

文章编号: 1001-0920(2004)12-1425-04

基于平衡学习的 CMAC 神经网络非线性辨识算法

朱大奇, 张 伟

(江南大学 控制科学与工程研究中心, 江苏 无锡 214215)

摘 要: 为提高小脑模型关节控制器(CMAC)神经网络在线学习的快速性和准确性, 提出一种平衡学习的概念, 并设计一种改进的CMAC学习算法. 在常规的CMAC中, 误差的校正值被平均地分配给所有激活存储单元, 而不管这些存储单元的可信度; 在改进的CMAC中, 利用激活单元先前学习次数作为可信度, 其误差校正值与激活单元先前学习次数的负 k 次方成比例. 仿真结果表明, 当 k 为一适当数值时, 改进CMAC具有较快的学习速度和较高的精度, 特别是在神经网络的初始学习阶段.

关键词: 小脑模型关节控制器; 信度分配; 平衡学习; 非线性辨识

中图分类号: TN915.01; TP301.6

文献标识码: A

Nonlinear identification algorithm of the improved CMAC based on balanced learning

ZHU Da-qi, ZHANG Wei

(Research Centre of Control Science and Engineering, Southern Yangtze University, Wuxi 214215, China
Correspondent: ZHU Da-qi, E-mail: zdq367@yahoo.com.cn)

Abstract: In order to improve online learning speed and accuracy of CMAC, an improved CMAC neural network model based on balanced learning concept is designed. In the conventional CMAC learning scheme, the correcting amounts of errors are equally distributed into all addressed hypercubes, regardless the credibility of those hypercubes. The proposed improved learning approach uses the learned times of the addressed hypercubes as the credibility (confidence) of the learned values. The correcting amounts of errors are proportional to the inverse of the k -th power of learned times. The method provides high learning speed when k is the optimal value in the early learning stage especially.

Key words: CMAC; credit assignment; balanced learning; nonlinear identification

1 引 言

在非线性动态系统的在线辨识中, 由于实时性的要求, 常规的递推辨识和卡尔曼滤波等串行算法难以达到预期效果; 而常用的BP神经网络算法, 因其收敛速度慢和局部极小的存在, 使其不仅实时性难以达到要求, 而且识别精度也存在不确定性^[1,2]. 自从Albus^[3,4]提出一种模拟小脑学习机构的小脑模型关节控制器(CMAC)以来, CMAC以其局部泛

化和收敛速度的优势而受到广泛关注^[5,6]. 但常规的CMAC仍需多个周期才能达到一定的精度^[7,8], 也就是说, 常规CMAC虽然收敛速度快于BP网络, 但对于在线学习来说, 仍难满足其快速性的要求. 为此, Nie和Geng等人^[9,10]将模糊集引入CMAC, 提出一种模糊CMAC算法, 增加了学习精度, 但收敛速度仍无法满足实时应用的需要^[11].

为提高CMAC的学习速度, 文献[11]在分析常

收稿日期: 2004-02-11; 修回日期: 2004-04-07.

基金项目: 江苏省自然科学基金资助项目(2004BK021); 总装备部国防预研基金资助项目(413170203).

作者简介: 朱大奇(1964—), 男, 安徽安庆人, 教授, 博士, 从事智能故障诊断、神经网络与模式识别等研究;

张伟(1973—), 男, 江苏南通人, 讲师, 硕士, 从事神经网络、图像处理等研究

规CMAC 权值调整规则的基础上,考虑到已学习知识的可信度,提出一种基于信度分配的CA-CMAC 算法.在常规CMAC 中,误差的校正值被平均地分配给所有激活存储单元,而不管这些存储单元的可信度;这种权值更新算法违背了信度分配的概念,更新的效果应与激活存储单元的可信度成比例.文献[11]中,被激活存储单元的权值调整正比于 $1/(f(j)+1)$,其中 $f(j)$ 是第 j 个被激活存储单元的已学习次数,可看成存储单元的可信度.分母加“1”是防止初始值为零.显然,学习次数越多,存储的知识越多,可信度越高,权值改变越少.误差的产生主要源于学习次数少的被激活存储单元,所以它们的权值修正值应大些.

权值调整的过程,本质上反映了网络“学习”与“遗忘”的关系.但文献[11]并未考虑信度分配与网络学习次数 $f(j)$ 的关联程度,以及学习次数 $f(j)$ 对网络学习效果的影响.即在网络权值调整过程中,未考虑“新知识学习”与“旧知识遗忘”的平衡问题.本文借鉴文献[11]的信度分配的概念,对其算法进行改进,提出一种“平衡学习”概念,寻找网络“新知识学习”与“旧知识遗忘”的最佳平衡.

2 常规CMAC 和基于信度分配的CMAC 神经网络模型

2.1 常规CMAC 神经网络

CMAC 的基本思想是:将学习的数据(知识)存储在交叠的存储单元(记忆空间)中,其输出为相应激活单元数据的累加和. CMAC 算法实现过程包含两个阶段:结果输出阶段和权值学习阶段.在结果输出阶段,CMAC 将所有被输入状态激活的存储单元的权值(存储数据)相加,即

$$y_s = \sum_{j=1}^N C_{sj} w_j \quad (1)$$

其中: N 为存储单元数; y_s 为状态 $s(s=1,2,\dots,n)$ 的实际输出值, n 为总状态数; w_j 为第 j 个存储单元的权值; C_s 为第 j 个存储单元是否被状态 s 激活的指示,当某个状态仅有 m 个存储单元被激活时,其 C_s 为1,而其他存储单元的 C_s 均为0.

在CMAC 算法中,结果输出阶段从CMAC 存储单元产生一实际输出,学习过程根据期望输出与实际输出的误差大小来更新CMAC 存储单元中的权值.在常规CMAC 算法中,误差被平均分配到所有被激活的存储单元.设 s 为某一状态, w_j^i 是经过第 i 次迭代后存储在第 j 个存储单元中的权值.常规CMAC 更新 w_j^i 算法为

$$w_j^i = w_j^{i-1} + \frac{\alpha}{m} C_s \left(\bar{y}_s - \sum_{j=1}^N C_{sj} w_j^{i-1} \right) \quad (2)$$

其中: \bar{y}_s 为状态 s 的期望输出, $\sum_{j=1}^N C_{sj} w_j^{i-1}$ 为状态 s 的实际输出, α 为学习常数.必须注意,只有那些被激活的存储单元其权值才被更新.

在上面的常规算法中,尽管误差被平均分配到所有被激活的存储单元,但经过 $i-1$ 次迭代后,最初的存储单元已包含了一些先前学习的知识,每个存储单元不再具有相同的学习历史,所以这些存储单元也不应有相同的可信度.若无视这些差异,所有被激活的存储单元都将获得相同的校正误差,那么由未学习状态产生的误差将对先前学习的信息产生腐蚀(corrupt).尽管这种腐蚀经过多个训练周期后会逐渐消失(这也是许多常规CMAC 算法应用成功的根据之所在),但对于在线动态系统的学习而言,其实时性要求非常高,有些情况下只允许在一到两个周期内完成学习任务,没有足够的时间来消除这种腐蚀,因此其学习结果常常无法满足在线学习的要求.

2.2 基于信度分配的CMAC(CA-CMAC)神经网络

为避免腐蚀效应,校正误差必须根据存储单元的可信度进行分配.然而,在CMAC 学习过程中,还没有一种好的方法来决定存储单元的权值.唯一可用的信息是该存储单元权值目前更新的次数.文献[11]假设,存储单元学习更新次数越多,其存储的数值越可靠,因此将存储单元的学习次数看成其可信度.可信度越高,存储的数值越可靠,其权值修正越小.于是式(2)可改写为

$$w_j^i = w_j^{i-1} + \alpha C_s \left\{ \frac{(f(j)+1)^{-1}}{(f(l)+1)^{-1}} \right\} \times \left(\bar{y}_s - \sum_{j=1}^N C_{sj} w_j^{i-1} \right) \quad (3)$$

其中: $f(j)$ 为第 j 个存储单元的学习次数, m 为某状态激活的存储单元数.此处的权值更新是校正误差必须与激活单元的学习次数成反比.尽管它能有效地改善学习性能,但并不是最好的结果,因为它没有考虑已学习的先前知识与未学习或少学习的知识各自对网络输出误差的影响程度,即“学习”与“遗忘”的平衡问题.

3 改进的基于信度分配的CMAC 神经网络

3.1 改进的信度分配

根据以上分析, 提出一种“平衡学习”的概念, 由此设计一种改进的基于信度分配的CMAC 神经网络模型ICA-CMAC. 此时式(3) 可改写为

$$w_j^i = w_j^{i-1} + \alpha C_s \left\{ \frac{(f(j) + 1)^{-k}}{m} \right\} \times \left(\bar{y}_s - \sum_{j=1}^N C_s w_j^{i-1} \right), \quad (4)$$

其中 k 为平衡学习常数 很明显, 当 k 为 0 或 1 时, ICA-CMAC 分别为常规CMAC 和文献[11] 的CA-CMAC 激活存储单元的学习次数 $f(j)$ 越大, 其存储的知识(先前学习的信息) 越多. 平衡学习常数 k 越大, 对学习次数 $f(j)$ 较大的存储单元来说, 其权值改变越少. 当 k 很大时, 学习次数 $f(j)$ 较大的存储单元其权值基本不变. 此时, 未学习的或学习次数 $f(j)$ 较少的激活单元在权值修正时, 将获得大多数误差校正. 在这种情形下, 网络学习中“记忆” 即“已学习知识的保持” 占主导地位

反之, 当 k 值很小时, 学习次数 $f(j)$ 对信度分配的影响也较小. 当 $k=0$ 时, 学习次数 $f(j)$ 对信度分配的影响为零. 此时, 误差被平均分配到所有被激活的存储单元, 这些存储单元都有相同的信度分配, 而不管学习次数 $f(j)$ 的大小. 这时在网络学习中“遗忘” 占主导地位

可见, 平衡学习常数 k 反映了网络训练过程中, 先前学习的信息与未学习或少学习信息对存储单元权值调整的影响程度. 不同的 k 会有不同的学习结果. 从后面的仿真结果可知, $k=1.2$ 时, 其学习速度最快, 说明此时网络的“记忆” 与“遗忘” 达到了最佳平衡

3.2 地址函数设计

在常规CMAC 中, 一般采用HASHING 技术来压缩存储空间, 但HASHING 映射会造成数据碰撞, 使得CMAC 的逼近性能下降. 本文利用文献[11] 的地址函数来产生所需要的存储单元的标记, 并通过如下规则为所有可能存储单元编码. 这种编址方法既简洁又不存在数据碰撞问题

以三维CMAC 为例, 详细内容参见文献[11]. 设 m 为CMAC 的级数, nb 为每级包含的块数, 则每维的等分块数为 $m * (nb - 1) + 1$. 在本例中, 仅用 $N = m * nb^3$ 个存储单元来映射 $(m * (nb - 1) + 1)^3$ 状态. 设三维坐标 (x_1, x_2, x_3) 表达的状态为 s , 由它激活的存储单元数为 m , 各激活存储单元的地址函数为 $s(j)$ ($j = 1, 2, \dots, m$), 则 $s(j) = F(x_1, x_2, x_3,$

$j)$. 定义:

- 1) if $j = 1$, 则 $i = 0$, 其他 $i = m - j + 1$;
- 2) $ax = \text{int}((x_1 + i)/m)$;
- 3) $ay = \text{int}((x_2 + i)/m)$;
- 4) $az = \text{int}((x_3 + i)/m)$;
- 5) $s(j) = F((x_1, x_2, x_3, j) = ax + ay + az * nb^2 + (j - 1) * nb^3 + 1$.

当状态 s 确定后, 应用地址函数, 则激活的存储单元地址便可直接由上面表达式计算而得. 因此无论是CMAC 的结果输出计算, 还是存储权值调整学习, 都可从这些存储单元中直接完成计算结果

4 仿真算例及结果分析

为说明ICA-CMAC 的在线学习效果, 以下面的非线性函数为例, 针对不同平衡学习参数 k 来比较网络的学习速度:

$$y(x_1, x_2) = \sin x_1 \cos x_2, \quad -\pi \leq x_1 \leq \pi, -\pi \leq x_2 \leq \pi \quad (5)$$

本例为二维CMAC, 每个变量包含 64 个等分块. 级数 $m = 9$, 每级包含 $nb = 8$ 块. 则总状态数为 $(m * (nb - 1) + 1)^2 = 4096 = 64 * 64$, 存储单元总数为 $m * nb^2 = 9 * 8 * 8 = 576$ (仅为总状态数的 14%). 取 $\alpha = 1$, 其训练数据数为 4 096. 学习结果如图 1 和图 2 所示




图 1 ICA-CMAC 的绝对误差




图 2 ICA-CMAC 方均根误差

在不同的 k 值下, 计算网络的绝对误差 TAE 和

方均根误差 RMSE, 即

$$\begin{aligned} \text{TAE} &= \sum_{s=1}^n |\bar{y}_s - y_s|, \\ \text{RMSE} &= \sqrt{\frac{1}{n} \sum_{s=1}^n (\bar{y}_s - y_s)^2}. \end{aligned} \quad (6)$$

其中: n 为总状态数, \bar{y}_s 为状态 s 的期望输出值, y_s 为状态 s 的实际输出数值 k 值取为: 0, 0.6, 1.0, 1.2, 1.5, 2.0

从图 1 和图 2 可以看出, 在网络学习的初始阶段(前 10 个周期), 不同的 k 值使误差下降的速度有很大差别: $k=0$ 时(常规 CMAC)收敛速度最慢; 随着 k 值的增加, 收敛速度变快, 在 $k=1.2$ 时收敛速度达到最快; k 值继续增大, 网络学习速度反而变慢. 可见 $k=1.2$ 为最佳平衡学习常数, 此时网络学习时的“记忆”与“遗忘”达到最佳平衡. 文献[11]提出的 CA-CMAC ($k=1$) 的学习速度处于最佳平衡值附近, 但它未能分析网络学习时“记忆”与“遗忘”的平衡问题, 其学习结果虽然比常规 CMAC 好, 但并非最优结果.

从图 1 和图 2 还可看出, 在网络学习的后续阶段(10 个周期后), 尽管 k 值不同, 但其学习误差区别却很小, 不同 k 值的网络都学习得很好. 这是因为网络学习过程中, 权值的调整依赖于误差的分配, 误差的分配又依赖于各存储单元的学习次数, 而学习次数在学习时间足够长时, 各存储单元将趋于相同. 另外, 对于 CA-CMAC ($k=1$) 和 ICA-CMAC ($k=1.2$) 而言, 其学习的某些中间结果(如第 3 周期)可能优于最终结果. 这是因为在开始阶段各单元学习次数不尽相同, 信度分配对 CMAC 学习结果影响较大, 误差可能较小, 而在学习时间足够长时, 各存储单元的学习次数将趋于相同, 信度分配对学习结果影响甚微, 误差趋于稳定. 这从另一方面反映了信度分配对学习结果的影响.

对于非线性动态系统的在线学习而言, 最初几个周期的学习速度极为重要. 因此, CMAC 神经网络学习算法的改进, 对提高非线性系统在线辨识的实时性具有一定的指导意义.

5 结 语

本文对 CMAC 算法进行改进, 提出一种平衡

学习的概念. 利用激活存储单元先前学习次数的负 k 次方作为权值调整的依据. 仿真结果表明, 当 $k=1.2$ 时, 在神经网络的初始学习阶段, 改进的 CMAC 具有较快的学习速度和较高的精度; 而当网络学习时间足够长时, 其学习效果趋于一致.

参考文献(References):

- [1] Hinton G E, Rumelhart, McClelland J L. *Distributed Representation, Parallel Distributed Processing* [M]. Cambridge: MIT Press, 1986.
- [2] Kosko B. A dynamical systems approach to machine intelligence [A]. *Neural Networks and Fuzzy Systems* [C]. NJ: Prentice-Hall, 1992: 135-141.
- [3] Albus J S. A new approach to manipulator control: The cerebellar model articulation controller (CMAC) [J]. *ASME J Dynamic Systems, Measurement, Control*, 1975, 97(1): 220-227.
- [4] Albus J S. Data storage in cerebellar model articulation controller (CMAC) [J]. *ASME J Dynamic Systems, Measurement, Control*, 1975, 97(1): 228-233.
- [5] Wong Y F, Sideris A. Learning convergence in cerebellar model articulation controller [J]. *IEEE Trans on Neural Networks*, 1992, 3(1): 115-121.
- [6] Lin C S, Chiang C T. Learning convergence of CMAC technique [J]. *IEEE Trans on Neural Networks*, 1997, 8(6): 1281-1292.
- [7] Iiguni Y. Hierarchical image coding via cerebellar model arithmetic computers [J]. *IEEE Trans on Image Processing*, 1996, 5(6): 1393-1401.
- [8] Hong C M, Lin C H, Tao T. Grey-CMAC model [A]. *Proc ISTEED Int Conf High Technology Power Industry* [C]. San Francisco, 1997: 39-44.
- [9] Nie J, Linkens D A. FCMAC: A fuzzified cerebellar model articulation controller with self-organizing capacity [J]. *Automatica*, 1994, 30(4): 655-664.
- [10] Geng Z J, McCullough C L. Missile control using fuzzy cerebellar model arithmetic computer neural networks [J]. *J Guid, Control, Dynamic*, 1997, 20(3): 557-565.
- [11] Shun-Feng S, Ted T, Hung T H. Credit assigned CMAC and its application to online learning robust controllers [J]. *IEEE Trans on Systems, Man and Cybernetics — Part B: Cybernetics*, 2003, 33(2): 202-213.