

基于集成学习的音乐识别方法研究

邱 诚¹ 王大海² 任伟家² 邹 权¹

(厦门大学信息科学与技术学院 厦门 361005)¹ (佳木斯大学音乐学院 佳木斯 154002)²

摘 要 随着信息和多媒体的发展,音乐数据变得更加丰富。如何能够高效地检索和管理音乐数据是一个挑战。音乐分类是音乐信息检索领域的一个关键问题,可以很好地管理不同类别的音乐数据。基于 K-Means 聚类的循环静态选择策略是一种双层选择集成模型,它的第一层是通过基于聚类的选择策略在全部的基分类器中筛选出相互之间差异性较大的候选基分类器集合,然后通过第二层的循环静态选择策略进行第二轮的选择操作,并进行投票集成,以达到更好的集成效果。通过两组标准的音乐数据集验证了该策略的有效性。

关键词 音乐信息检索,音乐分类,选择性集成学习,聚类,机器学习

Research of Music Recognition Based on Ensemble Learning

QIU Cheng¹ WANG Da-hai² REN Wei-jia² ZOU Quan¹

(School of Information Science and Technology, Xiamen University, Xiamen 361005, China)¹

(College of Music, Jiamusi University, Jiamusi 154002, China)²

Abstract With the development of information and multimedia technologies, music data became more and more diversity. It is a challenge to retrieve and manage the music data. Music classification is the key issue of music information retrieval and can help us manage different kinds of music data. The static selective strategy of circulating combination based on K-Means clustering is a double-layer selective ensemble model. In the first layer, clustering algorithm is employed to choose the classifiers with high diversity. Then, via the circulating framework, classifier candidates are generated by the static selective strategy and voted for the last result. Experiments on two bench music datasets verify the performance of the proposed strategy.

Keywords Music information retrieval, Music classification, Selective ensemble learning, Clustering, Machine learning

1 引言

随着信息和多媒体技术的发展,获得数字化音乐的途径越来越多,比如网络、收音机广播等^[1],在欣赏大量各式各样的音乐的同时,如何能够高效地检索和管理它们成了我们所要面对的难题。正因为这样,近年来音乐信息检索(MIR)吸引了越来越多研究机构和音乐产业的关注,成为目前比较热门的研究领域^[1]。音乐信息检索主要解决的问题是在大规模的音乐数据集中对特定的音乐类型进行检索,比如流派、情感、作曲者和乐器等。

为了能够更好地进行音乐检索,前期的工作就是要对大量的音乐文件进行分类注释。如果乐曲分类注释得好,那么顾客能够非常方便地查找到他们所感兴趣的乐曲,而且不同类别的乐曲之间存在不同的属性,因此将乐曲进行分类注释也是为了能够更有效地管理它们。由于乐曲分类注释受到主观因素影响较为严重,因此之前这项工作基本是人工完成的^[2]。但是面对海量的音乐文件,人工分类注释的能力有限,而且这种做法违背了高效检索和管理音乐文件的初衷,如何自动和精确地进行音乐分类,成了人们解决这些难题的主要途径。因此,音乐分类成为音乐信息检索领域一个关键的基本问题也是情理之

中的,近几年,音乐信息检索领域的专家和学者们将越来越多的注意力集中在如何更好地进行音乐分类上,许多新技术被用于完成这项任务,使得音乐分类获得了前所未有的发展。

对于一个分类系统来说,特征提取和分类器学习是它的两个关键部件^[3]。特征提取是研究选择哪些特征集合能够更好地让分类系统区分不同实例;分类器学习是研究通过什么形式的法则能够使得获得的类标记和特征集合之间的映射关系更准确。音乐分类和其他方面的分类问题相比,存在一些独特的地方,比如音乐分类提取乐曲的音频信号作为特征集,但是如果想要设计出更加精确的音乐分类系统,也同样要从特征提取和分类器学习两个方面入手。本文主要研究通过设计分类器来提高乐曲识别的精度,文中所使用的音乐数据集是通过音乐分析软件(如 Marsyas^[4])提取获得的。

K 近邻(K-Nearest Neighbor, KNN)^[5]和支持向量机(Support Vector Machine, SVM)^[6]是两种常用的分类器,近年来有许多学者将它们直接或同其他手段融合后用于经过不同的特征提取手段获得的音乐数据集上。Tzanetakis G^[7]和 Pampalk E^[8]都采用 KNN 算法在他们各自所提取的音乐特征集中进行分类实验;对于 SVM 分类器, Fu Zhou-yu 和 Lu Guo-jun 在文献[9]中利用 Multiple Kernel Learning (MKL)^[10]和

到稿日期:2012-02-20 返修日期:2012-07-26 本文受国家自然科学基金(61001013, 61102136),福建省自然科学基金(2011J05158)资助。

邱 诚(1987-),男,硕士生,主要研究方向为选择性集成学习、多标记分类、音乐信息检索;邹 权(1982-),男,博士,主要研究方向为大规模数据挖掘方法与应用, E-mail: zouquan@xmu.edu.cn.

Stacked Generalization(SG)^[11]两种框架配合通过特征结合手段处理得到的特征集来提高 SVM 的分类精度。

除了以上两种常用的方法之外, Tzanetakis G 在文献[7]中还利用高斯混合模型(Gaussian Mixture Model, GMM)^[12]对音乐流派数据进行分类并将结果与 KNN 的分类效果进行对比; Lee 等人^[13]采用 Nearest Centroid(NC)进行分类; Panagakis I 等人^[14]第一次利用基于稀疏表示的分类器(Sparse Representation-based Classifier, SRC)方法对音乐数据集进行分类, SRC 是一种利用特征集中的稀疏性进行分类的新手段, 在文献[14]中所取得的效果超过了 SVM, 甚至使人们觉得 SRC 是最适合音乐分类的手段; 其他被用于音乐分类的工具还有 Convolutional Deep Belief Network(CDBN)^[15], 这种方法是对具有多层卷积神经网络(Convolutional Neural Network, CNN)^[16]方法的扩展。当然, 近几年也有许多集成学习的方法被用于音乐分类并取得了不错的效果, 如文献[17]中 Bergstra J 等人就利用 boosting 框架^[18]集成决策树对音乐数据进行分类。

尽管多种机器学习方法被应用于音乐分类, 但当类别标签较多时, 该问题仍是一个弱分类问题, 没有得到很好的解决。对于不同的特征提取方法, 也没有某一种分类器能够战胜其他所有的分类器。因此有研究者提出了多分类器融合的思想, 即集成学习。随着集成学习的提出, 大量选择性集成策略被应用于解决各种弱分类问题, 并取得了较好的效果^[19-23]。本文提出一种基于聚类的静态分类器选择算法来解决音乐分类的问题, 并取得了较好的效果。

分类器设计是模式分类中的一个标准主题^[3]。集成学习是机器学习和模式识别中比较活跃的领域, 它训练多个分类器来解决相同的问题。传统的机器学习方法只采用一种法则来训练数据, 而集成学习尝试构建多种法则并将它们结合在一起使用^[24]。在绝大多数的分类问题上, 从大部分的实验中可以看出, 集成学习系统相对于基学习器而言, 表现出了更加强大的预测能力, 其中我们比较熟悉的集成分类系统有 Boosting 和 Bagging 决策树。

2 基于 K-Means 聚类的循环静态选择策略

目前集成分类器已在多个领域得到应用, 包括生物信息学^[19, 20]、软件重构^[21]、人脸识别^[22]以及疾病诊断^[23]等。集成学习分类器如果包含过多的冗余分类器, 就会导致集成学习的泛化性下降, 以至于预测精度降低, 同时耗时情况也难以估计。面对集成学习所存在的种种问题, 周志华等人首先提出“选择性集成”的概念。所谓选择性集成学习, 就是首先独立训练多个基学习器, 然后通过一定的选择策略, 从全部的候选学习器中选取部分基学习器构成子集, 这个子集中的学习器对特定的数据集预测较好且各个学习器彼此之间存在较大差异性, 通过集成子集中的学习器可得到更好的预测效果。在实践中, 人们也证实了要想得到好的集成学习器, 基学习器的正确性和多样性是必须要满足的两个条件^[25], 因为这种做法可以使得基学习器之间互相弥补各自的错误和偏差。

本文所提出的选择性集成策略首先利用基于 K-Means 聚类算法选择策略(K-Means-Based Selective Strategy, KMSS)对全部的候选分类器进行第一轮筛选, 选取彼此之间差异性较大的分类器, 形成新的候选分类器集合。然后, 通过

基于循环框架(Circulating Combination, CC)的静态选择策略对新的候选子集中的分类器进行第二层筛选, 以进一步提高集成分类器的精确度, 整体流程如图 1 所示。




图 1 选择策略流程图

2.1 相互一致性度量 κ

差异性度量是选择性集成策略中不可缺少的一部分, 但是人们还没有找到一种绝对优越的差异性度量方法。目前差异性度量可以大致分为成对差异性度量和非成对差异性度量, 成对差异性度量有: Q 统计、相关性系数 ρ 、不一致性度量和双故障度量等; 非成对差异性度量有: 熵度量 E 、困难性度量 Θ 和相互一致性度量 κ 等^[26]。本文采用的差异性度量是相互一致性度量 κ , 它是一种非成对差异性度量方式, 它的数值越小, 说明差异性越大。相互一致性度量 κ 结合了全部分类器的平均准确率来度量差异性。

本文选择相互一致性度量 κ 作为差异性度量手段, 不只是因为非成对差异性度量在根据差异性度量结果预测系统性能方面比成对的差异性度量方法要好^[27], 还因为本文模型的第二层中用到了循环集成框架。相互一致性度量 κ 除了考虑分类器之间的预测差异性, 还考虑分类器的精度, 这样使得差异性度量对于组合序列中已经存在的分类器不会过于排斥, 降低了差异性度量对于同种分类器的敏感性, 增大了找出较好集成效果组合的可能性。

2.2 基于 K-Means 聚类算法的选择策略

基于聚类的选择性策略是构成现有的选择性学习策略的子集。除了本文使用到的基于 K-Means 聚类算法的选择策略之外, 还有文献[28-32]中采用层次凝聚的聚类算法、基于确定性退火的软聚类算法、基于谱系聚类法和核聚类算法等选择策略。本文选择性集成模型的第一部分是基于 K-Means 聚类算法的选择策略^[33], 最早是由 Lazarevic 和 Obradovic 提出的, 他们将所有基分类器对全部实例的预测结果看作一个矩阵, 将每个基分类器对全部实例的预测结果看作一个向量, 然后观测这些向量之间的欧式距离, 应用 K-Means 聚类算法将基分类器分成相互之间差异性较大的多个簇。本文以 Giacinto 和 Roli 定义的基分类器 C_s 和 C_t 之间的距离^[28]作为进行 K-Means 聚类的主要依据, 如式(1)所示:

$$d(C_s, C_t) = 1 - \text{Prob}(C_s \text{ fails}, C_t \text{ fails}), \forall C_s, C_t \in T \quad (1)$$

基于聚类的选择性策略在时间方面比其他的方法具有一定的优势, 首先通过 K-Means 聚类算法在较短的时间内从全部基分类器中筛选出一个基分类器彼此之间差异性较大的子集, 之后的操作都在这个子集上进行。这种做法完全是根据多样性是获得良好的集成效果的重要条件之一而进行的。为了能够更好地满足正确性的要求, 在形成子集的过程中, 从每个聚类中挑选单独训练时预测效果较好的基分类器作为该聚类的代表。因为第二部分的选择策略是在循环集成的框架下进行的, 我们对全部的基分类器先进行聚类筛选, 减少了第二层选择策略的负担, 并降低了可能因为冗余基分类器的过度

膨胀导致整体集成效果大幅下降的风险。因此,根据种种原因得出,先通过基于聚类的选择策略进行预处理是科学合理的,符合集成法则。

算法 1 KMSS(T, O, k)

```

input 基分类器集合  $T = \{C_1, C_2, \dots, C_l\}$ ;
      矩阵  $O = (o_{ij})_{l \times N}$  中元素  $o_{ij}$  表示基分类器  $C_i$  对实例  $x_j$  的预测结果状态(正确为 1, 错误为 0);
      k 表示聚类簇数。
output 基分类器集合  $S = \{C_1^*, C_2^*, \dots, C_s^*\}$ 
从矩阵  $O$  中随机选择 k 个向量  $\{O_1, O_2, \dots, O_k\}$  作为初始聚类中心;
repeat
    通过式(1)计算每个实例到聚类中心的距离;
    选择最近的聚类中心,并加入到该聚类中心所在的聚类;
    根据新产生的聚类,计算该聚类新的聚类中心;
until 每个聚类不再发生变化;
    取出 k 个聚类中对应预测效果最好的分类器,形成  $S = \{C_1^*, C_2^*, \dots, C_s^*\}$ 

```

2.3 循环集成框架下的静态选择策略

循环集成框架的基本思想是首先根据识别精度的需要设定初始可信度阈值 θ_0 , 令 $\theta = \theta_0$, 然后将分类器按照某种的策略一个接一个地进入分类器序列 P , 并对序列中的全部分类器进行集成, 如果效果达到可信度阈值, 就输出结果 R , 否则就依次选入基分类器。当全部基分类器都经过判定仍未达到可信度阈值, 就通过步长 $\Delta\theta$ 降低可信度阈值 $\theta = \theta - \Delta\theta$, 再重复上述步骤^[34]。目前在循环集成框架下的选择策略主要包括基于选择的方法和基于排序的方法, 在文献[34]中首先通过互补指数将全部的基分类器进行排序, 然后在循环框架下将排好序的基分类器进行集成, 循环集成框架提高了单轮的集成效果, 并且增强了系统的灵活性。第一层模型所进行的基于 K-Means 聚类的基分类器筛选已经为循环框架提供了良好的集成环境, 减少了候选基分类器的个数, 使得循环框架下的选择性策略能够对较少的基分类器进行集成, 达到了较好的集成效果。同时, 对于本文的循环集成框架, 为了避免在初始可信度阈值和步长设置不当时出现基分类器数量过早膨胀而影响预测精度的情况, 我们设置了循环集成的基分类器的上限值, 并记录差异性最大的分类器组合, 当循环集成的分类器数量超过上限值时, 就会调整分类器序列为具有最大差异性的分类器组合。这种做法进一步预防了基分类器数量膨胀带来的负面影响, 同时也是按照具有较大差异性的分类器组合拥有较高获得较好预测精度的潜力来进行设计的。

算法 2 CC(T, θ_0 , $\Delta\theta$, $N_{\text{threshold}}$)

```

input 基分类器集合  $T = \{C_1, C_2, \dots, C_l\}$ ;
       $\theta_0$  表示初始可信度;
       $\Delta\theta$  表示步长;
       $N_{\text{threshold}}$  表示组合序列中分类器数量上限。
output 基分类器集合  $S = \{C_1^*, C_2^*, \dots, C_s^*\}$ 。
initialize  $S = \emptyset, \theta = \theta_0, S_{\text{suboptimal}} = S$ ;
begin
    while  $\theta \geq 0$  do
        if  $|S| > N_{\text{threshold}}$ 
             $S = S_{\text{suboptimal}}$ 
        end if
        根据选择策略 M, 向 S 中添加分类器子集  $S' = \{C_1', C_2', \dots, C_s'\}$ ;
        if  $S(L_{\text{val}}) \geq \theta$ 

```

```

            Return(S);
        end if
        确定评优标准 P;
        if  $P(S) > P(S_{\text{suboptimal}}) \& \& |S| \leq N_{\text{threshold}}$ 
             $S_{\text{suboptimal}} = S$ ;
        end if
         $\theta = \theta - \Delta\theta$ ;
    end while
end

```

本文采用集成前序选择 (Ensemble Forward Sequential Selection, EFSS) 作为循环框架下的静态选择策略^[35]。它的思想是基于顺序前进法, 顺序前进法是将精度最优作为入选标准的自下而上的搜索方法, 并且已经在许多方面得到应用, 比如特征选择。集成前序选择法是按基分类器的精度大小顺序比较组合前后的差异性, 如果差异性有所提高, 进一步比较集成精度的升降, 最后判定是否将分类器加入集成序列中。本文中集成前序选择策略将相互一致性度量 κ 作为差异性度量指标, 然后将其自身通过循环框架封装之后作为本文的第二层模型。

3 实验结果和分析

将本文的双层选择集成模型在两组标准音乐分类数据集上进行分类, 并将得出的实验结果同其他方法进行比较, 以说明本文分类模型的优越性。实验采用 Intel(R) Core(TM) i3-2100CPU, 在怀卡托智能分析环境 (Waikato Environment for Knowledge Analysis, WEKA) 中进行。由于音乐数据集都为多类别型数据, 因此挑选 WEKA 中对多分类音乐数据集具有较好分类效果的多种基分类器 (如 k 近邻、支持向量机等) 作为初始的基分类器集合。通过选择原理各不相同的基分类器, 可以更好地获得彼此之间差异性较大的基分类器集合。同时没有刻意地进行参数优化, 这种做法有利于提高整体差异性, 而且在初始效果较一般的基分类器条件下能获得较好的集成效果, 这更能说明本文双层选择性集成模型的有效性。实验中采用简单多数投票法将多个基分类器进行集成, 取 5 次五折交叉验证的平均精度进行比较。

3.1 Homburg 标准音乐分类数据集

实验的第一组数据是来自文献[36]的 Homburg 数据集, 是一组专门用于音乐分类或者聚类的标准数据集。它是通过提取 1856 首来自 Garageband 网站上的歌曲中的 10s 片段得到的, 数据集总共包含 9 个流派, 包含各个流派的具体情况如图 2 所示。全部的音频样本都是采用 mp3 的格式进行编码的, 其采样频率和位速度分别为 44100Hz 和 128mbit/s。这组数据由 49 维特征构成, 其中主要包括频谱特征、相位空间特征等^[36]。

将设计的分类模型应用到全部 49 维特征集合上的分类效果, 同文献[2]中该数据集经过不同方式的特征优化之后用 KNN、SVM 和 Random 分类器得到的分类效果进行比较, 结果如表 1 所列。

从分类的效果上来看, 虽然 Random、KNN 和 SVM 采用经过 3 种特征提取方法 AM^[37]、TSPSF^[38] 和 ESA^[2] 优化的数据集进行了实验, 但其结果还是与本文设计的方法运用在全部特征集上的分类效果有一定的差距, 这主要是由基分类器自身的局限性所导致的。




图2 Homburg数据集流派分布

表1 Homburg数据集分类结果

分类器	特征集	分类精度(%)
Random	AM	22.39
	TSPS	21.68
	ESA	25.40
KNN	AM	35.83
	TSPS	47.40
	ESA	51.88
SVM	AM	40.81
	TSPS	51.81
	ESA	57.81
KMSSCC	全部	59.05

3.2 GTZAN流派数据集

实验中的第二组数据集来自 Marsyas 网站,它曾被文献[7]用于音乐分类而被人们所熟知。这组数据集中包括 1000 首不同风格乐曲中 30s 的音乐片段,总共包括 10 个流派,分别是 Blues、Classical、Country、Disco、Hiphop、Jazz、Metal、Pop、Reggae 和 Rock,各种流派所占的比例几乎相等,只有 Blues 和 Rock 之间有 1 首的偏差,其他流派均为 100 首。

本文的方法在全部的特征集上的分类效果要明显地好于其他的,而且可以看出,GTZAN 流派数据集上的分类效果基本好过 Homburg 数据集的分类效果,如表 2 所列。这主要是因为 Homburg 数据集提取的音乐片段为 10s,而 GTZAN 流派数据集提取的音乐片段为 30s,它为音乐识别过程提供了更多的特征,同时 GTZAN 流派数据集各种类别的分布较为平均也是产生较好的分类效果的条件之一。但是,在 SVM 分类器对两组数据集进行分类时,发现 Homburg 数据集上的分类效果要好于 GTZAN 流派数据集,这是因为前者的特征集有 49 维而后者的特征集有 125 维,而且表 1 中 SVM 实验的数据集都有不同特征选择方法的处理。文献[8, 39]通过对 GTZAN 数据集的特征选择使得 SVM 也获得了不错的分类效果,这些情况都说明了 SVM 分类器比其他的分类器对特征空间更敏感。

表2 GTZAN流派数据集分类结果

分类器	分类精度(%)
GMM	61
KNN	60
SVM	37
RBF	57
Gaussian	59
KMSSCC	73±5

结束语 文中将设计的聚类和基于循环集成的静态选择策略相结合的方法应用到两组标准的音乐数据集上进行分类,并将结果同其他的方法进行比较,均得到了良好的分类效果,证明了该方法的有效性。同时,从分类结果上可以看出,本文的方法虽然整体效果比较好,但是波动较大,这是我们今后工作中将要解决的问题之一。今后的工作还要利用不同的

音乐特征选择方法对数据进行预处理,再通过双层选择集成方法进行分类,以取得效果的进一步提升。

参考文献

- [1] Fu Zhou-yu, Lu Guo-jun, Ting Kai-ming, et al. A survey of audio-based music classification and annotation [J]. IEEE Trans on Multimedia, 2011, 13(2): 303
- [2] Aryafa K, Shokoufandeh A. Music genre classification using explicit semantic analysis [C]//Proc of the 1st Int ACM workshop on Music information retrieval with user-centered and multimodal strategies. New York: ACM, 2011: 33
- [3] Duda R O, Hart P E. Pattern classification [M]. New York: Wiley, 2000
- [4] Shen jialie, Shepherd J, et al. Intelligent music information systems; tools and methodologies [M]. Michigan: Idea Group Reference, 2007: 31
- [5] Cover T, Hart P. Nearest neighbor pattern classification [J]. IEEE Trans on Information Theory, 1967, 13(1): 21
- [6] Boser B E, Guyon I M, Vapnik V N. A training algorithm for optimal margin classifiers [C]//Proc of the fifth annual workshop on Computational learning theory. New York: ACM, 1992: 144
- [7] Tzanetakis G, Cook P. Musical genre classification of audio signals [J]. IEEE Trans on Speech Audio Process, 2002, 10(5): 293
- [8] Pampalk E, Dixon S, Widmer G. On the evaluation of perceptual similarity measures for music [C]//Proc of the 6th International Conference on Digital Audio Effects. London, 2003
- [9] Fu Zhou-yu, Lu Guo-jun, Ting Kai-ming, et al. On feature combination for music classification [C]//Proc of the 2010 joint IAPR international conference on Structural, syntactic, and statistical pattern recognition. Berlin: Springer, 2010: 453
- [10] Lanckriet G R G, Cristianini N, Ghaoui L E, et al. Learning the Kernel matrix with semi-definite programming [J]. The Journal of Machine Learning Research, 2004, 5: 27
- [11] Wolpert D. Stacked generalization [J]. Neural Networks, 1992, 5(2): 241
- [12] Aucouturier J, Pachet F. Music similarity measures: What's the use? [C]//Proc of Int Conf on Music Information Retrieval. Paris: IRCAM, 2002
- [13] Lee C H, Shih J L, Yu K M, et al. Automatic music genre classification based on modulation spectral analysis of spectral and cepstral features [J]. IEEE Trans on Multimedia, 2009, 11(4): 670
- [14] Panagakis I, Kotropoulos C, Arce G R. Music genre classification using locality preserving non-negative tensor factorization and sparse representations [C]//Proc of 10th Int Society for Music Information Retrieval Conference. Kobe: ISMIR, 2009: 249
- [15] Lee H, Largman Y, Pham P, et al. Unsupervised feature learning for audio classification using convolutional deep belief network [C]//Proc of Advances in Neural Information Processing Systems. British Columbia: NIPS, 2009
- [16] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition [J]. Proc of the IEEE, 1998, 86(11): 2278

元,本文给出的讨论是S粗集中的一个新的应用研究方向。

参 考 文 献

- [1] Pawlak Z. Rough sets[J]. International Journal of Computer and Information Sciences,1982,11,1-356
- [2] Shi Kai-quan. S-rough sets and its applications in diagnosis-recognition for disease[C]// IEEE Proceedings of the First International Conference on Machine Learning and Cybernetics, 2002, 1:50-54
- [3] Shi Kai-quan,Cui Yu-quan. F -decomposition and \bar{F} -reduction of S-rough sets[J]. An International Journal Advances in Systems Science and Applications,2004,4:487-499
- [4] Shi Kai-quan. S-rough sets and knowledge separation[J]. Journal of Systems Engineering and Electronics,2005,2:403-410
- [5] Shi Kai-quan,Chang Ting-cheng. One direction S-rough sets[J]. International Journal of Fuzzy Mathematics,2005,2:319-334
- [6] Shi Kai-quan. Two direction S-rough sets[J]. International Journal of Fuzzy Mathematics,2005,2:335-349
- [7] Wang Hong-yu, Liu Yu-lan, Shi Kai-quan. Memory Knowledge and its memory mining[J]. An International Journal Advances

in systems Science and Applications,2005,4:546-553

- [8] Shi Kai-quan,Cui Yu-quan. One direction S-rough decision and decision model[C]// IEEE proceedings of the Fourth International Conference on Machine Learning and Cybernetics. 2004, 3:1352-1356
- [9] Cui Ming-hui,Shi Kai-quan. f -heredity knowledge and f -heredity mining[J]. Journal of Systems Engineering and Electronics, 2006,1:101-106
- [10] Hu Hai-qing, Wang yan, Shi Kai-quan. S-rough communication and its Characteristics[J]. Journal of Systems Engineering and Electronics,2007,1:148-154
- [11] Hao Xiu-mei,Du Ying-ling. S-knowledge mining and its(f, \bar{f})-attribute transfer dependence[C]// IEEE Proceedings of the Fifth International Conference on Fuzzy Systems and Knowledge Discovery. 2008,2:202-206
- [12] 郝秀梅,付海艳,史开泉. S粗集和 \bar{F} -隐藏知识发现[J]. 系统工程与电子技术,2008,4:644-648
- [13] 郝秀梅,李君. 粗信息矩阵的数量特征[J]. 模糊系统与数学, 2011,2:156-162

(上接第187页)

- [17] Bergstra J,Casagrande N,Erhan D, et al. Aggregate features and ADA BOOST for music classification [J]. Machine Learning, 2006,65(2/3):473
- [18] Freund Y, Schapire R E. A decision-theoretic generalization of on-line learning and an application to boosting [J]. Journal of Computer and System Science,1997,55(1):119
- [19] Zhang Yuan-wei, Yang Yi-fan, Huan Zhang, et al. Prediction of novel pre-microRNAs with high accuracy through boosting and SVM [J]. Bioinformatics,2011,27(10):1436
- [20] 邹权,郭茂祖,刘扬,等. 类别不平衡的分类方法及在生物信息学中的应用 [J]. 计算机研究与发展,2010,47(8):1407
- [21] Jiang Yuan, Li Ming, Zhou Zhi-hua. Mining extremely small data sets with application to software reuse [J]. Software: Practice and Experience,2009,39(4):423
- [22] Geng Xin, Zhou Zhi-hua. Image region selection and ensemble for face recognition [J]. Journal of Computer Science and Technology,2006,21(1):116
- [23] Zhou Zhi-hua, Jiang Yuan, Yang Yu-bin, et al. Lung cancer cell identification based on artificial neural network ensembles [J]. Artificial Intelligence in Medicine,2002,24(1):25
- [24] Wang Gang, Hao Jin-xing, Ma Jian, et al. A comparative assessment of ensemble learning for credit scoring [J]. Expert Systems with Applications,2011,38(1):223
- [25] Ghodselahi A. A hybrid support vector machine ensemble model for credit scoring [J]. International Journal of Computer Applications,2011,17(5):1
- [26] Kuncheva L I, Whitaker C J. Measures of diversity in classifier ensembles and their relationship with the ensemble accuracy [J]. Machine Learning,2003,51(2):181
- [27] Shipp C A, Kuncheva L I. Relationships between combination

methods and measures of diversity in combining classifiers [J]. Information Fusion,2002,3(2):135

- [28] Giacinto G, Roli F. An approach to the automatic design of multiple classifier systems [J]. Pattern Recognition Letters, 2001, 22(1):25
- [29] Bakker B, Heskes T. Clustering ensembles of neural network models [J]. Neural Networks,2003,16(2):261
- [30] 傅强. 选择性神经网络集成算法研究 [D]. 杭州:浙江大学,2007
- [31] 郭红玲. 多分类器选择关键技术研究 [D]. 镇江:江苏大学,2007
- [32] Cheng X Y, Guo H L. The technology of selective multiple classifiers ensemble based on kernel clustering [C]// Proc of the 2nd Symp on Intelligent Information Technology Application. Shanghai: IEEE,2008:146
- [33] Lazarevic A, Obradovic Z. Effective pruning of neural network classifier ensembles [C]// Proc of Int Joint Conf on Neural Networks. Washington DC: IEEE,2001:796
- [34] 郝红卫,王志彬,殷绪成,等. 分类器的动态选择和循环集成方法 [J]. 自动化学报,2011,37(11):1290
- [35] 张春霞,张讲社. 选择性集成学习算法综述 [J]. 计算机学报, 2011,34(8):1399
- [36] Hornburg H, Mierswa I, et al. A benchmark dataset for audio classification and clustering [C]// Proc of Int Conf on Music Information Retrieval. London: INRIA, 2005
- [37] Lartillot O, Toivainen P. MIR in Matlab(II): A toolbox for musical feature extraction from audio [C]// Proc of the 10th Conf on Digital Audio Effects. Bordeaux: DAFX, 2007
- [38] Mierswa I, Morik K. Automatic feature extraction for classifying audio data [J]. Machine Learning,2005,58(2/3):127
- [39] Li Tao, Ogihara M. Toward intelligent music information retrieval [J]. IEEE Trans on Multimedia,2006,8(3):564