

A Novel Weighted Mel-Filter Bank in Wireless Sensor Networks *

ZHAO Junyu, WEI Jianming, PAN Qiang, LIU Haitao *

(Key Laboratory of Wireless Sensor Network and Communication, Shanghai Institute of Microsystem and Information Technology,
The Chinese Academy of Sciences, Shanghai 200050, China)

Abstract : This paper develops a novel Weighted Mel-filter Bank (WMFB) used in acoustic feature extraction for vehicle classification. This novel filter bank emphasizes the frequency spectrum where the vehicles are more distinct while attenuates the frequency spectrum where the vehicles are less distinct by placing different weights on separated frequency. The discriminating ability of weighted Mel-filter bank obviously increases compared with conventional Mel-filter bank. Simulated and experimental results both show that WMFB not only shows more effectiveness in extracting distinct features between different types of vehicles than two frequently used feature extraction methods and achieves higher correct recognition ratio, but also reduces the complexity of computation.

Key words : wireless sensor network; feature extraction; Weighted Mel-filter Bank (WMFB); correct recognition ratio; complexity of computation

EEACC:6140B

无线传感器网络中一种新型加权 Mel 滤波器组 *

赵俊钰, 魏建明, 潘 强, 刘海涛 *

(中国科学院上海微系统与信息技术研究所无线传感网与通信中科院重点实验室, 上海 200050)

摘 要 : 提出了一种提取车辆声音特征的新型加权 Mel 滤波器组进行车辆的识别。这种新型滤波器组通过赋予各离散频率不同的权重, 突出车辆频谱之间差异较大频段的信息, 弱化较为相似频段的信息。相比于传统的 Mel 滤波器组, 加权 Mel 滤波器组的识别能力得到了显著提高。仿真和实测结果均表明, 与两种常用的特征提取方法相比, 加权 Mel 滤波器组不仅能更有效地提取不同类型车辆间的差异信息, 获得更高的正确识别率, 还降低了计算复杂度。

关键词 : 无线传感器网络; 特征提取; 加权 Mel 滤波器组 (WMFB); 正确识别率; 计算复杂度

中图分类号: TP391

文献标识码: A

文章编号: 1004-1699(2009)06-0844-08

随着无线通信, 计算机, 传感器技术的迅猛发展, 无线传感器网络应运而生。传感器节点通过感知目标的特征信息对不同目标进行分类识别是无线传感器网络的主要应用之一。在各种类型的传感器中, 声音传感器成本较低, 进行车辆识别效果较好^[1-2], 适合大批量铺设在需要进行车辆识别的无线传感器网络中。作为分类识别中关键的一步, 特征提取的质量对分类识别效果有很大的影响。在不同应用背景下, 需要根据目标声音信号的特征设计有针对性的特征提取算法。

本文提出了一种新的加权 Mel 滤波器组 (WMFB) 用于提取声音信号的倒谱系数作为特征, 进行轮式车和履带车的分类识别。通过提取训练信号的频谱, 可以分析出轮式车和履带车的频谱范围以及它们在各离散频率点的频响差异。针对两类车的频谱范围设计相应的 Mel 滤波器组, 根据两类车在各离散频率点上幅度的差异赋予各频点不同的权重, 从而形成加权 Mel 滤波器组。利用加权 Mel 滤波器组提取 SensIT 数据库^[3]中部分节点采集的声音信号的特征和实时采集数据的特征后分类得到的

基金项目: 上海市科委重点项目资助 (07dz15011)

收稿日期: 2009-02-20 修改日期: 2009-03-21

正确识别率以及计算复杂度的分析均表明:面向无线传感器网络的车辆识别时,针对车辆声音信号特性改进的加权 Mel 滤波器组可以获得比现有的一些常用特征提取算法更高的正确识别率,同时还降低了计算复杂度。

本文第 1 节简要总结现有的一些无线传感器网络中声音信号特征提取算法。第 2 节详细介绍并分析加权 Mel 滤波器组的设计流程。第 3 节利用加权 Mel 滤波器组提取 SensIT 数据库中轮式车和履带车的声音信号并对分类识别结果进行仿真。第 4 节给出了对实地采集的轻型轮式车和重型轮式车的声音信号进行实时分类的结果。第 5 节比较了 Mel 滤波器组和其他两种常用特征提取算法的计算复杂度,第 6 节对全文进行分析和总结。

1 相关工作

特征提取算法的研究一直是分类识别领域中的热点问题,针对不同应用背景,研究者们提出了许多特征提取算法。Wang^[4]利用 amplitude statistics, shape statistics, 功率谱密度 (PSD) 的峰值,峰值所在的频点位置以及小波包系数的均值,方差和能量作为特征进行车辆信号的识别,Zhu^[5]利用小波包提取各频段的能量值作为特征进行车桥振动噪声信号的分析,Mitra^[6]利用语音信号的音调频率,子带能量,能量周期和倒谱系数 (FCC) 作为特征进行不同类型音乐的识别,Choi^[7]利用图像的小波系数作为特征识别钱币,Jiang^[8]分别利用 Eigenfaces, KP-CA, Fisherfaces, D-LDA, R-LDA 和 KDDA 算法提取特征进行人脸识别。这些特征提取算法在语音识别等一些特定应用中取得了不错的效果。针对无线传感器网络车辆识别应用中的特征提取,深入的研究还不是很多,大部分相关的研究都只是把现有的一些其它应用中效果较好的特征提取算法直接移植过来。Wisconsin SensIT Team^[3]在无线传感器网络车辆识别方面的研究取得了很大成绩,但相关文章和成果中针对这方面应用的特征提取算法的研究和讨论也相对较少。

2 加权 Mel 滤波器组 (WMFB)

针对无线传感器网络的车辆识别问题,我们利用一种新的加权 Mel 滤波器组进行车辆声音特征的提取。本节将对这种加权 Mel 滤波器组的设计流程进行详细的分析和介绍。加权 Mel 滤波器组的设计分为 3 个部分:Mel 滤波器组的设计,权重的计算,加权 Mel 滤波器组的生成。

2.1 Mel 滤波器组的设计

Mel 滤波器组通常用于语音识别系统中。语音识别系统的采样率一般为 8 kHz 或 16 kHz,根据信号各离散频点幅度在频谱上的对称性,Mel 滤波器组一般都设计在 0~4 kHz 或 0~8 kHz 范围内;而在无线传感器网络的车辆识别中信号的采样率远远小于 8 kHz 或 16 kHz,例如:SensIT 数据库的数据采样率为 4 960 Hz,我们实地采集声音信号的采样率为 1 kHz。如果直接将传统的 Mel 滤波器组用于采样率较低的无线传感器网络的车辆识别中,在 $[0, \text{采样率}/2]$ 范围内将只有个数很少的 Mel 滤波器,对信号频谱的分辨率太低,会大大影响不同车辆的分类识别效果,显然是不适用的,所以要根据车辆信号的实际频谱范围来设计合适的 Mel 滤波器组。设计中我们采用 25 个 Mel 滤波器组成 Mel 滤波器组,由于 Mel 滤波器的形状对分类结果基本没有影响^[9],为了计算方便,我们选择使用三角形的 Mel 滤波器。

通过分析训练信号中轮式车和履带车的频谱,我们首先设计出适合轮式车和履带车频谱范围的 Mel 滤波器组。利用 SensIT 数据库中节点 1,节点 2 和节点 3 采集的部分轮式车和履带车的时间序列信号作为训练信号,通过对训练信号进行 FFT 求出两类车各自的频谱,如图 1。

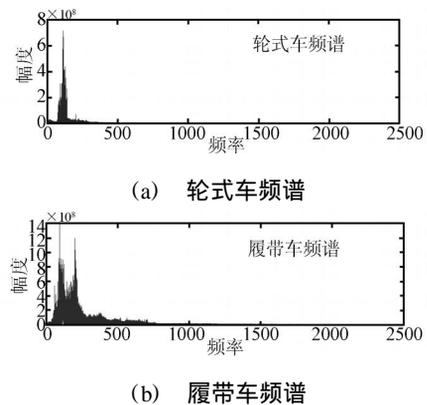


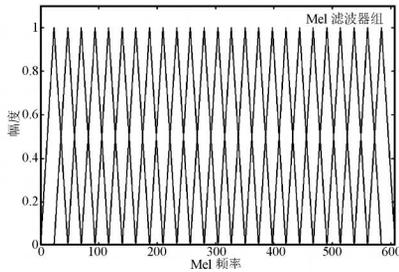
图 1 轮式车和履带车的频谱

根据图 1,我们可以看出,虽然 SensIT 数据库的数据采样率为 4 960 Hz,但无论是轮式车还是履带车的频谱范围都主要集中在低频段。轮式车的频谱基本全部集中在 0~500 Hz 范围内,履带车的频谱在 500 Hz 以上还残余一些信息,但幅度很低,与 0~500 Hz 范围内的信号强度相比完全可以忽略。因此,我们选择将 Mel 滤波器组设计在 0~500 Hz 范围内,这样可以在基本不丢失车辆信息的基础上减少计算量,缩短计算时间。

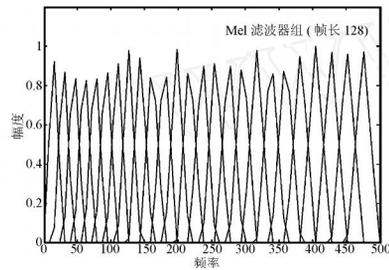
根据 Mel 频率与频率的转换表达式^[9]:

$$\text{mel}(f) = 2595 \times \log\left(1 + \frac{f}{700}\right) \quad (1)$$

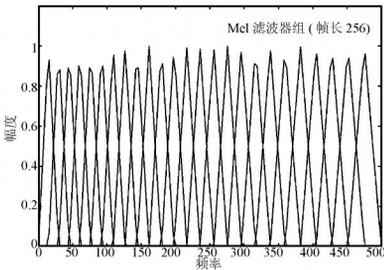
首先把频率 500 Hz 转换到 Mel 频率域,求得 Mel 滤波器组在 Mel 频率域的最高频率, mel(500) 607.45 Hz。根据求得的 607.45 Hz,将 25 个 Mel 滤波器平均分配在 0~607.45 Hz 的 Mel 频率域范围内,如图 2(a)。



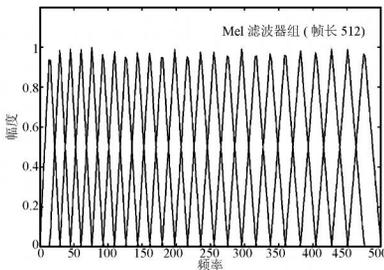
(a) Mel 滤波器组在 Mel 频域内的分布



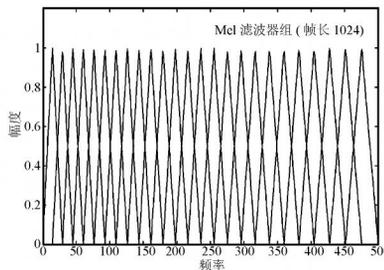
(b) 帧长为 128 时 Mel 滤波器组在频域内的分布



(c) 帧长为 256 时 Mel 滤波器组在频域内的分布



(d) 帧长为 512 时 Mel 滤波器组在频域内的分布



(e) 帧长为 1024 时 Mel 滤波器组在频域内的分布

图 2 Mel 滤波器组

由于 Mel 滤波器在 Mel 频率域中是平均分布的,重叠率为 50%,我们可以得到每个 Mel 滤波器在 Mel 频率域中的分布范围,转换到频域中就可以得到 Mel 滤波器组在频域中的分布情况,见表 1。

表 1 Mel 滤波器的分布范围和带宽

	起始频率/ Hz	终止频率/ Hz	带宽/ Hz
1	0	29.633	29.633
2	14.663	44.917	30.254
3	29.633	60.520	30.887
4	44.917	76.451	31.534
5	60.520	92.715	32.195
6	76.451	109.320	32.869
7	92.715	126.273	33.558
8	109.320	143.581	34.261
9	126.273	161.252	34.979
10	143.581	179.292	35.711
11	161.252	197.711	36.459
12	179.292	216.515	37.223
13	197.711	235.713	38.002
14	216.515	255.314	38.799
15	235.713	275.325	39.612
16	255.314	295.755	40.441
17	275.325	316.613	41.288
18	295.755	337.908	42.153
19	316.613	359.649	43.036
20	337.908	381.846	43.938
21	359.649	404.507	44.858
22	381.846	427.643	45.797
23	404.507	451.264	46.757
24	427.643	475.379	47.736
25	451.264	500	48.736

根据分割时间序列信号所采用的帧长,利用表达式(1)可以得到 Mel 滤波器组在频域内的分布信息。采用不同的帧长会得到不同分布的离散频点,所以拟合出的 Mel 滤波器组也会有差异,文中分别给出了帧长为 128、256、512、1024 时生成的 Mel 滤波器组作为示意,见图 2(b)~图 2(e)。

2.2 权重的计算

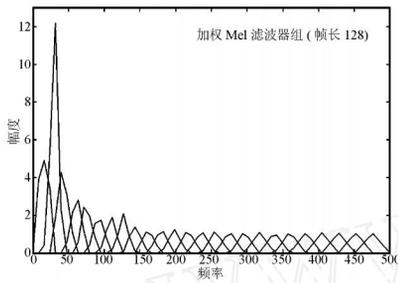
根据图 1 可以计算出轮式车和履带车的频谱在各离散频点上幅度的差异。假设帧长为 frame_len,可以用一个 frame_len/2 维的数组 Diff 来表示两类车的频谱在各离散频点的幅度差。然后通过表达式(2)计算出每个离散频点的权重:

$$Diff(i) = \frac{Diff(i) - Diff(i-1)}{Diff(i) + Diff(i-1)} \times \text{frame_len}/2 \quad (2)$$

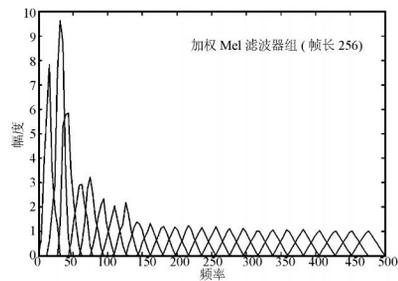
2.3 加权 Mel 滤波器组的生成

结合 2.1 中设计的 Mel 滤波器组和表达式(2)计算得到的频点相应的权重,即可拟合出 25 个加权

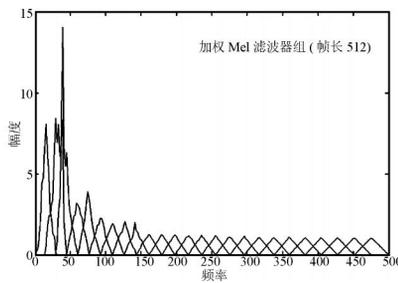
后的 Mel 滤波器组成的加权 Mel 滤波器组,见图 3。由于权重是根据轮式车和履带车在各离散频点处的幅度差异计算得到的,差异越大,相应的权重也越大;反之将赋予较小的权重,这样就突出了频谱中差异较大频段的信息,削弱了差异较小频段的信息,使提取的不同车辆的声音特征在特征空间中有更大的距离,从而改善了分类识别效果,提高了正确识别率。



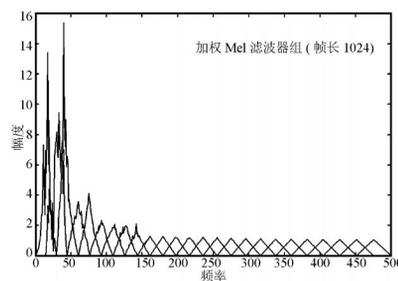
(a) 帧长为 128 时加权 Mel 滤波器组在频域内的分布



(b) 帧长为 256 时加权 Mel 滤波器组在频域内的分布



(c) 帧长为 512 时加权 Mel 滤波器组在频域内的分布



(d) 帧长为 1024 时加权 Mel 滤波器组在频域内的分布

图 3 加权 Mel 滤波器组在频域内的分布

3 特征提取和仿真结果

本节将比较利用加权 Mel 滤波器组提取的特征,利用小波包系数的能量倒谱作为特征和利用

amplitude statistics, shape statistics, 功率谱密度等频谱信息作为特征来进行分类得到的正确识别率。

3.1 特征提取

3.1.1 加权 Mel 倒谱

利用加权 Mel 滤波器组提取车辆声音信号的特征,需要对信号在前端进行预处理、归一化、加窗分帧、FFT,在后端进行倒谱系数的提取。

对时间序列信号进行预处理,即让时间序列信号通过一个高通滤波器 $H(z) = 1 - az^{-n}$,系数 a 一般取在 $0.9 \sim 1$ 之间^[10]。利用 $H(z)$ 对时间序列信号进行差分运算,抑制低频段的噪声,可以提高信号的信噪比。其后对信号进行归一化,目的是为了降低计算复杂度,减少计算量。通过系数 $= 5.44$ 的凯泽窗将归一化后的信号分成帧信号,各帧之间重叠率为 50%,与矩形窗相比凯泽窗可以减小频谱泄漏,与 Hamming 窗相比凯泽窗旁瓣频谱收敛得更快。帧长最好选为 $2n$,这样可以避免 FFT 时在帧信号后端补 0 的情况。加窗处理后,对每帧信号分别进行 FFT,根据表达式 (3) 对变换后的频谱信号各离散频点处的幅度求平方,得到各离散频点处的能量信号。

$$S[k] = (\text{real}(X[k]))^2 + (\text{imag}(X[k]))^2 \quad (3)$$

将 FFT 后求得的能量信号通过加权 Mel 滤波器组,得到加权 Mel 频谱。

$$\text{谱}[n] = \sum_{i=0}^{L/2} S[i]M_n[i] \quad n = 0, 1, \dots, N - 1 \quad (4)$$

其中, L 为 FFT 的长度, N 为加权 Mel 滤波器的个数, M 为存放各加权 Mel 滤波器在各离散频点幅度的数组。最后对加权 Mel 频谱的自然对数进行离散余弦变换(DCT)求取倒谱系数,文中选取 15 个倒谱系数作为特征。

$$c[t] = \sum_{i=0}^{N-1} \ln(\text{谱}[i]) \cos\left(\frac{t}{2L}(2i+1)\right) \quad t = 0, 1, \dots, C - 1 \quad (5)$$

其中, C 为倒谱系数的个数。

利用加权 Mel 滤波器组提取特征的具体流程见图 4。

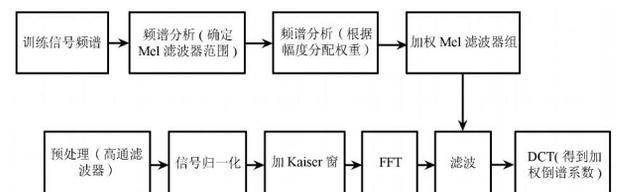


图 4 加权 Mel 滤波器组提取特征的流程图

3.1.2 小波包系数的能量倒谱

直接将时间序列信号分成帧信号,各帧之间重

叠率为 50%。对每帧信号进行 5 级小波包变换,得到 32 个频段的小波包系数。求取每个频段小波包系数的平方和,即每个频段的能量,再对这 32 个频段能量的自然对数进行 DCT 求得倒谱系数^[11]。为了有可比性,也选择 15 个能量倒谱系数作为特征。文中,我们选用的 db3 小波是 Daubechies 小波中的一种,其高通滤波器系数为 $[-0.3327 \ 0.8069 \ -0.4599 \ -0.135 \ 0.08544 \ 0.03523]$,低通滤波器系数为 $[0.03523 \ -0.08544 \ -0.135 \ 0.4599 \ 0.8069 \ 0.3327]$ 。

3.1.3 频谱特征

直接将时间序列信号分成帧信号,各帧之间重叠率为 50%。求得每帧信号的频域信息。用 $C(i)$, $i = 1, 2, \dots, L$ 表示每个离散频点处的幅值, $S = \sum_{i=1}^L C(i)$, 则 amplitude statistics 和 shape statistics 就可按表达式(6)和表达式(7)求取^[14]:

$$\text{amplitude} \left\{ \begin{aligned} \mu_{\text{amp}} &= \frac{1}{L} \sum_{i=1}^L C(i) \\ \text{amp} &= \sqrt{\frac{1}{L} \sum_{i=1}^L (C(i) - \mu_{\text{amp}})^2} \\ \text{amp} &= \frac{1}{L} \sum_{i=1}^L \left(\frac{C(i) - \mu_{\text{amp}}}{\text{amp}} \right)^3 \\ \text{amp} &= \frac{1}{L} \sum_{i=1}^L \left(\frac{C(i) - \mu_{\text{amp}}}{\text{amp}} \right)^4 - 3 \end{aligned} \right. \quad (6)$$

$$\text{shape} \left\{ \begin{aligned} \mu_{\text{shape}} &= \frac{1}{S} \sum_{i=1}^L i C(i) \\ \text{shape} &= \sqrt{\frac{1}{S} \sum_{i=1}^L (i - \mu_{\text{shape}})^2 C(i)} \\ \text{shape} &= \frac{1}{S} \sum_{i=1}^L \left(\frac{i - \mu_{\text{shape}}}{\text{shape}} \right)^3 C(i) \\ \text{shape} &= \frac{1}{S} \sum_{i=1}^L \left(\frac{i - \mu_{\text{shape}}}{\text{shape}} \right)^4 C(i) - 3 \end{aligned} \right. \quad (7)$$

根据表达式(8)求每帧信号的平均能量

$$P = \frac{1}{L} \sum_{i=1}^L C(i)^2 \quad (8)$$

再找出频谱中幅值最大的三个离散频点的位置和相应的幅值,加上前面求得的 amplitude statistics, shape statistics 和平均能量就构成了一个 15 维的由频域信息得到的特征向量。

3.2 分类识别

文中选择采用模糊分类器^[12]对提取的特征进行分类识别。模糊分类器通过区分模糊集来对车辆进行分类。首先通过成员函数 $\mu_{F_k}(x_k)$ 从训练信号的特征中抽象出训练模糊集,由于采用的是 15 维特

征,所以抽象得到 15 个模糊集 $F_k^l (k = 1, 2, \dots, 15) (k = 1, 2, \dots, 15)$ 和相应模糊集组合对应的判决结果 g^l 。得到目标信号的一个特征向量 x 后,模糊分类器通过成员函数 $\mu_{A_{x_k}}(x_k)$ 对其中的各维向量编码形成目标模糊集 $A_{x_k} (k = 1, 2, \dots, 15)$ 。把训练模糊集和目标模糊集相乘可以得到代表训练模糊集和目标模糊集相似程度的值 $f^l(x)$ 。

$$f^l(x) = \sup_{k=1}^{15} \mu_{A_{x_k}}(x_k) \mu_{F_k^l}(x_k) \quad (9)$$

在仿真中,履带车对应的 g^l 初始化为 1,轮式车对应的 g^l 初始化为 -1。通过判断表达式(10)中 $y(x)$ 的符号来给出分类结果, $y(x)$ 为正数就判为履带车, $y(x)$ 为负数就判为轮式车。

$$y(x) = \frac{\sum_{l=1}^M g^l f^l(x)}{\sum_{l=1}^M f^l(x)} \quad (10)$$

表达式(10)中, M 代表需要进行分类的车辆类别数,由于仿真中进行的是轮式车和履带车的分类,所以 M 取为 2。

下面我们将选用 SensIT 数据库中节点 1,节点 2 和节点 3 采集的时间序列信号作为源信号,利用模糊分类器对加权 Mel 滤波器组和另外两种算法提取的特征进行分类识别,通过比较正确识别率来验证加权 Mel 滤波器组的性能。仿真中采用交叉验证,即将特征集分成三个部分,其中两部分作为训练信号,一部分作为目标信号,这样通过选择不同的部分作为训练信号和目标信号进行三次验证,取三次正确识别率的平均值作为最终的正确识别率。由于选择不同帧长设计出的加权 Mel 滤波器组有差异,所以我们选择使用多种不同的帧长,对每种帧长的情况都给出分类结果。具体的分类结果见表 2,表 3。

表 2 SensIT 数据库轮式车的正确识别率

轮式车	128	256	512	1024
加权 Mel 倒谱系数	100 %	100 %	99.57 %	100 %
小波包系数的能量倒谱	92.57 %	97.83 %	97.73 %	96.57 %
频谱特征	96.50 %	96.37 %	95.80 %	92.07 %

表 3 SensIT 数据库履带车的正确识别率

履带车	128	256	512	1024
加权 Mel 倒谱系数	100 %	100 %	98.03 %	100 %
小波包系数的能量倒谱	90.55 %	97.33 %	96.57 %	95.13 %
频谱特征	94.23 %	95.66 %	95.53 %	95.60 %

从各种帧长情况下轮式车和履带车的正确识别率来看,相比于两种常用且比较成熟的特征提取算

法,对加权 Mel 滤波器组提取的车辆信号声音特征进行分类可以获得更高的正确识别率。无论是轮式车还是履带车,在各种帧长情况下基本都能够 100% 正确识别,比另外两种算法的正确识别率平均要高 3~7 个百分点。

4 实验结果与分析

对 SensIT 数据库中部分节点采集的时间序列信号进行特征提取并分类识别的仿真结果表明:加权 Mel 滤波器组提取车辆声音信号特征的效果优于另外两种常用的特征提取算法。为了进一步验证其在实际应用中的性能,我们将三种算法分别下载到硬件平台中,在一块 10 m ×10 m 的正方形区域中随机布设 10 个声音传感器,在正方形区域中再设置一个 sink 节点,10 个传感器分别把采集到的时间序列信号上传到 sink 节点中,sink 节点对所有上报信号进行集中式训练、处理,再把得到的加权 Mel 滤波器组系数下发到各个传感器节点,接下来各传感器节点即可以利用加权 Mel 滤波器组进行实时声音特征的提取和分类。

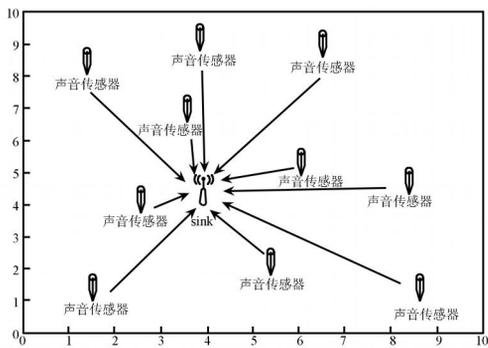
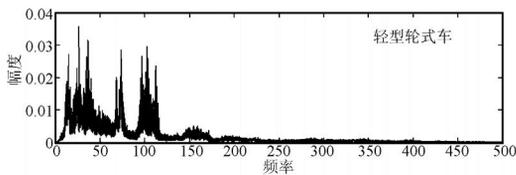
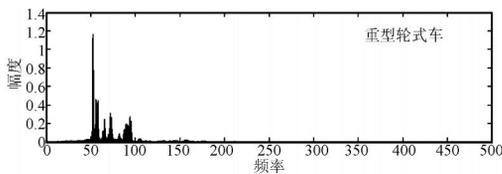


图 5 传感器随机布设

根据实测训练信号提取的轻型轮式车和重型轮式车的频谱见图 6。



(a) 轻型轮式车频谱



(b) 重型轮式车频谱

图 6 轻型轮式车和重型轮式车的频谱
在不同帧长情况下,利用三种算法对实测信号

进行实时特征提取,通过模糊分类器实时分类的结果见表 4,表 5。

表 4 轻型轮式车实时分类的正确识别率

轻型轮式车	128	256	512	1024
加权 Mel 倒谱系数	90.20 %	91.40 %	95.01 %	96.37 %
小波包系数的能量倒谱	74.00 %	81.04 %	88.32 %	90.31 %
频谱特征	82.40 %	79.44 %	82.54 %	78.47 %

表 5 重型轮式车实时分类的正确识别率

重型轮式车	128	256	512	1024
加权 Mel 倒谱系数	87.70 %	89.26 %	93.36 %	94.95 %
小波包系数的能量倒谱	64.53 %	81.73 %	85.33 %	86.75 %
频谱特征	71.64 %	77.08 %	76.77 %	78.42 %

由实时分类的结果可以看出,利用加权 Mel 滤波器组对实地采集的轻型轮式车和重型轮式车的声音信号进行实时特征提取,并通过模糊分类器得到的识别效果明显好于用小波包系数的能量倒谱和频谱信息作为特征进行分类得到的识别效果。采用加权 Mel 滤波器组得到的正确识别率比采用小波包系数的能量倒谱得到的正确识别率平均高出 10 个百分点左右,比采用频谱信息得到的正确识别率平均高出 15 个百分点左右。随着帧长从 128 增加到 1024,识别效果总体趋于上升,到 1024 时利用加权 Mel 滤波器组实时提取信号的声音特征得到的正确识别率可以达到 95% 左右。这是由于进行实地数据采集时,背景环境中存在一些突发噪声,把帧长取得稍长一点,可以有效地平滑这些突发的背景噪声,减小背景噪声对目标信号的干扰,所以获得了较好的识别效果;但也不能取得太长,否则对信号的分辨率降低,反而会导致识别效果的下降。

5 算法复杂度分析

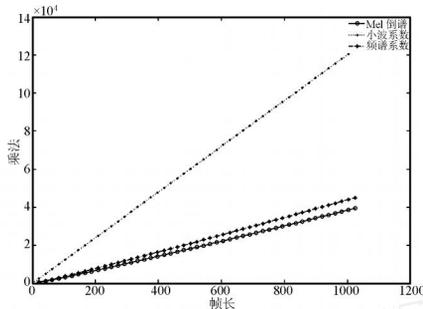
无线传感器网络节点的计算能力受到一定的限制,这样就对算法的计算复杂度提出了要求,计算复杂度相对较低的算法更适合应用于无线传感器网络中。下面就将本文提出的加权 Mel 滤波器组与其它两种特征提取算法的计算复杂度进行比较。

算法复杂度模型以 15 维的特征向量为基础,即三种特征提取算法均提取 15 维特征向量情况下的计算复杂度。其它模型参数设置分别为:Mel 滤波器组由 25 个 Mel 滤波器组成,小波包系数能量倒谱的提取采用 db3 小波,时间序列信号分割的帧长为 frame_len,各算法中 FFT 采用的点数取为和帧长一致。基于以上的算法复杂度模型,三种特征提取算法的计算复杂度近似见表 6。

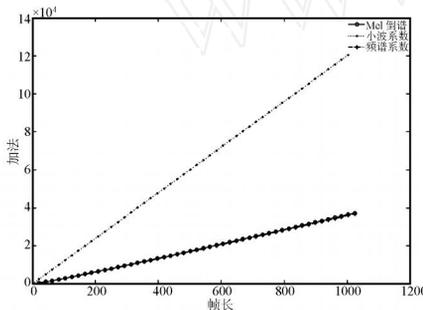
表6 三种特征提取算法的计算复杂度

计算复杂度	乘法(次)	加法(次)
加权 Mel 滤波器组	$2 \cdot \text{frame_len} \cdot \log_2 \text{frame_len} + 18.5 \cdot \text{frame_len}$	$2 \cdot \text{frame_len} \cdot \log_2 \text{frame_len} + 16.5 \cdot \text{frame_len}$
小波包系数的能量倒谱	$120 \cdot \text{frame_len}$	$120 \cdot \text{frame_len}$
频谱特征	$2 \cdot \text{frame_len} \cdot \log_2 \text{frame_len} + 24 \cdot \text{frame_len}$	$2 \cdot \text{frame_len} \cdot \log_2 \text{frame_len} + 16 \cdot \text{frame_len}$

取不同帧长时,算法复杂度的变化见图7。



(a) 乘法复杂度



(b) 加法复杂度

图7 三种特征提取算法的计算复杂度

从图7中,我们可以明显的看到,在不同帧长情况下,加权 Mel 滤波器组提取特征的乘法计算复杂度均为最低,加法计算复杂度比提取频谱系数的复杂度基本相同,但都远远小于提取小波包系数能量倒谱的计算复杂度,所以加权 Mel 滤波器组与传统的特征提取算法相比在计算复杂度上也具有一定的优势,对无线传感器网络节点的处理和计算能力的要求较传统的特征提取算法要低。

6 结论

本文提出了一种针对无线传感器网络中车辆识别应用的加权 Mel 滤波器组的设计方法,并对其性能进行了分析。加权 Mel 滤波器组根据不同车辆的频谱在各离散频点处幅度的差异,分配给各频点不同的权重,目的是为了突出不同车辆之间的差异信息,弱化相似信息,从而提高不同车辆特征在特征空间中的距离,提高分类识别率。仿真结果和实测结果均表明:在无线传感器网络中,利用加权 Mel 滤波器组提取车辆声音信号的特征进行分类不仅可以获得比利用现有的一些算法提取特征进行分类更

高的正确识别率,还降低了计算复杂度。仿真得到的正确识别率可以基本达到 100%,通过选择适当的帧长可以使实时分类的正确识别率也达到 95%以上,而计算复杂度却低于另外两种常用的特征提取算法,充分证明了在无线传感器网络中利用加权 Mel 滤波器组提取车辆声音信号的特征进行车辆识别的有效性和可行性。

在今后的工作中,我们将在加权 Mel 滤波器组的基础上进一步研究适用性更强,计算复杂度更低的滤波器,应用在无线传感器网络的多目标分类识别中,提高在多目标同时出现情况下无线传感器网络分类识别的有效性。

致谢

本文相关的研究作为上海市科委重点项目,得到了上海市科委的大力支持,在此表示衷心的感谢!

参考文献:

- [1] Xiao Shen, Shen Cong-wan, Hong Huo. An Improvement on Discrete Wavelet Transform-Based Algorithm for Vehicle Classification in Wireless Sensor Networks[C]// 2006 1st IEEE Conference on Industrial Electronics and Applications, May. 24-26, 2006, 1-4.
- [2] Yang S S, Kim, Y G, Choi Hongsik. Vehicle Identification Using Wireless Sensor Networks [C]// SoutheastCon, IEEE Proceedings, March. 22-25, 2007, 41-46.
- [3] <http://www.ece.wisc.edu/~sensit/> [EB/OL].
- [4] Wang Xiao-ling. High Accuracy Distributed Target Detection and Classification in Sensor Networks Based on Mobile Agent Framework [D]. [Ph. D. Thesis]. The University of Tennessee, 2004.
- [5] 朱福根. 车桥振动噪声信号特征提取方法的研究[J]. 传感技术学报, 2006, 19(4): 1070-1073.
- [6] Vikramjit Mitra, Wang, C.J. A Neural Network Based Audio Content Classification. Neural Networks[C]// Conference on International Joint, IJCNN, Aug. 12-17, 2007, 1494-1499.
- [7] Choi Euisun, Lee Jongseok, Yoon Joonhyun. Feature Extraction for Bank Note Classification Using Wavelet Transform [C]// 18th International Conference on Pattern Recognition, ICPR, 2006, 934-937.
- [8] Jiang Yun-fei, Guo Ping. Comparative Studies of Feature Extraction Methods with Application to Face Recognition[C]// IEEE International Conference on Systems, Man and Cybernetics, ISIC, Oct. 7-10, 2007, 3627-3632.

- [9] Zheng Fang, Zhang Guo-liang, Song Zhan-jiang. Comparison of Different Implementations of MFCC[J]. Journal of Computer Science and Technology (English Edition), 2001, 16(6): 582-589.
- [10] Han Wei, Chan Cheong-Fat, Choy Chiu-Sing. An Efficient MFCC Extraction Method in Speech Recognition[C]// Proceedings of the International Symposium on Circuits and Systems. 2006, 145-148.
- [11] Seekings P, Potter J. Classification of Marine Acoustic Signals Using Wavelets & Neural Networks[C]// Proceedings of the 8th Western Conference on Pacific Acoustics. 2003.
- [12] Yu Hui-ling, Sun Li-ping, Cao Jun. A Novel Method for Constructing Fuzzy Classifiers by Using SVMs[C]// International Conference on Mechatronics and Automation, ICMA, Aug. 5-8, 2007, 2368-2372.



赵俊钰(1983-),男,博士研究生,主要研究方向为无线传感器网络目标识别、定位,协同信息处理, karlzjy@gmail.com



刘海涛(1968-),男,研究员,博导,主要研究方向为无线传感器网络。

www.cnki.net