

基于聚类分析和集成神经网络的序列图像多目标识别算法

周涛^{1,2} 张艳宁¹ 袁和金^{1,4} 陆惠玲³ 李秀秀¹

(西北工业大学计算机学院 西安 710072)¹ (陕西理工学院数学系 汉中 723000)²
(陕西理工学院计算机系 汉中 723000)³ (华北电力大学计算机学院 保定 071003)⁴

摘要 针对现有的集成神经网络的训练子集选择时没有考虑样本空间的分布情况,使得构造的训练子集具有很大的随机性和主观性,集成的差异性不能有效保证的缺点,提出了一种新的基于 Hu 七阶矩、RPCL 聚类分析和集成神经网络的序列图像多目标识别算法。该方法首先在训练视频中连续提取序列图像中的目标——人、人群、汽车,利用 Hu 七阶矩提取轮廓信息。为了防止 Hu 七阶矩对小目标和非刚体目标的描述能力弱的缺点,再提取图像的面积信息。其次对所提取的 8 维数据采用基于对手惩罚策略的竞争学习算法(RPCL)进行聚类分析,得到待分样本的分布。再次采用提出的单个神经网络生成算法得到单个神经网络。最后采用相对多数方法对神经网络进行集成。采用基于 boosting, bagging 方法的集成神经网络和该算法进行比较,结果表明该方法的分类精度要高于传统方法,是一种有效的目标识别算法。

关键词 聚类分析, Hu 矩, 集成神经网络, 序列图像, 多目标识别

Multi-objects Recognition Algorithm in Sequence Images Based on Clustering Analysis and Ensemble Neural Networks

ZHOU Tao^{1,2} ZHANG Yan-ning² YUAN He-jin^{1,4} LU Hui-ling³ LI Xiu-xiu¹

(School of Computer Science, Northwestern Polytechnic University, Xi'an 710072, China)¹

(Department of Maths, Shaanxi University of Technology, Hanzhong 723000, China)²

(Department of Computer, Shaanxi University of Technology, Hanzhong 723000, China)³

(School of Computer Science, North China Electric Power University, Baoding 071003, China)⁴

Abstract These ensemble neural networks have great randomness and arbitrariness when choosing samples to build up the training subsets since they don't consider the distribution information of these samples. The performance of ensemble will deteriorate greatly once the training subsets are not appropriately selected. So in practical application, the training subsets must include many instances, which result in great needs of computation time and storage space. In order to overcome above drawbacks, this paper put forwards a new ensemble neural networks approach based on RPCL clustering analysis and Hu invariable moment. Firstly, we extracted targets from sequence images, such as pedestrian, crowd, car from single frame image in training video. The outline information was extracted by Hu invariable moment, in order to avoid the default that Hu invariable moment can not describe small targets and non-rigid targets, area information are extracted too; secondly, 8 dimension data about these samples were clustered using RPCL algorithm and obtain their distribution; thirdly, single neural network was constructed through this method proposed by this paper; finally, ensemble was constructed by relative majority voting method. We adopted ensemble neural network based on boosting and bagging method to compare this method, experiment result illustrate that the method has a high classification precision comparing with tradition method, and it is a effective target recognition approach.

Keywords Clustering analysis, Hu moment, Ensemble neural network, Sequence image, Multi-objects recognition

1 引言

机器学习是计算机科学中研究怎么让机器具有学习能力的一个分支,机器学习方法已经在科学研究、语音识别、人脸识别、手写识别、数据挖掘、医疗诊断、游戏等诸多领域中得到

应用。目前来说,机器学习的研究主要分为 4 个大方向^[1,2]: a) 通过集成学习方法提高学习精度; b) 扩大学习规模; c) 强化学习; d) 学习复杂的随机模型。集成学习位居当前机器学习领域的四大研究方向之首,其本质就是利用多个(通常是同质的)学习机来解决同一个问题,目的是更有效地提高学习系

到稿日期:2008-06-20 本文受国家自然科学基金(No:60472072),航天科技创新基金(No:06CASC0404),陕西省教育厅科研项目(No:08JK241)资助。

周涛(1977—),男,博士生,副教授,研究方向为模式识别、数据挖掘、软计算理论;张艳宁(1967—),女,博士,教授,博士生导师,研究方向为模式识别、计算机视觉、知识发现等。

统的泛化能力。1990年,文献[3]首次提出了神经网络集成方法。文献[4,5]指出集成学习之所以有效,可以归为3个方面的原因:统计上的原因、计算上的原因和表示上的原因。文献[6,7]指出,集成学习有效的条件是每个单一的学习器错误率都应当低于0.5,否则集成的结果反而会提高错误率。集成神经网络是集成学习里面一种重要的学习方法。文献[8]给出了神经网络集成泛化误差的分解公式,并表明只要个体神经网络泛化误差均值保持不变,增加差异性可以提高网络的泛化能力,因此构造具有较大差异的神经网络在理论上被认为是集成方法所具有的重要特性。但是构造不同神经网络(也称为差异性)并不是一件很简单的事情。神经网络集成的泛化误差等于集成中个体网络的平均泛化误差和平均差异度之差^[23],因此要增强神经网络集成的泛化能力,一方面应尽可能提高个体网络的泛化能力,另一方面应尽可能地增大集成中各网络之间的差异。

考察一个集成学习方法的时候,应该考虑以下两个方面的问题:1)怎么样生成多个不同的基本分类器。2)如何把多个基本分类器的分类结果整合起来。对于第一个问题,即个体分类器的生成方法,目前主要有: bagging^[9], boosting方法^[10],交叉验证划分方法^[11], ECOC方法^[12]等。对于第二个问题,即结论生成方法亦称为组合基模型的方法,最基本的组合方法是多数表决法。若分类器以概率值的形式输出,则简单平均方法与加权平均方法也是一种有效的组合方法。目前,除了线性组合方法外,还存在非线性集成方法,如Li和Yan等人分别给出了用粗糙集^[13]和模糊积分^[14]对各SVM的输出进行融合的新方法。相对于全体集成而言,选择性集成可能更为有效,Zhou和Zhang等人分别给出了采用遗传算法^[15]和免疫进化算法^[16]选择合适的分类器进行集成的方法。

集成方法的关键在于在给定的训练集上构造多个性能较好而又相对独立的分类器^[8]。常用的方法是利用重采样技术从训练集中选择样本,生成多个子集,以此为基础构造分类器进行集成,如 bagging, adaboost等。这样选择样本存在下面3个缺点:1)这些方法在选择样本时没有考虑样本的空间分布情况,因而具有很强的随机性和盲目性,一旦样本选择不合适,集成分类器的性能将会急剧下降;2)集成的神经网络差异性越大,集成神经网络性能越好,上述选择样本的方法是无法保证这个条件的;3)为了能较好地反映真实的样本分布,在实际应用中各训练子集一般需要包含较多的样本,但这无疑就增加了算法的时间和空间需求。在序列图像目标识别中,提取出来的目标是同一目标在不同时刻即不同帧的连续出现,具有较强的时态特性,因此不同目标在特定的特征描述下,其空间分布与非序列目标相比而言差异较大,传统的方法都没有考虑到这种情形。为了克服上述问题,进一步提高序列图像目标识别精度,本文在文献[21]的基础上提出了一种基于聚类分析的集成神经网络算法,并把该方法应用到序列图像目标识别。该方法首先从序列图像中提取3类训练样本——人、人群、汽车,对训练样本分类,得到3类样本,在每个类内采用基于对手惩罚策略的竞争学习(RPCL)算法对训练样本进行聚类分析,得到各类样本的聚类子集。然后,按照随机从人、人群、汽车3类样本的子集中选一类样本生成训练集来构造单神经网络,最后采用相对多数投票方法集成神经网络。

由于各训练子集的样本是在聚类分析的基础上选择的,能较好地反映真实的数据分布且规模相对较小,并且从不同类中选择—个样本构造的神经网络其差异性大于采用 bagging 或 boosting 等方法构造的神经网络,因而基于本文方法构造的集成神经网络具有较高的分类性能及较低的时间和空间复杂性。

本文第2节介绍采用的 RPCL 聚类算法和 Hu 七阶矩;第3节介绍提出的基于聚类分析的集成神经网络算法整体思想、单个神经网络生成策略、神经网络集成策略;第4节通过实验对该算法进行性能测试并对实验结果进行分析。最后是本文工作的总结。

2 基础知识介绍

2.1 RPCL 聚类算法

聚类分析是一种无监督的学习方法,它以样本之间的距离为基础,按照一定的准则将样本划分成分布在空间中不同区域的簇,每个簇的中心被称为聚类中心。可以说,聚类分析是了解和掌握样本在空间分布情况的一种简单而有效的方法。典型的聚类方法有 k 均值算法以及基于竞争的无监督学习方法等^[17]。但是这类方法中,聚类个数 K 和竞争神经元个数的选择是一个比较困难的问题,对聚类效果的影响很大。Xu 等人提出了一种基于对手惩罚的竞争学习算法(RPCL)^[18],能很好地克服上述问题。RPCL 算法的基本思想是:对每个输入而言,不仅竞争获胜单元的权值被修改以适应输入值。RPCL 算法由于引入对手惩罚机制,是一种鲁棒的聚类分析方法。

2.2 Hu 不变矩

不变矩特征^[19]就是图像中所具有的平移、旋转和比例不变性的数学特征。矩理论是 M. K. Hu 首先于1962年提出来的^[19],他给出了具有平移不变性、旋转不变性和比例尺度不变性的7个不变矩的表达式,并在计算机上对字母二值化图像进行了识别实验。在 Hu 的基础上,R. Y. Wong 在其研究中进一步给出了离散状态下的各阶矩的计算方法^[20]。图像的几何矩是图像函数在空间区域 D 内的积分,在实际处理中往往采用离散 HU 矩。

3 基于聚类分析的集成神经网络

3.1 基于聚类分析的集成神经网络算法思想

第一步:训练样本集 $X = \{x_1, x_2, \dots, x_m\}$ 。

第二步:根据样本自身的特点分成 n 类: $\pi_1, \pi_2, \dots, \pi_n$, 其中

$$\pi_1 = \{x_1^1, x_1^2, \dots, x_1^{|\pi_1|}\}, \pi_2 = \{x_2^1, x_2^2, \dots, x_2^{|\pi_2|}\}, \dots, \pi_n = \{x_n^1, x_n^2, \dots, x_n^{|\pi_n|}\}$$

$$X = \pi_1 \cup \pi_2 \cup \dots \cup \pi_n, \pi_i \cap \pi_j = \phi, 0 < i < j < n$$

第三步:对每一类样本进行聚类。

对于第 π_i 类中的样本,进行聚类,得到 p_i 个类: $class_i^1, class_i^2, \dots, class_i^{p_i}$, 样本的数目分别是 $||class_i^1||, ||class_i^2||, \dots, ||class_i^{p_i}||$ 。其中:

$$class_i^1 \cup class_i^2 \cup \dots \cup class_i^{p_i} = \pi_i;$$

$$class_i^j \cap class_i^k \neq \phi, 0 < i < j < k < p_i$$

对于其它类,进行同样的操作。

第四步:产生单个神经网络的训练样本。

从 π_1 的聚类结果 $class_1^1, class_1^2, \dots, class_1^{p_1}$ 中任选一个子类中的样本;

从 π_2 的聚类结果 $class_2^1, class_2^2, \dots, class_2^{p_2}$ 中任选一个子类中的样本;

依此类推,从每类样本集的聚类结果中选一个子类样本来构成一个神经网络训练样本。需要几个子神经网络,就选择几次样本。

第五步:利用产生的训练样本分别训练,得到对应的子神经网络。

第六步:采用相对多数投票对子神经网络结果进行集成。

文献[22]亦提出了一种基于聚类技术的选择性神经网络集成方法 CLU_ENN,但与本文算法思路不同。该文在获得个体神经网络后,并不是直接对这些神经网络进行集成,而是先应用聚类算法对这些神经网络模型聚类,以获得差异性较大的部分神经网络,然后由部分神经网络构成集成。可见,该方法与本文方法差异是很大的。我们是在对训练样本分类的基础上聚类来得到差异性较大的个体神经网络。

具体算法思想如图 1 所示。

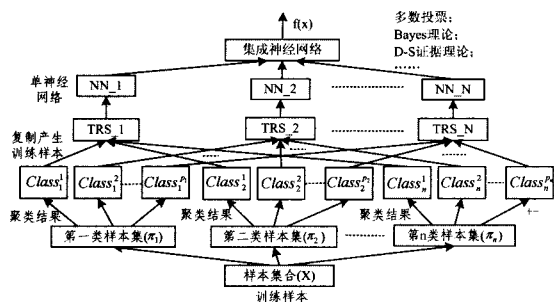


图 1 基于聚类分析的集成神经网络示意图

3.2 基于聚类分析的单个神经网络生成算法

算法名称:基于聚类分析的单个神经网络生成算法

算法输入:

1 训练样本集 $X = \{x_1, x_2, \dots, x_m\}$, m 为总的训练样本数;

2 样本类别数 n ;

算法输出:

训练好的单神经网络;

算法步骤:

begin

for $i=1:m$ //把训练样本分成 n 类

Switch (i)

Case Label=1, add sample x_i to Class π_1 ;

Case Label=2, add sample x_i to Class π_2 ;

...

Case Label= n , add sample x_i to Class π_n ;

End switch;

end for

for $i=1:n$ //对第 π_i 类样本进行聚类,得到 p_i 个类

$\{Class_1^i, Class_2^i, \dots, Class_{p_i}^i\} = \text{cluster}(\pi_i)$;

end for;

for $i=1:n$

//从每一类样本的聚类结果中随机抽取一类样本作为训练 i^{th} 个神经网络的训练数据集

$r(i) = \text{rand}(p_i)$; // $\text{rand}(p_i)$ 产生一个 $[1, p_i]$ 之间均匀分布的随机整数

Selecting these samples in $Class_i^{r(i)}$ from π_i randomly;

Adding it to the i^{th} training dataset;

end for

Training i^{th} neural network on the i^{th} dataset; //利用选取的训练样本生成单个神经网络

End

这里,每个训练子集的样本取遍 π_i ($i=1, 2, \dots, n$),并且每一类中取的样本是经过聚类得到的,其类内相似性是相对较大的,从而能够从某个侧面代表该类样本,具有一定的代表性,能够较好地反映样本的真实分布。因而,各训练子集的样本数目可以取得相对较小,从而有效降低集成 NN 的时、空复杂性。

3.3 神经网络集成算法

投票法的基本思想是多个基本分类器都进行分类预测,然后根据分类结果用某种投票的原则进行投票表决。按照投票原则的不同,投票法可以有一票否决、一致表决、少数服从多数、阈值表决等等。本文采用少数服从多数投票策略,其思想就是当各个基本分类器进行投票(加权或者不加权),得票数多的那个分类 C_i 作为对应实例 x 的最终分类。

4 实验结果及分析

我们采集实验视频 1min,得到 1500 帧序列图像,采用跟踪策略得到 1500 帧中所有的 3 类目标(人、人群、汽车),通过 HU 七阶不变矩提取目标的不变矩特征。由于跟踪目标较小, HU 七阶不变矩提取小目标轮廓特征不准确的特点,增加面积特征,这样每一个目标就得到一个 8 维的特征向量 $T = \{C_1, C_2, C_3, C_4, C_5, C_6, C_7, C_8\}$, $C_1 - C_7$ 表示 7 个不变矩特征、 C_8 表示区域面积特征。具体步骤如下:

1)连续截取视频图像 1min,1s 钟 25 帧,共计 $25 * 60 = 1500$ 帧;

2)利用跟踪策略,获得这 1min 以内 1500 帧中的所有目标(3 类:人、人群、汽车);

3)对获得的目标图像进行灰度处理,并最终得到二值化图像;

4)采用 HU 七阶不变矩来提取目标的轮廓信息,并同时提取目标的面积,得到训练数据集;

5)利用本文方法来构造集成神经网络,进行分类。

整体思路如图 2 所示。




图 2 整体思路示意图

需要说明的是,由于目标图像是从视频中提取出来的,由于跟踪算法、分割算法和实际情况的复杂性,导致提取出的目标具有以下特征:1)目标不完整;2)目标残缺;3)与其它目标有交叉;4)目标边界不规则;5)目标图像大小不同等问题。关于这些可以在图 3—图 5 中明确看到。

“人”、“人群”、“汽车”3 类,每类 220 张,前 200 张图像作为测试集合,后 20 张作为测试图像。首先把 600 张图像的不变矩特征和面积特征逐一提出,形成训练样本集,然后对每类




图3 “人”目标




图4 “人群”目标

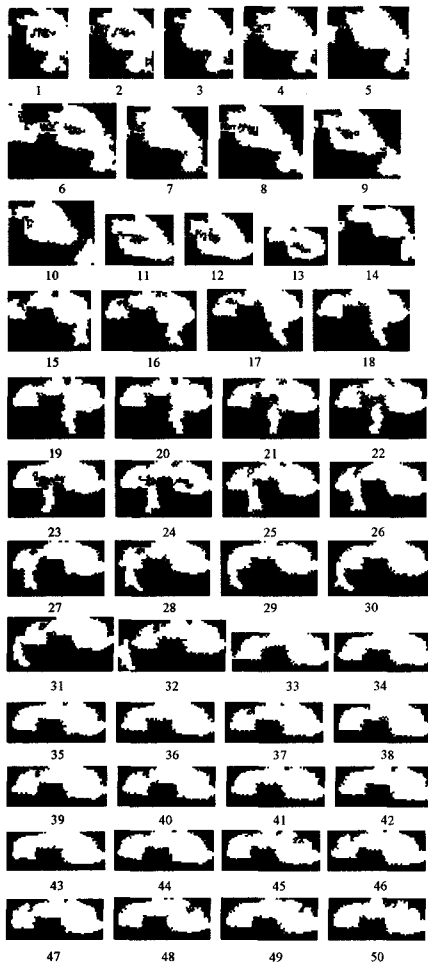


图5 “汽车”目标

样本分别采用 RPCL 聚类。每一类的聚类结果中任取一个子类(共 3 个)来组成单个神经网络的训练数据集,从而得到单个神经网络。重复上面步骤(具体重复次数视问题而定),得到多个神经网络。最后采用相对多数方式投票,得到集成神经网络。出于版面考虑,在不影响说明问题的前提下,这里给出每类目标中的前 50 个。测试样本也没有单独给出。

为了能够说明本文方法,我们选用 4 种数据集:“人”数据集 200 个、“人群”数据集 200 个、“汽车”数据集 200 个,以及 3 类目标混合数据集 600 个。采用的方法有神经网络进行分类、采用 bagging 策略的集成神经网络、采用 boosting 策略的集成神经网络以及本文方法,分别对每一个数据集进行了分类识别,统计结果如表 1 所示。

表 1 典型算法及本文算法分类精度统计表

算法	数据集			
	人	人群	车	三类目标混合
单神经网络	准确率(%) 75.96	69.75	78.13	65.28
Bagging	准确率(%) 89.35	85.51	91.53	89.69
Boosting	准确率(%) 94.88	93.95	95.36	90.25
本文方法	准确率(%) 97.14	95.86	96.32	95.78

从实验结果可以看到,无论采用哪种集成策略,其分类正确率都远远高于单神经网络的分类精度。其中本文提出的基于聚类分析的集成方法得到的识别率都高于基于 bagging 和 boosting 的集成神经网络。

结束语 从研究的问题来看,序列图像目标在特定特征描述下其空间分布差异较大。在不考虑样本空间分布的情况下,直接采用集成神经网络来识别,误差较大。从方法的角度来看,如何构造差异性较大的个体网络,从而改善集成神经网络的性能,始终是困扰研究者们的一个问题。本文在文献[21]的基础上提出了一种考虑样本空间分布特性的基于聚类分析的集成神经网络方法,通过聚类分析,将训练样本分成 m 类。生成单个网络时,在类间差异较大的两个类中选择样本,对单个网络进行训练。这类训练样本数目规模小,剪表性强,能较好地反映真实的样本分布情况。这样从根本上保证了能较好刻画问题,并且提高了个体网络的差异性。本文方法生成的集成神经网络在序列目标识别中有较高的分类精度和较低的时、空复杂度,并且最后通过实验验证,得到了较好的效果。

参 考 文 献

- [1] Dietterich T G. Machine learning research: Four current directions [J]. AI Magazine, 1997, 18(4): 97-136
- [2] Dietterich T G. Ensembles methods in Machine Learning [M]// 1st/nte. Workshop on Multiple Classifier Systems. Lecture Notes in Computer Science, New York, Springer-verlag, 2000: 1-15
- [3] Hansen L K, Salamon P. Neural network ensembles [J]. IEEE Transaction on Pattern Recognition and Machine Intelligence, 1990, 12(10): 993-1001
- [4] Dietterich T G. Ensemble learning. The Handbook of Brain Theory and Neural Networks. Second Edition (M. A. Arbib, Ed.). Cambridge, MA: The Mit Press, 2002: 405-408
- [5] Dietterich T G. Ensemble Methods in Machine Learning. Multiple Classifier Systems, Cagliari, Italy, 2000
- [6] Valentini G, Masulli F. Ensembles of learning machines. Lecture Notes in Computer Sciences. Heidelberg, Germany: Springer-Verlag, 2002
- [7] Yu ShiXin. Feature Selection and Classifier Ensembles: A Study

on Hyperspectral Remote Sensing Data. 2003. http://143.129.203.3/visielab/theses/shixin/thesis_yu.pdf

[8] Tesauro G, Touretzky D S, Leen T K, et al. Neural network ensembles, crosses validation, and active learning[C]. Advances in neural information processing system, Cambridge, MA: MIT Press, 1995; 231-238

[9] Breiman L. Bagging Predictors. Machine Learning, 1996, 24 (2): 123-140

[10] Freund Y, Schapire R. Experiments with a new boosting algorithm//Proc. the 13th Int. Conf. Machine Learning, Bari, Italy: Morgan Kaufmann, 1996

[11] Krogh A, Vedelsby J. Neural network ensembles, cross validation, and active learning// Tesauro G, Touretzky D S, Leen T K, eds. Advances in Neural Information Processing Systems 7. Cambridge, MA: MIT Press, 1995; 231-238

[12] Dietterich T G, Bakin H, Bakiri G. Solving multiclass learning problems via error-correcting output codes. Journal of AI Research, 1995, 2; 263-286

[13] Li Ye, Yin Ru-po, Cai Yun-ze, et al. A New Decision Fusion Method in Support Vector Machine Ensemble// Proceedings of Fourth International Conference on Machine Learning and Cybernetics. 2005; 3304-3308

[14] Yan Genting, Ma Guangfu, Zhu Liangkuan. Support Vector Machine Ensemble Based on Fuzzy Integral for Classification //

Third International Symposium on Neural Networks, 2006; 974-980

[15] Zhou Zhi-hua, Wu Jianxin, Tang Wei. Ensembling neural networks; many could be better than all. Artificial Intelligence, 2002; 239-263

[16] Zhang Xiangrong, Wang Shuang, Shan Tan, et al. Selective SVMs Ensemble Driven by Immune Clonal Algorithm// Applications on Evolutionary Computing, EvoWorkshops, 2005; 325-333

[17] Desieno D. Adding a conscience to competitive learning// Proc. of IEEE Int. Conf. Neural Networks, 1988; 117-124

[18] Xu Lei, Krzyzak A, Oja E. Rival Penalized Competitive Learning for Clustering Analysis, RBF net and Curve Detection. IEEE Trans on Neural Networks, 1993; 636-649

[19] Hu M K. Visual pattern recognition by moment invariants [J]. IEEE Trans on Information Theory, 1962, 8; 179-187

[20] Wong Y R. Scene Matching with Invariant Moments Computer Graphics and Image Processing, 1978, 8; 16-24

[21] Wang Cuiru, Yuan Hejin, Liu Jun, et al. A Novel Support Vector Machine Ensemble Based on Subtractive Clustering. Lecture Notes in Computer Science. Springer-verlag press, 2007, 4426; 849-856

[22] 李凯, 黄厚宽. 一种基于聚类技术的选择性神经网络集成方法 [J]. 计算机研究与发展, 2005, 42(4); 594-597

[23] 周志华, 陈世福. 神经网络集成 [J]. 计算机学报, 2002, 25(1); 1-8

(上接第 172 页)

结构变化下的不寻优和全寻优系统阶跃响应曲线如图 6(a)和图 6(b)所示。结构变化下的全寻优和原基础上寻优的最优解跟踪曲线如图 7(a)和图 7(b)所示。




图 6 结构变化下的控制特性影响




图 7 结构变化下的寻优最优解跟踪曲线

上述实验结果曲线对比表明,模糊控制器不仅对被控对象参数变化适应能力强,而且在对象模型结构发生较大改变的情况下,也能获得比较好的控制效果,这是模糊控制优于传统 PID 控制的重要特性。在模糊控制器上加入可演化机制后,其控制效果更好,且在原基础上进行自适应寻优,比重新寻优的效率更高。因此可演化模糊控制器的鲁棒性更强。

结束语 将演化硬件用于模糊控制的自适应研究是一个新的研究领域,在工业和军事上都有重大的应用价值。本文根据模糊控制器查询表的特点提出的查询表优化算法,具有编码简单、运行速度快的特点,有利于提高演化硬件的规模。

根据多值逻辑和 PLA 理论,提出的可演化查表式模糊逻辑控制器的硬件结构,只有四级延迟,运算速度比采用软件实现要快,有利于演化硬件建筑块的设计。在快速的时变、不确定性对象控制中可以获得良好的应用效果。

参考文献

[1] 张大斌,李元香,夏学文. 一种基于 PFLC 的可演化模糊逻辑控制器设计与实现[J]. 计算机科学, 2007, 34(5): 218-220

[2] Stoica A, Keymeulen D, Zebulum R, et al. Adaptive and Evolvable Analog Electronics for Space Applications[C]// International Conferences on Evolvable Systems (ICES 2007). 2007; 379-390

[2] Subbiah P, Ramamurthy B. The Study of Fault Tolerant System Design Using Complete Evolution Hardware[C]// IEEE International Conference on Granular Computing (CGC 2005). 2005; 642-645

[3] Stomeo E, Kalganova T, Lambert C. A Novel Genetic Algorithm for Evolvable Hardware[C]// IEEE Congress on Evolutionary Computation (CEC 2006). 2006; 134-141

[5] Tawdross P, Lakshmanan S K, Konig A. Intrinsic Evolution of Predictable Behavior Evolvable Hardware in Dynamic Environment[C]// The Sixth International Conference on Hybrid Intelligent Systems (HIS'06). 2006; 60-63

[6] Hereford J M. Fault - tolerant sensor systems using evolvable hardware[J]. IEEE Transactions on Instrumentation and Measurement, 2006, 55 (3); 846-853

[7] 李黎川, 卢秉恒. 采用遗传算法直接获取模糊控制器的查询表 [J]. 高技术通讯, 2000, 1; 66-70

[8] 雷英杰, 张善文, 李续武, 等. MATLAB 遗传算法工具箱及应用 [M]. 西安电子科技大学出版社, 2005; 62-94

[9] 诸静, 等. 模糊控制原理与应用 (第 2 版) [M]. 机械工业出版社, 2005(1); 212-213

[10] 楼顺天, 胡昌华, 张伟. 基于 MATLAB 的系统分析设计—模糊系统 [M]. 西安电子科技大学出版社, 2001; 40-75