

多级离散模糊神经网络稳定性的优化算法

崔梦天^{1,3}, 傅丽霞³, 赵海军², 钟勇¹

(1. 中国科学院成都计算机研究所 成都 610060; 2. 西华师范大学计算机学院 四川 南充 637002;
3. 四川邮电职业技术学院计算机科学系 成都 610067)

【摘要】针对模糊集理论在建模中对变化的外部环境适应能力差,以及基本神经网络模型不容易获得模糊集之间关系等问题,提出了一个具有基本模糊推理系统“IF-THEN”规则的多级离散模糊神经网络模型。分析了该模型的基本稳定性条件,并使用硬C均值聚类方法获得数据集之间的关系,采用遗传算法优化了该模型。最后通过计算机仿真验证了该模型的有效性。

关键词 多级离散模糊神经网络; 稳定性; HCM聚类; 遗传算法
中图分类号 TP368.5 文献标识码 A

Optimization Algorithm of Multi-Level Discrete Fuzzy Neural Networks for Solving Global Stability

CUI Meng-tian^{1,3}, FU Li-xia³, ZHAO Hai-jun², ZHONG Yong¹

1. Chendu Institute of Computer Applications, Chinese Academy of Sciences of China Chengdu 610060;
2. School of Computer Science, China-West Normal University Nanchong Sichuan 637002;
3. Dept. of Computer Science, Sichuan Post and Communication College Chengdu 610067)

Abstract To solve the problems of low adaptability for mutative external environment existed in the theory of fuzzy sets and the disadvantage of failing to obtain eventual relationship among the fuzzy sets existed in the model of neural networks, this paper proposes a multi-level discrete fuzzy neural networks model which has the “if-then” rule of fuzzy inference system. The essential stability condition of the model is analyzed. The model uses Hard C-Means (HCM) clustering to obtain fuzzy neural networks' eventual relationship among the fuzzy sets and applies evolutionary algorithm to optimize the model. The simulation results show the effectiveness of the proposed model.

Key words multi-level discrete fuzzy neural networks; stability; hard C-means clustering; genetic algorithms

模糊集理论用于在建模中针对一些实验数据中不确定性和模糊性问题上。模糊集理论提供了系统的、以语言表示这类信息的计算工具,通过使用由隶属函数表示的语言变量,它还可以进行数值计算。合理选择模糊规则是模糊推理系统的关键因素,它可以有效地对特定应用领域中的人类专门知识进行建模。尽管模糊推理系统具有模糊IF-THEN格式的结构化知识表示,但它仍缺少对变化的外部环境进行适应的能力。而神经网络的根本优点是对外部很强的适应性和从过去数据中学习的机制^[1-2]。

基本的神经网络兼有神经网络的“IF-THEN”规则。它的弊端是不能得到模糊集之间的关系。为解决它的不足,本文提出了一个离散模糊神经网络,该网络使用硬C均值(HCM)聚类和进化计算实现全

局稳定性。

1 基于规则的多级离散模糊神经网络的稳定性

对于一个模糊模型系统,模糊模型包含一组IF-THEN规则。假如 $z_1(t)$ is A_{i1} 并且 $z_p(t)$ is A_{ip} , 本文设计的模糊规则 i 为:

$$u(t) = -K_i[x(t) - x_r] + u_r, \quad i = 1, 2, \dots, r \quad (1)$$

式中 x_r 是一个状态参考轨迹; u_r 是响应输入轨迹; K_i 是反馈增益矩阵。规则的结论部分以它的输入和输出变量之间的一些线性关系来表达。多级离散神经网络的基本模型如图1所示^[3-4]。图中的“圆形”、“方形”指神经网络单元,“ ”和“ ”分别为乘积和求和神经元。神经网络由每个输入变量的模糊

划分表示。

神经网络的学习是通过调整神经元的联接来实现的^[5]。其值的修改通过一个标准的反传算法(BP)实现。




图1 基于规则的多级离散神经网络结构

1.1 基本稳定性条件

带有全局稳定性的神经网络意味着它有一个唯一的平衡。所有网络问题的解决都收敛于该平衡^[3]。分析全局稳定性对解决最优化问题是很重要的。假定目标函数 $E(x): \mathcal{R}^n \rightarrow \mathcal{R}$ 是可微分的, 则通过向量 $x = (x_1, x_2, \dots, x_n)^T \in \mathcal{R}^n$ 使之最小化, 保证一定的约束为^[7-8]:

$$\min \{E(x) \mid x \in \Omega\} \text{ 或 } \min \left\{ \frac{1}{2} x^T A x + x^T b \mid x \in \Omega \right\} \quad (2)$$

式中 A 是一个矩阵; b 是向量; $\Omega = \{x \in \mathcal{R}^n \mid x_i \in [c_i, d_i] \ i=1, 2, \dots, n\}$ 。 c_i, d_i 为常量 $c_i < d_i \ i=1, 2, \dots, n$ 。

$$x(k) = f(x(k-1)) - \alpha(Ax(k-1) + b) \quad (3)$$

式中 对于所有 $k \geq 1, \alpha > 0$ 是恒量。向量赋值激活函数 $f(x) = (f_1(x_1), f_2(x_2), \dots, f_n(x_n))^T: \mathcal{R}^n \rightarrow \mathcal{R}^n$ 定义为:

$$f_i(x_i) = \begin{cases} c_i & c_i < x_i \\ d_i & x_i > d_i \\ x_i & \text{否则} \end{cases} \quad i=1, 2, \dots, n \quad (4)$$

定义 1 当且仅当 $x^e = f(x^e - \alpha(Ax^e + b))$, $x^e \in \mathcal{R}^n$ 称为式(2)的一个平衡点^[3]。对于一个 $x = (x_1, x_2, \dots, x_n)^T \in \mathcal{R}^n$, 可以表示为:

$$\|x\| = \sqrt{\sum_{i=1}^n x_i^2} = \sqrt{x^T x} \quad (5)$$

定义 2 当网络有一个唯一的平衡点 x^e , 且存在常量 $\eta > 0$ 且 $\mu < 1$, 则使得对于所有的 $k \geq 1$, 有:

$$\|x(k) - x^e\| \leq \mu \|x(0) - x^e\| \exp(\eta k) \quad (6)$$

称网络式(4)为全局稳定的^[7-8]。常量 η 表示为网络的收敛率。

1.2 多级离散神经网络结构

通常的神经网络用HCM聚类方法通过系统输入空间的划分决定一些隶属函数的初始的参数值。本文研究的是离散模糊神经网络。通过HCM聚类构建数据群^[2]。群的数量相当于模型数量, 如图2所示。一组离散模糊神经网络模型并行使用来建立一个完整的模型。

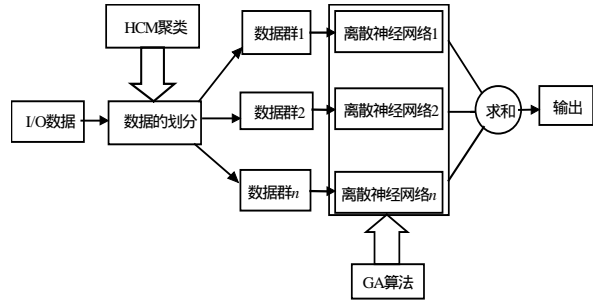


图2 多级模糊离散神经网络结构

1.3 HCM聚类方法

HCM聚类方法不仅广泛用于数据的组织和分类, 也用于数据压缩和模型构建。用该方法生成的多级离散神经网络结构的信息数据微粒按下列步骤产生^[2]。

1) 按照下列HCM聚类算法将训练数据划分为 p 个组。

(1) 固定组的数量 p ($2 \leq p < n$), 初始化划分矩阵 $W^{(0)} \in M_p$

$$M_p = \left\{ W \mid w_{ik} \in \{0, 1\}, \sum_{i=1}^p w_{ik} = 1, 0 < \sum_{k=1}^n w_{ik} < n \right\}$$

(2) 计算每个组的中心。

(3) 更新划分矩阵 $W^{(r)}$, 在数据点和聚类中心之间进行。

(4) 检测终止条件。IF $(\|W^{(r+1)} - W^{(r)}\| < \epsilon)$ 停止, 否则令 $r=r+1$, 返回步骤(2)。

2) 计算训练数据的中心矢量与检验数据的元素间的距离。

3) 划分基于预先构成的组中心的检验数据。

2 用进化计算实现多级离散神经网络的最优化

优化任何一个复杂模型的目的有两个:(1) 必须选择一些优化算法以便解决问题。(2) 优化算法的各种参数需要调谐以便能更好地执行算法。

GAs是不严格地建立自然选择和自然进化概念

基础上的一种非导数的随机优化技术^[5]。从本质上说,它们是并行搜索算法,是用在自然界基因中发现的操作,通过参数空间来指导搜索。无论理论上还是实践上,GAs都已被证明能提供强大的搜索能力。因此,在优化这些问题时能提供有效的方法,因为它有能力高效使用历史信息以获得新的问题解决方案和全局搜索的支持。

2.1 遗传算法

GAs算法是基于种群数量最优化技术。解决空间问题的研究是用几个基因操作数完成的。在GAs支持的研究中,有三个基本的操作数,它们是选择、交换、变异^[2,5]。选择是从当前一代生成一组新的种群。选择操作决定哪些个体参与生成下一代的个体,它是产生下一代交配池的过程。个体基因链按照其适应性函数值被复制在交配池中,交换处理如下:

(1) 来自交配池的成员随机交配。

(2) 每对基因链按照下列方式交换:位置 l 沿着基因链在区间 $[1, l-1]$ 随机被选择, l 是链的长度。两个链通过在位置 k 和 l 之间交换产生。变异是基因链位置的值随机交替的过程。变异能防止整个种群在任何局部的任一收敛到一个值,并且更为重要的是,它能防止种群收敛并停滞在任何局部的最优点。因此,由交换操作中得到的好染色体不会丢失。遗传算法如下:

Begin

$t=0$;

初始化: $P(0) := \{a_1(0), a_2(0), \dots, a_n(0)\} \in I^n$

$$\zeta = \begin{cases} \sum_{k=1}^N P_k & \text{if } \sum_{k=1}^N P_k = 0 \\ 0 & \text{否则} \end{cases}$$

评价适应性:

Where $P_k = \Delta_{\min}(\mathcal{O}_k(x))$ ($k=1, 2, \dots, N$)

While(适应性值 \neq 结束条件)Do

Begin

基因重组: $a_k'(t) := r(P(t))$

基因变异: $a_k''(t) := m(a_k'(t))$

评价: $P'(t) := Ft(x(t)) \cup Ft(x'(t))$

从 $P(t)$ 中选择 $P(t+1)$:

IF ($Ft(x(t)) < Ft(x'(t))$)

$x(t+1) = x'(t)$

Else

$x(t+1) = x(t)$

$t=t+1$

End

End

在种群 $P(t)$ 中,被重组的种群 $a_k'(t)$ 通过重组操作 r 获得。变异操作数 m 将生成 $a_k''(t)$, $P'(t)$ 是这两个操作之后,由 $x'(t)$ 个体组成的新的种群。下一个种群中的个体,如 $x(t+1)$ 将通过估计适应性函数 $F(t)$ 来选择。

2.2 遗传算法优化多级离散神经网络模型

为优化多级离散神经网络模型, GAs算法使用了一系列方法,如:在选择操作数时,使用二进制数,旋转赌轮法;在交叉操作数中进行一点交叉;在变异操作数中使用倒置法。本文用60代、种群规模为40、每个基因链有8位、交叉概率为0.7、变异概率为0.1、图3为用于模糊推理系统的GAs递阶结构。变量 x_1, x_2, \dots, x_k 表示输入变量神经网络模型;变量 p, q 表示学习率和激励系数,如图3所示。

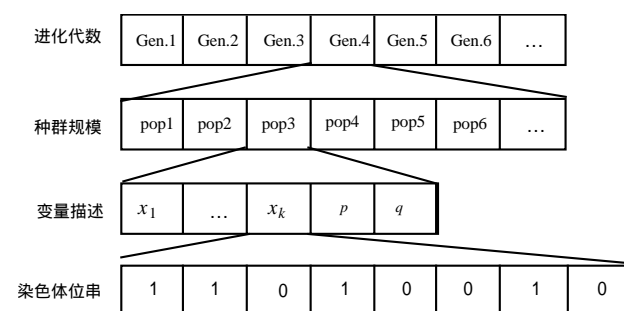


图3 用进化算法实现的多级离散神经网络模型的最优化结构

3 模拟和结果的讨论

本文用著名的Mackey-Glass混沌时间序列实验这个例子来评价所提出的方法的优点和有效性^[7]。

Mackey-Glass混沌模型为:

$$x_k = f(x_k) \quad (7)$$

$$y(t) = f(\mu, x_k) = \mu x_k (1 - x_k) \quad (8)$$

式中 $x_k \in V, k=0, 1, 2, 3, \dots$, 为不同时序的状态, $1 - \mu$ 称为分支参数, 作为测试对象产生时间序列数据, 并对其进行建模; $f(x_k)$ 为输入量; $y(t)$ 为输出。用60组 $[f(x_k), y(t-1)]$ 数据建模时, 用2个输入 $f(x_k)$ 和一个输出 $y(t)$ 。这里, 使每个输入变量形成颗粒的模糊集的数量为3, 全部数据集分为两部分: 训练数据集(30个)和检验数据集(30个)。模型的结构和参数是用HCM聚类方法和GAs算法实现的。图4为聚类结果, 图5为训练数据和检验数据的误差曲线。结果表明, 使用HCM聚类算法划分数据要比使用任意数据划分方法得到更好的执行。




图4 用HCM聚类实现的数据分布




图5 训练数据和检验误差曲线

4 结束语

本文提出了一个作为并行结构的离散模糊神经网络即多级离散模糊神经网络及其稳定性的实现方

法。HCM聚类可帮助构建组织优良有效的模型。处理信息颗粒的优化问题最重要的思想是通过利用聚类和进化计算。实验结果表明,在处理大量的数据集时,具有全局稳定的多级离散神经网络是可以快速完成信息处理的有效模型。

参考文献

- [1] 刘保韶. 随机规划与模糊规划[M]. 北京: 清华大学出版社, 1998.
- [2] 张智星. 神经—模糊与软计算[M]. 西安: 西安交通大学出版社, 2000.
- [3] TANA K C. Global exponential stability of discrete-time neural networks for constrained quadratic optimization[J]. Neurocomputing Neurocomputing, 2004, (56): 399-406.
- [4] SUNG K O, WITOLD P, HO S. Rule-based multi-FNN identification with the aid of evolutionary fuzzy granulation [J]. Knowledge-Based Systems, 2002, (17): 46-53.
- [5] JIN C B. Weighted fuzzy pattern matching[J]. Fuzzy Sets and Systems, 1988, 28: 313-331.
- [6] CHEN J Q, XI Y G. et al. On-line identification of nonlinear systems using fuzzy mode[J]. Journal of Acta Automatica Sinica, 1998, 24(1): 90-93.
- [7] BARABANOV N E, PROKHOROV D V. Stability analysis of discrete-time recurrent neural networks[J]. IEEE Trans. on Neural Networks, 2002, 13(2): 292-303.
- [8] XIA Y, WANG J. Global exponential stability of recurrent neural networks for solving optimization and related problems[J]. IEEE Trans. Neural Networks 2000, 11(4): 1017-1022.

编辑 刘文珍

(上接第613页)

- [5] CAO Y. Effective on-chip inductance modeling for multiple signal lines and application to repeater insertion[J]. IEEE Transaction on VLSI Systems, 2002, 10(6): 799-805.
- [6] MOHAMMAD H T, AHMED N, NOURANI M. Testing SoC interconnects for signal integrity using extended JTAG architecture[J]. IEEE Trans CAD of IC and Syst, 2004, 23(5): 800-811.

- [7] NORDHOLZ P, TREYTANAR D, OTTERSTEDT J, et al. Signal integrity problems in deep submicron arising from interconnects between cores[C]// Proceedings IEEE VLSI Test Symposium. Washington, DC, USA: IEEE Computer Society, 1998: 28-33.

编辑 漆蓉