献

- [1] MAFFI T, SOMMARIVA S, RANZI E, et al. A predictive kinetic model of sulfur release from coal [J]. *Fuel*, 2012, 91(1): 213–223.
- [2] KOSKO B. Fuzzy cognitive maps [J]. *International Journal of Man-Machine Studies*, 1986, 24(1), 65–75.
- [3] SHIGEO A. *Neural Networks and Fuzzy Systems* [M]. New York: Springer, 1997.
- [4] STYLIOS C D, GROUMPOS P P. Fuzzy cognitive maps: a soft computing technique for intelligent control proceedings [C] //Proceedings of 15th International Symposium on Intelligent Control. Rio, Patras, Greece: [s.n.], 2000: 97–102.
- [5] PAPAGEORGIOU E I. Yield prediction in apples using fuzzy cognitive map learning approach [J]. *Computers and Electronics in Agriculture*, 2013, 91(2): 19–29.
- [6] STYLIOS C D, GROUMPOS P P. Modeling complex systems using fuzzy cognitive maps [J]. *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, 2004, 34(1): 155–162.

- [7] STYLIOS C D, GROUMPOS P P. Fuzzy cognitive maps in modeling supervisory control systems [J]. *Journal of Intelligent and Fuzzy Systems*, 2000, 2(8): 83 – 98.
- [8] ZHANG J, LIU Z Q, ZHOU S. Dynamic domination in fuzzy causal networks [J]. *IEEE Translations on Fuzzy Systems*, 2006, 14(1): 42 – 57.
- [9] LIU Z, ZHANG J. Interrogating the structure of fuzzy cognitive maps [J]. *Soft Computing*, 2003, 7(3): 148 – 153.
- [10] KOTTAS T L, BOUTALIS Y S, CHRISTODOULOU M A. Fuzzy cognitive networks: a general framework [J]. *Intelligent Decision Technologies*, 2007, 1(4): 183 – 196.
- [11] DICKERSON J A, KOSKO B. Virtual worlds as fuzzy cognitive maps [C] //Proceedings of IEEE Virtual Reality Annual International Symposium. Seattle, Washington: [s.n.], 1993: 471 – 477.
- [12] PAPAGEORGIOU E, STYLIOS C D, GROUMPOS P P. Fuzzy cognitive map learning based on nonlinear Hebbian rule [M] //Advances in Artificial Intelligence. Berlin: Springer, 2003: 256 – 268.
- [13] KOULOURIOTIS D E, DIAKOURAKIS I E, EMIRIS D M. Learning fuzzy cognitive maps using evolution strategies: a novel schema for modeling and simulating high-level behavior [C] //Proceeding of the 2001 Congress on Evolutionary Computation. Seoul, Korea: [s.n.], 2001: 364 – 371.
- [14] PARSOPOULOS K E, PAPAGEORGIOU E I, GROUMPOS P P, et al. A first study of fuzzy cognitive maps learning using particle swarm optimization [C] //The 2003 Congress on Evolutionary Computation. Canberra, Australia: [s.n.], 2003: 1440 – 1447.
- [15] PAPAGEORGIOU E I, PARSOPOULOS K E, STYLIOS C D, et al. Fuzzy cognitive maps learning using particle swarm optimization [J]. *Journal of Intelligent Information Systems*, 2005, 7(25): 95 – 121.

作者简介:

陈 宁 (1970–), 女, 教授, 博士生导师, 从事复杂大系统建模与控制、FCM方法和数字图像处理等研究,E-mail:ningchen@csu.edu.cn;

王 磊 (1993–), 女, 硕士研究生, 从事FCM的建模与控制研究, E-mail: 122548287@qq.com;

彭俊洁 (1989–), 男, 博士研究生, 从事FCM的建模与控制研究, E-mail: 236579623@qq.com;

刘 波 (1978–), 女, 博士, 从事具有饱和约束的多智能体系统的协调控制, E-mail: 57562669@qq.com;

桂卫华 (1950–), 男, 中国工程院院士, 教授, 博士生导师, 主要研究方向为工业大系统递阶和分散控制理论及应用、复杂生产过程建模与控制, E-mail: gwh@csu.edu.cn.