

软组合概率神经网络分类器人脸识别方法

翟俊海 赵文秀

(河北大学数学与计算机学院 保定 071002)

摘要 概率神经网络分类器具有学习速度快、易于实现的特点,而且其输出是后验概率,使得分类器的软组合变得容易。利用概率神经网络的这些特点,提出了软组合概率神经网络分类器人脸识别方法,该方法包括 3 步:(1)对人脸图像做不完全小波包分解;(2)用包含低频成分的小波子空间图像训练概率神经网络分类器;(3)用模糊积分组合训练好的分类器。将该方法与 3 种基于矩阵子空间的人脸识别方法在 JAFFE、YALE、ORL 和 FERET 4 个人脸数据库上进行了实验比较,结果表明,提出的方法在识别精度和 CPU 时间两方面均优于其他 3 种方法。

关键词 概率神经网络,人脸识别,模糊积分,小波变换,子空间

中图分类号 TP181 文献标识码 A DOI 10.11896/j.issn.1002-137X.2015.7.065

Soft Combination of Probabilistic Neural Network Classifiers for Face Recognition

ZHAI Jun-hai ZHAO Wen-xiu

(College of Mathematics and Computer Science, Hebei University, Baoding 071002, China)

Abstract Probabilistic neural network (PNN) classifiers have fast learning speed and can be easily implemented. The outputs of PNN are posterior probabilities which facilitate the soft combination of classifiers. We proposed a face recognition algorithm named SCPNN, which combines PNN classifiers with fuzzy integral, and makes full use of the superiority of PNN and ensemble learning. The main steps of the proposed method include: the incomplete wavelet packet decomposition of face images, training PNN classifiers with wavelet subspace images which include low frequency components and combination of the trained PNN classifiers by fuzzy integral. The proposed algorithm SCPNN was compared with 3 matrix subspace algorithms on 4 face databases, which are JAFFE, YALE, ORL and FERET. The experimental results confirm that the proposed method outperforms the 3 matrix subspace algorithms in recognition accuracy and CPU time.

Keywords Probabilistic neural networks, Face recognition, Fuzzy integral, Wavelet transform, Subspace

1 引言

作为一个热门的研究方向,人脸识别^[1]得到了科研人员的广泛关注,并成功应用于安全检测、身份识别、视频监控等。对于静止的人脸图像,人脸识别的过程大致分为两个阶段:特征提取和分类识别。在子空间人脸识别^[2]的框架下,特征提取方法大致可分为两类:线性子空间方法和非线性子空间方法。PCA(Principal Component Analysis)^[3]方法是线性子空间方法中的奠基性工作。但 PCA 方法需要将人脸图像向量化,而向量化后的向量维数往往非常高,这给协方差矩阵特征值的计算带来了极大的困难。为了克服特征人脸方法的这一缺点, Yang 等人^[4]提出了 2DPCA 方法。但 2DPCA 只在水平方向提取人脸图像的特征,这导致它表示一幅人脸图像需要更多的系数,即具有非常高的空间复杂度^[5]。Zhang 等人^[5]提出的 (2D)²PCA 方法克服了上述缺点,汪洋等人^[6]提出了基于差空间的双向 2DPCA 人脸识别算法。沿着这一技

术路线,基于线性判别分析(Linear Discriminant Analysis, LDA),Belhumeur 等人^[7]提出了 Fisher 脸方法, Li 等人^[8]提出了 2DLDA 方法, Nousath 等人^[9]提出了 (2D)²LDA 方法。

非线性子空间方法主要包括基于核变换的方法、基于傅里叶变换的方法和基于小波变换的方法。基于核变换的方法组合了核方法和线性子空间方法。例如, Chu 等人^[10]提出了人脸识别的核判别分析方法, Kim 等人^[11]提出了人脸识别的核 PCA 方法。基于傅里叶变换和基于小波变换的人脸识别方法的基本思想是一样的,首先将人脸图像变换到不同频率的子空间,然后选择一个或若干个子空间图像用于人脸识别。代表性的工作包括拉普拉斯脸方法^[12]和小波脸方法^[13]。文献^[14]很好地综述了子空间人脸识别方法,文献^[15]从更广泛的角度对人脸识别进行了综述,关于基于视频的人脸识别研究可参考文献^[16]。

为了改进人脸识别的精度(识别率),科研人员将集成学习用于人脸识别,提出了一些集成人脸识别方法。如 Owusu

到稿日期:2014-07-30 返修日期:2014-11-08 本文受国家自然科学基金项目(71371063, 61170040),河北省自然科学基金项目(F2013201220, F2013201110),河北省高等学校科学技术研究重点项目(ZD20131028)资助。

翟俊海(1964—),男,博士,教授,主要研究方向为数据挖掘与模式识别, E-mail: mczjh@126.com; 赵文秀(1983—),女,硕士生,主要研究方向为模式识别。

等人^[17]提出了集成神经网络人脸识别方法,Pong等人^[18]提出了特征融合人脸识别方法,Kwak等人^[19]提出了基于模糊积分和小波变换的集成人脸识别方法。在文献[19]的方法中,所有的小波子空间图像都用于集成,但实验研究发现双向高频小波子空间图像对人脸识别的贡献非常小,有的几乎没有贡献。为了解决这一问题,提出了软组合概率神经网络分类器人脸识别方法,该方法包括3步:(1)对人脸图像做不完全小波包分解;(2)用包含低频成分的小波子空间图像训练概率神经网络分类器;(3)用模糊积分组合训练好的分类器。将其与3种基于矩阵子空间的人脸识别方法在JAFFE、YALE、ORL和FERET4个人脸数据库上进行了实验比较,实验结果显示所提出的方法在识别精度和CPU时间两方面均优于其它3种方法。

2 基础知识

本节给出将要用到的基础知识,包括二维小波变换和二维小波包变换、概率神经网络、模糊积分。

2.1 二维小波变换和二维小波包变换

图像 $f(x, y)$ 的二维小波变换包括两步^[20]: 第一步, 对 $f(x, y)$ 的每一行降 2 采样, 并用低通滤波器 L 和高通滤波器 H 滤波, 得到两个变换图像 $f_L(x, y)$ 和 $f_H(x, y)$; 第二步, 对变换图像 $f_L(x, y)$ 和 $f_H(x, y)$ 的每一列降 2 采样, 并用低通滤波器 L 和高通滤波器 H 滤波, 得到 4 个变换子空间图像 $f_{LL}(x, y)$ 、 $f_{LH}(x, y)$ 、 $f_{HL}(x, y)$ 和 $f_{HH}(x, y)$ 。这一过程称为图像 $f(x, y)$ 的一层二维小波变换, 如图 1(a) 所示, 上标表示分解的层数。其中, $f_{LL}(x, y)$ 是包含水平和垂直两个方向(行与列)低频成分的子空间图像, $f_{LH}(x, y)$ 是包含水平方向低频成分和垂直方向高频成分的子空间图像, $f_{HL}(x, y)$ 是包含水平方向高频成分和垂直方向低频成分的子空间图像, $f_{HH}(x, y)$ 是包含水平和垂直两个方向(行与列)高频成分的子空间图像。如果只在子空间图像 $f_{LL}(x, y)$ 上重复这一过程, 则称这一变换为图像 $f(x, y)$ 的二维小波包变换, 如图 1(b) 所示。如果在每一个子空间图像上都重复这一过程, 则称这一变换为图像 $f(x, y)$ 的二维小波包变换。




图 1 (a) $f(x, y)$ 的一层小波分解 (b) $f(x, y)$ 的二维小波包分解

图 1

2.2 概率神经网络

概率神经网络 (Probabilistic Neural Network, PNN)^[21] 由输入层、模式层和类别层构成。给定标准归一化的训练集 $D_1 = \{(x_j, y_j) | j = 1, 2, \dots, n\}$, 其中 $x_j \in R^d$, $\sum_{j=1}^d x_{ji}^2 = 1$, $y \in \Omega = \{\omega_1, \omega_2, \dots, \omega_k\}$, 即训练集中的样例分为 k 类, 设第 i 类样例包含 n_i 个样例, 其中 $i = 1, 2, \dots, k$ 。用 D_1 训练出的 PNN 如图 2 所示。




图 2 概率神经网络

在图 2 中, 输入层有 d 个结点, d 是特征的维数, 激活函数为 $y = x$; 模式层有 n 个结点, n 是样例个数, 激活函数为 $g(x) = \exp\{\frac{x-1}{\sigma^2}\}$, 其中 σ 为平衡参数; 类别层也叫求和层或输出层, 有 k 个结点, 激活函数为 $y = x$ 。

输入层和模式层之间采用全连接方式, 连接到模式层第 j 个结点的 d 个连接权 w_{ji} 分别是模式向量 x_j 长度归一化后的各个分量, 即 $w_{ji} = x_{ji}$, $i = 1, 2, \dots, d$, $j = 1, 2, \dots, n$ 。模式层到类别层采用稀疏连接的方式, 模式层的第 j 个结点只与其对应的类别结点有连接, 相应的连接权 $\beta_{jk} = 1$, 与其他结点无连接, 相应的连接权 $\beta_{jk} = 0$ 。PNN 的训练过程实际上是模式向量长度标准归一化的过程。

给定标准化的测试集 $D_2 = \{(x_t, y_t) | t = 1, 2, \dots, m\}$, 则对于任意的 $x_t \in D_2$, 将 x_t 输入到训练好的 PNN。

模式层第 j 个结点的输出为:

$$o_{ji} = \exp\{\frac{w_{ji}^T \cdot x_t - 1}{\sigma^2}\} = \exp\{\frac{\sum_{i=1}^d w_{ji} x_{ti} - 1}{\sigma^2}\} \quad (1)$$

类别层第 s 个结点的输出为:

$$p_{st} = \beta_{st}^T \cdot o_{jt} = \sum_{j=1}^{n_s} o_{jt} \quad (2)$$

因此, PNN 的输出为 $p_t = (p_{s1}, \dots, p_{sk})$, 其中 p_{st} ($s = 1, \dots, k$; $t = 1, \dots, m$) 表示样例 x_t 属于第 s 类的后验概率。令 $s_t = \arg \max_s \{p_{st}\}$, 则样例 x_t 的预测类别为 s_t 。如果 $s_t = y_t$, 则预测是正确的; 否则, 预测是错误的。

2.3 模糊积分

本节简要介绍将要用到的模糊积分的基本概念^[22]。设 $C = \{C_1, C_2, \dots, C_l\}$ 是从训练集 D_1 训练出的 l 个分类器集合, C_i ($1 \leq i \leq l$) 称为元分类器或基本分类器。对于任意的测试样例 $x \in D_2$ 和任意的 $C_i \in C$ ($C_i: R^d \rightarrow \Omega$), 有

$$C_i(x) = (p_{i1}(x), p_{i2}(x), \dots, p_{ik}(x)) \quad (3)$$

其中, $p_{ij}(x) \in [0, 1]$ ($1 \leq i \leq l$; $1 \leq j \leq k$) 表示分类器 C_i 将样例 x 分类为第 j 类的隶属度。

定义 1 给定 $C = \{C_1, C_2, \dots, C_l\}$, $\Omega = \{\omega_1, \omega_2, \dots, \omega_l\}$ 和 $D_2 = \{x | x \in R^d\}$ 。对于任意的 $x \in D_2$, 称下面的矩阵为决策剖面。

$$DP(x) = \begin{bmatrix} p_{11}(x) & \dots & p_{1j}(x) & \dots & p_{1k}(x) \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ p_{l1}(x) & \dots & p_{lj}(x) & \dots & p_{lk}(x) \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ p_{l1}(x) & \dots & p_{lj}(x) & \dots & p_{lk}(x) \end{bmatrix} \quad (4)$$

矩阵 $DP(x)$ 的第 i 行表示分类器 C_i 将样例 x 分类为各

个类的隶属度,矩阵 $DP(x)$ 的第 j 列表示不同的分类器将测试样例 x 分类为第 j 类的隶属度。

从服从相同分布的数据集训练出的各个分类器,彼此之间不可能是相互独立的,它们之间有交互作用,模糊积分可以很好地表示这种交互作用。

定义 2 给定 $C = \{C_1, C_2, \dots, C_l\}$, 设 $P(C)$ 是 C 的幂集, 定义在 C 上的模糊测度是一个集函数:

$$g: P(C) \rightarrow [0, 1]$$

满足如下条件:

- (1) $g(\emptyset) = 0, g(C) = 1$;
- (2) $\forall A, B \subseteq C, \text{若 } A \subseteq B, \text{则 } g(A) \leq g(B)$ 。

如果 $\forall A, B \subseteq C, A \cap B = \emptyset$, 下式成立, 则称 g 为 λ 模糊测度。

$$g(A \cup B) = g(A) + g(B) + \lambda g(A)g(B) \quad (5)$$

其中, $\lambda > -1$, 且 $\lambda \neq 0$, 它的值可由下式确定:

$$\lambda + 1 = \prod_{i=1}^l (1 + \lambda g_i) \quad (6)$$

其中, g_i 表示在单个分类器上的模糊测定, 即下面定义 3 中的模糊密度。

定义 3 给定 $C = \{C_1, C_2, \dots, C_l\}, \forall C_i \in C (1 \leq i \leq l)$, 令 $g_i = g(\{C_i\})$, g_i 称为分类器 C_i 的模糊密度。本文用下式确定模糊密度 g_i :

$$g_i = \frac{p(C_i)}{\sum_{j=1}^l p(C_j)} \quad (7)$$

其中, $p(C_i)$ 是分类器 C_i 性能的量度。

定义 4 给定 $C = \{C_1, C_2, \dots, C_l\}, g$ 是 C 上的模糊测度, 函数 $h: C \rightarrow R^+$ 关于 g 的 Choquet 积分定义为:

$$(C) \int h d\mu = \sum_{i=1}^l (h(C_i) - h(C_{i-1})) g(A_i) \quad (8)$$

其中, $0 \leq h(C_1) \leq h(C_2) \leq \dots \leq h(C_l) \leq 1, h(C_0) = 0, A_i \subseteq C, A_i = \{C_1, C_2, \dots, C_i\}, g(A_0) = 0$ 。

3 软组合概率神经网络分类器人脸识别方法

3.1 算法的基本思想

在实验研究中,发现某些小波子空间图像对提高人脸识别的精度贡献很小,有的几乎没有贡献。例如,在不同层次的小波子空间图像中,双向高频子空间图像对分类识别的贡献几乎为零。这就是说没有必要集成由这些子空间图像训练出的分类器,而应该集成那些由含有低频成分的子空间图像训练出的分类器。基于此,本文按图 3 所示的框架选择用于训练基本分类器的小波子空间图像。

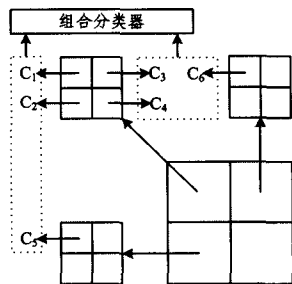


图 3 小波子空间图像集成框架

3.2 本文提出的算法

本文提出的算法 SCPNN 主要包括 3 步:(1)人脸图像的

不完全小波包分解;(2)按图 3 所示框架选择用于集成的小波子空间图像,并训练基本分类器;(3)用模糊积分软组合训练好的基本分类器。算法描述如下:

算法 SCPNN

输入:人脸数据库 $FDB = \{f_1(x, y), \dots, f_n(x, y)\}$

输出:识别规则

- Step 1 For $i=1$ to n ;
- Step 2 对人脸图像 $f_i(x, y)$ 做 m 层不完全小波包分解;
- Step 3 按图 3 所示框架,选择小波子空间图像;
- Step 4 用选择的小波子空间图像训练基本分类器: C_1, C_2, \dots, C_l ;
- Step 5 For $i=1$ to l ;
- Step 6 用式(7)计算计算模糊密度 g_i ;
- Step 7 用式(6)计算 λ ;
- Step 8 对每一幅人脸图像 $f(x, y)$;
- Step 9 计算决策剖面 $DP(f)$;
- Step 10 For $i=1$ to k ;
- Step 11 对 $DP(f)$ 的第 k 列由大到小排序,得到 $[d_{i_1 k}, d_{i_2 k}, \dots, d_{i_l k}]^T$, 相应的基本分类器的模糊密度记为 $g_{i_1}, g_{i_2}, \dots, g_{i_l}$;
- Step 12 令 $g(A_1) = g_{i_1}$;
- Step 13 For $t=2$ to l ;
- Step 14 用式(5)迭代计算 $g(A_t)$;
- Step 15 For $i=1$ to k ;
- Step 16 用式(8)计算

$$\mu_i(f) = (C) \int d d\mu$$

$$= d_{i_1 k}(f) + \sum_{j=2}^l d_{i_{j-1} k}(f) - d_{i_j k}(f) g(A_{j-1});$$
- Step 17 根据下式确定 f 的类标 k^* :

$$k^* = \arg \max_{1 \leq k \leq k} \{\mu_i(f)\}$$

4 实验结果及分析

本文提出的算法可以直接处理矩阵数据,通过两个实验来验证本文算法 SCPNN 的有效性。第一个实验分析参数 σ 对识别精度的影响,第二个实验与 3 个矩阵子空间人脸识别方法在 4 个数据库上就识别精度和 CPU 时间两方面进行了比较。4 个人脸数据库是 JAFFE、YALE、ORL 和 FERET,它们的基本信息列于表 1 中。3 个矩阵子空间人脸识别方法分别是 2DPCA、2DLDA 和文献[19]中的方法,文献[19]中的方法包括方法 1(WT+2DPCA)和方法 2(WT+2DLDA)。实验采用十折交叉验证的方法,实验环境是 PC 机,2.5GHz CPU,4GB 内存,实验工具是 MATLAB 8.1,选择的小波基函数是 BIOR 3.1。

表 1 实验所用人脸数据库的基本信息

数据库	图像数	分辨率	类别数
JAFFE	213	256×256	10
YALE	165	320×243	15
ORL	400	92×112	40
FERET	1400	80×80	200

实验 1 参数 σ 对识别精度的影响

PNN 的激活函数中的参数 σ 对识别精度有很大的影响。该实验研究参数 σ 和识别精度之间的关系,设参数 σ 从 0 变化到 50,步长为 5。对于 σ 的不同取值,记录算法 SCPNN 的相应识别精度值,变化曲线如图 4 所示。从图 4 中可以看出,对于不同的人脸数据库, σ 的合适取值范围是不同的。例如,对于人脸数据库 FERET, σ 的合适取值范围应该在区间 [23, 50]。而对于人脸数据库 JAFFE、YALE 和 ORL, σ 的合适取

值范围应该分别在区间[27, 35], [17, 20]和[4, 12]。在第二个实验中,对于人脸数据库 JAFFE、YALE、ORL 和 FERET, σ 的取值分别为 28、18、10 和 25。




图 4 参数 σ 和识别精度之间的关系

实验 2 与 3 种矩阵子空间人脸识别方法的比较

在实验 2 中,将本文方法与 2DPCA、2DLDA 和文献[19]中的方法就识别精度和 CPU 时间两方面进行了实验比较,文献[19]中的方法包括方法 1(WT+2DPCA)和方法 2(WT+2DLDA)。实验中,对每一个人脸数据库,选取 90%的样例作训练集,10%的样例作测试集。实验采用十折交叉验证的方法,实验结果是 10 的平均值,列于表 2 中。从表 2 的实验结果可以看出,本文算法 SCPNN 在识别精度和 CPU 时间两方面均优于其他 3 种方法,SCPNN 的识别精度高的原因是其集成了由不同频率子空间图像训练出的分类器,SCPNN 所用 CPU 时间少的原因是其选择了学习速度非常快的 PNN 作为基本分类器。

表 2 与 3 种矩阵子空间方法的实验比较结果(CPU 时间:s)

算法	性能	JAFFE	YALE	ORL	FERET
SCPNN	测试精度	0.991	0.884	0.993	0.790
	CPU 时间	2.793	2.669	1.575	1.374
2DPCA	测试精度	0.983	0.751	0.900	0.753
	CPU 时间	113.65	105.32	51.50	198.64
2DLDA	测试精度	0.910	0.851	0.921	0.786
	CPU 时间	103.68	138.13	25.55	183.18
WT+2DPCA	测试精度	0.840	0.645	0.852	0.773
	CPU 时间	24.36	22.58	18.22	87.28
WT+2DLDA	测试精度	0.774	0.740	0.822	0.790
	CPU 时间	21.92	20.83	16.69	82.52

结束语 本文提出了一种软组合分类器人脸识别方法,它用模糊积分组合概率神经网络分类器。本文提出的方法具有以下 3 个优点:(1)能充分利用概率神经网络和集成学习的优点;(2)用模糊积分融合基本分类器,能充分利用基本分类器之间的交互作用;(3)能用较少的 CPU 时间获得较高的识别精度。这些优点从实验结果中得到了证明。

参考文献

[1] Li S Z, Jain A K. Handbook of Face Recognition [M]. Springer London Ltd, 2005

[2] 章毓晋,贾慧星,李乐,等.基于子空间的人脸识别方法[M].北京:清华大学出版社,2009

Zhang Y J, Jia H X, Li L, et al. Subspace-based face recognition [M]. Beijing: Tsinghua University Press, 2009

[3] Turk M, Pentland A. Eigen-faces for recognition [J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86

[4] Yang J, Zhang D. Two-dimensional PCA: A new approach to appearance-based face representation and recognition [J]. IEEE Transactions Pattern Analysis and Machine Intelligence, 2004, 26(1): 131-137

[5] Zhang D, Zhou Z. (2D)²PCA: Two-directional two-dimensional

PCA for efficient face representation and recognition [J]. Neurocomputing, 2005, 69(1-3): 224-231

[6] 汪洋,严云洋,王洪元.基于差空间的双向 2DPCA 和 SVM 人脸识别算法 [J]. 计算机科学, 2012, 39(12): 268-271

Wang Y, Yan Y Y, Wang H Y. Face recognition based on residual space and SVM with bidirectional two dimensions PCA [J]. Computer Science, 2012, 39(12): 268-271

[7] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection [J]. IEEE Transactions Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720

[8] Li M, Yuan B. 2D-LDA: A novel statistical linear discriminant analysis for image matrix [J]. Pattern Recognition Letter, 2005, 26(5): 527-532

[9] Noushath S, Kumar G H, Shivakumar P. (2D)²LDA: An efficient approach for face recognition [J]. Pattern Recognition, 2006, 39(7): 1396-1400

[10] Chu W S, Chen J C, Lien J J. Kernel discriminant transformation for image set-based face recognition [J]. Pattern Recognition, 2011, 44(8): 1567-1580

[11] Kim K I, Jung K, Kim H J. Face recognition using kernel principal component analysis [J]. IEEE Signal Processing Letters, 2002, 9(2): 40-42

[12] He X, Yan S, Hu Y, et al. Face recognition using Laplacianfaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340

[13] Chien J T, Wu C C. Discriminant waveletfaces and nearest feature classifiers for face recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(12): 1644-1649

[14] Shakhnarovich G, Moghaddam B. Face recognition in subspaces [M]// Handbook of Face Recognition. Springer London Ltd, 2011: 19-49

[15] 李武军,王崇骏,张炜,等.人脸识别研究综述 [J]. 模式识别与人工智能, 2006, 19(1): 58-66

Li W J, Wang C J, Zhang W, et al. A survey of face recognition [J]. Pattern Recognition and Artificial Intelligence, 2006, 19(1): 58-66

[16] 严严,章毓晋.基于视频的人脸识别研究进展 [J]. 计算机学报, 2009, 32(5): 878-886

Yan Y, Zhang Y J. State-of-the-art on video-based face recognition [J]. Chinese Journal of Computers, 2009, 32(5): 878-886

[17] Owusu E, Zhan Y, Mao Q R. A neural-AdaBoost based facial expression recognition system [J]. Expert Systems with Applications, 2014, 41(7): 3383-3390

[18] Pong K H, Lam K M. Multi-resolution feature fusion for face recognition [J]. Pattern Recognition, 2014, 47(2): 556-567

[19] Kwak K C, Pedrycz W. Face recognition using fuzzy integral and wavelet decomposition method [J]. IEEE Transactions on Systems, Man, and Cybernetics-Part B, 2004, 34(4): 1666-1675

[20] Mallat S G. A theory for multiresolution signal decomposition: the wavelet representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1989, 11(7): 674-693

[21] Specht D F. Probabilistic neural networks [J]. Neural networks, 1990, 3(1): 109-118

[22] Kuncheva K I. Combining classifiers: Soft computing solutions [M]// Pal S K, Pal A, eds. Pattern Recognition: From Classical to Modern Approaches. World Scientific, 2001: 427-451