

基于改进的混合学习模型的手写阿拉伯数字识别方法

徐琴珍 杨绿溪

(东南大学信息科学与工程学院 南京 210096)

摘要: 在特征空间维数较高的手写阿拉伯数字识别问题中, 冗余的特征往往会意外增加学习模型刻画问题空间的复杂度, 影响手写阿拉伯数字识别的效率和精确度。该文提出了一种基于边界对特征的敏感度值进行特征选择的支持向量机树混合学习模型, 依据当前中间节点上的分类曲面对子样本空间中的样例特征的敏感程度选择特征, 在新构建的子样本集上训练子节点上的支持向量机。UCI 机器学习数据库中手写阿拉伯数字识别问题的仿真结果表明, 与其他算法相比, 该文提出的方法能够在提高或保持手写阿拉伯数字高识别精确率的同时, 精简问题空间, 从而简化混合学习模型的中间节点和整体结构。

关键词: 手写阿拉伯数字识别; 支持向量机树; 边界对特征的敏感度

中图分类号: TP391.43

文献标识码: A

文章编号: 1009-5896(2010)02-0433-06

DOI: 10.3724/SP.J.1146.2009.00064

An Improved Hybrid Learning Model Based Handwritten Digits Recognition Approach

Xu Qin-zhen Yang Lu-xi

(School of Information Science and Engineering, Southeast University, Nanjing 210096, China)

Abstract: This paper is concerned with the problem of handwritten digits recognition in high dimensional feature space. The residual feature information may bring undesirable complexity to the underlying probability distribution of the concept label for learning algorithm to capture. The recognition accuracy and efficiency of the so trained learning model are usually depressed. According to this situation, an improved confusion-crossed support vector machine tree is proposed. A feature selection process based on the sensitivity of the margin to a feature is presented for the training step of each support vector machine embedded in each internal node. The experimental results on optical handwritten digits recognition problem in UCI database indicate that the proposed approach achieves competitive or even better recognition accuracy in the condensed feature space. Further, it also obtains lower structure complexity on internal nodes and the whole hybrid learning model than the compared approaches.

Key words: Handwritten digits recognition; Support vector machine tree; Sensitivity of the margin to a feature

1 引言

随着社会信息化的不断发展, 手写阿拉伯数字的自动识别问题逐步引起了相关领域研究人员的密切关注, 在办公自动化、邮政地址自动识别、银行支票识别等领域的潜在应用前景十分广阔^[1]。手写阿拉伯数字识别问题可以归结为一种有监督学习问题, 即希望能够从给定的样本特征集中学习到分类所需要的知识或信息, 从而构建决策曲面。例如, 基于模式学习自适应函数神经网络的手写字体识别方法^[2], 基于广义回归神经网络和遗传算法相结合的方法^[3], 基于隐马尔可夫随机模型的方法^[1,4], 以及

本文作者在前期研究中提出的基于混淆交叉的支持向量机树学习模型(CSVMT)也可实现手写阿拉伯数字的识别^[5]。这些识别方法所面临的共同问题是: 学习或训练的结果能否最佳描述手写阿拉伯数字样本集中包含的关键知识, 而这些关键知识则包含在各维特征中。由于无法先验地指定一种最佳特征组合, 以实现手写阿拉伯数字识别问题空间的最佳描述, 而冗余的特征往往会意外增加学习算法刻画问题空间的复杂度, 构成“维度灾难”^[6], 进而降低学习的效率, 且可能增加学习模型复杂度^[7], 最终影响手写阿拉伯数字的识别效率和精确度。

就 CSVMT 学习模型而言, 对低维特征空间中的复杂多分类问题具有良好的泛化性和较高的识别精确率, 而对于特征空间维数较高的手写阿拉伯数字识别问题, 每个嵌入的支持向量机(SVM)的训练结果可能包含了冗余的特征信息, 从而可能导致

2009-01-06 收到, 2009-06-26 改回

国家自然科学基金(60702029)和东南大学人才引进科研启动费(4004001041)资助课题

通信作者: 徐琴珍 summer@seu.edu.cn

SVM 的决策曲面和混合学习模型的整体结构过于复杂。为了解决这一问题,本文提出了一种改进的混合学习模型手写字体识别方法—基于边界敏感度特征选择的 CSVMT 模型(FS-CSVMT)手写字体识别方法。特征选择的目标:实现以尽可能小的特征子集最精确地刻画手写阿拉伯数字识别的原始问题空间。FS-CSVMT 模型能够为每个嵌入的 SVM 选择不同的特征,即特征选择的过程和每次节点分裂(局部决策)密切相关。

本文的第2节简要介绍了 CSVMT 学习模型及其特性;第3节针对 FS-CSVMT 模型每个节点上不同的局部决策需要不同特征信息的特点,在基于最大输出信息的特征选择法基础上,提出了与 CSVMT 学习模型二叉树结构相结合的特征选择方法;第4节以 UCI 数据库中手写阿拉伯数字的识别问题为仿真,验证了基于 FS-CSVMT 学习模型的手写阿拉伯数字识别方法的性能,并与其他同类方法做了对比;最后总结本文工作。

2 基于混淆交叉的支持向量机树

CSVMT 学习模型的整体结构为二叉树(符号学习模型),中间节点嵌入了 SVM(非符号学习模型),因而是一种结合了符号学习模型与非符号学习模型特点的混合学习模型。二叉树结构使模型能够依据给定的教师信号或启发式产生的教师信号将原始问题分解到二叉树不同层次的节点上,通过逐层分解来解决复杂度较低的子问题;此外,与纯粹的决策树中间节点相比,嵌入的 SVM 能够在中间节点上提取更加复杂细致的特征信息。

SVM 的核函数会对 CSVMT 的识别性能产生较大的影响,而核函数的选择尚未形成确定的理论依据,近年来的支持向量机研究以高斯核、拉普拉斯核以及多项式核为最常用的几种核函数^[8], CSVMT 模型二叉树节点上的 SVM 也采用高斯核函数:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp\left[-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right] \quad (1)$$

运用高斯核函数的 SVM 的决策曲面性能与高斯核宽度 σ 以及惩罚参数关系密切,参数值设置不当可能造成训练样本上的过拟合或者欠拟合。CSVMT 学习模型降低了对这两个参数值设置的依赖,使 SVM 可以在更宽泛的参数值设置范围内获得相对稳定的泛化性能^[9]。

CSVMT 学习模型的二叉树结构决定了父节点的划分效果将直接影响其左右子树上训练子样本的分配,若父节点的决策曲面过于复杂,容易对分配到该节点的训练子样本过拟合。为降低这种风险,

我们提出了逐层递减的混淆交叉因子,使上层节点上的样例混淆交叉程度比其子树中间节点的交叉程度更充分。混淆交叉因子的收敛性将保证随着二叉树层次的加深,样例交叉程度逐层递减,避免无休止地交叉。设上层父节点 SVM_p 的两个子节点为 SVM_j 和 SVM_{j+1}, 分配到 SVM_p 上的训练样本子集为 \mathbf{S}_p , 则 SVM_p 上输入样例 \mathbf{x} 的空间变量为

$$\gamma_p(\mathbf{x}) = \sum_{i=1}^l \alpha_i y_i k(\mathbf{x}_i, \mathbf{x}) + b \quad (2)$$

其中 α_i 为拉格朗日乘子, \mathbf{x}_i 为支持向量, y_i 为该支持向量对应的类别, b 为偏置值。样例混淆交叉因子定义为

$$C_{\gamma_p, m} = \rho_0 \exp(-\lambda \cdot m) \bar{\gamma}_p \quad (3)$$

其中 m 为 SVM_j 和 SVM_{j+1} 所在的层数, $\rho_0 \in (0, 1)$ 为初始混淆交叉因子, $\bar{\gamma}_p = (1/|\mathbf{S}_p|) \sum_{\mathbf{x}_i \in \mathbf{S}_p} |\gamma_p(\mathbf{x}_i)|$, λ 控制交叉因子随着二叉树层次的增加而收敛的速度。 $C_{\gamma_p, m}$ 将取代简单的符号函数操作 $\text{sign}(\gamma)$, 成为训练样本在左右子树上分配的依据,混淆交叉后 SVM_j 和 SVM_{j+1} 上的训练样本子集 \mathbf{S}_j 和 \mathbf{S}_{j+1} 分别为

$$\mathbf{S}_j = \{\mathbf{x} | \mathbf{x} \in \mathbf{S}_p, \gamma_p(\mathbf{x}) \geq -C_{\gamma_p, m}\} \quad (4)$$

$$\mathbf{S}_{j+1} = \{\mathbf{x} | \mathbf{x} \in \mathbf{S}_p, \gamma_p(\mathbf{x}) \leq C_{\gamma_p, m}\} \quad (5)$$

混淆样例是指那些靠近决策曲面,因而容易被误分的样例。

$$\mathbf{S}_j \cap \mathbf{S}_{j+1} = \{\mathbf{x} | \mathbf{x} \in \mathbf{S}_p, |\gamma_p(\mathbf{x})| \leq C_{\gamma_p, m}\} \quad (6)$$

实现混淆交叉后,这些样例被同时保存在 SVM_j 和 SVM_{j+1} 的训练子样本集 \mathbf{S}_j 和 \mathbf{S}_{j+1} 中,从而使得那些对局部决策有重要影响的训练样例能够参与二叉树深层次的子树训练过程,构建更精细的局部决策超曲面,增强 CSVMT 学习模型的泛化性,这一特性已经在复杂多分类问题实验中得到了很好的验证^[9]。

3 FS-CSVMT 学习模型

SVM 的分类边界密切影响其泛化性,而分类边界对某一特征的敏感程度则刻画了该特征对分类边界的影响,因此选择最有效的特征子集在一定程度上有利于促进学习模型的结构简化及学习结果的泛化性增强。给定样本集 $\mathbf{S} = \{(\mathbf{x}_i, y_i), i = 1, 2, \dots, l\}$, 和核函数 $K(\cdot)$, 其中 $\mathbf{x}_i \in \mathbf{R}^N$, 对应的类别为 $y_i \in \{-1, +1\}$, 则 SVM 边界的平方倒数为

$$w^2 = \sum_j \alpha_j y_j K(\mathbf{x}_j, \mathbf{x}_j) \quad (7)$$

定义该边界对给定样本集上的第 n 维特征的敏感程度为

$$D_n(w^2) = \sum_i \left| \sum_j \alpha_i \alpha_j y_i y_j \frac{\partial K(\mathbf{x}_i, \mathbf{x}_j)}{\partial x_j^n} \right| \quad (8)$$

其中 x_j^n 表示向量 \mathbf{x}_j 的第 n 维特征。当 $K(\bullet)$ 为式(1)高斯核函数时, 可得分类边界对第 n 个特征的敏感程度为

$$D_n(w^2) = \sum_i \left| \sum_j \frac{1}{\sigma^2} \alpha_i \alpha_j y_i y_j k(x_i^n, x_j^n) (x_i^n - x_j^n) \right| \quad (9)$$

Sindhwani和Rakshit等提出了一种针对多分类SVM的特征选择方法——基于最大输出信息的特征选择方法^[7], 该方法中第 n 维特征的信用度取决于两个方面: (1) SVM边界相对于该特征的敏感度; (2) 每个二分类SVM的信用度。由于SVM最初是为了二分类问题设计的, 因此这种特征选择方法主要是针对多分类时, 需要多个二分类SVM按照一定规则组合完成多分类的情况, 特征选择的结果保持了高度一致性, 即每个二分类SVM都选用同样的特征子集进行训练。通过这种特征选择方法训练的多分类SVM学习模型, 其每个二分类SVM依然可能包含了部分冗余特征的信息, 而这些冗余的特征信息却可能是其它二分类SVM所必需的。

在多分类问题中, 很多情况下对于不同的局部决策曲面而言, 各维特征的重要性是随子问题而变化的, 这就表示各二分类SVM局部决策时所需要的特征可能是不同的。为此, 我们结合CSVMT模型分而治之的叉树结构, 提出了更加灵活的特征选择方法, 针对每个中间节点上局部决策曲面的不同情况进行特征选择, 使之更适用于CSVMT模型的训练。

在训练CSVMT学习模型的过程中, 各中间节点上的SVM根据当前划分到的训练样本子集实现局部决策曲面的构建。在不同的局部决策曲面中, 同一维特征的重要性往往会有变化, 这样就可以根据局部决策曲面构建的需要, 为每个嵌入的SVM选择有差异的特征子集, 从而精简子问题空间的特征信息, 实现CSVMT学习模型整体结构和中间节点学习过程的简化。由此可以看出, 各维特征在不同局部决策过程中的信用度可以直接定义为式(8)描述的局部决策边界对该维特征的敏感度值。为了实现嵌入SVM上的特征自组织选择的差异性, 需要同时控制特征子集的大小和成员选择, 本文在Sindhwani和Rakshit等人的研究基础上作了改进, 以分类边界对特征的敏感度值的局部和比率来优化各SVM上特征的自组织选择。分类边界对特征的敏感度值的局部和比率定义为

$$Sr = \frac{\sum_{i=1}^{m'} D_{n_i}}{\sum_{i=1}^N D_{n_i}}, m' \in \{1, 2, \dots, N\} \quad (10)$$

其中 D_{n_i} , $n_i \in \{1, 2, \dots, N\}$ 为敏感度值序列 $\{D_n, n = 1, 2, \dots, N\}$ 降序排列后对应的序列值, m' 为Sr达到给定的阈值 Sr^* 时选用的最少特征维数。式(10)描述的Sr在计算形式上与样本固有维数类似, 但意义完全不同。样本固有维数建立在近邻样本点的协方差矩阵特征值的局部和基础上, 对于每个样本点都必须计算近邻点及其协方差矩阵的特征值, 再得出每个样本点的固有维数, 样本集的整体固有维数由投票决定^[10], 计算过程比较复杂; 而 m' 的计算则依赖于边界对各维特征敏感度值 D_n , 在 D_n 的基础上直接按式(10)使Sr达到给定的值即可实现。

令局部和比率阈值为 Sr^* , 每个嵌入到中间节点的SVM上, 基于Sr的特征选择算法步骤如下:

(1) 在各中间节点上, 依据分配到的训练样本子集对SVM进行训练;

(2) 计算当前SVM分类边界对各维特征的敏感度值序列 $\{D_n, n = 1, 2, \dots, N\}$, 并对该序列值降序排列, 从而得到 $\{D_{n_i}, i = 1, 2, \dots, N\}$;

(3) 按式(10)计算Sr, 取满足 $Sr \geq Sr^*$ 的最小 m' 值, 作为当前SVM上选择的特征维数, 所选择的特征子集为 $\{n_i, i = 1, 2, \dots, m'\}$ 。

FS-CSVMT学习模型在每个中间节点上实现上述特征选择, 为每个嵌入的SVM构建有差异的精简的特征子集, 并在新构建的特征子集上训练SVM。令训练样本集 $\mathbf{S} = \{(\mathbf{x}_i, y_i), i = 1, 2, \dots, l\}$, 第 i 个样例的特征向量为 $\mathbf{x}_i \in R^N$, 该特征向量对应的类别为 $y_i \in \Omega (|\Omega| = c)$, c 为类别总数。FS-CSVMT学习模型的训练过程 $\text{Tree}(\mathbf{S}, C_{\gamma_p, m}, Sr^*)$ 如下所示:

输入: 训练样本集 \mathbf{S} , 令混淆交叉因子初始值 $C_{\gamma_0, 0} = \rho_0$, 局部和比率阈值 Sr^* ;

输出: FS-CSVMT学习模型 Tr 。

算法过程:

(1) 若当前训练节点为根节点, 则初始化FS-CSVMT模型的叉树结构, 输入各训练参数:

$\text{Initialize}(\text{Tr}, \mathbf{S}, C_{\gamma_p, m}, Sr^*)$, 否则执行步骤(2);

(2) 若分配到当前节点上的训练样本子集属于同一类, 则标记当前节点为叶节点 $\text{Leaf}(\mathbf{S})$, 终止当前子树的分支生长, 否则转至步骤(3);

(3) 根据当前节点上训练样本子集的类别, 采用启发式算法构建教师信号 \mathbf{S}_H ;

(4) 在 \mathbf{S}_H 的监督下训练当前节点上的SVM, 并根据计算得到的 D_n 和 Sr^* 选择特征, 创建特征选择后的训练样本子集 $\mathbf{S}_{\text{sub}} = \text{FS}(Sr^*, \mathbf{S}_H)$;

(5) 在 \mathbf{S}_{sub} 上训练当前中间节点上的支持向量机svm, 更新叉树结构: $\text{svm} = \text{TrainNode}(\text{Tr}, \mathbf{S}_{\text{sub}})$;

(6) 对左右子节点上的样本混淆交叉: $[\mathbf{LS}, \mathbf{RS}] =$

Cross(svm, $\mathbf{S}, C_{\gamma_p, m}$)), 并按照式(3)对混淆交叉因子逐层衰减: $C_{\gamma_{p_son}, m+1} = \text{Decrease}(C_{\gamma_p, m})$;

(7)递归训练左子树 $\text{Tree}(\mathbf{LS}, C_{\gamma_{p_son}, m+1}, \text{Sr}^*)$;

(8)递归训练右子树 $\text{Tree}(\mathbf{RS}, C_{\gamma_{p_son}, m+1}, \text{Sr}^*)$ 。

4 实验结果与分析

本文以UCI机器学习数据库中手写阿拉伯数字识别问题为仿真数据, 验证基于混合学习模型的手写字体识别方法的性能。仿真以随机抽取的2/3样例为训练样本, 剩下1/3样例用于测试。高斯核宽度 σ 设为一类中所有的点与另一类中最近样例点的距离均值, 高斯核的惩罚参数 $C = 500$, $\rho_0 = 0.3$, 衰减因子 λ 为0.1。以算法运行30次的平均值作为最终仿真结果。基于FS-CSVMT学习模型的手写阿拉伯数字识别方法与基于CSVMT学习模型的手写阿拉伯数字识别方法的仿真结果对比如表1所示, 其中Sr为边界敏感度值的局部和比率, N_{sv} 为中间节点上SVM的支持向量数, N_{node} 为中间节点总数, m' 为每个中间节点上的最小输入特征数, Prc表示模型的测试识别精确率。

表1中, FS-CSVMT模型的结构和识别精确率随着Sr的增加而变化。当Sr较低时, 问题空间被过

分简化, 一些对分类有贡献的非冗余特征被剔除, 导致中间节点上的分类曲面过于简单, 从而使学习模型的整体结构趋于复杂; 当Sr逐步增大时, 有用信息被进一步保留, 局部决策曲面进一步细化, 模型的整体结构趋于简单; 当Sr达到一定值时, FS-CSVMT的二叉树整体结构的大小不再变化, 此时, 随着有用信息量的增大, 中间节点上SVM的支持向量数 N_{sv} 的平均值随着Sr的增大不断增加, 使中间节点上构建的分类曲面不断细化, FS-CSVMT的手写字体识别精确率逐渐趋于稳定; 而Sr取适当值, 如Sr=0.95时, FS-CSVMT比CSVMT具有复杂度相对较低的中间节点($N_{sv}:103.69/122.25$), 同样简单的二叉树整体结构($N_{node}:9.0/9.0$), 更少的输入特征维数($m':41.57/64$), 而在手写阿拉伯数字的识别精确率上有了进一步提高(Prc:98.89/98.72)。此外, 即使局部和比率Sr取极限1.0时, FS-CSVMT学习模型各中间节点上的平均输入特征维数52.53仍然远低于总特征维数64, 这主要缘于FS-CSVMT模型在局部决策曲面的构建中摒除了那些对局部决策没有贡献的特征($D_n = 0$)。因此, 在适当的局部和比率Sr下, FS-CSVMT学习模型在剔除每个节点上的冗余特征信息后, 能够以更简单的局部决策曲面获得与CSVMT可比的手写字体识别精确率。

训练样本上学习得到的FS-CSVMT模型的结构示例如图1所示。其中 m' 为当前节点上选择的特征数, F 为选择特征的序号。图1示例说明, 各嵌入的SVM在训练局部决策曲面时不仅需要优化特征子集的成员, 同时也需要优化特征子集维数; 在二叉树的不同层次上, 甚至在同一层次的两个相邻子节点上, 训练局部决策曲面所选择的特征维数和成员都会有所变化。由此可知, 结合FS-CSVMT学习模型的特点进行特征选择能够对模型的训练起到积极的促进作用。

为说明基于FS-CSVMT的手写阿拉伯数字识别方法的特点, 本文将仿真结果与C4.5^[11], 基于列生成的线性规划boosting^[12]中最好的一种结果(AdaBoost), 以及Hsu研究对比的3种多分类支持向量机1-v-r M-SVM, 1-v-1 M-SVM, DAGSVM^[13]进行对比, 如表2所示。其中 N_{svm} 为SVM数, N_F 为采用的特征维数。从数值结果的对比可知, 基于FS-CSVMT的手写字体识别方法能够以复杂度相对较低的学习模型结构和局部决策曲面, 获得与其它基于SVM的识别方法可比的高识别精确率; 与基于C4.5和Adboost两种手写字体识别方法相比, 基于FS-CSVMT学习模型的手写字体识别方法具有更理想的识别精确率。

表1 FS-CSVMT 模型实验结果

方法	Sr	N_{sv}	N_{node}	m'	Prc (%)
FS-CSVMT	0.20	78.68	62.13	3.80	61.13
	0.25	46.47	76.00	4.89	78.37
	0.30	39.90	57.38	6.20	88.87
	0.35	49.16	33.63	7.46	91.60
	0.40	49.81	24.00	9.12	94.66
	0.45	64.66	14.25	10.83	95.97
	0.50	73.37	9.75	12.89	96.74
	0.55	77.81	9.88	14.64	97.21
	0.60	76.22	10.00	16.82	97.55
	0.65	82.90	9.00	19.29	98.07
	0.70	85.15	9.00	21.56	98.13
	0.75	92.22	9.00	24.81	98.46
	0.80	93.14	9.00	28.00	98.71
	0.85	96.92	9.00	31.49	98.69
	0.90	103.69	9.00	36.21	98.69
0.95	107.38	9.00	41.57	98.89	
1.00	117.20	9.00	52.53	98.90	
CSVMT	-	122.25	9.00	64.00	98.72

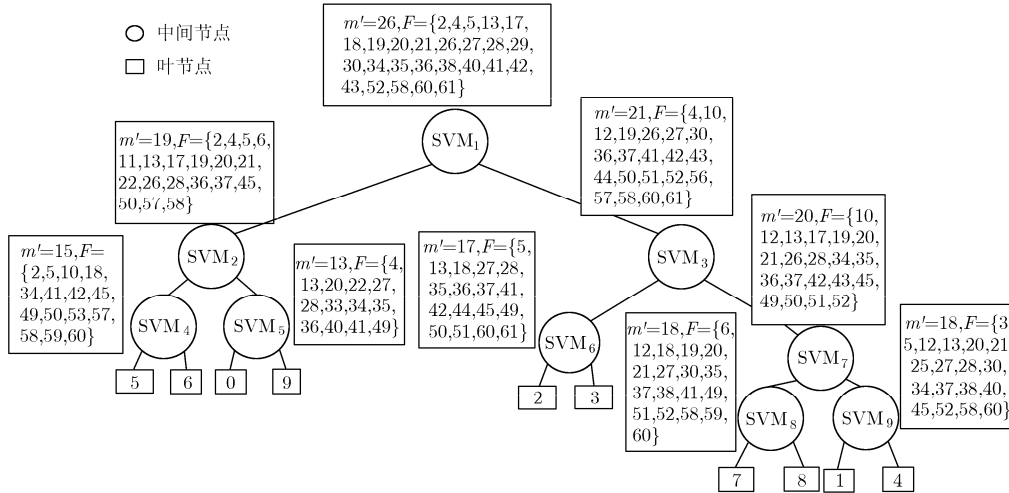


图1 FS-CSVM模型各中间节点上特征选择结果示例

表 2 FS-CSVMT 模型与其他模型的性能对比

识别方法	N_{sv}	N_{svm}	N_F	Prc (%)
C4.5	—	—	64	79.6
AdaBoost	—	—	64	95.1
1-v-r M-SVM	461.77	10.00	64	98.4
1-v-1 M-SVM	204.73	45.00	64	99.0
DAGSVM	204.73	45.00	64	99.0
FS-CSVMT	119.17	9.00	54.61	98.9

5 结束语

在特征空间维数较高的手写阿拉伯数字识别问题中, 由于无法先验地指定一种最佳特征组合, 以实现手写阿拉伯数字识别问题空间的最佳描述, 而冗余的特征往往会意外增加学习模型刻画问题空间的复杂度, 进而降低学习的效率, 且可能增加学习模型的复杂度, 最终影响手写阿拉伯数字的识别效率和精确度。针对这一情况, 本文提出了一种基于边界对特征的敏感度值进行特征选择的支持向量机树混合学习模型, 依据当前中间节点上的分类曲面对子样本空间中的样例特征敏感程度选择特征, 在新构建的子样本集上训练子节点上的支持向量机。最后以UCI机器学习数据库中64维手写阿拉伯数字特征数据作为仿真数据, 验证了基于FS-CSVMT混合学习模型的手写字体识别方法的性能, 并与其他方法作了比较。实验结果表明FS-CSVMT能够以复杂度相对较低的学习模型结构和局部决策曲面, 获得与其它识别方法可比甚至更高的识别精确率。

参考文献

[1] Awaidah S M and Mahmoud S A. A multiple

feature/resolution scheme to Arabic (Indian) numerals recognition using hidden Markov models. *Signal Processing*, 2009, 89(6): 1176-1184.

[2] Miao Kang and Dominic Palmer-Brown. A modal learning adaptive function neural network applied to handwritten digit recognition. *Information Sciences*, 2008, 178(20): 3802-3812.

[3] Polat Ö and Yildirim T. Genetic optimization of GRNN for pattern recognition without feature extraction. *Expert Systems with Applications*, 2008, 34(4): 2444-2448.

[4] Sabri Mahmoud. Recognition of writer-independent off-line handwritten Arabic (Indian) numerals using hidden Markov models. *Signal Processing*, 2008, 88(4): 844-857.

[5] 徐琴珍, 章品正, 裴文江, 杨绿溪, 何振亚. 基于混淆交叉支撑向量机树的自动面部表情分类方法. *中国图象图形学报*, 2008, 13(7): 1329-1334.

Xu Qin-zhen, Zhang Pin-zheng, Pei Wen-jiang, Yang Lu-xi, and He Zhen-ya. An automatic facial expression recognition approach based on confusion-crossed support vector machine tree. *Journal of Image and Graphics*, 2008, 13(7): 1329-1334.

[6] Melgani F and Bazi Y. Classification of electrocardiogram signals with support vector machines and particle swarm optimization. *IEEE Transactions on Information Technology in Biomedicine*, 2008, 12(5): 667-677.

[7] Sindhvani V, Rakshit S, Deodhare D, Erdogmus D, Principe J C, and Nivogi P. Feature selection in MLPs and SVMs based on maximum output information. *IEEE Transactions on Neural Networks*, 2004, 15(4): 937-948.

[8] Bo L F, Wang L, and Jiao L C. Training hard-margin support vector machines using greedy stagewise algorithm. *IEEE Transactions on Neural Networks*, 2008, 19(8): 1446-1455.

[9] 徐琴珍. 树型混合学习模型及其应用研究. [博士论文], 东南大学, 2006.

Xu Qin-zhen. Approach and application research of

- tree-structured hybrid learning models. [Ph. D. dissertation], Southeast University, 2006.
- [10] Saul L K and Roweis S T. Think globally, fit locally: Unsupervised learning of low dimensional manifolds. *Journal of Machine Learning Research*, 2004, 4(2): 119–155.
- [11] Quilan J R. C4.5: Programs for Machine Learning. San Mateo: Morgan Kaufmann Publishers, 1993: 17–26.
- [12] Bennett K P, Shawe-Taylor J, and Demiriz A. Linear programming boosting via column generation. *Machine Learning*, 2001, 46(1): 225–254.
- [13] Hsu C W and Lin C J. A comparison of methods for multiclass support vector machines. *IEEE Transactions on Neural Networks*, 2002, 13(2): 415–525.
- 徐琴珍: 女, 1977 年生, 讲师, 博士, 研究方向包括智能信息处理、超声图像处理、神经网络研究.
- 杨绿溪: 男, 1964 年生, 教授, 博士生导师, 研究领域包括通信信号处理、盲信号处理、神经网络研究.