

基于聚类分析和集成改进支持向量机的序列目标分类算法

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 针对现有集成支持向量机存在的训练子集随机性强、规模大、算法时空复杂度高等问题,提出了基于聚类分析的集成改进支持向量机算法。该方法首先采用基于对手惩罚策略的竞争学习算法(RPCL)对训练样本进行聚类分析,然后根据其聚类分布选择少量具有代表性的样本,并采用了基于种群收敛速度的自适应扰动的粒子群方法来训练单个支持向量机,最后通过相对多数投票方法得到集成支持向量机。实验表明相对于基于 Bagging, Adaboost 等方法而言,该方法在序列目标分类中对分类精度有较大提高,该方法构造的集成改进支持向量机具有较高的分类精度和较低的时、空复杂性。

关键词 粒子群算法, 支持向量机, 聚类分析, 对手竞争惩罚学习算法, 集成

Sequence Targets Classification Algorithm Based on Ensemble Improvement SVM and Clustering Analysis

ZHOU Tao^{1,2} ZHANG Yan-ning¹ 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 Aiming at the existing support vector machine ensemble's problems, e. g. strong randomness, larger scale of the training subsets and high complexity of the ensemble classifier, this paper put forwards a novel SVM ensemble construction method based on clustering analysis. The samples were clustered into several clusters according to their distribution with rival penalty competitive learning algorithm. A small quantity of representative instances were chosen as training sets and training SVM that adopt self-perturbation in population convergence speed. Ensemble Improvement SVM was constructed by relative majority voting. Sequence targets classification is used by this method, and classification precision of this method has higher classification accuracy and lower time and space complexity comparing to Bagging, Adaboost etc. selection algorithms.

Keywords PSO, Support vector machine, Clustering analysis, RPCL, Ensemble

1 引言

20 世纪 90 年代中期以来,支持向量机成为机器学习领域最有影响的成果之一,它的一个显著优点之一是不仅能将样本分开而且能够使得两类之间的分类间隔最大。然而,和神经网络等其他机器学习方法类似,由于训练样本相对有限,所以 SVM 在训练集上的分类性能很好,而在测试集上相对较差。集成(ensemble)是解决上述问题的一个有效方法,它首先建立一组比较精确而又相对独立的分类器对测试样本进行分类,然后采用一定的策略或准则将各个学习机的输出结果进行融合得到最终的判别结果。近几年来,集成学习在机器学习、神经网络、统计学等领域都成为一个相当活跃的研究热点,并被认为是当前机器学习领域的 4 大研究方向之

首^[1,2]。Kim 等人已将集成方法应用于支持向量机^[3,4],并取得了较好的效果。目前,集成 SVM 已被成功地应用于基因表达数据的分析^[6]、癌症识别^[7]、故障诊断等领域^[8]。

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,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。但存在的问题是,这些方法在选择样本时未考虑样本的空间分布情况,样本的选择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。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消耗。为了克服上述问题,本文提出了一种基于聚类分析的支持向量机集成算法。该方

到稿日期:2008-04-30 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。

法首先采用基于对手惩罚策略的竞争学习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,按照一定的策略从各聚类子集中选择少量样本生成训练集,并采用了基于种群收敛速度的自适应扰动的粒子群方法来训练单个支持向量机,最后通过相对多数投票方法得到集成支持向量机。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,因而基于本文方法构造的集成支持向量机具有较高的分类性能和较低的时间和空间复杂性。

2 基础知识介绍

2.1 RPCL 算法简介

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族,每个族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^[9,10]。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)^[11],能很好地克服上述问题。RPCL 算法的基本思想是:在竞争性神经网络中,对每一个输入样本,不仅按照一定的学习步长调整获胜神经元 C 的权值 w_c ,而且也按照一个相对较小的步长惩罚次优神经元(即获胜神经元 C 的对手)使其向远离输入样本的方向移动。RPCL 算法通过引入对手惩罚机制较好地解决了神经元个数的选择问题,是一种鲁棒的聚类分析方法。

2.2 Hu 不变矩

不变矩特征^[16]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^[16]。M. K. Hu 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分类实验。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^[17]。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。

2.3 改进支持向量机 PSO_SVM

支持向量机^[18,19](Support Vector Machine,简称 SVM)是统计学习理论中一种十分重要的方法,对统计学习理论的发展起到了巨大的推动作用。支持向量机的核心思想是利用核技巧将样本变换到高维特征空间,根据结构风险最小化原则和对偶原理,通过求解一个凸二次规划问题,找出支持向量及其系数构造最优分类面,使得该分类面不仅能够将两类样本分开,而且分类间隔最大。支持向量机具有完美的数学形式、直观的集合解释和良好的泛化能力,解决了模型选择与欠学习、过学习问题以及非线性问题,避免了局部最优解,有效地克服了“维数灾难”,且人为设定参数少,便于使用,已经在分类、识别、数据挖掘等领域得到广泛的应用。

SVM 训练的实质为求解一个带有界约束和线性等式约束的凸二次规划问题。经典的求解非线性规划的方法,如牛顿法、拟牛顿法等计算量大而且运算速度慢。粒子群优化算法^[20,21](Particle Swarm Optimization,简称 PSO)是由 J. Ken-

nedy 和 Eberhart 等人受鸟群觅食行为的启发而提出的一种仿生型种群智能优化算法,它是一种具有随机性的多点搜索算法,具有隐含的内在并行性,能够在多维空间中快速找到问题的最优解。将 PSO 应用于 SVM 的训练是一个新颖的尝试。由于基本 PSO 只能求解无约束优化问题,文献[22]提出了一种 LPSO 算法可以用于求解含有线性等式约束的优化问题。文献[23]将 LPSO 应用到了 SVM 的训练中,但主要针对的是大样本问题,其处理思想类似于 Chunking^[24],Decomposition^[25]等方法,只是采用 LPSO 求解二次规划。作者在文献[26]中提出了一种在基本 PSO 所采用的线性减少的惯性权重选择策略的基础上,引入了基于种群收敛速度的自适应扰动,并阐述了应用改进后的算法训练 SVM 的过程。作者这里简称为改进支持向量机,记为 PSO_SVM,此处不再累述文献中的内容,本文题目中的集成改进支持向量机指的就是该文中提出的 PSO_SVM。

3 基于聚类分析的集成改进支持向量机

3.1 聚类分析对集成改进支持向量机的影响

训练子集的构造对集成 PSO_SVM 的性能影响很大。如图 1 所示,当生成的训练子集仅由椭圆形框内的样本组成时,训练出的 PSO_SVM 的分界线如图所示。显然,对训练集而言,该 PSO_SVM 非常有效,但对由矩形框中的样本构成的测试集而言,则分类精度很差,绝大部分样本将被错误地分类。当采用这样的 PSO_SVM 进行集成时,其性能将会很差。为了克服上述现象,人们采用 Bagging, Adaboost 等方法,力图使得各训练子集的样本能够较好地反映真实的样本分布。然而这些方法在生成训练子集时,并没有考虑样本的空间分布情况,因而具有很大的随机性和盲目性。当采用这些方法构造集成 PSO_SVM 时,各训练子集必须包含较多的样本,否则一旦训练子集构造得不合适,集成改进支持向量机的性能将会严重下降。众所周知,支持向量机的训练所需的时间和存储空间和样本个数是密切相关的,上述方法必然增加算法的时、空复杂度。当训练样本集较大时,这个问题尤为突出。




图 1 训练样本选择对 PSO_SVM 泛化性能影响的示意图

3.2 基于聚类分析的集成改进支持向量机算法思想

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: π_1, π_2 。其中:

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

$$X = \pi_1 \cup \pi_2, \pi_1 \cap \pi_2 = \emptyset$$

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: $class_1^i, class_2^i, \dots, class_{p_i}^i$, 样本的数目分别是 $||class_1^i||, ||class_2^i||, \dots, ||class_{p_i}^i||$ 。其中:

$class_1^j \cup class_1^2 \cup \dots \cup class_1^{p_1} = \pi_1; class_1^j \cap class_1^k \neq \emptyset, 0 < j < k \leq p_1$

对于其它类,进行同样的操作。

第四步 产生单个 PSO_SVM 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;

从每类样本集的聚类结果中选一个子类样本来构成一个 PSO_SVM 训练样本,以此类推,需要几个子 PSO_SVM,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单个 PSO_SVM;

第六步 采用相对多数投票对单个 PSO_SVM 结果进行集成;

算法思想如图 2 所示。




图 2 基于聚类分析的集成 PSO_SVM 示意图

3.3 基于聚类分析的单个 PSO_SVM 生成算法

算法名称:基于聚类分析的 PSO_SVM 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 $n=2$;

算法输出:

训练好的单 PSO_SVM;

算法步骤:

begin

for $i=1:m$ //把训练样本分成 n 类,类别位 Label

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

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

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 个 PSO_SVM 的训练数据集

$r(i) = rand(p_i)$; // $rand(p_i)$ 产生一个 $[1, p_i]$ 之间均匀分布的

随机整数

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

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

end for

Training i^{th} PSO_SVM on the i^{th} dataset; //利用选取的训练样本生成单个 PSO_SVM

end

这里,每个训练子集的样本取遍 $\pi_i (i=1,2)$,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,具有一定的代表性的,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 PSO_SVM 的时、空复杂性。

3.4 支持向量机集成算法

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

本文采集实验视频 1 分钟,得到 1500 帧序列图像,采用跟踪策略得到 1500 帧中所有的二类目标(人,汽车),通过 HU 七阶不变矩提取目标的不变矩特征,由于是跟踪目标较小, 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 $T = \{C1, C2, C3, C4, C5, C6, C7, C8\}$, $C1 \sim C7$ 表示 7 个不变矩特征、 $C8$ 表示区域面积特征。具体步骤如下:

1. 连续截取视频图像 1 分钟,1 秒钟 25 帧,共计 $25 * 60 = 1500$ 帧;

2. 利用跟踪策略,获得这 1 分钟以内的 1500 帧中的所有目标(二类:人,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 PSO_SVM 进行分类。

整体思路如图 3 所示。




图 3 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 4 和图 5 中明确看到。

“人”、“车”二类,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 400 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(共二

个)来组成单个 PSO_SVM 的训练数据集,从而得到单个 PSO_SVM,重复上面步骤(具体重复次数视问题而定),得到多个 PSO_SVM,最后采用相对多数方式投票得到集成 PSO_SVM。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。




图4 “人”目标




图5 “汽车”目标

为了能够说明本文方法,我们选用 2 种数据集:“人”数据集(200 个)、“车”数据集(200 个),以及二类目标混合数据集(600 个),采用的方法有单 PSO_SVM 进行分类,采用 Bagging 策略的集成支持向量机,采用 Boosting 策略的集成支持向量机以及本文方法分别对每一个数据集进行了分类。其统计结果如表 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	车	二类目标混合
单 PSO_SVM	准确率(%)	74.56	77.11	61.11
Bagging	准确率(%)	83.21	90.13	85.19
Boosting	准确率(%)	93.18	94.16	89.15
本文方法	准确率(%)	96.11	95.21	94.98

从实验结果我们可以看到,无论采用哪种集成策略,其分类正确率都远远高于单 PSO_SVM 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分类率都高于基于 Bagging 和 Boosting 的集成 SVM。

结束语 针对现有集成支持向量机中训练子集随机性盲目性均强、规模大、算法时、空复杂度高等问题,提出了基于聚类分析的集成 PSO_SVM 构造方法。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 PSO_SVM 来分类误差较大;从方法的角度来看,如何构造差异性较大的个体 PSO_SVM 从而改善集成 PSO_SVM 的性能始终是困扰研究者们的一个问题。本文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 PSO_SVM 方法,通过聚类分析,将训练样本分成 2 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 PSO_SVM 进行训练,这类训练样本数目规模小,代表性强,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 PSO_SVM 的差异性。本文方法生成的集成 PSO_SVM 在序列目标分类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. AI Magazine,1997,18(4):97-136

[2] Dietterich T G. Ensembles in Machine Learning. Multiple Classifier Systems. Lecture Notes in Computer Science,2000:1-15

[3] Kim H C, Pang S, Je H M, et al. Constructing Support Vector Machine ensemble. Pattern Recognition,2003,36(12):2757-2767

[4] Kim H C, Pang S, Je H M, et al. Pattern classification using support vector machine ensemble.//Proceedings of the 16th International Conference on Pattern Recognition, Los Alamitos, CA, 2002:160-163

[5] Li Ye, Yin Ru-po, Cai Yun-ze, et al. A new decision fusion method in support vector machine ensemble.//Proceeding of the Fourth International Conference on Machine Learning and Cybernetics, 2005:3304-3308

[6] Valentini G, Muselli M, Ruffino F. Bagged ensembles of support vector machines for gene expression data analysis[A]//Proceedings of the International Joint Conference on Networks, 2003

[7] Valentini G , Muselli M , Ruffino F . Cancer recognition with bagged ensembles of support vector machines. Neuro computing,2004:461-466

[8] 李焱,蔡云泽,徐晓鸣. 基于支持向量机集成的故障诊断. 控制工程,2005,7:170-173

[9] Kohonen T. The Self-organization Map // Proc. IEEE. vol 78, 1990:1464-1480

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

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

[12] Ye Li, 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

- [13] 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
- [14] Zhou Zhi-hua, Wu Jianxin, Tang Wei. Ensembling neural networks; many could be better than all. Artificial Intelligence, 2002; 239-263
- [15] Zhang Xiangrong, Wang Shuang, Shan Tan, et al. Selective SVMs Ensemble Driven by Immune Clonal Algorithm // Applications on Evolutionary Computing: EvoWorkshops, 2005; 325-333
- [16] Hu M K. Visual Pattern Recognition by Moment Invariants[J]. IEEE Trans on Information Theory, 1962, 8; 179-187
- [17] Wong Y R. Scene Matching with Invariant Moments Computer Graphics and Image Processing, 1978, 8; 16-24
- [18] Vapnik V N. The Nature of Statistical Learning Theory. New York: Springer-Verlag, 1995
- [19] Cortes C, Vapnik V. Supporter vector networks. Machine Learning, 1995, 20; 273-297
- [20] Kennedy J, Eberhart R C. Particle swarm optimization // Proc of IEEE International Conference on Neural Networks, 1995; 1942-1948
- [21] Shi Y, Eberhart R C. A modified particle swarms optimizer // Proc of IEEE Congress on Evolutionary Computation, Alaska, 1998; 69-73
- [22] Paquet U, Engelbrecht A P. A new particle swarm optimizer for linearly constrained optimization // Proc of IEEE Congress on Evolutionary Computation, 2003; 227-233
- [23] Paquet U, Engelbrecht A P. Training support vector machines with particle swarms // Proc of International Joint Conference on Neural Networks, 2003; 1593-1598
- [24] Vapnik V N. Estimation of Dependences Based on Empirical Data. Moscow: Nauka, 1979
- [25] Osuna E, Freund R, Girosi F. An improved training algorithm for support vector machines // Proc of Neural Networks for Signal Processing, 1997; 276-285
- [26] 周涛, 张艳宁, 袁和金, 等. 基于改进粒子群算法的支持向量机[J]. 计算机工程与应用, 2007, 43(15); 44-46

(上接第 133 页)




图 5 MAS 算法的运行快照 ($spacing = 8$, (a)–(f) 依次是算法的 6 个运行步)




图 6 边缘检测效果对比



图 7 噪声图像边缘检测效果对比

(其中噪声为均值为 0, 方差为 0.01 的高斯噪声)

缘得出边缘特征表示,并在本文中成功地应用到 MAS 中。

在实验中,首先采用了无噪声的图像,然后对图像添加高斯噪声,共同验证了算法的适用性和有效性。

目前 MAS 的相关理论及技术在体系上还不完整,如何进一步丰富和完善 MAS 的理论体系和开发方法是未来要重点研究的问题。本文中得到的结果是, MAS 根据图像中像素相互之间的特别关系,令每个 Agent 有的放矢,从而完成较为理想的检测效果。下一步的工作是:一方面是继续寻求 MAS 在图像处理方向的应用研究;另一方面是有效细化结果边缘,同时寻找更佳边缘表示方法。

参 考 文 献

- [1] 段瑞玲,李庆祥,李玉和. 图像边缘检测方法研究综述[J]. 光学技术, 2005, 31(3); 415-419
- [2] 张小琳. 图像边缘检测技术综述[J]. 高能量密度物理, 2007, 1; 37-40
- [3] Mahdjoub J, Guessoum Z, Michel F, et al. A multi-agent approach for the edge detection in image processings[J] // EUMAS'06, 2006; 62-73
- [4] Richard N, Dojat M, Garbay C. Situated Cooperative Agents: a Powerful Paradigm for MRI Brain Scans Segmentation[J] // ECAI'02, 2002; 33-37
- [5] Liu J, Tang Y Y, Cao Y C. An Evolutionary Autonomous Agents Approach to Image Feature Extraction[J]. IEEE Trans. Evolu. Compu., 1997, 1(2); 141-158
- [6] Liu J. Reactive Agents for Adaptive Image Analysis[J] // Autonomous Agents'1998, 1998; 441-448
- [7] Liu J, Zhao Y. On Adaptive Agentlets for Distributed Divide-and-Conquer: A Dynamical Systems Approach[J]. IEEE Trans. Systems, Man and Cybernetics—Part A: Systems and Humans, 2002, 32(2); 214-227
- [8] Bovenkamp E G P, Dijkstra J, Bosch J G, et al. Multi-agent segmentation of IVUS images[J]. Pattern Recognition, 2004, 37; 647-663
- [9] Rodin V, Benzinou A, Guillaud A, et al. An immune oriented multi-agent system for bioLogical image processing[J]. Pattern Recognition, 2004, 37; 631-645
- [10] Guillaud A, Benzinou A, Troadeb H, et al. Autonomous agents for edge detection and continuity perception on otolith images[J]. Image and Vision Computing, 2002, 20; 955-968
- [11] Köthe U. Edge and Junction Detection with an Improved Structure Tensor[J]. DAGM, 2003; 25-32
- [12] Köthe U. Integrated Edge and Junction Detection with the Boundary Tensor[J] // ICCV'03, 2003, 1; 424-431
- [13] Weijer J, Gevers T, Smeulders A W M. Robust Photometric Invariant Features from the Color Tensor[J]. IEEE Transactions on Image Processing, 2006, 15(1); 118-127