

文章编号: 1001-0920(2003)01-0092-04

基于分类器联合的联机图形识别方法研究

李昌华¹, 杨 兵¹, 谢维信²

(1. 西安电子科技大学 电子工程学院, 陕西 西安 710071; 2. 深圳大学 校长办公室, 广东 深圳 518060)

摘 要: 研究基于不同模式特征的多分类器联合问题, 提出一种新的分类器联合方法。将该方法应用于联机几何图形的识别, 实验中联合了 3 种分类器, 每种分类器的机制各不相同, 并且都基于不同的模式特征。将该分类器联合方法与现有的几种联合方法进行实验比较, 实验结果表明该方法具有较高的识别率。

关键词: 分类器联合; 联机图形识别; 隐马尔可夫模型; 模糊特征提取

中图分类号: TP391.4 **文献标识码:** A

Study of on-line graphics recognition based on classifier combination

LI Chang-hua¹, YANG Bing¹, XIE Weixin²

(1. School of Electronic Engineering, Xidian University, Xi'an 710071, China;

2. President Office, Shenzhen University, Shenzhen 518060, China)

Abstract: The problem of combining multiple classifiers, which are different in mechanism and based on different pattern features is studied. A new scheme for classifier combination is proposed. The scheme is applied to an on-line graphics recognition problem in which there are three classifiers to be combined. The scheme is compared with several other existing combination schemes experimentally. The results show that the scheme has a higher classification rate than others.

Key words: Classifier combination; On-line graphics recognition; HMM; Fuzzy feature

1 引 言

在许多模式识别应用中, 使用多个分类器进行分类是很有益的, 因为这些分类器能相互提供补充信息, 通过多个不同分类器的适当联合, 识别的效率和准确率都会有所提高^[1]。目前, 已研究出多种分类器联合方法, 并已证明一些联合方法优于最佳的单一分类器。针对基于不同特征描述的多分类器联合问题, 文献[2]提出一种分类器联合的理论框架, 并且指出在联合分类过程中, 所有的模式特征描述都可结合起来用于做出决策。现有的一些联合方法都可视为这种思路的特例。

基于文献[2]的理论框架, 本文提出一种新的分类器联合方法, 该方法改善了文献[2]的求和规则联合方法。求和规则联合方法所需的假定过于苛刻, 因而引进了误差。为此, 本文方法对这种误差做了补偿, 并将新的联合方法应用于联机图形识别以验证其效能, 因此本文将对实验及实验结果做出说明。

2 分类器联合方法的理论设计

2.1 理论框架

考虑一个模式识别问题, 其中模式 Z 需要被指派为 m 个可能类 $(\omega_1, \omega_2, \dots, \omega_m)$ 中之一。现有 R 个分类器, 每个分类器利用各自不同的测量值向量表

收稿日期: 2001-08-13; 修回日期: 2002-04-15。

基金项目: 国防预研基金资助项目(6665); 陕西省自然科学基金资助项目(99X14)。

作者简介: 李昌华(1963—), 男, 江苏南京人, 副教授, 博士, 从事模式识别、多媒体技术等研究; 杨兵(1969—), 男, 辽宁大连人, 副教授, 博士, 从事信号处理、人机交互等研究。

示该模式, 将第 i 个分类器所用的测量值向量记为 x_i 。在测量值空间中每个类都有一个模型, 模型以概率密度函数 $p(x_i|\omega)$ 表示, 每个类的先验概率记为 $P(\omega)$ 。这些模型是互斥的, 即每个类仅有一个模型与之相对应。依据贝叶斯理论, 在给定测量值 $x_i (i = 1, 2, \dots, R)$ 的情况下, 模式 Z 应被指派给类 ω , 只要这种解释的后验概率取得最大值, 即

$$\text{assign } Z = \omega \text{ if } P(\omega | x_1, \dots, x_R) = \max_k P(\omega | x_1, \dots, x_R) \quad (1)$$

式(1)右端的后验概率函数的计算, 依赖于以联合概率密度函数 $p(x_1, \dots, x_R|\omega)$ 形式出现的测量值的高阶统计特征知识, 而这是很难推断的。所以有必要简化该式, 并以每个单独的分类器所做的决策支持计算来表达, 每个分类器仅仅利用由向量 x_i 所传达的信息。这样不仅使式(1)在计算上成为可行, 而且为设计开发一系列的分类器联合策略提供了基本思路。

根据贝叶斯定理, 有

$$P(\omega | x_1, \dots, x_R) = \frac{p(x_1, \dots, x_R|\omega)P(\omega)}{p(x_1, \dots, x_R)} \quad (2)$$

其中 $p(x_1, \dots, x_R)$ 是测量的无条件概率密度。于是可将其表达为

$$p(x_1, \dots, x_R) = \prod_{j=1}^m p(x_1, \dots, x_R|\omega)P(\omega) \quad (3)$$

$p(x_1, \dots, x_R|\omega)$ 是由分类器所抽出的测量值的联合概率分布。假定所用的这些模式描述是条件统计独立的, 则有

$$p(x_1, \dots, x_R|\omega) = \prod_{i=1}^R p(x_i|\omega) \quad (4)$$

对于大多数应用而言, 这个条件独立性的假设是满足的。该假设能对现实情况提供一个有效的近似。由式(2)~(4)得

$$P(\omega | x_1, \dots, x_R) = \frac{P(\omega) \prod_{i=1}^R p(x_i|\omega)}{\prod_{j=1}^m P(\omega) \prod_{i=1}^R p(x_i|\omega)} \quad (5)$$

将式(5)用于规则(1), 可获得决策规则

$$\text{assign } Z = \omega \text{ if } P(\omega) \prod_{i=1}^R p(x_i|\omega) = \max_{k=1}^m P(\omega) \prod_{i=1}^R p(x_i|\omega) \quad (6)$$

或以每个分类器分别产生的后验概率的形式表达为

$$\text{assign } Z = \omega \text{ if } P^{-(R-1)}(\omega) \prod_{i=1}^R P(\omega | x_i) =$$

$$\max_{k=1}^m P^{-(R-1)}(\omega) \prod_{i=1}^R P(\omega | x_i) \quad (7)$$

决策规则(7)是非常苛刻的, 也是非常重要的。如果某个分类器的输出为零, 则总结果为零。在规则(7)的基础上, 可以设计开发出其他的分类器联合方法。

2.2 分类器联合方法的设计

后验概率可表达为

$$P(\omega | x_i) = P(\omega) (1 + \delta_{ki}) \quad (8)$$

将式(8)代入式(7)中的后验概率, 有

$$P^{-(R-1)}(\omega) \prod_{i=1}^R P(\omega | x_i) = P(\omega) \prod_{i=1}^R (1 + \delta_{ki}) \quad (9)$$

假设 1 每个单一分类器所计算出的后验概率不会显著地偏离其先验概率^[2], 即满足 $\delta_{ki} \ll 1$ 。

将式(9)右端的乘积展开, 并略去等于或高于二次的项, 则式(9)右端可近似为

$$P(\omega) \prod_{i=1}^R (1 + \delta_{ki}) \approx (1 + R)P(\omega) + \sum_{i=1}^R P(\omega | x_i) \quad (10)$$

利用式(9)和(10)对式(7)进行近似, 可得到求和决策规则^[2]

$$\text{assign } Z = \omega \text{ if } (1 + R)P(\omega) + \sum_{i=1}^R P(\omega | x_i) = \max_{k=1}^m [(1 + R)P(\omega) + \sum_{i=1}^R P(\omega | x_i)] \quad (11)$$

在实际应用中, 求和联合规则是一个经常使用的规则。在以上用基于贝叶斯理论框架对求和联合规则的推导过程中, 使用了一个限制性很强的假设, 即假设 1。在大多数应用中, 这个假设都不会成立。事实上, 对于一个给定的模式 Z , 当与某个类 ω 的模型比较时, 分类器输出的后验概率, 有些明显大于先验概率, 有些明显小于先验概率, 有些则与先验概率几乎相等。因此, 使用式(10)会引起较大的误差。这一点给了作者一个启发: 如果能设法在某种程度上补偿这个误差, 则会得到比求和规则更好的分类器联合规则。为此, 本文从求积规则(7)出发, 研究如何补偿该误差的影响。注意到式(9)右端可以写成

$$P(\omega) \prod_{i=1}^R (1 + \delta_{ki}) = \frac{1}{R} P(\omega | x_1) \prod_{i=2}^R (1 + \delta_{ki}) + \dots + \frac{1}{R} P(\omega | x_R) \prod_{i=1}^{R-1} (1 + \delta_{ki}) \quad (12)$$

令 $V_l = \prod_{i=1, i \neq l}^R (1 + \delta_i)$, 由式(9) 有

$$P^{-(R-1)}(\omega) \prod_{i=1}^R P(\omega | x_i) = P(\omega) \prod_{i=1}^R (1 + \delta_i) = \frac{1}{R} \prod_{l=1}^R P(\omega | x_l) V_l \quad (13)$$

于是可得乘积决策规则(7) 的等价形式

$$\text{assign } Z = \omega \text{ if } \prod_{l=1}^R P(\omega | x_l) V_l = \max_{k=1}^m \left[\prod_{l=1}^R P(\omega | x_l) V_l \right] \quad (14)$$

对式(11) 稍作变形, 便得到求和规则的等价形式

$$\text{assign } Z = \omega \text{ if } \prod_{i=1}^R \left[P(\omega | x_i) - \frac{R-1}{R} P(\omega) \right] = \max_{k=1}^m \left\{ \prod_{i=1}^R \left[P(\omega | x_i) - \frac{R-1}{R} P(\omega) \right] \right\} \quad (15)$$

因为式(14) 中的每个 $P(\omega | x_i) V_l$ 都相等, 所以如果有 $P(\omega | x_i) > P(\omega | x_j)$, 则必有对应的 $V_i < V_j$ 。若将式(14) 理解为加权求和, 则较大的后验概率所对应的权值较小。然而, 若将式(15) 理解为加权求和, 则较大的后验概率所对应的权值却较大。因为若设

$$P(\omega | x_i) - \frac{R-1}{R} P(\omega) = \alpha P(\omega | x_i)$$

则有

$$\alpha = 1 - \left[\frac{R-1}{R} P(\omega) \right] / [P(\omega | x_i)]$$

即 $P(\omega | x_i)$ 越大, α 也越大, 恰好与规则(14) 相反。这说明式(10) 所引起的误差对后验概率输出较大的分类器给予了较大的权值。

因此, 如果能找到式(14) 中 V_l 的某种逼近, 构造一组加权值, 采用加权求和的联合规则, 便可补偿由式(10) 所引入的误差, 得到比求和规则更好的分类器联合规则。于是本文提出以下加权求和分类器联合规则

$$\text{assign } Z = \omega \text{ if } \prod_{i=1}^R W_{ji} P(\omega | x_i) = \max_{k=1}^m \left[\prod_{i=1}^R W_{ki} P(\omega | x_i) \right] \quad (16)$$

其中

$$W_{ki} = \frac{1}{1 + \beta \frac{P(\omega | x_i) - P_k^{\min}}{P_k^{\max} - P_k^{\min}}} \quad (17)$$

式中 $P_k^{\min} = \min_{i=1}^R P(\omega | x_i)$
 $P_k^{\max} = \max_{i=1}^R P(\omega | x_i)$

β 是 W_{ki} 取值范围的控制参数, 这里取其为 4。 W_{ki} 的取值范围为 $[0.2, 1]$ 。

3 基于分类器联合的联机图形识别

联机几何图形的笔画识别较为困难。比如: 联机手写汉字识别无须对圆和椭圆做出区分, 但在联机几何图形的识别中, 必须区分出弧、直线、圆、椭圆、角以及其他许多几何基元^[3]。通过联合多个分类器, 可使几何图形的笔画识别率有所提高。作者在实验中所采用的图形取自国家某部制订的地图符号集合, 该符号集合共有 900 多个符号, 从中总结出 57 种笔画类型。

3.1 分类器与模式特征

本文使用的第 1 种分类器是一个基于模糊特征的线性分类器, 每个笔画表达为一个实值的特征向量, 利用模糊特征提取方法得到这些特征向量。线性分类器将待识模式的输入特征向量对每个笔画类型做出类属判断, 每个笔画类对应于一个特征值上的线性决策函数(即加权值)。根据规格化处理后的训练数据, 训练算法计算出每个模式类的各个权值。

所用的第 2 种分类器是一个隐马尔可夫模型分类器, 通过 L PC 特征抽取获得观测序列。对于每种笔画类型建立一个 HMM, 也就是估计出模型参数 (A, B, π) , 这种模型使得该笔画类型的观测向量得到最大的似然度。对于一个待识的未知笔画, 计算出对每个可能模型的类属似然度^[4]。

所使用的第 3 种分类器是一个前馈神经网络分类器, 使用的特征基于笔画的大小、起始角度、相邻点的角度差以及笔尖的移动速度等信息。网络的输入层节点对应于各个特征值, 网络的输出层节点对应于每个类, 节点的输出值反映了对相应类的类属支持^[5]。

上述 3 种分类器所用的特征集合彼此间有较大的差异, 而且分类器的原理也各不相同, 因此各个分类器的输出之间有较低的相关性。

3.2 实验结果

作者使用包括本文的加权求和规则(16), 对 4 种联合方法做了实验比较, 总共使用 2 300 个样本。单一分类器的识别率如表 1 所示, 各种联合方法的识别率如表 2 所示。

表 1 单个分类器的识别率

分 类 器	识别率 /%
模糊特征线性分类器	88.57
HMM	91.22
神经网络	90.61

表 2 不同联合方法的识别率

联合规则	识别率 /%
取 中	93.52
取 大	92.13
求 和	91.22
加权求和	97.52

以上二表说明, 单一分类器的识别率低于联合分类器的识别率, 使用加权求和规则的联合方法的识别率高于所比较的其他联合方法的识别率。实验中发现, 许多被求和规则联合方法误分类的样本已由加权求和规则联合方法所改正。

4 结 论

本文研究了多分类器联合以及联机图形识别问题, 基于通用的分类器联合的理论框架, 提出一种分类器联合方法。该方法改进了文献[2]的求和规则联合方法, 并从理论上说明了改进的原因。将该分类器联合方法应用于联机图形识别, 提高了分类准确率。所联合的分类器有 3 种, 每种分类器的机制各不相同, 并且都基于不同的模式特征。将该联合方法与现有的几种联合方法进行实验比较, 实验结果表明, 在

所比较的方法中这种联合方法的识别率最高。

参考文献(References):

- [1] Xu L, Krzyzak A, Suen C Y. Methods of combining multiple classifiers and their applications to handwriting recognition[J]. *IEEE Trans Syst Man Cybern*, 1992, 22(3): 418-435
- [2] Josef Kittler, Mohamad Hatef, Robert P W D, et al. On combining classifiers[J]. *IEEE Trans Pattern Anal Mach Intell*, 1998, 20(3): 226-239
- [3] 李昌华, 杨兵, 谢维信. 手绘图形结构的识别方法研究[J]. 西安电子科技大学学报, 2000, 27(S): 98-101. (Li C H, Yang B, Xie W X. Study of hand-sketched graphics structure recognition methods[J]. *J Xidian Univ*, 2000, 27(S): 98-101.)
- [4] Rabiner L, Juang B H. *Fundamentals of Speech Recognition*[M]. Beijing: Press Tsinghua Univ Prentice Hall, 1999. 321-389
- [5] Rubine D. Criteria for gesture recognition technologies[A]. *Neural Networks Pattern Recognition - Camp Int* [C]. Chichester: Ellis Horwood Limited, 1992. 243-263

(上接第 91 页)

所采用的数据为上午 9 时以后的连续 12 个样本点, 样本点的采样间隔为 8 min, 利用回归模型对未来的 10 个时间点的数据进行预测。图 3(a) 表示一天的样本数据及预测数据, 预测的平均误差为 0.1656; 图 3(b) 表示另一天的样本数据及预测数据, 预测的平均误差为 0.1288。图中, “+”点为实测数据, “*”点为预测数据。

4 结 语

支持向量机回归建模将低维非线性的输入映射到高维线性的输出, 模型简单, 具有良好的应用前景。由于理论较新, 这方面的研究主要局限于理论, 很少应用于实际。本文将其应用于温室温度的变化建模, 取得了良好的效果。目前, 多数有关支持向量机的研究仅仅局限于理论和仿真, 因此将理论应用于解决实际问题的研究具有重要意义。

参考文献(References):

- [1] Vapnik V. *The Nature of Statistical Learning Theory* [M]. New York: Springer, 1999
- [2] Müller K R, Smola A J, Rätsch G, et al. Predicting time series with support vector machines[A]. *Proc*

- ICANN 97*[C]. New York: Springer, 1997. 999-1004
- [3] Drucker H, Burges C J, Kaufman L, et al. Support vector regression machines[A]. *Adv Neural Inform Proc Syst*[C]. Cambridge: MIT Press, 1997. 155-161
- [4] Vapnik V, Golowich S, Smola A. Support vector method for function approximation, regression estimation and signal processing[A]. *Adv Neural Inform Proc Syst*[C]. Cambridge: MIT Press, 1997. 281-287
- [5] Boser B E, Guyon I M, Vapnik V N. A training algorithm for optimal margin classifiers[A]. *5th Annual ACM Workshop COLT* [C]. Pittsburgh: ACM Press, 1992. 144-152
- [6] Campbell C. Algorithmic approaches to training support vector machines: A survey[A]. *Proc ESANN 2000*[C]. Belgium: D-Facto Publications, 2000. 27-36
- [7] Marsh L S, Albright L D. Economically optimum day temperature for greenhouse hydroponic lettuce production — Part 2: Results and simulations[J]. *Trans ASAE*, 1991, 34(3): 557-562
- [8] Maksarov D, Chalabi Z S. Computing bounds on greenhouse energy requirements using bounded error approach[J]. *Contr Eng Prac*, 1998, (6): 947-995