

一种双目标排序层分类器融合方法

刘明¹ 袁保宗¹ 苗振江¹

摘要 最近 Melnik 提出了一种新的排序层分类器融合思想, 指出在分类器融合过程中既要调节对不同分类器的侧重程度, 又要利用不同序号值提供的置信度信息. 但是在 Melnik 提出的融合方法中, 参数数量随着分类器数量的增加呈指数级增长, 在分类器数目增加时会产生维数灾难问题. 在 Melnik 的思想启发下, 本文提出了一种新的融合方法, 该方法将对序号的变换与分类器的加权组合协调起来, 能够更好地实现 Melnik 提出的目标. 另外, 本文给出了一种用连续可微函数表示的分类错误率表达式, 设计了基于梯度下降的参数调节方法. 在实验中本文设计了融合掌纹图像数据和手指图像数据的多模态身份识别系统, 观察了不同数目分类器条件下的融合效果. 实验结果表明本文方法的分类正确率高于传统方法和 Melnik 的方法.

关键词 分类器融合, 生物特征识别, 掌纹识别, 手指图像识别
中图分类号 TP391.4

A Double-objective Rank Level Classifier Fusion Method

LIU Ming¹ YUAN Bao-Zong¹ MIAO Zhen-Jiang¹

Abstract Recently, Melnik proposed a new rank level classifier fusion idea, which managed to keep a balance between the preference for the specific classifier and the confidence it had in any specific rank. However, Melnik's classifier fusion method suffers from "the curse of dimensionality". The number of parameters increases exponentially with the increase of the number of classifiers. Inspired by Melnik's idea, we propose a new fusion method, which achieves Melnik's objectives through combination of the rank transforming and the weighted classifier integration. Furthermore, a continuously differentiable classification error expression is given. Based on that, a gradient descent parameter tuning algorithm is designed. We develop a multi-modal identity recognition system by fusion of palmprint and finger image data. Many experiments have been conducted to test the performance of our method under the condition of different classifier numbers. The experimental results show that the performance of our method is better than those of traditional methods and Melnik's method.

Key words Classifier fusion, biometrics, palmprint recognition, finger image recognition

1 引言

在模式识别领域, 分类器融合已经成为一个研究热点. 到目前为止, 人们已经提出了很多分类器融合方法, 这些方法可以分成 3 类: 抽象层融合, 排序层融合和度量层融合^[1]. 本文研究内容属于排序层融合.

排序层融合方法又可以分成两类: 类集合缩小法和序号重排法^[2]. 类集合缩小法将样本可能属于的模式类组成一个集合, 然后根据各个分类器的输出不断缩小该集合, 直到找出一个可能性最大的类别. 序号重排法根据各个基本分类器的输出重新

对各模式类进行排序, 包含被分类样本可能性最大的模式类被排在前边. 在这两类方法中, 序号重排法受到较多关注. 早期的序号重排法有 BC (Baoda count) 方法、HR (Highest rank) 方法、逻辑回归方法. BC 方法和 HR 方法比较简单, 不需要训练; 逻辑回归方法具有学习能力, 能够通过训练集上的学习, 调整融合规则中的参数.

Saranli^[3] 基于统计理论对排序层融合进行了理论分析, 并提出了一种融合框架. 但是该方法需要估计序号的每一种可能的组合出现的概率, 这在类别数比较多, 训练样本数比较少的环境下会发生“维数灾难”问题. 为此, Saranli 提出了通过划分特征空间减少统计量的解决方案. 然而, 面对一个实际问题, 如何找到一种很好的划分方法是一个尚未解决的难题.

最近, Melnik^[4] 对排序层融合问题给出了一种新的理论性分析. 该文研究了排序层融合中两个关键性问题: 其一是要调节对不同分类器的侧重程度; 其二是要利用不同序号值包含的置信度信息. 调节对不同分类器的侧重程度, 即确定分类器的合理组合方式, 使不同分类器对融合结果的影响不同. 利用

收稿日期 2006-10-25 收修改稿日期 2007-4-24
Received October 25, 2006; in revised form April 24, 2007
国家重点基础研究发展计划 (973 计划) (2006CB303105, 2004CB318110), 国家自然科学基金 (60441002), 大学重大项目基金 (2003SZ002) 资助

Supported by National Basic Research Program of China (973 Program) (2006CB303105, 2004CB318110), National Natural Science Foundation of China (60441002), and University Key Research Project (2003SZ002)

1. 北京交通大学信息科学研究所 北京 100044
1. Institute of Information Science, Beijing Jiaotong University, Beijing 100044
DOI: 10.1360/aas-007-1276

不同序号值包含的置信度信息, 是指增强小序号值对融合结果的影响. 小的序号值代表比较高的置信度, 而大的序号值代表比较低的置信度. 当序号值比较小时, 序号的变化对置信度的变化影响比较大; 而当序号值比较大时, 序号的变化对置信度变化的影响比较小. 为了表达方便, 本文将确定分类器的合理组合方式与充分利用不同序号提供的置信度信息看成是排序层融合的两个目标, 而将能够实现这两个目标的排序层融合方法称为双目标排序层融合方法. 文献 [4] 还给出了一种具体的排序层融合方法—MGR (Mixed group ranks) 方法. MGR 方法是一种双目标排序层融合方法, 但是它只适用于被融合的分类器数目非常少的情况, 否则需要确定的参数数量呈指数级增长.

本文在 Melnik 提出的融合框架下提出了一种新的双目标排序层融合方法. 在该方法中首先根据序号值与置信度的关系对序号进行变换, 增强小序号值的影响, 然后再进行融合, 并且同时对变换参数与融合参数进行优化. 在度量层融合方法的研究领域中, 一些文献采用了变换置信度方法提高融合系统的性能^[5~8], 尤其是文献 [5] 中提出了将变换参数与融合参数同时优化的方法, 这与本文方法比较相似. 但是本文研究的问题有很大的特殊性, 上述文献是对置信度进行变换, 目的是为了解决不同分类器输出的置信度不匹配的问题. 本文是对序号进行变换, 目的是为了增强小序号值对融合结果的影响. 与 MGR 方法相比, 本文方法包含的参数较少, 而且配备了一种有效的方法确定其参数, 分类正确率高.

本文方法在多模态身份识别问题上进行了测试, 设计了融合掌纹图像数据和手指图像数据的多模态身份识别系统, 并且将本文方法与逻辑回归方法和 MGR 方法进行了比较, 实验结果表明本文方法的正确识别率高于其他方法.

2 双目标排序层分类器融合

2.1 相关工作

考虑一个模式识别问题, 假设有 L 个模式类: $\{\omega_1, \omega_2, \dots, \omega_L\}$, M 个基本分类器 (被融合的分类器): $\{C_1, C_2, \dots, C_M\}$. 对于任意一个输入样本 x , 令 $r_l^m(x)$ 表示基本分类器 C_m 输出的模式类 ω_l 对应的序号. 全部 $r_l^m(x)$ 组成一个矩阵 $R(x)$, $R(x)$ 的每一列对应于一个模式类, 每一行对应于一个基本分类器. 分类器融合问题就是要根据矩阵 $R(x)$ 计算样本 x 属于每一个模式类 ω_l 的总置信度 $S_l(x)$, 即确定一组置信度函数

$$S_l(x) = f_l(R(x)), \quad l = 1, 2, \dots, L \quad (1)$$

早期的排序层融合方法研究的目标大都是如何

有效地组合各个基本分类器, 以提高分类正确率, 其中代表性的方法是逻辑回归方法^[2]. 逻辑回归方法的融合规则是线性的, 表达式为

$$S_l(x) = - \sum_{m=1}^M w_m r_l^m(x) \quad (2)$$

其中 w_m ($m = 1, 2, \dots, M$) 是需要确定的权值.

尽管逻辑回归方法能够较好地解决参数问题, 直接将线性融合规则用于排序层融合还存在一个比较大的弊端, 即不论序号值大小, 序号值的变化对融合结果的影响是相同的. 而实际上, 当序号值比较小时, 序号的变化对置信度的变化影响比较大; 而当序号值比较大时, 序号的变化对置信度的变化的影响比较小. 针对这一现象, Melnik 提出了排序层融合方法研究的另外一个目标, 即要增强小序号值对融合结果的影响. 为了在融合过程中能够达到这个目标, Melnik 给出了一个排序层融合框架, 并且在该框架下提出了 MGR 方法.

Melnik 的融合框架是通过定义一组置信度函数性质给出的, 这些性质是:

1) 对应于某一模式类的置信度函数仅与对应于该类的序号有关, 即对于任意模式类 ω_l 有

$$S_l(x) = f_l(r_l^1(x), r_l^2(x), \dots, r_l^M(x)) \quad (3)$$

2) 单调性. 置信度函数 $S_l(x)$ ($l = 1, 2, \dots, L$) 应该随着任意一个序号的增加而下降, 即对于任意模式类 ω_l 和两组序号 $\mathbf{u} = (u_1, u_2, \dots, u_M)$, $\mathbf{v} = (v_1, v_2, \dots, v_M)$ 有

$$u_m \geq v_m, \quad m = 1, 2, \dots, M \Rightarrow f_l(\mathbf{u}) \leq f_l(\mathbf{v}) \quad (4)$$

3) 对于任意实数 $0 \leq \lambda \leq 1$, 置信度函数 $S_l(x)$ ($l = 1, 2, \dots, L$) 应该满足

$$f_l(\mathbf{u}) \geq f_l(\mathbf{v}) \Leftrightarrow f_l(\mathbf{u}) \geq f_l(\lambda \mathbf{u} + (1 - \lambda) \mathbf{v}) \quad (5)$$

性质 1) 有效地减少了置信度函数的维数; 性质 2) 保证对于任何一个基本分类器, 比较小的序号提供的置信度总是大于比较大的序号提供的置信度; 性质 3) 能够增强小序号值对融合结果的影响.

Melnik 的融合框架提出了排序层融合的一个新目标, 即要增强小序号值的影响, 所以本文将满足这一融合框架的方法称为双目标排序层融合方法. 基于该融合框架, Melnik 给出了 MGR 方法. 这种方法的融合规则可以表示为

$$f_l(r_l^1(x), \dots, r_l^M(x)) = - \sum_{A \subseteq \{1, 2, \dots, M\}} w_A \min\{r_l^m(x) : m \in A\} \quad (6)$$

这里集合 A 为集合 $\{1, 2, \dots, M\}$ 的任意子集, 它的数量为 $2^M - 1$ 个; $w_A \geq 0$ 为权值, 可以在训练集上用逻辑回归方法得到. 这种融合规则虽然也是线性的, 但是与传统的线性融合规则有很大差别. 它的每一项对应于基本分类器集合的一个子集, 当该子集中包含多个分类器时, 从中选取一个参与融合, 但是选取哪个分类器与分类器的输出值有关, 这样它利用了分类器的输出值的特点. 另一方面, 每个基本分类器都是基本分类器集合的一个子集, 被分配给一个权值, 从而又利用了不同分类器的特点.

文献 [4] 证明, MGR 方法满足 Melnik 给出的 3 个性质, 从而能够增强小信号值的影响, 能够较好地利用不同序号提供的置信度信息. 在这个意义上, MGR 方法为排序层融合理论研究带来了新思路. 但是当基本分类器的数目增多时, 它的参数数量呈指数级增长, 这样就会产生“维数灾难”问题.

2.2 本文方法

双目标排序层融合方法与经典的排序层融合方法的本质区别是在排序层融合过程中要增强小序号值的影响. 基于这种思想, 本文提出首先根据序号值包含置信度信息的变化规律对每个分类器输出的序号值进行变换, 增强小序号值的影响, 然后再进行融合. 本文的融合规则可以表示为

$$f_i(r_i^1(x), r_i^2(x), \dots, r_i^M(x)) = \sum_{m=1}^M w_m g_m(r_i^m(x)) \quad (7)$$

其中 $w_m \geq 0$, $g_m(\cdot)$ 为单调下降凸函数, 用以对序号值进行变换.

容易证明新的融合规则满足 Melnik 给出的 3 个性质. 首先, 对应于某一模式类的置信度函数仅与对应于该类的序号有关, 它满足性质 1); 其次, 式 (7) 的每一项都是单调下降函数, 总的置信度随着任意序号的增加而下降, 所以它满足性质 2); 最后, 令 $\lambda = 0$, 则 $f_i(\lambda \mathbf{u} + (1 - \lambda)\mathbf{v}) = f_i(\mathbf{v})$, 从而

$$f_i(\mathbf{u}) \geq f_i(\lambda \mathbf{u} + (1 - \lambda)\mathbf{v}) \Rightarrow f_i(\mathbf{u}) \geq f_i(\mathbf{v})$$

所以证明式 (5) 成立仅需证明其左边能导出右边. 为此给置信度函数 $f_i(\mathbf{u})$ 的每个取值都定义一个水平集 $\Gamma_{\mathbf{u}} = \{\mathbf{u} : f_i(\mathbf{u}) \leq s\}$, 并且将每个序号的定义域拓广为正实数 (凸集). 由于每个 $g_m(\cdot)$ 都是凸函数, 凸函数的正加权和还是凸函数, 所以式 (7) 定义的置信度函数是凸函数. 又由于在凸集上定义的凸函数的水平集是凸集, 所以每个水平集 $\Gamma_{\mathbf{u}}$ 都是凸集. 所以对于任意两组序号 $\mathbf{u} = (u_1, u_2, \dots, u_M)$, $\mathbf{v} = (v_1, v_2, \dots, v_M)$, 若 $f_i(\mathbf{u}) \geq f_i(\mathbf{v})$, 则有

$$f_i(\mathbf{u}) \geq \lambda f_i(\mathbf{u}) + (1 - \lambda)f_i(\mathbf{v}) \geq f_i(\lambda \mathbf{u} + (1 - \lambda)\mathbf{v})$$

既然当序号为正实数时, 式 (5) 成立, 那么当序号为正整数时, 式 (5) 仍然成立, 所以式 (7) 定义的融合规则也满足性质 3). 这样, 本文提出的融合方法符合 Melnik 提出的融合框架.

根据文献 [4], 序号值包含置信度信息的变化规律为: 当序号值比较小时, 序号的变化对置信度的变化影响比较大; 而当序号值比较大时, 序号的变化对置信度的变化的影响比较小. 所以式 (7) 中的函数 $g_m(\cdot)$ ($m = 1, 2, \dots, M$) 不仅单调下降, 而且随着自变量的增大, 下降速度越来越慢. 在常用的连续可微函数中, 指数为负值的幂函数和底小于 1 的指数函数都比较符合这一特点, 本文通过实验发现幂函数略好于指数函数, 所以本文推荐将函数 $g_m(\cdot)$ 规定为指数为负值的幂函数, 其形式为

$$g_m(t) = t^{-b_m} \quad (8)$$

其中 $b_m \geq 0$ 是待确定的参数. 将式 (8) 代入式 (7), 得到本文采用的具体融合规则为

$$f_i(r_i^1(x), r_i^2(x), \dots, r_i^M(x)) = \sum_{m=1}^M w_m (r_i^m(x))^{-b_m} \quad (9)$$

本文提出的新融合规则仅包含两组参数: 一组参数 w_m ($m = 1, 2, \dots, M$), 用来调节不同分类器对最终分类的影响; 另外一组参数 b_m ($m = 1, 2, \dots, M$), 用来增强小序号值的影响.

与 MGR 方法相比, 本文方法具有以下 3 个优点:

- 1) 参数数量少 (当被融合的分类器数量大于 2 时);
- 2) 参数有实际意义;
- 3) 函数表达式具有很好的解析性.

这些优点有利于我们确定合适的参数, 更好地实现 Melnik 提出的融合思想, 有效地解决分类器融合问题.

3 参数求解

为了确定融合规则中的参数, 本文采用了一种有监督的机器学习方法 — 梯度下降算法. 为此需要首先定义一个连续可微的目标函数. 在分类问题中, 常用的目标函数有最小均方误差 (Minimum squared error, MSE) 目标函数和最小分类误差 (Minimum classification error, MCE) 目标函数. MSE 目标函数形式上比较简单, 其缺点是不能使分类误差最小化. 文献 [9] 对 MCE 目标函数及参数优

化进行了深入研究. 根据其研究成果, 定义 MCE 目标函数需要 3 个步骤: 首先, 给出一个分类错误率的测度, 这个测度在分类正确和错误时取值符号相反; 然后将该测度用连续可微的函数近似表示出来; 最后用一个阶跃函数对它进行变换. 经过这 3 个步骤后得到的目标函数形式上是比较复杂的.

Paredes 等^[10] 在研究最近邻分类器时提出了一种比较简单的定义 MCE 目标函数的方法. 在该方法中, 针对每一个训练样本, 在其同类样本和异类样本中各选择一个与其距离最近的样本, 然后根据这两个被选择的样本定义一个形式上连续可微的分类错误测度函数. 由于样本选择受到参数的影响, 所以得到的分类错误测度函数是不可微的. 为此, Paredes 假定当参数在很小的范围内变化时, 参数的变换对样本的选择没有影响, 从而近似认为根据这两个被选择的样本定义的分类错误测度函数是连续可微的. 这样就不需要文献 [9] 中确定 MCE 目标函数的第 2 个步骤, 而且得到的目标函数比较简单. 本文借鉴了 Paredes 的思想, 下面给出本文确定 MCE 目标函数的方法及结果.

假定样本 x 属于模式类 $\omega_{q(x)}$, 根据式 (9) 可以计算样本 x 属于模式类 $\omega_{q(x)}$ 的总置信度

$$S_{q(x)}(x) = \sum_{m=1}^M w_m (r_{q(x)}^m(x)^{-b_m}) \quad (10)$$

同样可以计算样本 x 属于其他模式类的总置信度 $S_l(x)$, $l \in \Lambda$, ($\Lambda = \{1, 2, \dots, M\} - \{q(x)\}$).

对样本 x 的分类误差可以表示为

$$err(x) = S_{q(x)}(x) - \min\{S_l(x) : l \in \Lambda\} \quad (11)$$

由于不同模式类对应的序号向量不同, $err(x) = 0$ 的情况不会出现, $err(x)$ 的值仅有以下两种情况:

- 1) $err(x) > 0$, 此时对样本 x 的分类是正确的;
 - 2) $err(x) < 0$, 此时对样本 x 的分类是错误的.
- 定义一个阶跃函数

$$step(t) = \frac{1}{1 + e^{Qt}} \quad (12)$$

其中参数 Q 是一个比较大的正数, 本文实验中取 $Q = 100$.

用该函数对分类误差进行变换, 将对样本的分类正确与否表示出来, 方法如下

$$err'(x) = \frac{1}{1 + e^{Q(S_{q(x)}(x) - \min\{S_l(x) : l \in \Lambda\})}} \quad (13)$$

假设训练集为 D , 则本文方法在训练集上的分类错误率可以表示为

$$E_D = \sum_{x \in D} \frac{1}{1 + e^{Q(S_{q(x)}(x) - \min\{S_l(x) : l \in \Lambda\})}} \quad (14)$$

为了用梯度下降算法计算置信度函数的参数, 需要错误率的表达式是连续可微的, 然而在式 (14) 中, 存在一个不可微的表达式 $\min\{S_l(x) : l \in \Lambda\}$. 为此, 假定 $\min\{S_l(x) : l \in \Lambda\} = S_{p(x)}$, 即在除去样本 x 的真实类别 $\omega_{q(x)}$ 以外的模式类中, 存在一个置信度最高的模式类 $\omega_{p(x)}$. 在对参数进行求导时, 假定融合规则中的参数仅在一个很小的范围内变化, 从而可以近似认为参数的变化不影响到各个模式类对应的置信度的排序, 即参数的变化与 $p(x)$ 的值无关. 这样可以将式 (14) 简化为

$$E_D = \sum_{x \in D} \frac{1}{1 + e^{Q(S_{q(x)}(x) - S_{p(x)}(x))}} = \sum_{x \in D} \frac{1}{1 + e^{Q \sum_{m=1}^M w_m (r_{q(x)}^m(x)^{-b_m} - r_{p(x)}^m(x)^{-b_m})}} \quad (15)$$

将式 (15) 定义的近似错误率作为目标函数, 使其最小化, 可以用梯度下降算法求出各个融合参数. 为此需要按照下面的式 (16) 和 (17) 计算 E_D 相对于各个融合参数的导数.

4 实验

4.1 实验数据

本文采用了李强等采集的手部图像数据库^[11]. 该图像库中包含 98 个人的 1971 组掌纹图像和手指图像, 适合于进行多分类器融合实验. 掌纹识别已经成为生物特征识别领域中的一个研究热点, 这方面的研究很多^[12~15]. 手指图像识别是目前新出现的一

$$\frac{\partial E_D}{\partial w_m} = \sum_{x \in D} \frac{-Q e^{Q(S_{q(x)}(x) - S_{p(x)}(x))}}{(1 + e^{Q(S_{q(x)}(x) - S_{p(x)}(x))})^2} (r_{q(x)}^m(x)^{-b_m} - r_{p(x)}^m(x)^{-b_m}) \quad (16)$$

$$\frac{\partial E_D}{\partial b_m} = \sum_{x \in D} \frac{Q w_m e^{Q(S_{q(x)}(x) - S_{p(x)}(x))}}{(1 + e^{Q(S_{q(x)}(x) - S_{p(x)}(x))})^2} (r_{q(x)}^m(x)^{-b_m} \ln(r_{q(x)}^m(x)^{-b_m}) - r_{p(x)}^m(x)^{-b_m} \ln(r_{p(x)}^m(x)^{-b_m})) \quad (17)$$

个研究方向. 李强^[11] 首先提出了基于手指图像的身份认证方法, 并且给出了一种基于边缘信息的特征提取方法; Ribaric^[16] 提出了融合掌纹图像和手指图像的身份认证系统; 王长宇^[17] 提出了基于手指背关节的身份认证方法.

李强等采集的图像库中, 每组图像包括掌纹图像、食指图像、中指图像、无名指图像和小拇指图像各一幅. 本文实验中仅选用了掌纹图像、食指图像、中指图像. 这样设计是因为很多人的无名指和小拇指不容易伸直, 所以基于无名指与小拇指的识别算法的稳定性比较差.

4.2 实验设计

在实验中将原始图像分为 3 个集合: 训练集, 校验集和测试集. 训练集包含每个人的 3 组, 共 98×3 组图像, 用来训练基本分类器; 校验集包含每个人的 3 组, 共 98×3 组图像, 用来训练融合算法; 其他图像全部用做测试样本.

掌纹图像下采样为 32×32 , 手指图像数据下采样为 30×90 . 每种图像数据分别经过主分量方法 (Principal component analysis, PCA) 和线性判别分析 (Linear discrimination analysis, LDA) 进行降维^[18], 转化为 32 维的特征样本, 然后经过最近邻分类器进行分类. 这样根据每种输入数据可设计两个基本分类器 (最近邻分类器), 共可获得 6 个基本分类器. 对于任意输入样本, 每个基本分类器计算该样本与每类样本的最近邻距离, 并且根据距离的大小将各个模式类排序, 输出一组序号, 全部基本分类器的输出结果综合起来构成一个序号矩阵.

在实验中, 将本文方法与逻辑回归方法以及 MGR 进行了比较. 校验集的样本经过各个基本分类器的处理后得到的序号矩阵构成融合算法的训练集, 测试集的样本经过各个基本分类器的处理后得到的序号矩阵构成融合算法的测试集. 在本文方法的训练过程中, 算法的迭代次数上限为 100, 参数 w_m 初值为 $1/M$, 参数 b_m 初值为 1. 在逻辑回归方法与 MGR 方法中, 参照文献 [2] 的参数值, 将序号的最大值设为 10.

为了比较各个融合方法的性能, 本文还进行了基本分类器的数目为 2 个、3 个的情况下的实验. 从 6 个基本分类器中任选 2 个进行融合实验, 共有 15 种情况, 可进行 15 次实验; 而融合 3 个分类器, 可以进行 20 次实验. 这种实验设计方法可以比较充分的显示融合算法的性能.

4.3 实验结果

本文进行了复杂条件下的多模态身份识别实验, 实验中的数据图像分辨率低, 采集于不同的时间, 训练样本少. 在这样的条件下, 各个基本分类器的错误

率比较高, 如表 1 所示.

表 1 基本分类器的分类错误率

Table 1 Classification error rates of the base classifiers

数据源	基于 PCA 的分类器 (%)	基于 LDA 的分类器 (%)
掌纹	10.41	7.45
食指	7.59	10.85
中指	6.0	6.15

第一部分实验是融合两个基本分类器的实验, 将本文方法与逻辑回归方法以及 MGR 进行比较. 从 6 个分类器中选择两个分类器, 可以进行 15 次实验, 这些实验的错误率见图 1, 平均错误率见表 2. 可以看出 MGR 方法的平均错误率低于逻辑回归方法, 但是改进量比较小. 本文方法的平均错误率比 MGR 方法下降了约 1 个百分点. 本文方法在 14 次实验中都明显优于逻辑回归方法和 MGR 方法, 仅在一次实验中, 其错误率略高于 MGR 方法.




图 1 融合两个分类器的实验

Fig. 1 Fusion experiments of two classifiers

表 2 融合两个分类器时的平均错误率

Table 2 Average classification error rates of fusion of two classifiers

逻辑回归 (%)	MGR (%)	本文方法 (%)
5.32	4.89	3.86

第二部分实验是融合 3 个基本分类器的实验, 仍然将本文方法与逻辑回归方法以及 MGR 方法进行比较. 在这部分实验中, 本文方法有时不能超过其他方法. 为了便于分析原因, 我们将实验划分为相关分类器实验和独立分类器实验. 首先我们进行相关分类器的实验, 从 6 个分类器中选择 3 个分类器, 选择的 3 个分类器之中有 2 个分类器的输入数据来自同一个数据源, 这样可以进行 12 次实验, 实验结果如图 2 所示. 然后进行独立分类器的实验, 从 6 个分类器中选择输入数据来自不同数据源的 3 个分类

器, 可以进行 8 次实验, 实验结果如图 3 所示. 融合三个分类器的平均错误率见表 3. 从数据中可以看出增加了一个分类器之后, 各融合算法的分类正确率有很大的提高. 当基本分类器之间存在相关关系的时候, 本文方法略优于其他方法, 但是改进量不大. 当分类器之间是独立关系时, 本文方法在每一次实验中均优于 MGR 方法和逻辑回归方法.




图 2 融合三个相关分类器的实验

Fig. 2 Fusion experiments of three correlated classifiers




图 3 融合三个独立分类器的实验

Fig. 3 Fusion experiments of three independent classifiers

表 3 融合三个分类器时的平均错误率

Table 3 Average classification error rates of fusion of three classifiers

	逻辑回归 (%)	MGR (%)	本文方法 (%)
相关分类器	2.96	2.87	2.66
独立分类器	1.55	1.53	0.93

第三部分实验是融合全部 6 个基本分类器的实验. 由于此时如果采用 MGR 方法, 融合参数将增加到 $2^6 - 1 = 63$ 个, 融合规则过于复杂, 所以我们仅将本文方法与逻辑回归方法进行了比较. 表 4 给出了两种方法的错误率. 可以看到, 融合算法的错误率又有一定程度的下降, 本文方法优于逻辑回归方法.

表 4 融合 6 个分类器的错误率

Table 4 Classification error rates of fusion of six classifiers

逻辑回归 (%)	本文方法 (%)
0.65	0.29

4.4 实验分析

本文进行了不同条件下的大量实验, 实验结果显示本文方法的分类正确率高于传统的排序层融合方法与 Melnik 提出的融合方法. 这是由于下面两个原因:

- 1) 本文方法中的参数设置更加合理, 能够更好地实现排序层分类器融合的两个目标;
- 2) 本文方法带有一个很好的参数优化算法, 能够从数据中学习合适的参数.

在融合两个基本分类器的实验中, 基本分类器之间的关系非常简单, 本文方法在分类正确率方面明显超过了逻辑回归方法和 MGR 方法.

在融合 3 个基本分类器的实验中, 当基本分类器之间是独立关系时, 本文方法明显优于逻辑回归方法和 MGR 方法, 但是当分类器之中有两个相关时, 本文方法与其他方法的差异不明显. 导致这一现象的原因是由于当 3 个基本分类器中有两个分类器的输入数据来自同一数据源而另外一个分类器的输入数据来自其他数据源时, 基本分类器之间差别的影响增加了, 而序号值差异的影响变小了. 在这种情况下, 双目标排序层融合方法的优势减小了.

在融合 6 个基本分类器的实验中, 基于每个数据源产生的分类器的数目相同, 此时基本分类器之间的差别的影响减少了, 而序号值的差异的影响变大, 本文方法的优势又增大了.

5 结论

本文根据 Melnik 的融合思想提出了双目标多分类器融合的概念, 并且给出了一种新的排序层分类器融合方法. 该方法将对序号的非线性变换与分类器的加权组合协调起来, 并且具备一种有效的参数优化方法.

在实验中, 本文设计了融合掌纹图像、食指图像和中指图像的多模态身份识别系统, 进行了各种情况下的大量实验. 实验结果表明, 本文方法与传统的排序层融合方法和 Melnik 的融合方法相比具有更好的学习能力和更高的分类正确率.

References

- 1 Xu L, Krzyzak A, Suen C Y. Methods for combining multiple classifiers and their applications to handwriting recognition. *IEEE Transactions on Systems, Man, and Cybernetics*, 1992, 22(3): 418~435

- 2 Ho T K, Hull J J, Srihari S N. Decision combination in multiple classifier systems. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1994, **16**(1): 66~75
- 3 Saranli A, Demirekler M. A statistical unified framework for rank-based multiple classifier decision combination. *Pattern Recognition*, 2001, **34**(4): 865~884
- 4 Melnik O, Vardi Y, Zhang C H. Mixed group ranks: preference and confidence in classifier combination. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2004, **26**(8): 973~981
- 5 Liu C L. Classifier combination based on confidence transformation. *Pattern Recognition*, 2005, **38**(1): 11~28
- 6 Kittler J. A framework for classifier fusion: is it still needed? *Lecture Notes in Computer Science*, 2000, **1876**: 45
- 7 Lin X F, Ding X Q, Chen M, Zhang R, Wu Y S. Adaptive confidence transform based classifier combination for Chinese character recognition. *Pattern Recognition Letters*, 1998, **19**(10): 975~988
- 8 Artukorale A S, Suganthan P N. Combining classifiers based on confidence values. In: *Proceedings of the 5th International Conference on Document Analysis and Recognition*. Bangalore, India: IEEE, 1999. 37~40
- 9 Juang B H, Katagiri S. Discriminative learning for minimum error classification. *IEEE Transactions on Signal Processing*, 1992, **40**(12): 3043~3054
- 10 Paredes R, Vidal E. Learning weighted metrics to minimize nearest-neighbor classification error. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2006, **28**(7): 1100~1110
- 11 Li Q, Qiu Z D, Sun D M. Personal identification using knuckleprint. *Lecture Notes in Computer Science*, 2004, **3338**: 680~689
- 12 Han C C, Cheng H L, Lin C L, Fan K C. Personal authentication using palm-print features. *Pattern Recognition*, 2003, **36**(2): 371~381
- 13 Li Qiang, Qiu Zheng-Ding, Sun Dong-Mei, Liu Lu-Lu. Online palmprint identification based on improved 2D PCA. *Acta Electronica Sinica*, 2005, **33**(10): 1886~1889
(李强, 袁正定, 孙冬梅, 刘陆陆. 基于改进二维主成分分析的在线掌纹识别. *电子学报*, 2005, **33**(10): 1886~1889)
- 14 Yuan Guo-Wu, Wei Xiao-Yong, Xu Dan. Palmprint-based personal verification. *Journal of Computer-aided Design and Computer Graphics*, 2005, **17**(12): 2590~2595
(袁国武, 魏骁勇, 徐丹. 基于掌纹的身份鉴别. *计算机辅助设计与图形学学报*, 2005, **17**(12): 2590~2595)
- 15 Wu Xiang-Qian. Palmprint Feature Analysis for Personal Authentication [Ph.D. dissertation], Harbin Institute of Technology, 2004
(邬向前. 面向身份识别的掌纹特征分析 [博士学位论文], 哈尔滨工业大学, 2004)
- 16 Ribaric S, Fratric I. A biometric identification system based on eigenpalm and eigenfinger features. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, **27**(11): 1698~1709

- 17 Wang Chang-Yu, Song Shang-Ling, Sun Feng-Rong, Mei Liang-Mo. A novel biometrics technology-finger-back articular skin texture recognition. *Acta Automatica Sinica*, 2006, **32**(3): 360~367
(王长宇, 宋尚玲, 孙丰荣, 梅良模. 一种新的生物特征识别模式 - 手指背关节皮纹识别. *自动化学报*, 2006, **32**(3): 360~367)
- 18 Liu Qing-Shan, Lu Han-Qing, Ma Song-De. A survey: subspace analysis for face recognition. *Acta Automatica Sinica*, 2003, **29**(6): 900~911
(刘青山, 卢汉清, 马颂德. 综述人脸识别中的子空间方法. *自动化学报*, 2003, **29**(6): 900~911)



刘明 北京交通大学博士研究生. 主要研究方向为多模态生物特征识别, 图像处理. 本文通信作者.

E-mail: liuming@hbu.edu.cn

(LIU Ming Ph. D. candidate at Beijing Jiaotong University. His research interest covers multi-modal biometrics and image processing. Corresponding

author of this paper.)



袁保宗 教授. 主要研究方向为计算机视觉、虚拟现实、图像处理、计算机图形学、语音信号处理, 多媒体信息处理及数据通信.

E-mail: bzyuan@center.njtu.edu.cn

(YUAN Bao-Zong Professor. His research interest covers digital signal processing, speech signal processing, image processing, computer vision, computer graphics, multimedia information processing, and data communication.)



苗振江 北京交通大学教授. 1994 ~ 2004 年学习工作于法国图卢兹国家理工学院和加拿大科学院信息技术研究所, 主要研究方向为人机交互, 普适计算, 虚拟现实, 图像与语音处理.

E-mail: zjmiao@bjtu.edu.cn

(MIAO Zhen-Jiang Professor at Beijing Jiaotong University. From 1994 to 2004, he worked at French Institut National Polytechnique de Toulouse and National Research Council of Canada. His research interest covers human-computer interaction, pervasive computing, virtual reality, and image and speech processing.)