

# 基于动态权值的多分类器故障诊断系统

黄江涛<sup>1,2,3</sup>, 王明辉<sup>3</sup>, 李武劲<sup>3</sup>, 古 博<sup>3</sup>

(1. 广西师范学院计算机与信息工程学院, 广西南宁 530023; 2. 科学计算与智能信息处理  
广西高校重点实验室, 广西南宁 530023; 3. 四川大学计算机学院, 四川成都 610065)

**摘 要:** 为提高动态系统故障诊断的精确性, 以及减少系统运行环境对故障诊断带来的影响, 本文提出了一种基于动态权值的多分类器故障诊断系统. 该方法使用决策支持度来衡量当前诊断任务中各分类器的实时决策可信度, 并将其联合分类器性能指标动态地为各分类器赋予融合权值, 决策性能好且决策支持度高的分类器决策结果获得较大的融合权值, 同时, 使不可靠决策结果的融合权值趋近于零. 在此基础上, 将多分类器系统优化为实时性能较好的分类器组成的子系统, 减少了不可靠决策的干扰, 进一步提高了融合决策的精确度. 试验表明本文方法具有良好的诊断决策性能, 能获得比单个分类器和常用的一些融合算法更高的分类准确度.

**关键词:** 故障诊断; 多分类器系统; 数据融合; 决策支持度; 动态权值

**中图分类号:** TP391.4      **文献标识码:** A      **文章编号:** 0372-2112 (2012) 04-0734-05

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2012.04.018

## Multiple Classifier Fault Diagnosis System Based on Dynamic Weight

HUANG Jiang-tao<sup>1,2,3</sup>, WANG Ming-hui<sup>3</sup>, LI Wu-jing<sup>3</sup>, GU Bo<sup>3</sup>

(1. College of Computer and Information Engineering, Guangxi Teachers Education University, Nanning, Guangxi 530023, China;

2. Key Lab of Scientific Computing and Intelligent Information Processing in Universities of Guangxi, Nanning, Guangxi 530023, China;

3. College of Computer Science, Sichuan University, Chengdu, Sichuan 610065, China)

**Abstract:** In order to improve the accuracy of fault diagnosis for dynamic system, and reduce the diagnosis influence from operating environment, a new fusion method in multiple classifier system based on dynamic weight is proposed. The new approach dynamic assigns weights to base classifiers according to their classification accuracy and decision support value. Bigger weights are assigned to more reliable decision output, and the weights of unreliable outputs are close to zero. In this sense, a subsystem is used to make final decision instead of system. Experimental results demonstrate that the new fusion method can get good fault diagnosis performance, and it can get higher accuracy than single classifier and some common used fusion methods.

**Key words:** fault diagnosis; multiple classifier system; data fusion; decision support value; dynamic weight

## 1 引言

动态系统在日常生产生活中发挥着重要的作用, 其系统的规模和复杂程度随着现代科学技术水平的日益提高而迅速增加, 故障类型也趋于多样化发展. 如果其中某些微小故障不能够及时检测并排除, 就可能造成整个系统的失效; 同样, 如果故障被错检, 也会对系统的正常运行造成影响.

传统的故障诊断包括两个步骤: 特征值提取和模式分类<sup>[1]</sup>. 通常对于一种故障类型来说, 不同的分类器会有不同的诊断精确度; 即使是同一个分类器, 对不同故障类型的诊断能力也是不同的. 同时, 动态系统故障诊

断容易受到运行环境的影响, 而且影响程度不一, 所以, 在动态系统故障诊断过程中, 单纯地对单个分类器进行研究, 不断提高其分类精确度, 往往得不到令人很满意的结果. 多分类器系统将多个结构不同的分类器联合进行融合决策, 该技术可以获取更多的有效决策信息, 利于提高分类精确度, 也可以获得更高的鲁棒性, 将其应用到动态系统故障诊断领域不失为明智的选择.

多分类器系统已经在模式识别的相关领域获得了成功的应用. 多分类器融合方法主要包括分类器选择和分类器联合两大方法. 分类器选择通过静态或动态选择分类器系统中最优分类器进行最终决策. 分类器联合通过融合多分类器系统的各个基本分类器决策输出信息

进行融合决策,目前主要包括多数投票法<sup>[2]</sup>,加权平均法<sup>[3]</sup>,等级次序规则(包括 Borda 计数法<sup>[4,5]</sup>,平均法,乘积规则,最大规则,最小规则,中值规则<sup>[6]</sup>等),贝叶斯方法<sup>[2,3,7]</sup>,D-S 证据理论<sup>[2,8]</sup>,BKS 方法<sup>[9,10]</sup>,模糊积分<sup>[3,11]</sup>,决策模板<sup>[3,12,13]</sup>等.这些分类器联合方法能提取更多有效的决策支持信息,比分类器选择方法更为常用,但是分类器联合方法在融合有效决策支持信息的同时,也不可避免地融合了不可靠的决策输出.为了进一步减少不可靠决策输出对融合决策的干扰,提高融合决策的精确度,本文提出了一种新的基于动态权值的多分类器融合方法.该方法首先定义了决策支持度,用来衡量当前识别任务中各基本分类器的实时决策可信度.决策支持度由多分类器系统中类内最相似决策输出决定.然后,将其联合各个基本分类器的训练性能指标动态地为各分类器赋予融合权值,保证决策支持度高且决策性能好的决策输出能获得较大的权值,实时不可靠决策输出即决策支持度低的决策输出被赋予的权值趋近于零,在此基础上,多分类器系统可以优化为更精确的多分类器子系统.针对动态系统故障诊断是一个时序过程,在该新融合方法中加入一步状态转移决策支持度,构建故障诊断融合模型.试验表明该方法具有较优的性能,能有效排除漏检误检单分类器的干扰,可以得到比单分类器和常用的一些联合方法更高的识别性能.

## 2 基于动态权值的融合诊断

分类器联合方法一般分为 3 个层次:决策层融合、排序层融合和度量层融合.在决策层融合层次上,各分类器输出为某个确定的类别号;而在排序层融合层次,各分类器输出为给定测试样本属于各类可能性的一个排序列表,该排序列表有可能是全类别的排序列表,也可能是部分类别的排序列表;在度量层融合层次上,各分类器的输出则为样本属于各类置信度的度量值.度量层融合能够拥有比决策层融合和排序层融合更丰富的决策信息量.本文提出的融合方法就是一种新的基于度量层融合层次之上的分类器联合方法.

传统的度量层融合方法较多地使用静态融合方法,即先提出融合模型,然后在训练分类器过程中同步训练模型中的相关参数.这种方法能使模型在统计意义上达到最优,但不能随着输入信息的改变以及分类器输出的异常自动修正相关参数,缺乏灵活性.针对该问题,本文提出的基于动态权值的融合方法能够有效地动态更新融合模型中的相关参数,提高融合模型的抗干扰能力和分类精确度.

### 2.1 基于动态权值的融合模型

给定一个分类空间  $P$ ,该空间包含  $M$  种互斥类别

$P = C_1 \cup \dots \cup C_M$ ,其中,  $C_i$  代表一种类别( $\forall i \in \Lambda = \{1, \Lambda, M\}$ ).假定多分类器系统存在  $K$  个基本分类器(用  $e_k$ ( $\forall k \in \Omega = \{1, \dots, K\}$ )表示),则各个基本分类器有后验概率  $P_{e_k}(C_i|x)$  输出,其中,  $x$  为输入样本.多分类器系统在输入样本  $x$  的情况下,可以获得如下决策输出矩阵:

$$\begin{bmatrix} P_{e_1}(C_1|x) & P_{e_1}(C_2|x) & \dots & P_{e_1}(C_M|x) \\ P_{e_2}(C_1|x) & P_{e_2}(C_2|x) & \dots & P_{e_2}(C_M|x) \\ \vdots & \vdots & \ddots & \vdots \\ P_{e_k}(C_1|x) & P_{e_k}(C_2|x) & \dots & P_{e_k}(C_M|x) \end{bmatrix} \quad (1)$$

多分类器融合决策输出(即联合分类器  $E$  输出)就是通过给每个分类器不同类别识别输出赋予一动态权值,然后融合各个分类器的后验概率获得的.本文方法的具体融合过程是在单类别识别中完成的,如多分类器系统在类别  $C_i$ ( $\forall i \in \Lambda$ )上的识别融合决策输出通过下面公式求得:

$$P_E(C_i|x) = \sum_{k=1}^K \beta_{ki} P_{e_k}(C_i|x) \quad (2)$$

其中,  $\beta_{ki}$  是动态权值,其存在一致性:  $\sum_{k=1}^K \beta_{ki} = 1$  ( $\forall i \in \Lambda$ ).在完成所有类别的决策输出后,通过式(3)对联合分类器  $E$  的融合决策输出进行归一化.


$$\hat{P}_E(C_i|x) = \frac{P_E(C_i|x)}{\sum_{j=1}^M P_E(C_j|x)}, \quad \forall i \in \Lambda \quad (3)$$

归一化后保证了融合决策分布在各类别的置信度(后验概率)之和为 1.最后,通过选择具有最大后验概率的类作为当前输入样本  $x$  所属的类,完成最终决策.也就是说,系统联合分类器  $E$  的决策结果输出为:

$$E(x) = i \text{ with } \hat{P}_E(C_i|x) = \max_{j \in \Lambda} \hat{P}_E(C_j|x) \quad (4)$$

本文方法使用的动态权值不同于传统方法的静态赋予权重,其权值的分配没有在多分类器系统训练过程中进行有效训练.但训练过程中获取的先验知识,如分类器的分类性能指标,对多分类器系统中权重的分配具有较好的指导意义.因此,各分类器的分类准确度  $\mu_k$ ( $\forall k \in \Omega$ )和单类别识别准确度  $\mu_k$ ( $\forall k \in \Omega, i \in \Lambda$ )分别被作为动态权值分配的考虑因素之一,这两个准确度指标均采用识别率,如分类器的分类准确度通过式(5)获得,其中,  $N_{ij}(e_k)$  表示分类器  $e_k$  将属于类别  $C_i$  的输入样本识别为类别  $C_j$  的个数.这些准确度信息是基于训练数据的一个统计量,无法完全体现分类器对不同输入样本的实时识别性能.而且,当分类器对输入样本的某些特征数据敏感时,容易导致输出空间中某些类别识别输出发生较大变动,所以,在动态权值分配中除了考虑准确度信息,分类器在各类别识别中的实

时性能指标也十分重要。为了标识多分类器系统中各个分类器各个类别后验概率输出的相对决策可靠度,定义了决策支持度。决策支持度为类内决策支持指标,由决策输出与多分类器系统中同一类别最近邻决策输出之差决定。首先,通过式(6)计算各个决策输出与其最近邻决策输出之差的绝对值。容易发现,该值越小,对应的决策输出在多分类器系统同类识别中具有越大的实时可靠度。且易知,决策输出最近邻差值的绝对值取值范围为 $[0, 1]$ 。然后,寻找一个函数将这些最近邻差绝对值映射到另一坐标,在该新坐标上,最近邻差绝对值越小,则映射值越大,反之,最近邻差绝对值越大,则映射值越小。同时,为了减小不可靠决策输出对融合决策的干扰,映射值随着最近邻差绝对值的增大需急速下降,并且最近邻差绝对值大于某个值时,映射值趋近于零。由图1所示的指数分布函数 $\exp(-x/\lambda)$ 可知,当 $\lambda$ 取值为0.1时,该函数满足映射函数的要求,因此,函数 $\exp(-x/0.1)$ 被用来作为映射函数,映射值被定义为决策支持度。决策支持度 $\omega_{ki} (\forall k \in \Omega, i \in \Delta)$ 的计算公式如式(7)所示。



$$\mu_k = \frac{\sum_{i=1}^M N_{ii}(e_k)}{\sum_{i=1}^M \sum_{j=1}^M N_{ij}(e_k)} \quad (5)$$

$$\tau_{ki} = \min_{k', k' \neq k} |P_{e_k}(C_i | x) - P_{e_{k'}}(C_i | x)| \quad \forall k, k' \in \Omega, i \in \Delta \quad (6)$$

$$\omega_{ki} = \exp\left(-\frac{\tau_{ki}}{0.1}\right) \quad (7)$$

决策支持度作为决策输出的实时性能指标与统计性能指标(分类准确度)一起被用来决定各决策输出在多分类器系统融合决策中的权值,具体通过下式进行计算:

$$\beta_{ki} = \frac{(\alpha\mu_k + (1-\alpha)\mu_{ki})\omega_{ki}}{\sum_{k'=1}^K (\alpha\mu_{k'} + (1-\alpha)\mu_{k'i})\omega_{k'i}} \quad \forall k \in \Omega, i \in \Delta \quad (8)$$

其中, $\alpha$ 为控制参数,用来控制基本分类器分类准确度和单类别识别准确度在融合决策中的权重。将式(8)代入式(2)即可获取融合决策输出。

## 2.2 动态系统故障诊断融合模型

上一小节已经介绍了基于动态权值的多分类器系统融合模型,本小节将继续扩展该模型,以便其能够更有效地应用于动态系统故障诊断中。动态系统故障诊

断是一个在线的、连续的过程,当故障隐患发生时,无论是渐进地还是突发地,相关状态特征信息均会发生不同程度的变化,这一变化也会体现在各分类器的决策输出中。为了提高多分类器系统对故障隐患发生的敏感性,一步状态转移决策支持度被引入到基于动态权值的融合模型中。同时,动态系统在不同运行环境中会受到不同程度的噪声干扰,这些干扰直接影响着状态分析过程中提取的特征值,导致分类器无法达到训练时获取的分类性能。因此,作为动态权值分配考虑因素之一的分类器统计性能指标(分类准确度)需要在实际应用中得到不断更新。性能更新因子被用来实时更新分类器整体性能和各类别识别性能。

一步状态转移决策支持度与决策支持度一样,通过一步状态转移在多分类器系统中相同状态下其它一步状态转移的最近邻值决定。首先计算各决策输出的一步状态转移值,如式(9)所示,其中, $t$ 代表动态系统故障诊断时序值,且 $k \in \Omega, i \in \Delta$ 。

$$\theta_{ki}^t = P_{e_k}^t(C_i | x) - P_{e_k}^{t-1}(C_i | x) \quad (9)$$

当 $t=1$ 时, $\theta_{ki}^t = P_{e_k}^t(C_i | x)$ 。然后,通过式(10)和式(11)计算一步状态转移决策支持度。

$$\zeta_{ki}^t = \min_{k', k' \neq k} |\theta_{ki}^t - \theta_{k'i}^t|, \quad \forall k, k' \in \Omega, i \in \Delta \quad (10)$$

$$\tilde{\omega}_{ki}^t = \exp\left(-\frac{\zeta_{ki}^t}{0.1}\right) \quad (11)$$

性能更新因子则由各分类器决策输出与融合输出的方差在多分类器系统中同类方差总和的比率决定。然后,性能更新因子以一定的更新率更新分类器整体准确度和单类别识别准确度信息。性能更新因子存在奖励和惩罚两种性质。当某个决策输出更接近于融合输出时,说明该决策输出对融合输出贡献较大,也反映出该决策输出所在分类器以及所在分类器在当前类别识别性能上均具有较好的性能,此时,性能更新因子表现为奖励性质,其值域在正数空间;反之,性能更新因子表现为惩罚性质,其值域在负数空间。分别计算分类器准确度性能更新因子 $\nu_k (k \in \Omega)$ 和单类别识别准确度性能更新因子 $\nu_{ki} (k \in \Omega, i \in \Delta)$ 如式(12)和式(13)所示,然后通过式(14)和式(15)更新分类器相关准确度指标。在式(14)和(15)中, $\eta > 0$ 为更新率,一般地 $0.01 \leq \eta \leq 0.1$ ,本文取 $\eta = 0.01$ 。

$$\nu_k^t = \frac{1}{K} - \frac{\sum_{i=1}^M (P_{e_k}^t(C_i | x) - \hat{P}_E^t(C_i | x))^2}{\sum_{k'=1}^K \sum_{i=1}^M (P_{e_{k'}}^t(C_i | x) - \hat{P}_E^t(C_i | x))^2} \quad (12)$$

$$\nu_{ki}^t = \frac{1}{K} - \frac{(P_{e_k}^t(C_i | x) - \hat{P}_E^t(C_i | x))^2}{\sum_{k'=1}^K (P_{e_{k'}}^t(C_i | x) - \hat{P}_E^t(C_i | x))^2} \quad \forall k \in \Omega, i \in \Delta \quad (13)$$

$$\mu_k^{t+1} = \mu_k^t + \eta \mu_k^t, \quad \forall k \in \Omega \quad (14)$$

$$\mu_{ki}^{t+1} = \mu_{ki}^t + \eta \mu_{ki}^t, \quad \forall k \in \Omega, i \in \Lambda \quad (15)$$

准确度  $\mu$  具有上下确界:  $\sup(\mu) = 1, \inf(\mu) = 0$ . 由定义可知,  $\mu^1$  为分类器在训练阶段时获得的分类准确度. 此时, 可以将 2.1 小节提出的基于动态权值的融合模型扩展为动态系统故障诊断融合模型, 如式(16)所示.

$$P_k^t(C_i | x) = \frac{\sum_{k=1}^K (\alpha \mu_k^t + (1 - \alpha) \mu_{ki}^t) \omega_k^t \tilde{\omega}_{ki}^t}{\sum_{k=1}^K (\alpha \mu_k^t + (1 - \alpha) \mu_{ki}^t) \omega_k^t \tilde{\omega}_{ki}^t} \cdot P_k^t(C_i | x), \quad \forall i \in \Lambda \quad (16)$$

### 3 试验及其分析

本文试验采用 UCI 数据库<sup>[14]</sup>中的数据集 Robot Execution Failures Data Set 下的 4 个子数据集: LP1-LP4, 每个子数据集分别定义了不同的故障诊断学习问题. 以 LP1 子数据集为例, 其定义了机器人达到抓住位置过程中的故障问题, 包括了碰撞冲突, 前面碰撞, 障碍以及正常状态. 在多分类器系统中, 使用了  $k$ -NN,  $k$ -Means, parzen 三种不同的分类器. 其中,  $k$ -NN 和  $k$ -Means 这两种分类器又通过设置不同的  $k$  值分别获取两个分类器作为多分类器系统的基本分类器. 因此, 本文试验采用的多分类器系统由 5 个基本分类器组成, 它们分别是: 3-NN 分类器, 5-NN 分类器, 11-Means 分类器, 17-Means 分类器和 parzen 分类器.

四种不同的数据集 (LP1-LP4) 分别被随机抽取 1/2 的样本数据作为训练数据, 而全部数据被作为测试数据. 在训练过程中, 我们发现本文融合方法中的控制参数与融合性能的关系在不同数据集的表现是不一致的, 如图 2 所示. 这种情况主要是因为多分类器系统中不同分类器对不同数据集在整体识别性能和单个类别识别性能上存在着较大的差异. 根据图 2 的情况, 本文




图2 控制参数在不同数据集上与融合性能的关系

试验中, 在不同数据集上的取值分别为:  $\alpha = 1$  (LP1),  $\alpha = 1$  (LP2),  $\alpha = 0.26$  (LP3),  $\alpha = 0.75$  (LP4). 表 1 给出了多分类器系统各个基本分类器和本文融合方法在四个不同数据集上的测试结果, 该结果为 100 次试验的平均值. 从表 1 中给出的试验结果可以看到, 本文融合方法在 LP1, LP3 和 LP4 上均具有最优的决策性能, 在 LP2 上, 比  $k$ -Means 分类器 ( $k = 17$ ) 小一个多百分点, 而比其它四个基本分类器在性能上均有较大的提高. 从表 1 也可以清晰地看到, 在 LP2 和 LP3 数据集上, 多分类器融合受到更大的不可靠决策干扰, 因为两个  $k$ -NN 分类器在这两个数据集上的分类准确度均较低. 因此, 融合决策性能也会受到一定的影响. 为了进一步分析本文融合方法的决策性能, 以及抗干扰能力, 投票法和最大值规则法被用来与本文融合方法进行比较, 如表 2 所示.

表 1 基本分类器与本文融合方法的性能比较

分类器	准确率 (%)			
	LP1	LP2	LP3	LP4
$k$ -NN 分类器 ( $k = 3$ )	82.49	56.13	55.62	81.58
$k$ -NN 分类器 ( $k = 5$ )	71.17	46.04	46.04	77.99
$k$ -Means 分类器 ( $k = 11$ )	73.32	69.02	68.98	75.98
$k$ -Means 分类器 ( $k = 17$ )	84.23	74.47	73.21	81.74
parzen 分类器	68.81	69.21	69.34	80.34
本文融合方法	86.47	73.06	73.81	89.60

表 2 不同融合方法的性能比较

融合方法	准确率 (%)			
	LP4	LP1	LP2	LP3
投票法	82.56	60.98	60.81	87.18
最大值规则法	85.97	67.11	65.34	89.23
本文融合方法	86.47	73.06	73.81	89.60

从表 2 可以看出, 最大值规则法和本文融合方法在四个数据集上均要优于投票法. 最大值规则法和本文融合方法在 LP1 和 LP4 数据集上性能较为接近, 而在 LP2 和 LP3 数据集上相差较大. 这是因为多分类器系统在 LP2 和 LP3 数据集上存在的不可靠决策干扰较大, 这对很多常见的融合方法均会构成影响, 不同程度地降低融合决策性能. 本文方法能够更有效地抵抗不可靠决策的干扰, 在融合决策性能上仍然能够保持高于或者接近于多分类器系统中最优分类器的性能. 因此, 本文提出的融合方法在融合决策上拥有比一些常用融合方法更强的抵抗不可靠决策干扰能力, 鲁棒性更强,




图3 不同融合方法的融合决策准确度比较

图 3 给出了更为直观的比较情况。

## 4 结论

本文首先提出了一种基于动态权值的多分类器融合模型,然后在此基础上,提出了动态系统故障诊断融合模型。本文方法通过决策支持度来衡量决策输出的实时决策可信度,并将其联合统计性能指标进行基本分类器动态权值分配,能有效提高可靠度高的决策输出对融合决策的支持,降低不可靠决策对融合决策的干扰。该方法结构简单,易于实现,通过实际数据试验,表明本文提出的融合方法具有较强的抵抗不可靠决策干扰的能力,能够获取较好的决策性能,在识别准确度上比单个分类器和一些常用融合方法有更高的性能指标。

## 参考文献

- [1] W Wang, D Kanneg. An integrated classifier for gear system monitoring[J]. *Mechanical Systems and Signal Processing*, 2009, 23(4): 1298 - 1312.
- [2] L Xu, A Krzyzak, C Y Suen. Methods of combining multiple classifiers and their applications to handwriting recognition[J]. *IEEE Transactions on Systems, Man and Cybernetics*, 1992, 22(3): 418 - 435.
- [3] L I Kuncheva. *Combining Pattern Classifiers: Methods and Algorithms*[M]. New Jersey, USA: Wiley-Interscience publication, 2004.
- [4] T K Ho, J Hull, S N Srihari. Decision combination in multiple classifier systems[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1994, 16(1): 66 - 75.
- [5] E Kim, W Kim, Y Lee. Combination of multiple classifiers for the customer's purchase behavior prediction[J]. *Decision Support Systems*, 2002, 34(2): 167 - 175.
- [6] J Kittler, M Hatef, R P W Duin, J Matas. On combining classifiers[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1998, 20(3): 226 - 239.
- [7] H Altincay. On naive Bayesian fusion of dependent classifiers[J]. *Pattern Recognition Letters*, 2005, 26(15): 2463 - 2473.
- [8] 李剑峰, 乐光新, 尚勇. 基于改进型 D-S 证据理论的决策层融合滤波方法[J]. *电子学报*, 2004, 32(7): 1160 - 1164.  
Li Jian-feng, Yue Guang-xin, Shang Yong. Decision-level fusion filtering algorithm based on advanced D-S theory of evidence[J]. *Acta Electronica Sinica*, 2004, 32(7): 1160 - 1164. (in Chinese)
- [9] Y S Huang, C Y Suen. A method of combining multiple experts for the recognition of unconstrained handwritten numerals[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1995, 17(1): 90 - 94.
- [10] C A Shipp, L I Kuncheva. Relationships between combination methods and measures of diversity in combining classifiers[J]. *Information Fusion*, 2002, 3(2): 135 - 148.
- [11] A R Mirhosseini, H Yan, K-M Lam, T. Pham. Human face image recognition: an evidence aggregation approach[J]. *Computer Vision and Image Understanding*, 1998, 71(2): 213 - 230.
- [12] L I Kuncheva. Using measures of similarity and inclusion for multiple classifier fusion by decision templates[J]. *Fuzzy Sets and Systems*, 2001, 122(3): 401 - 407.
- [13] 米爱中, 郝红卫, 郑雪峰, 涂序彦. 一种自调整权值的多分类器融合方法[J]. *电子学报*, 2009, 37(11): 2604 - 2609.  
Mi Ai-zhong, Hao Hong-wei, Zheng Xue-feng, Tu Xu-yan. A method of multiple classifier fusion with self-adjusting weights[J]. *Acta Electronica Sinica*, 2009, 37(11): 2604 - 2609. (in Chinese)
- [14] A Asuncion, D J Newman. UCI Machine Learning Repository [OL]. <http://www.ics.uci.edu/~mlearn/MLRepository.html>, Irvine, CA: University of California, School of Information and Computer Science, 2009.

## 作者简介



**黄江涛** 男, 1979 年 12 月出生于广西玉林, 2011 年毕业于四川大学图象图形研究所, 博士, 现为广西师范学院计算机与信息工程学院、科学计算与智能信息处理广西高校重点实验室副研究员, 主要研究方向为模式识别与人工智能, 数据融合, 图像处理等。  
E-mail: jiangtao\_huang@163.com



**王明辉** 男, 1971 年 6 月出生, 现为四川大学计算机学院教授、博士生导师, 发表学术论文近百篇, 主要研究方向为多源信息融合、图形图像处理、现代智能交通系统和多目标跟踪等。

**李武劲** 男, 1985 年 9 月出生于湖南省平江县, 现为四川大学计算机学院博士研究生, 主要研究方向为图像处理。

**古博** 男, 1983 年 6 月出生于四川省大竹县, 现为四川大学计算机学院博士研究生, 主要研究方向为图像处理、图像融合。