

# 模糊灰色认知网络的建模方法及应用

陈宁<sup>1</sup> 彭俊洁<sup>1</sup> 王磊<sup>1</sup> 郭宇骞<sup>1</sup> 桂卫华<sup>1</sup>

**摘要** 针对具有不确定性非线性系统的机理模型难以建立的问题, 提出了基于模糊灰色认知网络 (Fuzzy grey cognitive networks, FGCN) 的非线性系统建模方法. 该方法将模糊认知网络和灰色系统理论相结合, 把模糊认知网络的节点状态值和权值扩展为灰色区间, 引入灰度来评判可靠性. 采用一种带终端约束的非线性 Hebbian 学习算法 (Nonlinear hebbian learning, NHL) 辨识 FGCN 的模型参数, 引入了与 FGCN 模型中节点的系统实际测量值对应的灰数值, 在更新机制中增加了包含系统测量值与预测值之差的修正项, 对权值进行有监督的修正. 利用水箱控制系统进行的仿真实验结果表明, 本文提出的建模方法能解决对数据存在不确定性或缺失的复杂系统建模的难题, 所建的模型能做出接近人类智能的控制决策, 所采用的权值学习方法具有收敛速度快、学习结果精准等优点, 并克服了传统非线性 Hebbian 算法对初值依赖性强的缺点, 对不确定性系统的建模具有广泛适用性.

**关键词** 模糊认知网络, 灰色系统理论, Hebbian 学习算法, 终端约束

**引用格式** 陈宁, 彭俊洁, 王磊, 郭宇骞, 桂卫华. 模糊灰色认知网络的建模方法及应用. 自动化学报, 2018, 44(7): 1227–1236

**DOI** 10.16383/j.aas.2017.c160578

## Fuzzy Grey Cognitive Networks Modeling and Its Application

CHEN Ning<sup>1</sup> PENG Jun-Jie<sup>1</sup> WANG Lei<sup>1</sup> GUO Yu-Qian<sup>1</sup> GUI Wei-Hua<sup>1</sup>

**Abstract** For nonlinear systems with uncertainty, a method of nonlinear system modeling based on fuzzy grey cognitive networks (FGCN) is proposed. By combining fuzzy cognitive networks modeling method and grey system theory, the state value of fuzzy cognitive networks (FCN) node is extended to grey interval. The concept of grey level is introduced to judge the accuracy of the results. This method has the advantages of fuzzy cognitive networks graphical representation and the features of grey system theory that are effective and reliable in the scene of small data, poor information. Moreover, nonlinear Hebbian learning (NHL) with terminal constraint is adopted to identify the system parameters. In the process of weights learning, the algorithm introduces the actual value of the node in the system and increases the difference between measured values and predicted values to amend the weights on the basis of the original update mechanism, then the final value iteration formula is obtained after normalization. The proposed modeling method and the weight learning method are verified in the water tank control system. The algorithm has the advantages of fast convergence rate and accurate study results, and overcomes the traditional shortcoming of nonlinear Hebbian learning, i. e., strong dependence of initial value. Simulation results illustrate the applicability of the FGCN and the algorithm to model uncertain systems.

**Key words** Fuzzy cognitive networks (FCN), grey system theory, Hebbian learning, terminal constraint

**Citation** Chen Ning, Peng Jun-Jie, Wang Lei, Guo Yu-Qian, Gui Wei-Hua. Fuzzy grey cognitive networks modeling and its application. *Acta Automatica Sinica*, 2018, 44(7): 1227–1236

现代工业过程中普遍具有强非线性和不确定性的特点, 难以用传统的数学机理建模方法描述过程动态变化, 因此这种形式的建模方法很难满足实际应用要求<sup>[1]</sup>. 在无数学机理模型的情况下, 人类需要依靠逻辑推理等智能对感知的信息进行处理, 形成经验、知识和规律, 进而完成复杂不确定系统的

分析和控制. 作为这种智能方法之一的模糊认知图 (Fuzzy cognitive map, FCM)<sup>[2]</sup>, 具有形式化描述、数值推理、模糊信息的表达等特点, 能够成为建立在系统的原始数据和研究者之间的一座桥梁. FCM 是一种由节点、弧和权重组成的有向图<sup>[3–4]</sup>. 其中, 节点又被称为概念节点, 权值范围为  $[0, 1]$ , 可以代表系统的某一种特性. 两个概念节点之间的因果关系则用带符号和权重的弧表示, 取值范围为  $[-1, 1]$ . FCM 由于其良好的动态特性和学习能力, 因此被广泛应用在复杂系统建模、过程分析、决策制定等方面<sup>[5]</sup>. Anninou 等通过分析影响人类患有帕金森综合征的相关因素, 使用 FCM 呈现了帕金森综合征

收稿日期 2016-08-06 录用日期 2017-06-22  
Manuscript received August 6, 2016; accepted June 22, 2017  
国家自然科学基金 (61673399), 湖南省自然科学基金项目 (2017JJ2329) 资助  
Supported by National Natural Science Foundation of China (61673399), and Natural Science Foundation of Hunan Province (2017JJ2329)

本文责任编辑 刘艳军  
Recommended by Associate Editor LIU Yan-Jun

1. 中南大学信息科学与工程学院 长沙 410083  
1. School of Information Science and Engineering, Central South University, Changsha 410083

的数学模型, 提供了一个非常有趣的研究方向<sup>[6]</sup>. 文献 [7] 对人的个性与情绪之间的关系进行了分析, 建立了一种基于 FCM 的数学模型, 这种模型对开发人性化系统具有非常可观的意义. Kreinovich 采用 Miller 准则, 将多元神经网络简化为一元神经网络, 证明了仅用经验和主观意识也能让 FCM 有效地描述系统<sup>[8]</sup>. Obiedat 等利用动力学系统与神经网络相结合的方法, 分析并建立了社会生态系统的 FCM 模型, 结果表明该方法能够为决策者提供合适的建议<sup>[9]</sup>. Christen 使用 FCM 作为工具, 分析了苏格兰农业系统管理经验, 发现了农业制度不善的问题<sup>[10]</sup>. 张燕丽针对大型非线性系统, 提出了 T-S 建模方法, 并在倒车系统中进行了验证<sup>[11]</sup>.

传统的 FCM 建模方法通过离线的方法模拟系统过程, 且对专家知识具有很强的依赖性. 由于传统 FCM 的局限性, 在根据专家知识和实际系统数据建立了系统的模糊认知图的情况下, FCM 就处于离线运作状态. 因此, 如果专家的知识不够准确, 就会导致所建立的系统 FCM 模型无法正确地反应当前系统的实际状态. 为了与实际系统保持密切实时联系, 并且对实时系统做出更准确的控制和决策<sup>[12]</sup>, 一种基于 FCM 进行扩展的模糊认知网络 (Fuzzy cognitive networks, FCN)<sup>[13-15]</sup> 建模方法就应运而生. FCN 框架由一个模糊认知图、一个基于实际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组成. FCN 只在初始点使用或者完全脱离专家经验, 能够克服传统 FCM 建模方法对专家经验依赖性强的缺点.

灰色系统理论 (Grey system theory, GST) 在系统模型的建立过程中做出了巨大的贡献. 该理论通过利用概率论与数理统计的方法取得随机性被弱化、规律性被增强的新数据序列, 由于新的序列既体现了原序列的变化又消除了波动性的特性, 灰色系统理论能够解决部分参数未知的系统问题. 吉培荣提出了无偏差灰色预测模型, 该模型极大地消除了传统模型的固有偏差<sup>[16-17]</sup>. 文献 [18] 建立了灰色预测模型, 通过预测中国台湾人口中使用互联网的人数与实际值相比较, 验证了该模型的有效性. 文献 [19] 提出了一种能应用于复杂工程的灰色模型控制器, 并验证了该控制器的优秀性能.

通过对 FCN 和灰色系统理论现状进行研究, 针对 FCN 和灰色系统理论的优点, 发现二者的结合对具有耦合性、非线性及高不确定性等特点的系统模型建立具有重要的意义. FCN 模型参数设定很大程度上影响模型精度, 而 FCN 模型中初始权值就是一个非常重要的参数. 权值学习方法通过一定的机制更新不断对系统权值进行更新, 从而达到提高 FCN 模型精度的目的. 文献 [20] 提出了一种简单的微分

Hebbian 学习方法 (Differential Hebbian learning, DHL), 而 DHL 是一种无监督的学习方法, 因此无法在实际系统中广泛应用. 非线性 Hebbian 学习方法 (Nonlinear Hebbian learning, NHL) 于 2003 年由 Papageorgiou 等<sup>[21]</sup> 提出, 在系统权值学习具有广泛的应用. 文献 [22] 提出了一种 LASSOFCM 的学习方法, 该方法能在没有任何先验知识的少量数据的情况下学习大规模的 FCM 系统, 在一些领域难以得到应用. Natarajan 等对影响印度甘蔗产量的土壤和气候等各种因素进行了分析并建立了 FCM 模型, 采用结合数据驱动的非线性 Hebbian 学习方法 (DDNHL) 和遗传算法对模型的参数进行了辨识<sup>[23]</sup>. Baykasoglu 等讨论了扩展的大洪水算法 (Extended great deluge algorithm, EGDA) 在训练 FCM 方面的应用, EGDA 作为一种较好的算法, 主要存在的问题是参数唯一<sup>[24]</sup>.

本文将灰色理论和网络反馈控制理论结合, 在 FCM 的基础上提出了模糊灰色认知网络建模方法和带终端约束的非线性 Hebbian 权值计算方法, 所建模型能做出接近人类智能的控制决策, 解决对数据存在不确定性或缺失的复杂系统建模的难题. 本文安排如下: 第 1 节介绍 (Fuzzy grey cognitive networks, FGCN) 模型建模机制及其特性; 第 2 节介绍传统 NHL 算法并提出了带终端约束的非线性 Hebbian 算法; 第 3 节利用一个水箱控制过程验证本文方法的有效性; 第 4 节对文章进行总结与展望.

## 1 模糊灰色认知网络

模糊灰色认知网络是一种结合 FCN 和灰色系统理论 (GST) 的软计算技术. FGCN 模型是在 FCN 的基础上, 通过对模糊概念和节点之间的灰色关系的不精确描述来表示非结构化知识, 从而提供一个抽象级的直观、详细的系统建模方法.

一个非线性系统可以用 FGCN 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, 对应系统的不同工况. 用  $C = \{C_1, C_2, \dots, C_n\}$  表示构成有向图的顶点的概念集合, 每一个节点代表系统的特征, 如变量、状态、事件、目标等. 节点状态值反应概念节点的取值 (模糊的或确定的). 灰数节点状态值用  $\otimes \mathbf{A}$  表示:

$$\otimes \mathbf{A} = (\otimes A_1 \otimes A_2, \dots, \otimes A_n) = ([\underline{A}_1, \overline{A}_1], [\underline{A}_2, \overline{A}_2], \dots, [\underline{A}_n, \overline{A}_n]) \quad (1)$$

其中,  $n$  是模型中节点总数目,  $\otimes A_i$  可以是灰数也可以是白数 (即  $\underline{A}_i = \overline{A}_i$ ). 用  $A_i^k$  表示节点  $C_i$  在  $k$  时刻的状态, 其取值由系统的实际取值转换而来, 值域为  $[0, 1]$ . 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  $C_j$  的状态随原因概念节点  $C_i$  的状态值成正比例变化; 反之, 如果  $W_{ij} < 0$ , 则结果概念节点  $C_j$  的状态随原因概念节点  $C_i$  的状态值成反比例变化; 如果  $W_{ij} = 0$ , 则概念节点  $C_j$  的状态与概念节点  $C_i$  的状态值没有关联.

连接两个节点之间的边代表节点之间的因果关系, 值域为  $[1, -1]$ . 如果取值为正, 则结果概念节点  $C_j$  的状态随原因概念节点  $C_i$  的状态值成正向变化; 反之, 如果取值为负, 则结果概念节点  $C_j$  的状态随原因概念节点  $C_i$  的状态值成反向变化; 如果取值为零, 则概念节点  $C_j$  的状态与概念节点  $C_i$  的状态值没有关联. 由于 FGCN 是结合神经网络和灰色系统理论的方法, 两个节点之间带权弧的大小都表示为一个灰数权值.

$$\otimes W_{ij} \in [\underline{W}_{ij}, \overline{W}_{ij}], \forall i, j \rightarrow -1 \leq \underline{W}_{ij} \leq \overline{W}_{ij} \leq 1 \quad (2)$$

其中,  $i$  表示原因节点,  $j$  表示结果节点.

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以及与其有因果关系的节点取值影响.

在迭代计算节点下一个时刻的值时, 利用一个阈值函数将灰色状态值转换到一个规范化的范围内. 通常使用 S 曲线函数来保证状态值取值在  $[0, 1]$  区间.

节点状态值的更新方程为

$$\otimes \mathbf{A}^k = f(\otimes \mathbf{A}^{k-1} + \otimes \mathbf{A}^{k-1} \cdot W(\otimes)) \quad (3)$$

特别的, 稳定节点和输出节点的状态值应该取以系统实际测量值为基值的灰数:

$$\otimes A_i^k = A_i^{\text{system}} + \varepsilon \quad (4)$$

其中,  $\otimes \mathbf{A}^k$  是  $k$  时刻的灰色状态值矢量,  $\otimes \mathbf{A}^{k-1}$  是  $k-1$  时刻的灰色状态值矢量,  $W(\otimes)$  是该模型的灰数权值矩阵,  $\otimes A_i^k$  是第  $i$  个节点  $k$  时刻的灰数状态值,  $A_i^{\text{system}}$  是稳定节点和输出节点的系统实际值, 通过实时测量或者事先给定,  $\varepsilon$  是振幅,  $f = 1/(1 + e^{-cx})$  是阈值函数, 用来保证状态值取值在  $[0, 1]$  区间.

由于引入了灰色理论, FGCN 增加了一个灰度 (用  $\varphi(\otimes A_i)$  表示) 来衡量系统的不确定性. 如果灰度取值大, 则结果的不确定性高; 反之, 则不确定性小. 传统 FCN 没有使用不确定性的标准来评判结果.

$$\varphi(\otimes A_i) = \frac{|l(\otimes A_i)|}{l(\otimes \phi)} \quad (5)$$

其中,  $|l(\otimes A_i)|$  是灰色状态值  $\otimes A_i$  长度的绝对值,  $l(\otimes \phi)$  是状态值取值空间的长度绝对值. 在 FGCN 中, 节点状态值的取值空间可以是  $[0, 1]$  或者  $[-1, 1]$ , 因此  $l(\otimes \phi)$  取值为

$$l(\otimes \phi) = \begin{cases} 2, & \text{若 } \otimes A_i \subseteq [-1, 1], \forall \otimes A_i \\ 1, & \text{若 } \otimes A_i \subseteq [0, 1], \forall \otimes A_i \end{cases} \quad (6)$$

如果  $l(\otimes A_i) = 0$ , 则无论  $l(\otimes \phi)$  取值如何,  $l(\otimes A_i)$  为零, 即灰度为零,  $\otimes A_i$  是白数, 没有不确定性. 如果  $l(\otimes A_i) = l(\otimes \phi)$ , 灰度将是无穷大, 即  $\varphi(\otimes A_i) = \infty$ .

根据以上分析, FGCN 与传统的 FCN 相比有以下优点:

1) FGCN 作为一个广义概念, 包括了模糊和灰色的概念, 能够更好地处理信息不完整以及因素间关系不确定的系统, 比传统的 FCN 更加贴近人类的智能决策;

2) FGCN 允许在建模过程中出现概念和概念节点之间因果关系的不确定性和多义性;

3) FGCN 可以表示更多的节点之间的关系. 比如, 它能够在系统节点之间关系只知道一部分或者完全未知的情况下建立准确的模型;

4) 在推理过程中用灰度表示输出节点的不确定性, 提高了输出结果的可靠性;

5) 当 FGCN 的灰色状态值和灰色权值的灰度全部取零时, 则输出结果与传统 FCN 一致, 而灰度的存在使其比 FCN 多了判断结果准确性的标准.

## 2 基于 FGCN 的带终端约束的权值迭代算法

在已经建立系统的 FGCN 模型的前提下, 需要对模型中的权值进行辨识. 非线性 Hebbian 算法是一种无监督权值学习方法<sup>[17]</sup>, 它利用权值关联的原因节点状态值与结果节点状态值的乘积对连接权值进行无向修正, 没有其他约束条件来提高学习效率和模型准确度. 由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, 使学习效率和准确度都受到影响.

为使模糊认知网络实时精准反应系统状态并做出正确的控制, 必须改进 NHL 算法. 由于离线学习模型对系统工况的变化不敏感, 要提高模型的跟踪能力, 需将权值的学习与系统实际工况相结合. 考虑到每一次迭代学习得到的状态值作为控制量作用于原系统, 可以得到一个实时值并将其作为学习目标, 故本文引进系统实际测量值作为约束来更新 FGCN 的权值, 从而提出带终端约束的非线性 Hebbian 算法.

带终端约束的非线性 Hebbian 算法的权值更新引入了系统实际反馈作为约束, 将模型预测值与系统实际测量值之差作为调整权值的标准. 由于差值大小直接反应预测值与真实值的差距, 故可由此实现对权值进行有向修正, 在提高收敛速率的同时也解决了传统的无监督 NHL 对初始值依赖性强的缺点.

用符号  $\otimes \mathbf{A}$  表示 FGCN 中状态节点的状态值, 用  $\otimes W^k$  代表  $k$  时刻节点间弧的灰数权值, 每一次迭代都利用模型的预测值与系统实际值之间的误差对权值进行修正. 带终端约束的 NHL 算法如下:

$$\otimes W_{ji}^{k+1} = (1 - \gamma)(\otimes W_{ji}^k) + \eta(\otimes A_j^{\text{FGCN}}) \times (\otimes A_i^{\text{FGCN}}) + \kappa \otimes p_i (1 - \otimes p_i) \times (\otimes A_j^{\text{FGCN}}) \quad (7)$$

其中,  $\otimes A_i^{\text{system}}$  是节点  $C_i$  包含灰度的实际测量值,  $\otimes A_i^{k, \text{FGCN}}$  是节点  $C_i$  的 FGCN 计算值.  $\otimes W_{ji}^{k+1}$  代表节点  $C_j$  对节点  $C_i$  在  $(k+1)$  时刻的灰数权值,  $\otimes W_{ji}^k$  代表节点  $C_j$  对节点  $C_i$  在  $k$  时刻的灰数权值,  $\otimes A_i^{\text{FGCN}}$  代表节点  $C_i$  的 FGCN 计算所得灰数,  $\otimes A_j^{\text{FGCN}}$  代表节点  $C_j$  的 FGCN 计算所得灰数,  $\gamma$  是衰减率,  $\eta$  是学习率,  $\kappa$  是修正率, 通常

$0 < \gamma, \eta, \kappa < 0.1$ .  $\otimes p_i$  是节点  $C_i$  的灰度误差, 其定义为

$$\otimes p_i = \frac{\otimes A_i^{\text{system}} - \frac{1}{1 + e^{-\left(\otimes A_i^{\text{system}} + \sum_{j=1, j \neq i}^N \otimes A_j^{\text{system}} \otimes W_{ji}\right)}}}{\otimes A_i^{\text{system}} - \otimes A_i^{\text{FGCN}}} \quad (8)$$

为了避免  $\otimes W$  的过度增长, 保证其取值在  $[-1, 1]$ , 要求  $\otimes W$  的取值满足  $\|\otimes W\| = 1$ , 故在每一步计算中均按式 (9) 对式 (7) 进行归一化.

在式 (9) 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. 当学习率  $\eta$  和修正率  $\kappa$  足够小时, 分母根号下表达式的泰勒展开式的高阶可以省略. 假定权值矩阵的第  $i$  行已知, 则第  $j$  列的权值计算可简化为式 (10). 考虑到衰减率  $\gamma$  通常取为一个远小于 1 的正数, 即  $(1 - \gamma)^2 \approx 1$ , 故式 (10) 可以继续近似简化为式 (11). 相应地, 权值更新公式 (7) 可以近似简化成式 (14).

**注 1.** 在式 (7) 中, 前面两项  $(1 - \gamma)(\otimes W_{ji}^k) + \eta(\otimes A_j^{\text{FGCN}}) \times (\otimes A_i^{\text{FGCN}})$  是 Hebbian 理论的权值

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

$$\begin{aligned} & \sum_{j=1, j \neq i}^n ((1 - \gamma)(\otimes W_{ji}^k) + \eta(\otimes A_j^{\text{FGCN}}) \cdot (\otimes A_i^{\text{FGCN}}) + \kappa(\otimes p_i) \cdot (1 - \otimes p_i) \cdot \otimes A_j^{\text{FGCN}})^2 \approx \\ & \sum_{j=1}^n [(1 - \gamma)^2 \cdot (\otimes W_{ji}^k)^2 + 2\eta \cdot (1 - \gamma) \cdot (\otimes A_j^{\text{FGCN}}) \cdot (\otimes A_i^{\text{FGCN}}) \cdot (\otimes W_{ji}^k) + \\ & 2\kappa(1 - \gamma)(\otimes p_i) \cdot (1 - \otimes p_i) \cdot (\otimes W_{ji}^k)] \approx \end{aligned} \quad (10)$$

$$\begin{aligned} & \vdots \\ & (1 - \gamma)^2 + 2\eta \cdot (1 - \gamma) \cdot (\otimes A_j^{\text{FGCN}})^2 + 2\kappa(1 - \gamma)(\otimes p_i) \cdot (1 - \otimes p_i) \cdot (\otimes A_j^{\text{FGCN}}) = \\ & (1 - \gamma)^2 \left( 1 + \frac{2\eta \cdot (\otimes A_j^{\text{FGCN}})^2 + 2\kappa(\otimes p_i) \cdot (1 - \otimes p_i) \cdot \otimes A_j^{\text{FGCN}}}{1 - \gamma} \right) \end{aligned}$$

$$\begin{aligned} & \frac{1}{\sqrt{1 + \frac{2\eta \cdot (\otimes A_j^{\text{FGCN}})^2 + 2\kappa(\otimes p_i)(1 - \otimes p_i) \cdot (\otimes A_j^{\text{FGCN}})}{1 - \gamma}}} \approx \\ & \frac{1}{1 + \frac{\eta \cdot (\otimes A_j^{\text{FGCN}})^2 + \kappa(\otimes p_i)(1 - \otimes p_i) \cdot (\otimes A_j^{\text{FGCN}})}{1 - \gamma}} \approx \\ & 1 - \frac{\eta \cdot (\otimes A_j^{\text{FGCN}})^2 + \kappa(\otimes p_i)(1 - \otimes p_i) \cdot (\otimes A_j^{\text{FGCN}})}{1 - \gamma} \end{aligned} \quad (11)$$

修正, 计算模型中节点状态值对权值的修正; 后面一项  $\kappa \otimes p_i(1 - \otimes p_i) \times (\otimes A_j^{\text{FGCN}})$  中, 因  $\kappa$  很小,  $\otimes p_i$  和  $1 - \otimes p_i$  都小于 1, 三者相乘小于等于  $0.25\kappa$ , 因此可以保证每一个  $\otimes W_{ji}^k$  的取值都在  $[-1, 1]$  范围内.

迭代的两个终止标准为

标准 1.

$$F_1 = |\hat{A}_i^{\text{FGCN}} k + 1 - \hat{A}_i^{\text{FGCN}} k| < e \quad (12)$$

标准 2.

$$F_2 = |\hat{p}_i| < v \quad (13)$$

其中,  $\hat{p}_i$  是节点的灰度误差白数化的取值, 一般取  $v = 0.001$ , 当所有节点的误差都满足式 (13) 时终止迭代.

$$\begin{aligned} \otimes W_{ji}^{k+1} = & (1 - \gamma) \otimes W_{ji}^k + \\ & [\eta + \kappa(\otimes p_i) \cdot (1 - \otimes p_i)](\otimes A_j^{\text{FGCN}}) \cdot \\ & (\otimes A_i^{\text{FGCN}}) + \kappa(\otimes p_i) \cdot (1 - \otimes p_i) \cdot (\otimes W_{ji}^k) \cdot \\ & (\otimes A_j^{\text{FGCN}}) - \eta \otimes W_{ji}^k (\otimes A_j^{\text{FGCN}})^2 \end{aligned} \quad (14)$$

综上所述, 基于 FGCN 模型的带终端约束的非线性 Hebbian 算法流程图如图 1 所示.

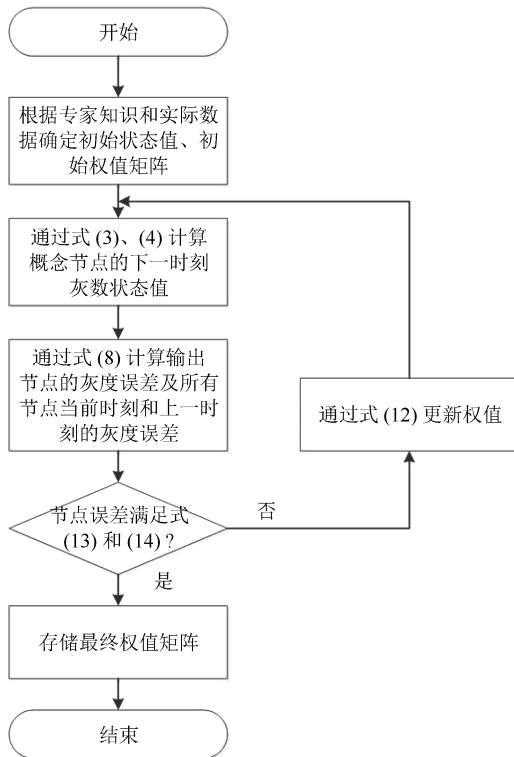


图 1 基于 FGCN 带终端约束的非线性 Hebbian 算法流程图

Fig. 1 Flowchart of NHL with terminal constraints based on FGCN

引进了系统反馈的带终端约束的 NHL 在每一次迭代中都根据实际测量值对权值进行修正, 故

能快速收敛到准确反映系统的权值, 也克服了非线性 Hebbian 算法对初始值依赖性强的缺点, 提高了 FGCN 模型的灵活性和动态性. 因此经过带终端约束的非线性 Hebbian 算法训练权值的 FGCN 能够更好地模拟实际系统.

### 3 仿真分析

图 2 所示为包括两个水箱、三个开关、一个加热元件和两个温度计的水箱控制系统. 每个水箱有一个入水阀和一个出水阀, 且第一个水箱的出水阀是第二个水箱的入水阀. 其工作原理如下:

水箱 1 的温度通过调节加热元件控制, 水箱 1 的温度比水箱 2 的温度高; 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. 水箱的液位高度通过开关 1、开关 2 和开关 3 控制. 当水箱 1 的水位过高时, 打开开关 2 放水, 当水箱 1 的水位过低时, 打开开关 1 进水; 当水箱 2 的水位过高时, 打开开关 3 放水, 当水箱 2 的水位过低时, 打开开关 2 进水.




图 2 水箱控制过程

Fig. 2 The control process of tanks

为了确定描述水箱控制系统的 FGCN 对象, 必须考虑到系统的变量, 如两个水箱中液位的高度、温度的高低; 系统中影响变量的要素, 如阀门的状态 (打开、关闭或者部分打开)、加热元件的状态等.

在控制过程中, 1 号水箱的液位受开关 1 和开关 2 的影响; 2 号水箱的液位受开关 2 和开关 3 的影响; 开关 1 受 1 号水箱温度和液位的影响; 开关 2 受 1 号水箱液位、2 号水箱液位和温度的影响; 开关 3 受 2 号水箱的液位的影响; 1 号水箱的温度与加热元件相互影响; 2 号水箱的温度受开关 2 的影响.

针对上述水箱控制过程, 利用专家知识和历史数据, 通过一系列相互关联的节点来描述其相应的动态系统, 建立的 FGCN 模型如图 3 所示.

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  $C_8$ . 两个节点间的权值  $\otimes W_{ij}$  表示节点  $C_j$  对节点  $C_i$  的影响. 系统的控制目标有两个: 1) 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; 2) 两个水箱的温度保持在最大值  $T_{\max}$  和最小值  $T_{\min}$  之间.

即控制目标变量是 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

$$\begin{aligned} H_{\min}^1 &\leq H^1 \leq H_{\max}^1 \\ H_{\min}^2 &\leq H^2 \leq H_{\max}^2 \\ T_{\min}^1 &\leq T^1 \leq T_{\max}^1 \\ T_{\min}^2 &\leq T^2 \leq T_{\max}^2 \end{aligned} \quad (15)$$

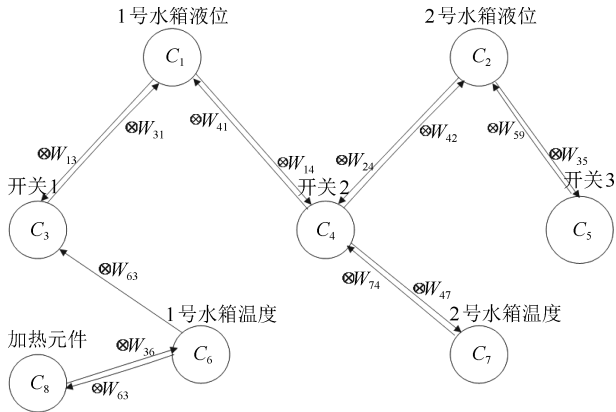


图 3 水箱控制过程的 FGCN 模型

Fig.3 FGCN model of the tank control process

水箱控制系统的 FGCN 模型包含 8 个节点，权值矩阵维数为  $8 \times 8$ ，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。根据不同的需求，水箱控制系统有不同的控制目标。在本次模拟中，专家定义目标节点的控制目标为  $ADC_1 = 0.72$ 、 $ADC_2 = 0.66$ 、 $ADC_6 = 0.78$ 、 $ADC_7 = 0.64$ 。由于实际系统不可能达到一个完全确定的平衡点，故将控制目标扩展成一个适度的区间：

$$\begin{aligned} 0.65 &\leq ADC_1 \leq 0.80 \\ 0.60 &\leq ADC_2 \leq 0.75 \\ 0.70 &\leq ADC_6 \leq 0.88 \\ 0.55 &\leq ADC_7 \leq 0.75 \end{aligned} \quad (16)$$

系统中各个元素之间的影响程度各异，根据历

史数据和经验，专家确定权值初始值矩阵为式 (17)。

FGCN 模型在灰度为零时，灰色状态值退化为白数，用灰色初始值表示为

$$\begin{aligned} \otimes \mathbf{A}_0 = & [[0.44, 0.44], [0.55, 0.55], \\ & [0.6, 0.6], [0.7, 0.7], [0.59, 0.59], \\ & [0.61, 0.61], [0.54, 0.54], [0.52, 0.52]] \end{aligned} \quad (18)$$

FGCN 模型在灰度不为零时，取初始值以  $\pm 0.1$  为振幅，即灰度  $\varphi(\otimes \mathbf{A}_i) = 0.2$ ，用灰色初始值表示为

$$\begin{aligned} \otimes \mathbf{A}'_0 = & [[0.34, 0.54], [0.45, 0.65], [0.5, 0.7], \\ & [0.6, 0.8], [0.49, 0.69], [0.51, 0.71], \\ & [0.44, 0.64], [0.42, 0.62]] \end{aligned} \quad (19)$$


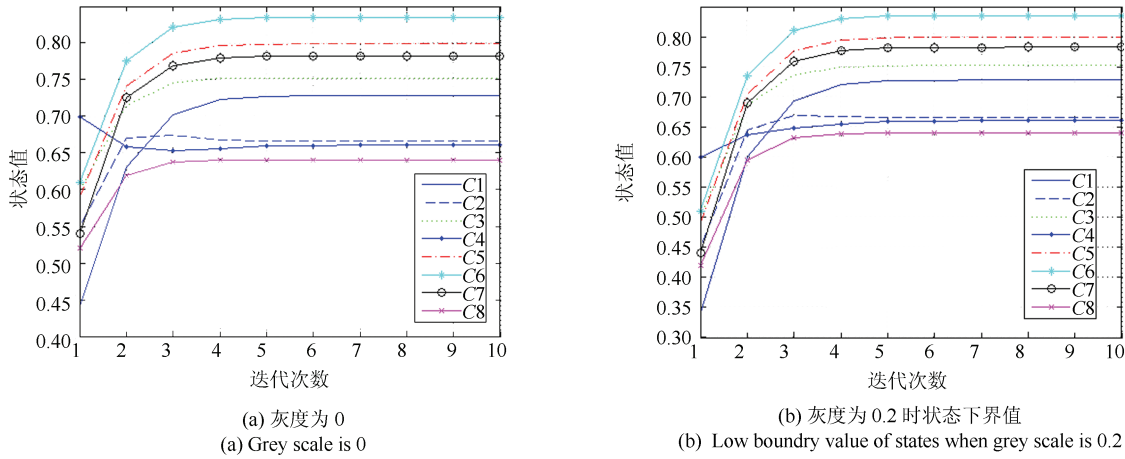
在给定初始状态值和权值矩阵的基础上，先后在灰度为零和灰度不为零的 FGCN 模型的基础上，利用初值、NHL 学习方法所得权值和用带终端约束的非线性 Hebbian 算法学习所得权值，对达到平衡状态的各节点终值的准确度以及收敛速度进行对比，分析 FGCN 模型的性能以及各学习算法的优劣。

在专家给定初始权值  $W_0$  的基础上，基于 NHL 学习算法对权值进行训练，得到一个如式 (20) 所示的最终权值矩阵。再分别取式 (18) 和式 (19) 所示的系统状态初始值，将最终权值矩阵代入所建立的水箱系统 FGCN 模型中，经过数次迭代达到平衡状态。系统状态稳态值如表 1 所示，迭代过程如图 4 所示。

当 FGCN 模型的初始值灰度为零时，得到的稳定状态值满足所要求的控制区间，利用灰度能判断所得结论的正确性；当 FGCN 模型的初始值灰度不为零时，由于引入灰色系统理论，在动态迭代中能够减少系统的不确定性，在达到稳定时能够得到一个灰度为零或灰度取值很小的输出结果，且灰度区间与灰度为零时的结果很接近。NHL 学习后新的权值  $W_{NHL}$  能够使 FGCN 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 (16)

$$W_0 = \begin{bmatrix} 0 & 0 & -0.5 & 0.2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -0.5 & 0.37 & 0 & 0 & 0 \\ 0.5 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -0.6 & 0.67 & 0 & 0 & 0 & 0 & 0.25 & 0 \\ 0 & -0.82 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.53 & 0 & 0 & 0 & 0 & -0.4 \\ 0 & 0 & 0 & -0.1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.7 & 0 & 0 \end{bmatrix} \quad (17)$$

$$W_{NHL} = \begin{bmatrix} 0 & 0.0555 & -0.4649 & 0.2420 & 0.0657 & 0.0691 & 0.0641 & 0.0524 \\ 0.0577 & 0 & 0.0610 & -0.4782 & 0.4136 & 0.0676 & 0.0672 & 0.0513 \\ 0.5304 & 0.0607 & 0 & 0.0593 & 0.0716 & 0.0753 & 0.0698 & 0.0571 \\ -0.5742 & 0.6881 & 0.0616 & 0 & 0.0649 & 0.0683 & 0.2985 & 0.0519 \\ 0.0672 & -0.8157 & 0.0709 & 0.0619 & 0 & 0.0786 & 0.0729 & 0.0597 \\ 0.0706 & 0.0665 & 0.5611 & 0.0650 & 0.0785 & 0 & 0.0766 & -0.3681 \\ 0.0651 & 0.0613 & 0.0687 & -0.0453 & 0.0724 & 0.0761 & 0 & 0.0577 \\ 0.0542 & 0.0512 & 0.0573 & 0.0500 & 0.0604 & 0.7300 & 0.0589 & 0 \end{bmatrix} \quad (20)$$



(c) 灰度为 0.2 时状态上界值  
(c) Up boundry value of states when grey scale is 0.2

图 4 NHL 学习的 FGCN 仿真结果

Fig. 4 FGCN simulation results trained by NHL

表 1 NHL 算法学习的仿真结果

Table 1 Simulation results trained by NHL

概念节点	FGCN 模型 (灰度为零)			FGCN 模型 (灰度不为零)		
	灰色稳态值 $\otimes \mathbf{A}_i$	灰度 $\varphi(\otimes \mathbf{A}_i)$	白化值 $\hat{A}_i$	灰色稳态值 $\otimes \mathbf{A}_i$	灰度 $\varphi(\otimes \mathbf{A}_i)$	白化值 $\hat{A}_i$
1	[0.728, 0.728]	0	0.728	[0.7279, 0.7280]	0.0001	0.72795
2	[0.6663, 0.6663]	0	0.6663	[0.6662, 0.6663]	0.0001	0.66625
3	[0.7523, 0.7523]	0	0.7523	[0.7522, 0.7523]	0.0001	0.75225
4	[0.6608, 0.6608]	0	0.6608	[0.6608, 0.6609]	0.0001	0.66085
5	[0.799, 0.799]	0	0.799	[0.7989, 0.7991]	0.0002	0.799
6	[0.835, 0.835]	0	0.835	[0.8349, 0.8351]	0.0002	0.835
7	[0.7826, 0.7826]	0	0.7826	[0.7826, 0.7827]	0.0001	0.78265
8	[0.6399, 0.6399]	0	0.6399	[0.6397, 0.6399]	0.0002	0.6398

所示的控制目标范围,说明经过 NHL 学习后的系统模型,能够让所有输出节点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,取值为零的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等.

由于 NHL 是无监督学习算法,仅仅依靠当前时刻原因节点状态值和结果节点状态值的乘积来对权值进行修正,而原因节点状态值和结果节点状态值的取值又与前一时刻的权值密切相关.因此,当权值的初始取值发生改变时,其学习结果会跟着改变,导致系统模型发生相应的变化,即 NHL 存在对初始值的强依赖性.而带终端约束的 NHL 学习方法引入了系统反馈,水箱系统中系统反馈为系统稳定时各节点的状态实际测量值.由实际系统测量可得,在当水箱达到稳定时,水箱的实际系统状态值为

$$A^{\text{system}} = [0.73 \ 0.67 \ 0.75 \ 0.66 \ 0.80 \ 0.83 \ 0.78 \ 0.63] \quad (21)$$

在专家给定初始权值  $W_0$  的基础上,基于带终端约束的 NHL 学习算法对权值进行训练,得到一个如式 (22) 所示的最终权值矩阵.分别取式 (18) 和

式 (19) 所示的系统状态初始值,将最终权值矩阵代入所建立的水箱系统 FGCN 模型中,经过数次迭代达到平衡状态.系统状态稳态值如表 2 所示,迭代过程如图 5 所示.

由表 2 的结果可以看出,当 FGCN 模型的初始值灰度为零时,得到的稳定状态值满足所要求的控制区间,利用灰度可以判断所得结论的准确性;当 FGCN 模型的初始值灰度不为零时,由于引入灰色系统理论,在动态迭代中能够减少系统的不确定性,在达到稳定时能够得到一个灰度为零或灰度取值很小的输出结果,且灰数区间与灰度为零时的结果很接近.

对 NHL 和带终端约束的 NHL 算法学习后系统 FGCN 模型仿真结果,以灰度为 0.2 下界为例,如图 4(b) 和图 5(b) 所示.图 5(b) 中带终端约束的 NHL 迭代步数最少,并且权值能收敛到工艺指标要求范围之内.带终端约束的 NHL 算法中,由于引进系统的反馈,在每一次的迭代中都根据实际测量值对权值进行修正,故一般情况下迭代步数较少,且达到稳定状态时会满足系统实际要求.图 4(b) 中的 NHL 算法是无监督机制,满足标准 1、标准 2 (式 (12) 和式 (13)) 才停止迭代,故一般情况下迭代步数较多,且达到稳定状态时是否满足系统实际要求不能得到保证.因此,结果表明,经过带终端约

$$W_{\text{NHL}} = \begin{bmatrix} 0 & 0 & -0.4572 & 0.4013 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -0.4736 & 0.8750 & 0 & 0 & 0 \\ 0.8613 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -0.5778 & 0.8981 & 0 & 0 & 0 & 0 & 0.7354 & 0 \\ 0 & -0.9075 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.8217 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.0355 & 0 & 0 & 0 & -0.1216 \\ 0 & 0 & 0 & 0 & 0 & 0.9205 & 0 & 0 \end{bmatrix} \quad (22)$$

表 2 带终端约束非线性 Hebbian 算法学习仿真结果  
Table 2 Simulation results trained by NHL with terminal constraints

概念节点	FGCN 模型 (灰度为零)			FGCN 模型 (灰度不为零)		
	灰色稳态值 $\otimes A_i$	灰度 $\varphi(\otimes A_i)$	白化值 $\hat{A}_i$	灰色稳态值 $\otimes A_i$	灰度 $\varphi(\otimes A_i)$	白化值 $\hat{A}_i$
1	[0.73, 0.73]	0	0.73	[0.7300, 0.7301]	0	0.73005
2	[0.67, 0.67]	0	0.67	[0.6700, 0.6701]	0.0001	0.67005
3	[0.75, 0.75]	0	0.75	[0.7500, 0.7500]	0.0001	0.75005
4	[0.66, 0.66]	0	0.66	[0.6599, 0.6600]	0.0001	0.65995
5	[0.80, 0.80]	0	0.8	[0.8000, 0.8001]	0.0001	0.80005
6	[0.8304, 0.8304]	0	0.8304	[0.8304, 0.8305]	0.0001	0.83045
7	[0.7799, 0.7799]	0	0.7799	[0.7798, 0.7799]	0.0001	0.77985
8	[0.6290, 0.6290]	0	0.629	[0.6290, 0.6291]	0.0001	0.62905



束的非线性 Hebbian 算法学习相对于非线性 Hebbian 算法学习, 不仅能保证系统状态值落入期望范围且精度较高, 而且收敛速度也明显加快.

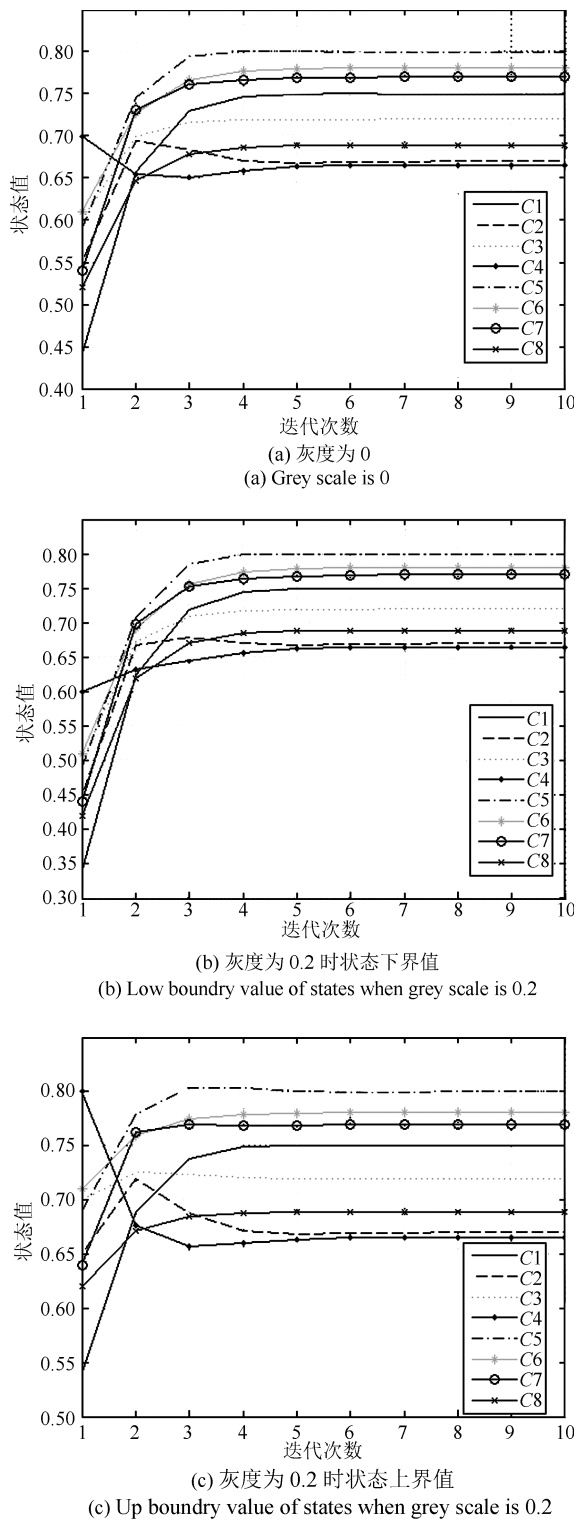


图 5 带终端约束的 NHL 学习的 FGCN 仿真结果  
Fig. 5 FGCN simulation results trained by NHL with terminal constraints

## 4 结论

1) 提出了非线性系统的模糊灰色认知网络模型及其建模方法. 将模糊认知网络建模方法和灰色系统理论相结合, 把模糊认知网络的节点状态值和权值扩展为灰色区间, 引入了与 FGCN 模型中节点的系统实际测量值对应的灰数值来评判模型可靠性. 仿真实验结果表明, 利用本文提出的建模方法能解决对数据存在不确定性或缺失的复杂系统建模的难题, 所建模型能做出接近人类智能的控制决策, 对不确定性系统的建模具有广泛适用性.

2) 采用了带终端约束的非线性 Hebbian 权值学习算法并将其用于辨识 FGCN 的模型参数. 与普通的 NHL 学习方法相比, 本文算法将系统反馈引入到权值迭代过程中, 通过有监督的学习方法使权值的迭代趋近于系统真实值, 提高了学习质量. 仿真实验结果表明, 该算法收敛速度快, 精确度高且不依赖于专家确定的初始值, 通过迭代过程减小了系统的灰度, 提高了模型精度和可靠性, 克服了传统 NHL 对初始值依赖性大的缺点.

## References

- Maffi T, Sommariva S, Ranzi E, Faravelli T. A predictive kinetic model of sulfur release from coal. *Fuel*, 2012, **91**(1): 213–223
- Kosko B. Fuzzy cognitive maps. *International Journal of Man-Machine Studies*, 1986, **24**(1): 65–75
- Abe S. Neural networks and fuzzy systems. *Journal of the Acoustical Society of America*, 1998, **103**(6): 49–71
- Stylios C D, Groumpos P P. Fuzzy cognitive maps: a soft computing technique for intelligent control. In: Proceedings of the 2000 IEEE International Symposium on Intelligent Control. Rio Patras, Greece: IEEE, 2000. 97–102
- Papageorgiou E I, Aggelopoulou K D, Gemtos T A, Nanos G D. Yield prediction in apples using Fuzzy Cognitive Map learning approach. *Computers & Electronics in Agriculture*, 2013, **91**(2): 19–29
- Antigoni P, Anninou, Groumpos P P. Modeling of parkinson's disease using fuzzy cognitive maps and non-linear hebbian learning. *International Journal on Artificial Intelligence Tools*, 2014, **23**(5): 17.
- Fatahi S, Moradi H. A fuzzy cognitive map model to calculate a user's desirability based on personality in e-learning environments. *Computers in Human Behavior*, 2016, **63**: 272–281.
- Kreinovich V, Stylios C D. Why fuzzy cognitive maps are efficient. *International Journal of Computers Communications & Control*, 2015, **10**(6): 825–833
- Obiedat M, Samarasinghe S. A novel semi-quantitative Fuzzy Cognitive Map model for complex systems for addressing challenging participatory real life problems. *Applied Soft Computing*, 2016, **48**: 91–110
- Christen B, Kjeldsen C, Dalgaard T, Martin-Ortega J. Can fuzzy cognitive mapping help in agricultural policy design and communication? *Land Use Policy*, 2015, **45**: 64–75

- 11 Zhang Yan-Li. The Modeling and Control of Dynamic System Based on Fuzzy Cognitive Maps [Ph.D. dissertation], Dalian University of Technology, China, 2012  
(张燕丽. 基于模糊认知图的动态系统的建模与控制 [博士学位论文], 大连理工大学, 中国, 2012)
- 12 Kottas T, Stimoniaris D, Tsiamitros D, Kikis V, Boutalis Y, Dialynas E. New operation scheme and control of Smart Grids using Fuzzy Cognitive Networks. In: Proceedings of the 2015 IEEE Eindhoven on PowerTech. Eindhoven, Netherlands: IEEE, 2015. 1–5
- 13 Zhang J Y, Liu Z Q, Zhou S. Dynamic domination in fuzzy causal networks. *IEEE Transactions on Fuzzy Systems*, 2006, **14**(1): 42–57
- 14 Liu Z Q, Zhang J Y. Interrogating the structure of fuzzy cognitive maps. *Soft Computing*, 2003, **7**(3): 148–153
- 15 Kottas T L, Boutalis Y S, Christodoulou M A. Fuzzy cognitive network: a general framework. *Intelligent Decision Technologies*, 2007, **1**(4): 183–196
- 16 Ji Pei-Rong, Huang Wei-Song, Hu Xiang-Yong. Unbiased gray prediction model. *Systems Engineering and Electronic*, 2000, **22**(6): 78–80  
(吉培荣, 黄巍松, 胡翔勇. 无偏灰色预测模型. 系统工程与电子技术, 2000, **22**(6): 78–80)
- 17 Ji Pei-Rong, Huang Wei-Song, Hu Xiang-Yong. A Study on the properties of grey forecasting model. *System Engineering Theory and Practice*, 2001, (9): 105–108  
(吉培荣, 黄巍松, 胡翔勇. 灰色预测模型特性的研究. 系统工程理论与实践, 2001, (9): 105–108)
- 18 Wu W Y, Chen S P. A prediction method using the grey model GMC(1, n) combined with the grey relational analysis: a case study on Internet access population forecast. *Applied Mathematics and Computation*, 2005, **169**(1): 198–217
- 19 Lian R J, Lin B F, Huang J H. A grey prediction fuzzy controller for constant cutting force in turning. *International Journal of Machine Tool & Manufacture*, 2005, **45**(9): 1047–1056
- 20 Dickerson J A, Kosko B. Virtual worlds as fuzzy cognitive maps. *Presence: Teleoperators and Virtual Environments*, 1994: **3**(2): 173–189
- 21 Papageorgiou E, Stylios C, Groumpos P. Fuzzy cognitive map learning based on nonlinear hebbian rule. In: Proceedings of the 2003 Australian Conference on Artificial Intelligence. Berlin, Germany: Springer 2003. 256–268
- 22 Wu K, Liu J. Robust learning of large-scale fuzzy cognitive maps via the lasso from noisy time series. *Knowledge-Based Systems*, 2016, **113**: 23–38
- 23 Natarajan R, Subramanian J, Papageorgiou E I. Hybrid learning of fuzzy cognitive maps for sugarcane yield classification. *Computers & Electronics in Agriculture*, 2016, **127**: 147–157
- 24 Baykasoglu A, Durmusoglu Z D U, Kaplanoglu V. Training fuzzy cognitive maps via extended great deluge algorithm with applications. *Computers in Industry*, 2011, **62**(2): 187–195



陈宁 中南大学教授. 主要研究方向为复杂系统建模与控制、模糊认知网络建模方法研究. 本文通信作者.

E-mail: ningchen@csu.edu.cn

(CHEN Ning Professor at Central South University. Her research interest covers modeling and control of complex systems, and fuzzy cognitive networks.

Corresponding author of this paper.)



彭俊洁 中南大学博士生. 主要研究方向为非线性系统的建模与控制及模糊认知网络建模方法研究.

E-mail: yuzoudiyi@126.com

(PENG Jun-Jie Ph.D. candidate at Central South University. His research interest covers modeling and control of nonlinear systems, and fuzzy

cognitive networks.)



王磊 中南大学硕士. 主要研究方向为非线性系统的建模与控制.

E-mail: 122548287@qq.com

(WANG Lei Master student at Central South University. Her research interest covers modeling and control of nonlinear systems.)



郭宇骞 中南大学教授. 主要研究方向为非线性控制系统, 混杂控制系统, 逻辑演化网络.

E-mail: gyuqian@csu.edu.cn

(GUO Yu-Qian Professor at Central South University. His research interest covers nonlinear control systems, hybrid control systems and logic

networks.)



桂卫华 中国工程院院士, 中南大学教授. 主要研究方向为复杂工业过程建模与优化控制, 分散鲁棒控制及故障诊断.

E-mail: gwh@csu.edu.cn

(GUI Wei-Hua Academician of Chinese Academy of Engineering, professor at Central South University. His research interest covers modeling and

optimal control of complex industrial process, distributed robust control, and fault diagnoses.)