

基于双极偏好的滑动窗口参数优化方法

邱飞岳^{1,2} 金锋涛² 王丽萍^{3,4} 张维泽¹

(浙江工业大学现代教育技术研究所 杭州 310023)¹ (浙江工业大学信息工程学院 杭州 310023)²
(浙江工业大学智能信息处理研究所 杭州 310023)³ (浙江工业大学经贸管理学院 杭州 310023)⁴

摘要 滑动窗口是形状匹配中的常用检测方法,可以检测图像中不同尺度不同位置的多个物体。检测效果采用检测率和误检率来衡量。在传统的滑动窗口检测方法中,通常基于经验选取滑动步长和图像缩放规模这两个参数值,来获得较高的检验率和较低的误检率。然而这是典型的两目标优化问题,传统方法未考虑决策者对检验率与误检率的不同偏好。根据实际情况,考虑到决策者的正偏好(高检验率与低误检率)及负偏好(低检验率和高误检率),引入双极偏好控制策略,提出基于双极偏好的多目标粒子群算法(BPMOPSO)的滑动窗口参数优化方法。通过 Leeds Cows 图像数据集上图像的检测实验结果表明,与传统算法相比,该算法显著改善了滑动窗口检测中的检验率和误检率,且大大提高了运行效率。

关键词 滑动窗口,多目标算法,双极偏好,参数优化

中图分类号 TP301.6 **文献标识码** A

Sliding Window Parameter Optimization Method Based on Bipolar Preferences

QIU Fei-yue^{1,2} JIN Feng-tao² WANG Li-ping^{3,4} ZHANG Wei-ze¹

(Institute of Modern Educational Technology, Zhejiang University of Technology, Hangzhou 310023, China)¹

(College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023, China)²

(Institute of Intelligence Information Processing, Zhejiang University of Technology, Hangzhou 310023, China)³

(College of Business Administration, Zhejiang University of Technology, Hangzhou 310023, China)⁴

Abstract One of the commonly-used detection methods in shape matching is the sliding window, in which multiple objects, different in size and position, can be detected. The detection performance is generally measured by detection rate and false positive rate. The two parameters in sliding window detection method, sliding step and the scale step are empirically selected for high detection rate and low false positive rate. However, those two factors can be formulated as a typical two-objective optimization problem, while the empirical selection shows no consideration over decision-makers' different preferences regarding detection rate and false positive rate. Given the fact that decision makers' positive preferences are represented by high detection rate and low false positive rate, and negative preferences, by low detection rate and high false positive rate, the paper introduced the bipolar control strategy and then proposed a new way to optimize the sliding window parameters based on Bipolar Preference Multi-objective Particle Swarm Optimization (BPMOPSO). The new method was applied in the detection experiment on Leeds Cows image datasets. The experiment results show that the performance of the new method is largely improved, i.e., the false positive rate declines sharply and the detection rate improves significantly, and that the efficiency of the algorithm ameliorates considerably as well.

Keywords Sliding window, Multi-objective algorithm, Bipolar preferences, Parameter optimization

1 引言

通过特征选取构建物体隐式形状模型后,需要将模型和图像进行形状匹配来检测图像中的物体,从而评估模型的泛化能力和学习方法的有效性。形状匹配,是指在形状描述的基础上,通过一定的度量准则来衡量形状间的相似度。为了

检测图像中不同尺度不同位置上的多个物体,物体检测常采用滑动窗口检测方法^[1-3]。该方法采用一个大小给定的窗口,以给定步长从待检测图像上滑动取值,每次滑动时,将提取的特征与物体模型进行给定阈值下的匹配。如 Viola 和 Jones^[2]采用初始 24×24 像素、以 1.25 倍比例逐次放大,滑动步长为 1.5 的滑动窗口用于人脸检测。Agarwal 等^[3]则提

到稿日期:2013-05-15 返修日期:2013-09-13 本文受国家自然科学基金(61379077,61070135),国家社会科学基金(10GBL095),浙江省自然科学基金(LY12F02032)资助。

邱飞岳(1965—),男,博士,教授,硕士生导师,主要研究方向为智能控制、优化理论与方法、学习科学与媒体技术, E-mail: qfy@zjut.edu.cn; 金锋涛(1989—),男,硕士生,主要研究方向为图像处理分析、多目标进化算法; 王丽萍(1964—),女,博士,教授,博士生导师,主要研究方向为信息处理、决策优化、商务智能; 张维泽(1983—),男,博士,讲师,主要研究方向为机器学习、物体检测和图像处理分析。

出从 0.48 到 1.2 倍,以 0.12 为间隔对待检测图像作 6 次缩放(等价于滑动窗口的反比例缩放)进行汽车检测。虽然传统方法简单有效,但参数基于经验取值,具有一定的主观性。同时,检测效果与置信度阈值的选取有关。对于给定置信度阈值和滑动窗口参数,仅得到一组检验率和误检率。因此为了准确评估物体模型的泛化能力,需要统计在不同匹配参数时的检验率和误检率,并以此为坐标绘制 ROC(Receiver Operating Characteristic)曲线^[4]。

当滑动窗口参数给定时,检验率和误检率是相互冲突的两个量^[3],选择一个合适的置信度阈值极其重要而又难以得到;若采用 F-measure^[5]、AUC^[6]等将 ROC 转换为单目标进行求解,则指标间的冲突性不能充分表达,从而带来很大的指标值损失,最优阈值只是一个折中方案。随着多目标优化理论的发展,很多学者提出直接以检验率、误检率等为目标,用 MOEA 对阈值等参数进行优化,如 Everson 等人^[7]以三分类器模型为例,以各分类器的误检率为目标,采用基于 PAES 的进化算法实现阈值的优化,提高了分类的准确性;Chatelain 等人^[8]针对检验率和误检率与 SVM 分类器参数之间的关系,提出了 ROC 前沿概念,并采用经典的 NSGA-II,在交叉验证过程中调整阈值,提高了数字的识别率;Verschae 等人^[9]提出以检验率、误检率和特征数量为 3 个目标,利用改进的 SGA 来优化人脸匹配时的置信度阈值,以在保证一定准确率的前提下减少特征数量,提高检测效率。然而,以上方法对多个目标的优化都停留在完整 ROC 前沿的搜索上,未考虑决策者对检验率与误检率的不同偏好,而且均未考虑到决策者偏好对滑动窗口参数选择的影响,从 ROC 曲线上获取满足决策者需要的置信度阈值也并不直观。

本文针对决策者对物体检测中的检验率与误检率的不同偏好,并结合多目标粒子群算法^[10],提出基于双极偏好的多目标粒子群算法的滑动窗口参数优化方法,利用对检验率与误检率的多种偏好引导参数优化,为决策者提供最优方案。

2 多目标算法重要概念及定义

2.1 多目标优化相关概念

多目标优化问题又称为多标准优化问题。不失一般性,一个具有 n 个决策变量、 m 个目标变量的多目标优化问题^[11]可表述为:

$$\begin{cases} \min y = F(x) = (f_1(x), f_2(x), \dots, f_m(x))^T \\ \text{s. t. } g_i(x) \leq 0, i=1, 2, \dots, p \\ h_j(x) \leq 0, j=1, 2, \dots, q \end{cases} \quad (1)$$

式中, $f_i(x)$ ($k=1, \dots, m$) 为目标函数, $g_i(x)$ ($i=1, \dots, p$) 和 $h_j(x)$ ($j=1, \dots, q$) 分别为目标函数所满足的约束。 $x=(x_1, x_2, \dots, x_n) \in X$, $y=(y_1, y_2, \dots, y_m) \in Y$, 式(1)中, x 表示决策向量, y 表示目标向量, X 表示决策向量 x 形成的决策空间, Y 表示目标向量 y 形成的目标空间。

定义 1(可行解集合)^[12] 对于某个 $x \in X$, 如果满足式(1)中的约束条件 $g_i(x)$ ($i=1, \dots, p$) 和 $h_j(x)$ ($j=1, \dots, q$), 则称 x 为可行解, 由 X 中的所有的可行解组成的集合称为可行解集合, 记为 X_f , 且 $X_f \subseteq X$ 。

定义 2(Pareto 占优)^[12] 假设 $x_A, x_B \in X_f$ 是式(1)所示多目标优化问题的两个可行解, 则称与 x_B 相比, x_A 是 Pareto 占优, 当且仅当 $\forall i=1, 2, \dots, m, f_i(x_A) \leq f_i(x_B) \wedge \exists j=1, 2,$

$\dots, m, f_i(x_A) < f_i(x_B)$, 记作 $x_A > x_B$, 也称为 x_A 支配 x_B 。

定义 3(Pareto 最优解)^[12] 一个解 $x^* \in X_f$ 称为 Pareto 最优解(或非支配解), 当且仅当满足如下条件:

$$\neg \exists x \in X_f: x > x^*$$

2.2 基本粒子群算法

粒子群优化算法(Particle Swarm Optimization, PSO)是由 Kenredy 和 Eberhart 于 1995 年在鸟群、鱼群和人类社会行为规律的启发下提出的一种基于群智能(Swarm Intelligence)的演化计算^[13]。Kennedy 和 Eberhart 最早提出的 PSO 算法用式(2)、式(3)更新粒子状态。

$$v_{id} = v_{id} + c_1 r_1 (p_{id} - x_{id}) + c_2 r_2 (p_{gd} - x_{id}) \quad (2)$$

$$x_{id} = x_{id} + v_{id} \quad (3)$$

式(2)、式(3)中: c_1, c_2 为正常数, 称为学习因子; r_1, r_2 是介于 $[0, 1]$ 间的随机数; $v_{id} \in [-V_{\max}, V_{\max}]$, $V_{\max}$ 是常数, 根据具体问题设定。迭代终止条件一般选为最大迭代次数或者为粒子群迄今为止搜索到的最优位置满足预定最小适应阈值。

2.3 TOPSIS 方法

TOPSIS(Technique for Order Preference by Similarity to an Ideal Solution)方法^[14]是一种逼近理想解的方法, 其主要思想是在可行方案中找到最贴近正理想解的同时又最远离负理想解的方案作为最终的解决方案。该方法首先定义了正理想解 S^+ 和负理想解 S^- , 对于任一备选解集 S_i , 其与正负理想解的距离用欧氏距离定义, 分别记为 d_i^+ 和 d_i^- , 方案 S_i 的相对贴适度可用式(4)计算。

$$C_i = \frac{d_i^-}{d_i^+ + d_i^-} \quad (4)$$

相对贴适度 C_i 越大表示该解离正理想解越近, 同时远离负理想解, 相对贴适度 C_i 值最大的方案即为最终选定的解决方案。如图 1 所示, 解 i 即为最终的最优解。




图 1 TOPSIS 方法示意图

3 基于双极偏好的滑动窗口参数优化方法

3.1 基于双极偏好的多目标粒子群优化算法

1. 程序初始化: 设置初始参数, 获取决策者的正负偏好点, 设置每个子目标的权重 w_i ($i=1, \dots, M$) 和最小贴适度 $C_{\min}$ 。初始化内部种群大小为 A , 外部种群最大容量为 N , 最大循环代数为 $T_{\max}$, 粒子初始速度为 0, 初始位置为个体最佳位置。

2. 全局最优解更新: 利用最小粒子夹角方法^[15]选取全局最优解, 然后, 将其代入式(2)和式(3)来更新粒子速度和位置, 引导粒子飞行, 并以小概率进行变异扰动。

3. 构造非支配解集: 利用 NSGA-II^[16]的非支配解集构造方法构造非支配解集。

4. 外部种群管理: 外部种群是用来保存算法在搜索过程

中产生的一些非支配解,算法需要事先规定外部种群 $Arch$ 的大小 N 。当外部种群的有效解的数量达到最大值时对外部种群进行管理。设第 t 代外部种群 $Arch_t$ 包含 n_t 个有效解,有 $n_t \leq N$ 。当内部搜索进行到第 $t+1$ 代时产生了 m 个有效解,将这 m 个有效解复制到外部种群中,并与外部种群中已有的 n_t 个有效解进行对比。若 2 个个体的目标值相同,删除 2 个个体中的任意一个;若 2 个个体存在支配关系,保存非支配解,删除支配解。经过以上过程形成含有 n_t' 个非支配解个体的 $Arch_t'$ 。

对于 $Arch_t'$,首先需要分别计算其中每个粒子与正偏好点和负偏好点的距离。本文采用加权欧氏距离表示粒子与正负偏好点的距离,其中权重为每个子目标的相对权重 w_i 。然后,根据式(4)分别求出 $Arch_t'$ 中 n_t' 个非支配解的相对贴进度,并按照降序进行排列。若 $n_t' \leq N$,保留所有非支配解,则外部种群的后 $N-n_t'$ 个个体为空;否则,删除后 $n_t'-N$ 个相对贴进度低的非支配解,形成种群 $Arch_{t+1}$ 。

5. 终止条件:若达到最大迭代数,则输出外部种群,选择相对贴进度大于 C_{min} 的 Pareto 最优解作为最终解集,输出结果;若没有满足条件的 Pareto 最优解,则重新调整 C_{min} 或正负偏好点。

BPMOPSO 算法流程图如图 2 所示。




图 2 BPMOPSO 算法流程图

3.2 双极偏好控制策略在滑动窗口检测中的应用

3.2.1 图像检测性能评价方法

引入双极偏好控制策略之前,定义 3 个图像检测评价指标及其计算公式,如下:

误检率: false positive rate

$$\text{False positiverate} = \frac{FP}{FP + TN} \quad (5)$$

检验率: detection rate

$$\text{Detection rate} = \frac{TP}{TP + FN} \quad (6)$$

准确率: precision rate

$$\text{Precision rate} = \frac{TP}{TP + FP} \quad (7)$$

式(5)~式(7)中, TP, FP, FN, TN 分别代表:

TP (True Positive): 本属于正类且被判别为正类的样本个数;

FP (False Positive): 本属于负类且被判别为正类的样本个数;

FN (False Negative): 本属于正类且被判别为负类的样本个数;

TN (True Negative): 本属于负类且被判别为负类的样本个数。

3.2.2 双极偏好控制策略

在采用滑动窗口进行形状匹配时,滑动窗口的大小及步长与置信度阈值是影响匹配效果的几个主要参数。考虑到决策者对高检验率与低误检率的喜好(正偏好)、对低检验率和高误检率的厌恶(负偏好),引入多目标粒子群算法(MOPSO)。该算法将双极偏好融入到多目标粒子群算法中,利用双极偏好控制粒子进化,搜索到贴近于正偏好同时又尽量远离负偏好解的 Pareto 最优解集。

双极偏好控制策略对 ROC 前沿的影响机制如图 3 所示。该算法通过引入相对贴进度 C ,将决策者的正负偏好信息转化成欧氏距离的比值($C = \frac{d^-}{d^+ + d^-}$),进而对相互 Pareto 非支配的方案进行优劣排序,使方案集中在既靠近正偏好点又远离负偏好点的区域内(如 ROC 前沿面上的圆点部分)。




图 3 双极偏好控制策略

算法使用双极偏好引导粒子群进化,其中双极偏好解的选取是最重要的一个步骤。决策者需要确定正偏好解和负偏好解,决策者在定义偏好解时可不考虑解的可行性。

3.3 基于双极偏好的滑动窗口参数优化方法

为了提高物体检测的效率,提出基于双极偏好多目标粒子群算法(BPMOPSO)的滑动窗口匹配方法。为便于实现,利用 $TP_r(\text{Sensibility}) + FN_r = 1$ 将最大化检验率,即敏感性(Sensibility)转化为最小化漏检率(FN_r),建立最小化模型:

$$\begin{aligned} \min f_{FP_r}(s, t, th, \Delta) &= \frac{m_n^+(s, t, th, \Delta)}{M_n} \\ \min f_{FN_r}(s, t, th, \Delta) &= 1 - \frac{m_p^+(s, t, th, \Delta)}{M_p} \\ \text{s. t. } \begin{cases} LB \leq s, t, th \leq UB \\ g(\Delta) \leq 0 \end{cases} \end{aligned}$$

其中, M_n 和 M_p 分别为测试集中的负样本数和正样本数, m_n^+ 表示测试集中负样本经渐进分配匹配方法判断为正样本的数量, m_p^+ 表示测试集中正样本经渐进分配匹配方法判断为负样本的数量, UB 和 LB 表示窗口大小 s 、滑动步长 t 及阈值 th 的上界和下界, $g(\Delta)$ 表示未知参数 Δ 可能满足的条件。

基于上述两目标优化模型,结合 BPMOPSO 和渐进分配匹配算法,采用交叉验证策略对参数进行自动优化,该优化过程如图 4 所示。

在交叉验证过程中,首先,将 BPMOPSO 各粒子在决策空间上的初始值传递至物体检测过程,作为窗口滑动检测的参数值,如移动步长 t ;通过寻找可能的旋转与缩放方式,渐进分配匹配方法对滑动窗口内是否存在模型对应的物体进行判定;经此验证后,统计检测的正样本数与负样本数;基于该统计,求得两个目标值 f_{FP_r} 和 f_{FN_r} 作为粒子的适应值,返回 BP-

MOPSO;根据所得目标值与双极偏好的相对贴进度调整参数,经粒子群搜索、变异、精英排序过程等使参数得到优化;循环该参数优化过程与匹配验证过程,直到满足停止条件。




图4 基于BPMOPSO的交叉验证过程示意图

经以上交叉验证过程后,可得到一组靠近正偏好又远离负偏好的前沿解 S_{opt} 。依据 $\text{Max}_{(s,t,th) \in S_{opt}} C$ 选取相对贴进度最大的解 (s^*, t^*, th^*) ,其即为最优解,所对应的滑动窗口步长、匹配阈值便是满足决策者双极偏好的最优匹配方案。

4 仿真实验

整个实验平台为 Intel(R) Core(TM) 2Duo T6400CPU @2.00GHz, 2.0GB RAM,所有程序代码均在 Microsoft Visual Studio 2008 版本中运行。实验中所用到的训练、验证及测试图像均来自 Leeds Cows 图像数据集 (<http://www.vision.ee.ethz.ch/bleibe/data/datasets.html>)。

4.1 双极偏好设置

本文以偏好点的形式来表示决策者的偏好信息。在算法初始过程中,决策者首先需要根据实际问题给出正负偏好点,正偏好点表示决策者希望解集靠近的点,负偏好点表示决策者希望解集远离的点。理论上决策者在给定正负偏好点的过程中,无须考虑选取的正负偏好点是否位于可行区域,如果决策者选取的正参考点正好位于 Pareto 前沿上,则算法的搜索结果会返回该解作为最优方案;否则,算法将搜索到离正偏好点最近,同时尽量远离负偏好点的 Pareto 前沿区域上的解集供决策者参考。在处理实际问题时,决策者需要根据实际问题情况,给定可行的正负偏好点。

考虑到本文处理的是一个实际的复杂多目标优化问题,且处理的图像较复杂,在实验过程中,设定种群大小为 10,最大迭代次数为 20,为了得到最佳的检测结果即最低的误检率和最高的检验率,设定正偏好点为 $P_1(0.01, 0.01)$,负偏好点为 $P_2(1, 1)$ 。滑动窗口滑动步长和图像缩放规模的参数优化范围分别为 $[0.2, 1.0]$, $[1.2, 3.0]$,以滑动窗口滑动步长和图像缩放规模为优化参数,以误检率(False positive rate)和检验率(Detection rate)为优化目标函数,用 BPMOPSO 进行优化。

4.2 仿真实验结果与分析

在实验过程中本文使用了与文献[17]相同的训练集、验证集和测试集。实验内容分为 2 部分,第一部分在码表大小为 50 时,分别检测匹配率为 0.50,0.52,0.54 和 0.56 情况下的检验率和误检率;第二部分在码表大小为 24 时,分别检测匹配率为 0.60,0.64,0.68 和 0.72 情况下的检验率和误检

率。文献[17]的实验结果如表 1 所列,本文的实验结果如表 2 所列。从实验结果可以看出,相比于表 1,表 2 的结果得到了优化,误检率显著降低,检验率显著提高,尤其是部分情况下检验率几乎接近于 1。表 1 的实验中,滑动窗口滑动步长和图像缩放规模均通过经验设定。表 2 的实验中引入了基于双极偏好的多目标优化方法,根据决策者的偏好,用交叉验证策略对参数进行自动优化。在文献[17]的基础上,本实验进一步计算了检测的准确率,从表 2 中可以看到,实验在获得如此低的误检率和如此高的检验率的同时,也保证了较高的检验准确率。

表 1 参数优化前的数据


Category	Codebook size	Matching ratio	False positive rate	Detection rate
Cow	50	0.50	0.000474497	0.992481
		0.52	0.000366953	0.944000
		0.54	0.000259414	0.929825
		0.56	0.000181810	0.890909
		0.60	0.000728256	0.976744
	24	0.64	0.000445884	0.947826
		0.68	0.000255947	0.865385
		0.72	0.000130002	0.737374

表 2 参数优化后的数据

Category	Codebook size	Matching ratio	False positive rate	Detection rate	Precision rate
Cow	50	0.50	0.000148120	1.000000	0.576923
		0.52	0.000179258	1.000000	0.434783
		0.54	0.000110153	1.000000	0.555556
		0.56	0.000060305	0.909091	0.714286
		0.60	0.000396177	1.000000	0.326531
	24	0.64	0.000241980	1.000000	0.344828
		0.68	0.000150964	0.900000	0.642857
		0.72	0.000078348	1.000000	0.500000

表 3 优化后得到的最佳参数值

Category	Codebook size	Matching ratio	最佳滑动步长	最佳图像缩放规模
Cow	50	0.50	0.205859	2.243430
		0.52	0.207708	2.393710
		0.54	0.207232	2.378360
		0.56	0.210448	2.292630
		0.60	0.200000	2.107610
	24	0.64	0.210861	2.431820
		0.68	0.200000	2.345490
		0.72	0.212157	1.331690



白色点是框的中心,白色框表示正确结果,黑色框表示错误结果

图5 检测结果图像

通过基于双极偏好的多目标优化方法得到了与表 2 对应的滑动窗口的最佳滑动步长和检测图像的最佳缩放规模,其结果如表 3 所列。图 5 呈现了一些实验图像的检测结果,白色框代表正确的检验结果,黑色框代表错误的检测结果。但是基于图像集的复杂性,目前无法获得精确的 Pareto 前沿,这也是以后需要着重深入研究的方向。

4.3 算法运行时间对比

算法的运行效率是衡量一个算法优劣的重要指标。为比较加入优化算法前后的运行效率,本文统计了 20 次优化前后所耗费的运行时间,并取平均值,如表 4 所列。从表 4 中可以看出优化后算法的运行时间显著优于优化前的。

表 4 优化前后算法运行时间

Category	Codebook size	Matching ratio	Running time (second)
Cow	50	0.50	Before 525.311
			After 435.123
		0.52	Before 543.256
			After 461.324
		0.54	Before 535.457
			After 457.283
		0.56	Before 560.765
			After 456.831
	24	0.60	Before 530.855
			After 424.123
		0.64	Before 548.156
			After 468.678
		0.68	Before 536.789
			After 460.443
		0.72	Before 508.389
			After 438.275

结束语 滑动窗口是形状匹配中常用的检测方法,滑动步长和图像缩放规模是滑动窗口检测过程中的两个重要参数。传统方法是根据经验来选取,均未考虑到决策者偏好对滑动窗口参数选择的影响。本文引入双极偏好概念,结合多目标粒子群算法,对滑动窗口检测过程中的滑动步长和图像缩放规模这两个参数进行了优化,并以检验率和误检率为目标优化函数。实验结果表明,基于双极偏好的多目标粒子群(BPMOPSO)方法优化得到的参数进行滑动窗口检测,在相同的检测环境下,与优化前相比,误检率明显下降,检测率显著提高。本文还进一步对优化前后的算法运行效率进行了比较,实验结果同样表明参数优化后的算法运行效率与优化前相比得到了很明显的提高。今后的研究中将把此优化算法运用于更多且更加复杂的图像中,以期能进一步扩大算法的适用范围,并且尝试用其他多目标算法来获得近似 Pareto 前沿。

参 考 文 献

[1] Shotton J, Blake A, Cipolla R. Multi-scale categorical object recognition using contour fragments[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 30(7): 1270-1281

[2] Viola P, Jones M. Rapid object detection using a boosted cascade

of simple features[C]//Proceeding of IEEE Conference on Computer Vision and Pattern Recognition, Hawaii, USA; IEEE, 2001;511-518

[3] Agarwal S, Awan A, Roth D. Learning to detect objects in images via a sparse, part-based representation[J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2004, 26(11): 1475-1490

[4] Fawcett T. An introduction to ROC analysis[J]. Pattern Recognition Letters, 2006, 27: 861-874

[5] Perez C B, Olague G. Learning invariant region descriptor operators with genetic programming and the f-measure[C]//Proceedings of the Nineteenth International Conference on Pattern Recognition, Florida, USA; IEEE, 2008; 3201-3204

[6] Airola A, Pahikkala T, Waegeman W, et al. An experimental comparison of cross-validation techniques for estimation the area under the ROC curve[J]. Computational Statistics and Data Analysis, 2011, 55(4): 1828-1844

[7] Everson R M, Fieldsend J E. Multi-class ROC analysis from a multi-objective optimisation perspective[J]. Pattern Recognition Letters, 2006, 27: 918-927

[8] Chatelain C, Adam S, Lecourtier Y, et al. A multi-model selection framework for unknown and/or evolutive misclassification cost problems[J]. Pattern Recognition, 2010, 43: 815-823

[9] Verschae R, Solar J R, Koppen M, et al. Improvement of a face detection system by evolutionary multi-objective optimization [C]//Proceedings of the Fifth International Conference on Hybrid Intelligent Systems. Rio de Janeiro, Brazil; IEEE, 2005; 361-366

[10] 王丽萍, 江波, 蔡建湖, 等. 基于双极偏好控制的多目标粒子群优化算法研究[J]. 信息与控制, 2009, 38(6): 711-717

[11] Deb K. Multi-Objective Optimization Using Evolutionary Algorithms[M]. Chichester; John Wiley & Sons, 2001

[12] 公茂果, 李焦成, 杨咚咚, 等. 进化多目标优化算法研究[J]. 软件学报, 2009, 20(2): 271-289

[13] Kennedy J, Eberhart R. Particle swarm optimization [C]//Proceedings of the 1995 IEEE International Conference on Neural Networks Proceedings. Piscataway, NJ, USA; IEEE, 1995: 1942-1948

[14] Hwang C L, Yoon K S. Multiple attribute decision making: methods and applications; A state-of-the-art survey[M]. Berlin, Germany: Springer-Verlag, 1981

[15] Gong Dun-wei, Zhang Yong, Zhang Jian-hua. Multi-objective particle swarm optimization based on minimal particle angle[J]. Lecture Note in Computer Science, 2005, 3644: 571-580

[16] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II [J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197

[17] Zhang Wei-ze, Vézien J M, Tong Ruo-feng, et al. Hough transformed contour line segments for object detection[C]// IADIS International Conferences Computer Graphics, Visualization, Computer Vision and Image Processing. Freiburg, Germany; 2010; 235-242