

CMAC 的无交叠感受域变分辨率学习方法

杨艳丽¹, 曹广忠²

(1. 深圳大学计算机系, 广东深圳 518060; 2. 深圳大学工程与技术学院, 广东深圳 518060)

摘 要: 本文根据 CMAC 的样本选取方法、权值修正方法、量化方法选择的不同, 提出了一种适于可编程逻辑硬件实现的 CMAC 快速学习方法——变分辨率无交叠感受域法。通过二维函数的学习仿真验证了此学习方法是快速有效的, 在精度上有进一步的改进。

关键词: CMAC; 变分辨率; 无交叠感受域法

中图分类号: TP271 **文献标识码:** A **文章编号:** 0372-2112 (2002) 12A-2153-02

The CMAC Learning Algorithms of Non-Overlapping Receptive Field with Variable Resolution

YANG Yan-li, CAO Guang-zhong

(College of Information Engineering, Shenzhen University, Shenzhen, Guangdong 518060, China)

Abstract: Considering the initialization of the CMAC weight memory cells the selection of the training samples, and a quantization method of the input variable, the faster CMAC learning algorithms, variable resolution of non-overlapping receptive field is proposed, which can be conveniently realized in hardware Programming Logic Circuit. The simulation results show that the algorithms have high convergence speed and improved accuracy.

Key words: CMAC; variable resolution; non-overlapping receptive field

1 引言

感受域序贯训练法和随机训练法^[1,6]较好地解决了 CMAC 泛化特性所产生的学习干扰和学习精度不高的问题。Lin 和 Chiang^[2]提出了基于高斯基函数的 CMAC 模型的一种快速算法, 在局部立方体内需计算的基函数与整个基函数空间相比大为减少, 硬件实现该算法较复杂。Lin 和 Chiang^[3]提出了一种将 CMAC 寻址技术和权值递归结合起来的的学习方法 LWR-CMAC, 输出具有可微性, 只是所需内存较大, 硬件实现困难。本文从样本选取、权值修正、量化方法的选择出发, 以可编程逻辑硬件实现为出发点构造基于无交叠感受域的变分辨率学习方法。

2 问题的提出

设第 i 个训练样本的输入向量激活 K 个内存单元, x_{ij} 是第 j 个激活的内存单元, $j=1, 2, \dots, K$, $w(x_{ij})$ 是第 j 个激活的内存单元 x_{ij} 所对应的权值。对应于第 i 个样本的输出值就是 $p_i = \sum_j w(x_{ij})$ 。设 d_i 是样本中的期望输出值, 误差 $e_i = d_i - p_i$ 。按照 CMAC 的基本学习规则, 权值修正量为 e_i/K 。

在对第 k 个训练样本点的学习中, 将使已学习过的第 i 个训练样本点的输出由 $p_i = \sum_j w(x_{ij})$ 变为 $p_i = \sum_j w(x_{ij}) - C_{ik}e_k/K$, 其中 C_{ik} 为样本 i 和 k 激活相同内存单元的个数。 $C_{ik}e_k/K$ 就是在学习第 k 个训练样本点时对第 i 个样本学习结果的错误修正量。

当 C_{ik} 为 0 时, $C_{ik}e_k/K$ 为 0。就是如果第 k 个训练样本点和第 i 个样本点激活的内存单元没有重叠, 在学习第 k 个训练样本点时就不会产生对第 i 个样本学习结果的错误修正。

C_{ik} 取决于 CMAC 映射的构成和训练样本的选取, 选定了映射的构成后, 在确定样本的学习中, C_{ik} 是一个常数。

学习干扰是对于训练样本而言的, 对于非训练样本, 这种交叠就是 CMAC 的插值和泛化特性。干扰程度直接取决于训练样本输入向量的选取和输入向量的感受域。感受域大小与所激活的内存单元个数和输入向量分辨率有关。如果输入向量 S 的第 j 个分量 S_j 的分辨值大, 则 S_j 的微小变化就能使 S_j 所激活的 K 个内存单元的权值发生较大变化, 而如果分辨值小, 则 S_j 的较大的变化才会使部分单元的权值有所改变。

3 用无交叠感受域样本初始化权值单元

在 CMAC 的训练中通常假定权值的初始值全为 0, 如果以无交叠感受域为目标选择样本来对所有权值单元进行初始化, 则在初始化后对应于样本集上的训练误差将为 0, 仅在非样本集上存在误差。误差的大小与相邻样本点处的权值有关, 并且是相邻样本点处权值的某种函数。在选择初始化样本集时, 要满足任意两个样本的输入向量的感受域都没有交叠。用这个初始化样本集以学习速率为 1 来填充对应的内存单元, 任一内存单元的权值只赋值一次, 没有学习干扰问题。

初始化样本集的样本点数 N_s 是由输入空间的维数 I 、输入变量轴的最大量化值 Q 和分辨率 r 以及输入变量的分散内存块个数 K 值来确定的。一维 CMAC 所需的初始化样本点数等于第一个量化函数的中间变量个数, 多维 CMAC 所需的初始化样本集的样本点数 N_s 为 $N_s = \prod_{i=1}^I (M_{i1})$ 。在初始化过程中, 输入空间边界附近向量对应的某些内存单元有可能没有被初始化。这是由于输入变量量化函数的中间变量数不同而

引起的,可以通过调整 K 和分辨率 r 使输入变量的每个量化函数的中间变量数相等来解决.只要满足同一输入变量的各个量化函数的中间变量数相等的条件,所有的内存单元就都可被初始化.

4 逐点学习与变分辨率量化

在初始化完成后,为减小非样本点处的训练误差,可在输入空间中随机地逐点选择训练样本进行“抛光”.只要用于训练的随机训练样本足够多,就可保证均匀地分布于整个输入空间.由于初始化后,权值的调整幅度较小,学习干扰的 $C_{ik}e_k/K$ 部分很小.在对逐点学习收敛性的分析中,已知当学习次数趋于无穷、学习速率趋于 0 时,学习过程将是最小均方误差学习过程,可以得到任意的训练精度^[4].

CMAC 的逼近精度在很大程度上取决于量化分辨率.量化间距越小,逼近精度越高;但太高的量化精度需要海量的内存单元,硬件实现困难. CMAC 的量化通常是等距均匀量化,采用相同的分辨率.在被逼近函数变化剧烈(函数偏导的绝对值大)的空间里,量化间距显得过大,逼近精度降低;而在被逼近函数变化平缓(函数偏导的绝对值小)的区间里,相对较小的量化间距反而浪费了 CMAC 的内存资源.被逼近函数偏导的绝对值表示了函数在该分量上的变化剧烈程度,可用作变分辨率量化的依据.与等距量化相同内存需求的情况下,等距量化与变分辨率量化的最大量化值相同.

设 z_x 为最小量化值, Q_x 为变量本身的最大量化值, D_x 为偏导的最大量化值, q_x 为 x 的量化值, t_x 为 x 的中间量化变量, d_x 为偏导的量化值,有 $z_x = (x_{\max} - x_{\min}) / (Q_x D_x)$. x' 为 x 的偏导,对 x' 采用等距量化,有 $d_x = [((x' - x'_{\min}) / (x'_{\max} - x'_{\min})) D_x]$,其中 $[\cdot]$ 为取整运算.

基于偏导绝对值的变分辨率量化满足 $t_{xi} = t_{xi-1} + d_{xi}$,并且 $q_x = [t_x / D_x]$, $t_x = [(x - x_{\min}) / z_x]$.实际实现和仿真中,可按最小分辨率逐点递增的方式来完成变分辨率量化.在保持量化 bit 不变的前提下,采用变分辨率方法使 CMAC 的逼近精度大大提高,解决在梯度变化较大的地方绝对误差较大、在过 0 点附近的相对误差较大的问题.

5 仿真算例与结果讨论

以二维函数 $f(x, y) = \sin(x)\sin(y)$, $0^\circ < x < 360^\circ$, $0^\circ < y < 180^\circ$ 来验证该方法的有效性.表 1 为分散内存块数 $K=4$,最大量化值 Q 分别取 63、127、511、1023、2047,仅采用初始化样本学习方法、均值权值修正、均匀量化的结果.可以看出初始化样本数等于内存单元总数,保证了所有内存单元无遗漏地被全部初始化.随着最大量化值的增加,均方误差值 RMS 和绝对误差的幅值在减小,但内存单元数在增加,内存的利用率维持不变.

图 1(a)为 x, y 分别按 8bit 变分辨率量化,最大量化值 $Q=255$ 时的仿真结果.图 1(b)为绝对误差值,最大误差的绝对值约为 0.0026,均方误差值为 $RMS = 0.00084$.在相同的 K 和 Q 情况下,虽然变分辨率比不变分辨率的最大绝对误差和均方误差大,但是相对误差变小,提高了信号的信噪比.最大绝对误差变大的原因是由于在幅值较大之处的量化间距较

大、分辨率低所致.由于存在较大的绝对误差值,使均方误差大也增大.

表 1 Q 变化的学习结果 ($K=4, l=2$, 初始化样本学习, 均值权值修正, 等距量化)

最大量化值 Q	63	127	255	511	1023	2047
初始化样本数	288	1088	4224	16640	66048	263168
每个内存的单元数	72	272	1056	4160	16512	65792
内存单元总数	288	1088	4224	16640	66048	263168
均方误差值 RMS	0.00915	0.00233	0.00059	0.00015	0.00004	0.00001
最大绝对误差值	0.02	0.006	0.002	0.00038	0.0001	0.00002
内存利用率	0.06348	0.06348	0.06348	0.06348	0.06348	0.06348




图 1 二维函数无交叠感受域变分辨率学习结果 ($Q=511$)

6 结论

本文研究一种适于可编程逻辑硬件实现的 CMAC 快速学习方法,构造一种可快速逼近训练函数的方法.针对均匀量化在梯度变化较大地方绝对误差较大和在过 0 点附近相对误差较大的问题,解决 CMAC 在小信号时相对误差较大的问题,提高无交叠感受域学习方法的学习精度.通过二维函数的仿真结果表明:变分辨率方法比不变分辨率方法的最大绝对误差和均方误差大,但是相对误差变小,提高了小信号的信噪比.

参考文献:

- [1] D E Thompson, S Kwon. Neighborhood sequential and random training techniques for CMAC[J]. IEEE Trans Neural Network, 1995, 6(1): 196 - 202.
- [2] C Chiang, C Lin. CMAC with general basis function[J]. Neural Networks, 1996, 9(7): 1199 - 1211.
- [3] C Lin, C Chiang. Integration of CMAC technique and weighted regression for efficient learning and output differentiability[J]. IEEE Trans, S. M. C. 1998, 28(2): 231 - 236.
- [4] 杨艳丽. 分散神经网络控制器及机器人分散控制策略研究[D]. 西安: 西安交通大学研究生院, 1999.
- [5] Jan J C, Shih-Lin Hung. High-order MS CMAC neural network [J]. IEEE Trans, 2001, NN-12(3): 598 - 603.
- [6] Selahattin Sayil, Kwang Y Lee. A hybrid maximum error algorithm with neighborhood training for CMAC[A]. Inter. Joint Conf. on Neural Networks[C]. Honolulu, 2002. 12 - 17.

作者简介:



杨艳丽 女, 1964 年 12 月生于西安市, 深圳大学信息工程学院计算机系副教授, 分别于 1987、1995、1999 年获西安交通大学学士、硕士、博士学位, 已经发表论文 10 多篇, 目前主要研究方向: 机电系统的智能控制.