

采用潜在概率语义模型和 K 近邻分类器的音频分类算法

辛欣^{1,3}, 陈曙东^{2,3}, 仝明磊⁴, 胡文皓^{1,3}, 刘陈伟^{1,3}, 葛浩栋³

(1. 中国科学院大学 电子电气与通信工程学院, 北京 100049;

2. 中国科学院微电子研究所, 北京 100029;

3. 中国物联网研究发展中心, 江苏 无锡 214135;

4. 上海电力学院 电子与信息工程学院, 上海 200090)

摘要: 提出一种基于潜在概率语义(PLSA)模型和 K 近邻分类器的音频分类算法. 首先, 将信号特征向量送入潜在概率语义模型中训练, 获得声音主题词袋模型; 然后, 使用 K 近邻分类器(KNN)进行分类. 实验结果表明: 与传统的 K 近邻分类算法相比, 提出的算法在分类效果上有较明显的改善.

关键词: 梅尔频率倒谱系数; 词-频共现矩阵; 声音主题词袋模型; 潜在概率语义模型; K 近邻分类器
中图分类号: TP 391 **文献标志码:** A

音频分类是异常声音检测系统中的重要模块, 可以依据音频特征区分不同的音频信号. 在音频分类研究中, Radhakrishnan 等^[1]给出在电梯里检测罪案的音频分类系统框架. 该系统提取梅尔倒谱系数(Mel frequency cepstral coefficients, MFCC)特征, 用高斯混合模型(GMM)进行分类和识别报警声、撞墙声等声音事件. Atrey 等^[2]采用过零率 ZCR 和线性倒谱系数(linear frequency cepstral coefficient, LFCC)等特征参数, 使用 GMM 模型进行分类. 结合词袋模型, Aucouturier^[3]提出了对应的帧袋模型, 将音频中的一些连续的音频帧作为一个整体提取相应的音频特征. 冀中等^[4]提出了一种与 HMM 相结合的分层音频分类算法. Zeng 等^[5]采用一些常用的音频特征, 如梅尔倒谱系数、声音功率等进行聚类 and 分类, 利用潜在概率语义模型(PLSA)对音乐片段进行分类. 容宝华^[6]提出了一种基于 MFCC 的简化的特征, 选取最近邻分类器和 K 近邻分类器, 对音频进行分类. 目前, 音频分类算法在异常声音监测系统中的作用仍然不够理想. 为了改善分类准确率, 本文在传统的 K 近邻分类算法基础上进行改进, 在提取音频信号特征以后不立即进行分类, 而是先送入 PLSA 概率语义模型获取声音主题词袋模型, 降低语音信号特征矩阵的维数, 再使用分类器进行分类.

1 音频分类算法

算法分为 3 个模块: 特征提取与处理模块、概率潜在语义模型模块和分类器模块, 分别完成特征矩阵提取、获取声音主题词袋模型和分类功能.

1.1 特征提取与处理

由于梅尔频率倒谱系数含有语义信息, 并结合人耳感知特性与语音信号的产生机制, 具有良好的识别能力和抗噪性能. 而差分倒谱系数能表现出 2 个音频帧之间的关联, 体现帧与帧之间的信息量. 因此, 选择提取前 12 维的 MFCC 系数和 12 维的 MFCC 一阶差分系数.

在特征提取之前, 需要对每一段音频进行预处理. 首先, 对原始音频信号进行预加重处理, 以提升高

收稿日期: 2015-09-18

通信作者: 陈曙东(1977-), 女, 研究员, 博士, 主要从事大数据管理的研究. E-mail: chenshudong@ciotc.org.

基金项目: 江苏省基础研究计划(自然科学基金)面上项目(BK20141116)

频部分的能量,减少尖锐噪声的影响;然后,分割音频为 1 s 大小的片段,相邻片段间无重叠部分;再对每个片段加汉明窗形成帧,帧长约 23 ms,相邻帧之间有 50% 的重叠部分.特征提取流程,如图 1 所示.

对得到的语音信号进行滤波、去噪,获取 24 维 MFCC 特征向量.类似于文本文件,每一段语音信号相当于一篇文本,文本中的词对应语音信号中的 MFCC 帧向量.对于已知类别的语音信号训练集,由于每段语音信号长度不一样,假如第 i 个语音信号 d_i 包含 M 帧,每一帧是 N 维,那么每一个语音信号表示为 $d_i = \{\omega_1, \omega_2, \omega_3, \dots, \omega_M\} \in \mathbf{R}^{M \times N}, i = 1, 2, 3, \dots, n$.

全部音频文件构成一个 $V \times N$ 的矩阵,其中, $V = M \times n$. 这个矩阵是一个由帧向量构成的全部特征集合,进而可以得到一个 $V \times n$ 的词-频共现矩阵 $T_{i,j} = \text{num}(\tau_j, d_i)$,它由音频文件在这个特征集中出现的频率构成.对于测试音频文件(语音信号)集 $d_{\text{test},i}, i = 1, 2, 3, \dots, n_{\text{test}}$,同样会得到一个 $V \times n_{\text{test}}$ 的词-频共现矩阵 $T_{\text{test}} = \text{num}(\tau_j, d_{\text{test}})$.

1.2 概率潜在语义分析模型

概率潜在语义分析模型(probabilistic latent semantic analysis, PLSA)通过^[7]奇异值分解,将高维词汇-文档共现矩阵降到低维的潜在语义空间,使表面上不相关的词汇能体现深层次的语义联系,从而能解决部分文档语义分析中同义词与异义词的问题.

在 PLSA 的方法中,将隐含变量 $z \in Z = \{z_1, z_2, z_3, \dots, z_k\}$ 与词汇 $w \in W = \{\omega_1, \omega_2, \dots, \omega_M\}$ 在文档 $d \in D = \{d_1, d_2, \dots, d_N\}$ 中出现的频率(词频共现矩阵)联系起来,该统计模型表示为^[8]词汇与文档的联合概率.

$P(d_i)$ 是每段语音信号出现的概率, $P(z_k | d_i)$ 表示潜在主题类别 z_k 的条件概率, $P(\omega_i | z_k)$ 表示在潜在主题 z_k 下产生音频帧 ω_i 的概率,即

$$P(d_i, \omega_j) = P(d_i)P(\omega_j | d_i), \quad (1)$$

$$P(\omega_j | d_i) = \sum_{k=1}^K P(\omega_j | z_k)P(z_k | d_i). \quad (2)$$

PLSA 模型假设词-文档对之间相互独立,潜在语义词 z_k 在词和文档上的分布独立.模型给出目标函数为

$$L = \sum_{i=1}^N \sum_{j=1}^M f(d_i, \omega_j) \log P(d_i, \omega_j).$$

上式中: $f(d_i, \omega_j)$ 为词汇 ω_j 在文档 d_i 中的概率.

采用 EM 算法求解参数,有如下 2 个步骤.

步骤 E

$$P^{(r)} = (z_k | d_i, \omega_j) = \frac{P^{(r-1)}(\omega_j | z_k)P^{(r-1)}(z_k | d_i)}{\sum_{k=1}^K P^{(r-1)}(\omega_j | z_k)P^{(r-1)}(z_k | d_i)}, \quad (3)$$

步骤 M

$$P^{(r)}(\omega_j | z_k) = \frac{\sum_{i=1}^N f(d_i, \omega_j)P^{(r)}(z_k | d_i, \omega_j)}{\sum_{j=1}^M \sum_{i=1}^N f(d_i, \omega_j)P^{(r)}(z_k | d_i, \omega_j)}, \quad (4)$$

$$P^{(r)}(z_k | d_i) = \frac{\sum_{j=1}^M f(d_i, \omega_j)P^{(r)}(z_k | d_i, \omega_j)}{\sum_{k=1}^K \sum_{j=1}^M f(d_i, \omega_j)P^{(r)}(z_k | d_i, \omega_j)}. \quad (5)$$

通过不停地迭代步骤 E 和步骤 M,直到收敛,使得 L 最大化.训练结束后,得到的 $P(z_k | d_i)$ 即为声

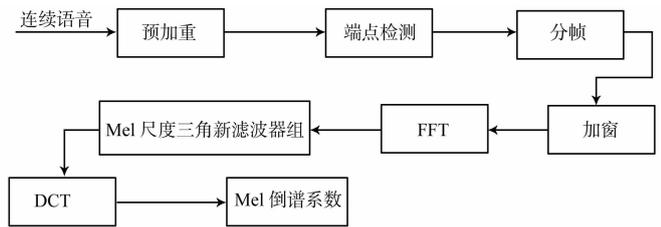


图 1 特征提取流程图

Fig. 1 Feature extraction flow chart

音主题词袋模型. 而对于测试语音, 则得到 $P(z_k | d_{\text{test}})$. $P(z_k | d_i)$ 和 $P(z_k | d_{\text{test}})$ 作为分类器的输入进行分类. 由于文中算法是在 K 近邻算法上的改进, 所以选择 K 近邻(K-nearest neighbor, KNN)分类器.

1.3 分类器

K 近邻是一种基本分类与回归方法^[9]. 设特征空间 χ 是 n 维实数向量空间 \mathbf{R}^n , $\mathbf{x}_i, \mathbf{x}_j \in \chi$, $\mathbf{x}_i = (x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(n)})^T$, $\mathbf{x}_j = (x_j^{(1)}, x_j^{(2)}, \dots, x_j^{(n)})^T$, $\mathbf{x}_i, \mathbf{x}_j$ 的 L_p 距离为

$$L_p(\mathbf{x}_i, \mathbf{x}_j) = \left(\sum_{l=1}^n |x_i^{(l)} - x_j^{(l)}|^p \right)^{1/p}, \quad p \geq 1. \quad (6)$$

当 $p=2$ 时, L_p 称为欧氏距离(Euclidean distance). 文中算法的 KNN 采用欧氏距离.

K 近邻算法具体如下.

输入: 训练数据集

$$T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}.$$

其中: $\mathbf{x}_i \in \chi \subseteq \mathbf{R}^n$ 为训练实例的特征向量; $y_i \in \gamma = \{c_1, c_2, \dots, c_k\}$ 为实例的类别, $i=1, 2, \dots, N$.

特征向量 \mathbf{x} 为 $P(z_k | d_i)$, y 通过人工方法标注为已知的. 测试特征向量 \mathbf{x}_{test} 为 $P(z_k | d_{\text{test}})$.

输出: 实例 \mathbf{x}_{test} 所属的类 y .

1) 根据距离度量, 在训练集 T 中找出与 \mathbf{x}_{test} 最近邻的 k 个点, 涵盖 k 个点的 \mathbf{x} 的邻域记为 $N_k(\mathbf{x})$.

2) 在 $N_k(\mathbf{x})$ 中, 根据分类决策准则(如多数表决规则)决定 \mathbf{x} 的类别 y , 即

$$y = \arg \max_{c_j} \sum_{\mathbf{x}_i \in N_k(\mathbf{x})} I(y_i = c_j), \quad i = 1, 2, \dots, N; \quad j = 1, 2, \dots, k. \quad (7)$$

式(7)中: I 为指示函数, 即当 $y_i = c_j$ 时, I 为 1; 否则, I 为 0.

2 实验与结果分析

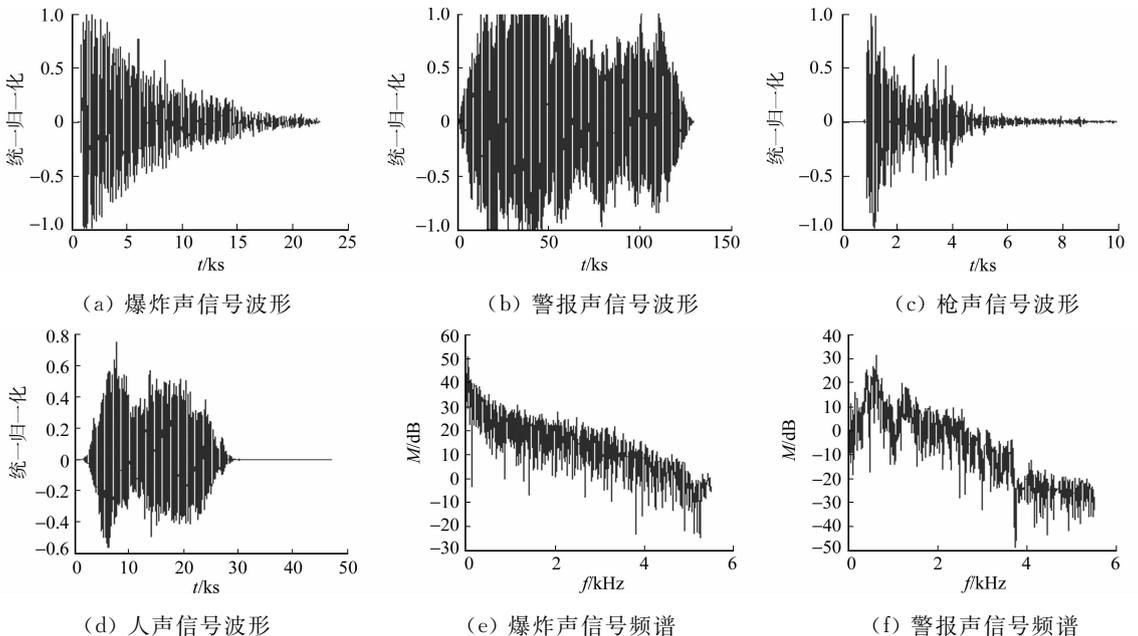
2.1 训练样本

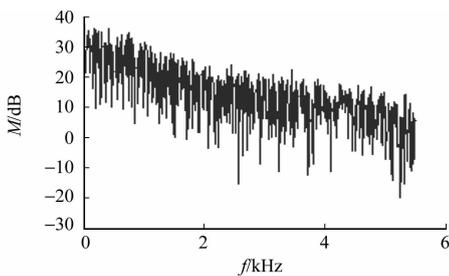
为了验证文中算法的有效性, 采用已获得标记后的音频样本集, 在单机实验环境中验证, 并与传统的 KNN 算法作对比.

1) 测试环境搭建: 4 GB 内存的 PC 机; Windows 7 操作系统; Matlab R2010b.

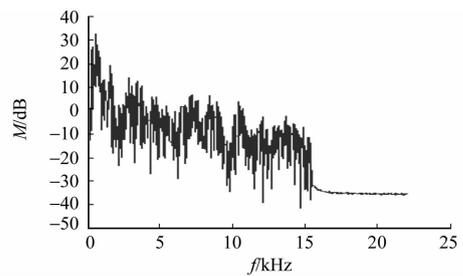
2) 测试数据集: 4 类音频文件, 分别是爆炸声、枪声、警报声、人声(呼救声). 其中, 训练声音文件 192 个, 测试音频文件 90 个. 声音是未经过去噪的原始语音.

这 4 类声音是异常声音检测系统中最重要的检测对象, 能够检测出这几种声音有很重要的实际价值. 因此, 实验中以此为测试数据集. 训练语音的各类别样本, 如图 2 所示. 图 2 中: t 为时间; f 为频率;





(g) 枪声信号频谱



(h) 人声信号频谱

图 2 训练语音波形图和频谱图

Fig. 2 Training voice waveform and spectrum

M 为幅度.

2.2 实验验证

分别提取训练声音信号和测试声音信号的 MFCC 和一阶差分 MFCC 特征后, 构建词-频共现矩阵, 送入 PLSA 模型进行训练获得 $P(z_k | d_i)$ 和 $P(z_k | d_{\text{test}})$, 再送入 KNN 分类器中, 得到分类结果.

使用 K 近邻分类, 当 k 取值不同时, 分类的准确率是不同的. 当 k 取值不同时, 使用 PLSA+KNN 的分类方法与直接使用 KNN 分类方法的结果对比, 如图 3 所示. 图 3 中: η 为分类准确率; k 为最近邻的数目.

由图 3 可知: 当 $k=11$ 时, 分类准确率最高. 取 $k=11$, 对比其他分类方法的准确率 (η), 如表 1 所示.

表 1 $k=11$ 时不同算法分类结果对比Tab. 1 Comparisons of classification results when k is taken as 11

| 算法 | PLSA+KNN | KNN | PLSA+SVM |
|-----------|----------|-------|----------|
| $\eta/\%$ | 38.89 | 35.56 | 37.78 |

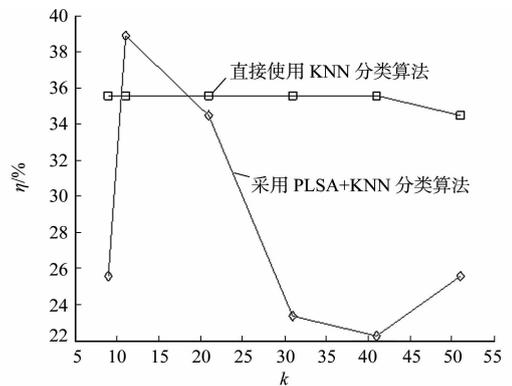
由于文中实验数据处理及环境、参数设置的问题, 实验的结果与原始论文中的算法的结果之间可能有所差别.

2.3 结果分析

在实验中, 对于 4 类音频文件组成的训练集, 先构建词-频共现矩阵, 使用 PLSA 模型计算隐含主题类别的条件概率, 获得声音主题词袋模型, 再送入 KNN 分类器的方法比直接用 KNN 分类器处理词频矩阵的分类方法有更高的准确率, 准确率提高了大约 3.3%. 对于 KNN 分类器, k 值的选取也会影响到算法的分类精度. 文中算法对比了 PLSA+KNN 算法与传统 KNN 算法分别在 k 取最优值时的分类效果. 此外, 如果使用 SVM^[10] 分类器 (PLSA+SVM), 相较于 KNN 也有约 2.2% 的提高. 而同样是先送入 PLSA 模型中, 选择了不同的分类器时, PLSA+KNN 算法比 PLSA+SVM 算法有更好的性能表现, 提高了约 1.1%. 由于音频数据样本量少、特征提取方法等原因, 整体准确率偏低. 但是, 不同分类方法之间的区别还是较为明显的. 实验结果表明: 文中算法相较于传统算法, 在分类效果上有较明显的改善.

3 结束语

音频分类模块属于异常声音监测系统的重要模块. 目前, 采用的传统分类算法在分类效果方面不能很好地满足实际的需求. 提出一种基于潜在概率语义模型和 K 近邻算法的音频分类算法. 该算法首先对音频信号进行信号处理获取特征矩阵, 然后送入潜在概率语义模型, 再使用 K 近邻分类器进行分类. 实验中, 将文中算法应用于 4 类音频文件组成的数据集, 并与传统的 KNN 分类算法进行了分类效果对比. 结果表明: 文中算法在分类效果方面有较明显的改善. 同时, 验证了使用其他分类器 (PLSA+SVM) 时的分类效果. 由于验证用的实验对象数量和品种不够, 算法本身也有一些局限, 整个研究还有进一步提升的空间, 未来将继续改进.

图 3 k 取不同值时分类结果Fig. 3 Classification results of different values of k

参考文献:

- [1] RADHAKRISHNAN R, DIVAKARAN A. Systematic acquisition of audio classes for elevator surveillance[C]// SPIE Image and Video Communications and Processing. San Jose: [s. n.], 2005: 64-71.
- [2] ATREY P K, MADDAGE N C, KANKANHALLI M S. Audio based event detection for multimedia surveillance [C]// International Conference on Acoustics, Speech and Signal Processing. Toulouse: IEEE Press, 2006: 3-5.
- [3] AUCOUTURIER J J. The bag-of-frames approach to audio pattern recognition: A sufficient model for urban soundscapes but not for polyphonic music [J]. Journal of Acoustical Society of America, 2007, 122(2): 881-891.
- [4] 冀中. 面向新闻视频内容分析的音频分层分类算法[J]. 计算机应用研究, 2009, 26(5): 1673-1675.
- [5] ZENG Zhi, ZHANG Shuwu. A novel approach to musical genre classification using probabilistic latent semantic analysis model [C]// International Conference on Multimedia and Expo. New York: IEEE Press, 2009: 486-489.
- [6] 容宝华. 基于最小距离的音频分类方法的研究[J]. 电声技术, 2012, 36(11): 46-51, 65.
- [7] 张宝印. 面向情感的电影背景音乐分类方法研究[D]. 武汉: 华中科技大学, 2011: 26.
- [8] 石晶, 戴国忠. 基于PLSA模型的文本分割[J]. 计算机研究与发展, 2007, 44(2): 242-248.
- [9] 李航. 统计学习方法[M]. 北京: 清华大学出版社, 2013: 37-40.
- [10] 郭金玲, 王文剑. 一种基于数据分布的SVM核选择方法统计学习方法[J]. 华侨大学学报(自然科学版), 2013, 34(5): 525-528.

Audio Classification Algorithm Using Probabilistic Latent Semantic Models and K Nearest Neighbor Classifier

XIN Xin^{1,3}, CHEN Shudong^{2,3}, TONG Minglei⁴,
HU Wenhao^{1,3}, LIU Chenwei^{1,3}, GE Haodong³

(1. School of Electronic, Electrical and Communication Engineering,
University of Chinese Academy of Sciences, Beijing 100049, China;

2. Institute of Microelectronics, Chinese Academy of Sciences, Beijing 100029, China;

3. China R&D Center for Internet of Things, Wuxi 214135, China;

4. School of Electronics and Information Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: The paper proposed an audio classification algorithm based on probabilistic latent semantic analysis model (PLSA) and K-nearest neighbor classifiers (KNN). The algorithm first feed the audio signal feature vector into the PLSA model training to get a bag of sound frames models, then classify with the KNN classifier. Experimental results showed that the proposed classification algorithm has better classification effect compared with the traditional KNN algorithm.

Keywords: Mel frequency cepstral coefficients; word-frequency of co-occurrence matrix; bag of sound frames models; probabilistic latent semantic analysis model; K-nearest neighbor classifiers

(责任编辑: 黄晓楠 英文审校: 吴逢铁)