

基于曼哈顿距离加权协同表示分类的车辆识别

罗涛, 冯玉田, 王瑞

(上海大学 通信与信息工程学院, 上海 200444)

摘要: 加权稀疏表示分类 (WSRC) 在声频传感器网络下的车辆识别中取得了不错的效果; 但是稀疏表示分类 (SRC) 中实际上起较大作用的是字典中所有类的协同表示, 因此协同表示分类 (CRC) 被提出用来提升算法效率, CRC 框架还改进了残差计算方式来提高识别精度; 在 WSRC 中发现保局性对提升识别率起到很好的作用, 因此在 CRC 中引入加权编码, 提出了声频传感器网络下基于加权协同表示分类 (WCRC) 的车辆识别方法, 取得了明显的速度 (相比 WSRC、SRC) 以及不错的精度 (对比 WSRC、CRC、SRC) 提升; 同时针对欧氏距离对样本相似性判断的不足, 将曼哈顿距离引入加权编码, 进一步地提出了基于曼哈顿距离加权协同表示分类 (Manhattan-WCRC) 的车辆识别方法, 取得了最高的识别率, 而运算速度与 WCRC 接近。

关键词: 稀疏表示; 协同表示; 加权编码; 欧氏距离; 曼哈顿距离; 声频传感器网络; 车辆识别

Vehicle Recognition Based on Manhattan Distance Weighted Collaborative Representation based Classification

Luo Tao, Feng Yutian, Wang Rui

(School of Communication and Information Engineering, Shanghai University, Shanghai 200444, China)

Abstract: Weighted sparse representation based classification (WSRC) has achieved good results in vehicle recognition in acoustic sensor networks. However, the collaborative representation of all classes in the dictionary actually plays an important role in the sparse representation based classification (SRC). collaborative representation based classification (CRC) is proposed to improve the efficiency of the algorithm. The CRC framework also improves the residual calculation method to improve the recognition accuracy. It is found in WSRC that data locality plays a very good role in improving the recognition rate. Therefore, weighted coding is introduced into CRC, and a vehicle recognition method based on Weighted Collaborative Representation based Classification (WCRC) in acoustic sensor networks is proposed, which achieves obvious speed (compared with WSRC, SRC) and good accuracy (compared with WSRC, CRC, SRC) improvement. At the same time, in view of the shortcomings of Euclidean distance in judging sample similarity, the Manhattan distance is introduced into weighted coding, and a vehicle recognition method based on Manhattan distance weighted collaborative representation based classification (Manhattan-WCRC) is proposed. Manhattan-WCRC achieves the best recognition rate with almost the same speed as WCRC.

Keywords: sparse representation; collaborative representation; weighted coding; Euclidean distance; Manhattan distance; acoustic sensor networks; vehicle recognition

0 引言

实现车辆类型的自动识别可以在现实中带来很多的益处, 比如军事攻防、智慧城市等方面。对于车型识别的研究, 很多都是基于图像处理所进行的^[1-2], 但是基于图像的车辆识别可能受到遮挡、光照、隐蔽性不足等等影响, 因此本文的研究主要是通过声频来进行车辆目标类型的分类识别。

在模式识别中, 分类算法起到了至关重要的作用。稀疏表示分类 (SRC)^[3]在人脸识别领域的应用取得了很大的

成功, 基于 SRC 发展的算法在很多模式识别领域展开了广泛的研究: Wen^[4]等提出了一种基于新型字典的 SRC 方法用于人脸识别; 张^[5]等结合了多特征融合和 SRC 用于农业害虫识别; 在声频车辆目标识别领域, Wang^[6]等采用 SRC 得到了不错的分类识别结果等等。但是, SRC 类型的算法可能在识别过程中比较耗时, Zhang^[7-8]等在研究中发现, 在实际的人脸识别问题中, 协同表示在稀疏表示分类算法中发挥了更大的作用, 因此提出了协同表示分类 (CRC) 算法, 相比于 SRC, 明显地提高了人脸识别速度。同时, CRC 算法框架还改进了传统框架中重构残差的计算公式, 可一定程度提升分类精度。由于 CRC 的高效性, 众多围绕着 CRC 的模式识别研究相继展开: Yang^[9]等提出了核版本的协同表示分类方法用于图像分类; 李^[10]等提出了使用 CRC 来进行步态的识别; 王^[11]等采用声频和振动信号多任务联合的 CRC 来进行车辆识别等等。

在 SRC 的研究中, Lu^[12]等发现将每一个训练样本和测

收稿日期: 2018-12-21; 修回日期: 2019-01-19。

基金项目: 国家自然科学基金项目 (61771299)。

作者简介: 罗涛 (1994-), 男, 浙江台州人, 硕士研究生, 主要从事压缩感知、模式识别方向的研究。

通讯作者: 冯玉田 (1966-), 男, 浙江平湖, 工学博士, 副教授, 主要从事压缩感知、信号检测与处理方向的研究。

试信号的相似性考虑进分类算法中将提升 SRC 的识别精度，因此提出了加权稀疏表示分类 (WSRC) 方法并在人脸识别中取得了较好的效果。保局性^[13-14]对于分类器具有十分重要的意义，类似的，将保局性考虑进 CRC 的加权类型的协同表示分类算法被广泛的提出用于图像领域的模式识别研究中^[15-17]。

在采用声频进行车辆类型识别的领域，罗^[18]等基于 Lu^[12]等的思想，提出了基于 WSRC 的车辆识别，证明了在声频车辆类型识别中，其基于保局性的加权编码方式仍然可以对分类识别精度的提升起到很好的作用。由于保局性在声频车辆识别中的良好表现和 CRC 理论所展现出的高效性，本文在声频车辆目标识别中，将加权编码引入到 CRC 方法框架中，提出了在声频无线传感器网络下基于加权协同表示分类 (WCRC) 的车辆识别，用以提高车辆识别速度和精度。同时对于使用欧氏距离进行加权编码^[18]造成的样本相似性判断不足，本文将曼哈顿距离引入加权编码中以提升识别精度，进一步提出了基于曼哈顿距离加权协同表示分类 (本文称之为 Manhattan-WCRC) 的声频车辆目标识别。通过实验，本文将在同等条件下通过和 WSRC、CRC、SRC 作对比，来验证 Manhattan-WCRC、WCRC 在采用声频特征信号进行车辆目标类型识别中的可行性和优势。

1 声频车辆目标识别框架

通过声波来识别车辆目标类型是可行的，但是车辆在行驶过程中产生的原始信号包含了大量的噪声，所以在分类识别前需要进行很多步骤的处理，本文总结了声频传感器网络下的车辆目标识别框架。

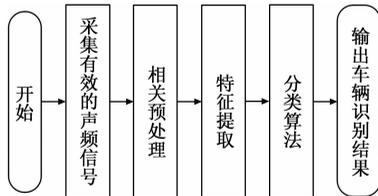


图 1 声频车辆目标识别模型

如图 1 模型所示，具体分类识别过程由以下几步组成：

- 1) 需要采集到车辆行驶过程中产生的有效声波信号。可以通过在需要检测的车辆目标的行驶道路上搭建基于声频的无线传感器网络进行声频信号的采集，再采用恒虚警率 (CFAR)^[19]算法，获得原始声频数据中真正有效信号。
- 2) 对采集到的经过 CFAR 算法检测的有效信号，进行相关方面的预处理 (主要包括预加重、分帧和加窗、以及端点检测)。
- 3) 对于已经预处理后的声频车辆目标信号使用 MF-CC^[6] (梅尔频率倒谱系数) 进行声频信号的特征提取。其中，MFCC 算法是在声音识别领域中最常见且行之有效的特征提取算法。
- 4) 将特征提取后的信号输入到分类算法 (包括训练集

和待测信号)，从而预测待测信号的所属类别，以实现车辆类型识别的目的。由于分类算法在声频车辆目标识别中占有非常重要的地位，本文主要研究了分类算法在车辆识别中的性能。

2 稀疏和协同表示分类

2.1 稀疏表示分类

稀疏表示分类实质上是通过将所有训练信号构成字典，然后通过字典来对测试信号进行稀疏表示得到测试信号的系数向量 (字典对测试信号进行稀疏表示后的向量)，再将每个类的系数向量和每个类的字典进行重构与原测试信号求残差，残差最小那一类便是测试信号所归属的那一类。

声频车辆目标识别中的稀疏表示分类 (SRC) 方法框架总结如下：

- 1) 输入包含了 L 个类别的训练集字典 D (其中：信号特征维度为 M ，信号的个数为 N ，构成了一个 $M \times N$ 矩阵)：

$$D = [D_1, \dots, D_i, \dots, D_L] \in R^{M \times N_i} \quad i = 1, 2, \dots, L \quad (1)$$

其中：每一类训练样本 D_i 包含 n 个同类别的测试样本：

$$D_i = [d_i^1, \dots, d_i^k, \dots, d_i^n] \in R^{M \times n} \quad k = 1, 2, \dots, n \quad (2)$$

接下来输入一个要判断类别的测试样本 $x \in R^M$ ，和正则化参数 λ 。(下文中测试样本 x 和训练字典 D 都以此为准，不再做详细描述。)

- 2) 获得测试样本 x 被训练字典稀疏表示后的系数向量 $\hat{\alpha}$ ，可以通过以下解决 ℓ_1 -范数最小化问题：

$$\hat{\alpha} = \arg \min_{\alpha} \|\alpha\|_1 \quad s.t. \quad \|D\alpha - x\|_2^2 \leq \epsilon \quad (3)$$

在适当的 ϵ (ϵ 为信号的噪声水平) 和 λ 参数条件下，等价于以下的式子：

$$\hat{\alpha} = \arg \min_{\alpha} \left\{ \frac{1}{2} \|x - D\alpha\|_2^2 + \lambda \|\alpha\|_1 \right\} \quad (4)$$

- 3) 各类重构残差计算：

$$r_i(x) = \|x - D\hat{\alpha}_i\|_2 \quad i = 1, 2, \dots, L \quad (5)$$

- 4) 输出识别结果：

$$identity(x) = \arg \min_i r_i(x) \quad (6)$$

2.2 协同表示分类

Zhang^[7-8]等指出在人脸识别中通常都是小样本的问题，其每一类的字典都是欠完备的，通过每一类的欠完备字典单独来表示测试样本是不稳定的。可以通过两种方式来解决这个问题：1) 将每一类训练字典都引入足够多的样本来构成超完备字典，但是这在上述实际问题中已经难以实现。2) 在 SRC 中，实际上可以在一定 ℓ_1 -范数稀疏约束下，通过所有类一起来协同表示测试样本。

其中 Zhang^[7-8]等分析指出，在 SRC 中对于提高分类识别率起主要作用的是协同表示，而不是 ℓ_1 正则化项：

$$\hat{\alpha} = \arg \min_{\alpha} \{ \|x - D\alpha\|_2^2 \} \quad (7)$$

但是，当样本数变大时，式 (7) 将会变的不稳定，因此 SRC 中通过施加 ℓ_1 -范数稀疏约束来得到稳定的解，但是求解 ℓ_1 -范数最小化问题会比较耗时，可以采用 ℓ_2 -范

数来正则化系数向量的解 (使得解稳定, 同时注入一定的稀疏性), 从而大幅度降低运算时间, 同时得到相对接近的识别结果。在 CRC 中, 给出基于正则化最小二乘法的系数向量解法:

$$\hat{\beta} = \arg \min_{\beta} \{ \|x - D\beta\|_2^2 + \lambda \|\beta\|_2^2 \} \quad (8)$$

其中式 (6) 可以改写为:

$$\hat{\beta} = Px \quad (9)$$

其中:

$$P = (D^T D + \lambda \cdot I)^{-1} D^T \quad (10)$$

这里 I 为单位矩阵, 矩阵 P 可以通过已知的训练字典提前计算好, 加之矩阵计算的速度是非常快的, 因此 CRC 的识别速度得到了明显的提高。

在采用声频特征信号进行车辆识别的领域, 其每一类也很难获得足够的样本, 即每一类的字典同样是欠完备的。因此, 其系数向量的求解也可以采用式 (8) 的方法。同时, 在协同表示分类框架中, Zhang^[7-8] 等指出在重构残差的计算中可以引入 $\|\hat{\beta}_i\|_2$ (包含了一定的判别信息), 用以提高识别精度:

$$r_i(x) = \frac{\|x - D\hat{\beta}_i\|_2}{\|\hat{\beta}_i\|_2} \quad i = 1, 2, \dots, L \quad (11)$$

在声频车辆目标识别中, 同样可以引入 $\|\hat{\beta}_i\|_2$, 并且在下文的实验中证实了引入 $\|\hat{\beta}_i\|_2$ 对于声频车辆目标识别率的提升是比较有益的。

声频车辆目标识别中的协同表示分类 (CRC) 方法框架总结如下:

- 1) 输入训练字典 D 、正则化参数 λ 。
- 2) 提前计算矩阵 P :

$$P = (D^T D + \lambda \cdot I)^{-1} D^T$$

3) 识别开始, 输入测试信号 x , 获得协同表示后的系数向量 $\hat{\beta}$:

$$\hat{\beta} = Px$$

- 4) 各类重构残差计算:

$$r_i(x) = \frac{\|x - D\hat{\beta}_i\|_2}{\|\hat{\beta}_i\|_2} \quad i = 1, 2, \dots, L$$

- 5) 输出识别结果:

$$\text{identity}(x) = \arg \min_i r_i(x)$$

3 加权协同表示分类

3.1 加权编码方法

SRC 在全局的表示过程中, 忽略了输入信号局部的分布结构, 而局部保持特性 (以下称之为保局性)^[13] 在分类器里却起到了比较有益的作用^[14]。为了弥补 SRC 对于保局性的重视程度不足, Lu^[12] 等在人脸识别领域提出了加权稀疏表示分类 (WSRC) 算法, 并且在精度上有不错的提高。以上主要是针对图像领域的工作, 罗^[18] 等提出将 WSRC 引入了声频车辆目标识别领域, 通过测试信号和每一个训练样本之间的相似度 (基于欧氏距离) 将稀疏表示后的系数向量添加不同的权值来提升识别效果。基于以上所做的工作, 本文将声频无线传感器网络下车辆识别中的 WSRC 的加权

编码方法总结如下:

- 1) 输入测试信号 x 、训练字典 D 、系数向量 $\hat{\chi}$ 。
- 2) 计算权值 W 。 W 为对角矩阵, 其对角元素为:

$$\text{diag}(W) = [f(x, d_1^k), \dots, f(x, d_i^k), \dots, f(x, d_L^k)]^T \quad (12)$$

其中:

$$f(x, d_i^k) = \|x - d_i^k\|_2^S \quad i = 1, 2, \dots, L; k = 1, 2, \dots, n \quad (13)$$

这里 d_i^k 为训练字典 D 中每一类的每一个训练样本。 $\|\cdot\|_2$ 为 ℓ_2 -范数, 即采用欧氏距离来表示测试信号和每个训练信号之间的距离 (相似性)。S 为距离的 S 次幂, 本文称作局部适配参数 S 值。在此加权编码方法中, S=0 时等同于未加权。

- 3) 分配权重, 得到加权后的系数向量:

$$\hat{\chi}^w = W^{-1} \hat{\chi} \quad (14)$$

加权后的系数向量中, 测试信号所归属类的系数向量和该类字典的重构率会更好, 相反的, 和测试信号相似度更小 (距离值更大) 类部分对应的系数向量和该类字典的重构率会越差 (即残差会越大), 从而拉开了两者重构率之间的差距, 以达到提高识别率的目的。为方便对比, 本文给出声频车辆目标识别中的 WSRC 方法框架总结如下:

- 1) 输入测试信号 x 、训练字典 D 、正则化参数 λ 。
- 2) 获得稀疏表示后的系数向量 $\hat{\alpha}$:

$$\hat{\alpha} = \arg \min_{\alpha} \left\{ \frac{1}{2} \|x - D\alpha\|_2^2 + \lambda \|\alpha\|_1 \right\}$$

- 3) 将 $\hat{\alpha}$ 通过表 3 的加权编码得到 $\hat{\alpha}^w$;
- 4) 各类重构残差计算:

$$r_i(x) = \|x - D\hat{\alpha}_i^w\|_2 \quad i = 1, 2, \dots, L \quad (15)$$

- 5) 输出识别结果:

$$\text{identity}(x) = \arg \min_i r_i(x)$$

3.2 加权协同表示分类

通过在协同表示分类中考虑进保局性, 很多人在图像领域的模式识别研究中提出了类似的加权类型的协同表示分类算法^[15-17]。但是这些都主要是在图像识别领域的应用, 本文主要将加权协同表示分类 (WCRC) 引入到声音领域, 考虑到样本的局部保持特性, 将以上加权编码方法加入到 CRC 方法框架中, 提出了声频传感器网络下基于加权协同表示分类 (WCRC) 的车辆识别方法。WCRC 在 CRC 的基础上实现了加权编码, 充分考虑了 CRC 中样本的保局性, 以此来提升 CRC 在声频车辆目标识别中的准确率。同时, 由于 CRC 中将 $\|\hat{\beta}_i\|_2$ 引入到残差判别中来提升识别率, WCRC 中也仍然将加权后的 $\|\hat{\beta}_i^w\|_2$ 引入到残差判别中用以提升识别率。最重要的, WCRC 是由 CRC 改进而来, 在车辆声频信号中的计算效率将明显高于 WSRC 和 SRC。本文将本节所提方法框架总结如下:

- 1) 输入训练字典 D 、正则化参数 λ 。
- 2) 提前计算矩阵 P :

$$P = (D^T D + \lambda \cdot I)^{-1} D^T$$

- 3) 识别开始, 输入测试信号 x , 获得协同表示后的系

数向量 $\hat{\beta}$:

$$\hat{\beta} = Px$$

4) 将 $\hat{\beta}$ 通过表 3 的加权编码得到 $\hat{\beta}^w$ 。

5) 各类重构残差计算:

$$r_i(x) = \frac{\|x - D\hat{\beta}_i^w\|_2}{\|\hat{\beta}_i^w\|_2} \quad i = 1, 2, \dots, L \quad (16)$$

6) 输出识别结果:

$$identity(x) = \arg \min_i r_i(x)$$

4 曼哈顿距离加权协同表示分类

曼哈顿距离 (Manhattan distance) 又称作城市街区距离 (City Block distance), 以二维空间为例, 如图 2 可以看到, 在拥有众多街区的纽约曼哈顿, 从 A 点到 B 点最短的距离为欧氏距离, 但是实际的情况 (因为街区房子的阻隔, 不能直接由 A 到 B 抵达终点) 可能需要经过 1 或 2 路线的距离长度 (其中路线 1 和路线 2 的长度是等价的)。其中路线 1 或 2 所代表的距离长度可能比路线 3 带有更多的实际信息。受此启发, 类比到声频车辆目标识别领域, 在加权编码中引入曼哈顿距离来取代欧氏距离, 从而提高测试信号和训练信号之间相似度的判断能力, 以提高加权协同表示分类方法的识别率。

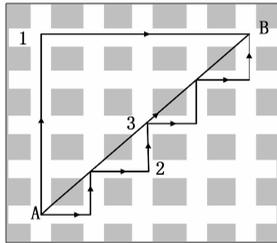


图 2 曼哈顿距离平面示意图

下面对表 3 加权编码方法中的式 (13) 进行分析。为方便分析, 令 $f(x, d_i^k)$ 中的 $x = a, d_i^k = b$ 。其中的 a, b 都是特征维度为 M 的向量。

原加权编码方法中基于欧氏距离进行编码:

$$f(a, b) = \|a - b\|_2^s = \sqrt{\sum_{h=1}^M (a_h - b_h)^2} = \sqrt{(a_1 - b_1)^2 + \dots + (a_h - b_h)^2 + \dots + (a_M - b_M)^2} \quad (17)$$

接下来给出采用基于曼哈顿距离的加权编码:

$$f(a, b) = \|a - b\|_1^s = \left(\sum_{h=1}^M |a_h - b_h| \right)^s = (|a_1 - b_1| + \dots + |a_h - b_h| + \dots + |a_M - b_M|)^s \quad (18)$$

其中, 欧式距离 ($\|\cdot\|_2$) 对应的为 ℓ_2 -范数, 曼哈顿距离 ($\|\cdot\|_1$) 对应的为 ℓ_1 -范数。

由式 (17)、(18) 可以看出, 当声频测试和训练特征信号之间的距离向量中存在一些较大的分量时, 使用欧式距离计算距离时, 将会忽视掉一些较小值, 但是这较小的分量仍然保持了一些相似性的判断信息。使用曼哈顿距离计算车辆声频特征信号的距离时, 会使得这些较小分量仍然可以一定程度地贡献本身所包含的相似信息, 从而提升

加权效果。

基于以上分析, 本文提出了声频传感器网络下基于曼哈顿距离加权协同表示分类 (Manhattan-WCRC) 的车辆识别方法。下面给出本节所提方法框架的总结如下:

1) 输入训练字典 D 、正则化参数 λ 。

2) 提前计算矩阵 P :

$$P = (D^T D + \lambda \cdot I)^{-1} D^T$$

3) 识别开始, 输入测试信号 x , 获得协同表示后的系数向量 $\hat{\beta}$:

$$\hat{\beta} = Px$$

4) 将表 3 中加权编码方法的式 (13) 更新为采用曼哈顿距离加权编码的式 (18)。

5) 将 $\hat{\beta}$ 通过表 3 更新后加权编码得到 $\hat{\beta}^w$ 。

6) 各类重构残差计算:

$$r_i(x) = \frac{\|x - D\hat{\beta}_i^w\|_2}{\|\hat{\beta}_i^w\|_2} \quad i = 1, 2, \dots, L$$

7) 输出识别结果:

$$identity(x) = \arg \min_i r_i(x)$$

5 实验结果

5.1 实验设置

为了验证以上理论, 本文进行了采用声频特征信号进行车辆目标类型识别的 Matlab 仿真实验, 主要研究了不同分类算法的识别性能。本实验数据集和文献^[18]一样, 主要包括两种军事车辆类型: 重型轮式卡车 (DW) 和履带车 (AAV)。总共为 180 个经过声频车辆目标识别框架处理 (特征提取后, 分类算法前) 后的数据。

在分类识别实验设置中, AAV 总共包括 90 个特征信号样本, DW 也包括 90 个特征信号样本。实验中, 将每一个 AAV 数据和 DW 数据分别设为标签 0 和 1。随机取每一类的 n 个样本来作为训练集, 剩下的每一类的 $90 - n$ 个样本来作为测试集。这里, 训练集总大小为 $2n$, 测试集总大小为 $2 * (90 - n)$ 个, 下文中以每一类训练样本大小 n 来指代训练集大小。其中, n 依次设置为 20、30、40、50、60、70。以上的实验框架如果只进行单次实验将会有误差, 最终实验采用将以上实验框架循环 100 次再取平均的办法来获得最终实验结果。

对于上述的表示型分类识别算法, SRC、WSRC 中求解 ℓ_1 -范数最小化问题采用 LIBADMM^[20] 工具包求解。在实验中, SRC、WSRC 的 λ 值设为 10, CRC、WCRC、Manhattan-WCRC 的 λ 值设为 100。加权编码方法中的 S 值为经验值, 将在下一节的实验结果中给出。本文中, 实验平台采用的操作系统为: Windows 10 系统。仿真软件平台为: Matlab R2015b。电脑 CPU 配置为: Intel (R) Core (TM) i7-6700HQ CPU @ 2.60GHz。

5.2 实验结果与分析

5.2.1 实验一

在 CRC 方法框架中, 引入了 $\|\hat{\beta}\|_2$ 重新定义了残差计算方式, 理论上说, $\|\hat{\beta}\|_2$ 的引入可以增加 CRC 的识别精

度, 因此在本实验中, 给出了使用 $\|\hat{\beta}_i\|_2$ 判别的 CRC, 和不使用 $\|\hat{\beta}_i\|_2$ 的 CRC (表格中称为 CRC_no), 以及传统 SRC 的识别率比较。实验结果如表 1 所示。

表 1 SRC 和不同残差计算方式下的 CRC 识别率 %

分类算法	训练集大小					
	20	30	40	50	60	70
SRC	88.01	89.23	90.13	90.58	90.80	91.30
CRC_no	87.60	88.78	89.58	89.89	89.95	90.23
CRC	89.10	90.46	91.26	91.35	91.75	91.45

以上实验中, 可以看到在采用声频特征信号进行车辆类型识别的领域中采用 $\|\hat{\beta}_i\|_2$ 的 CRC 比不

采用 $\|\hat{\beta}_i\|_2$ 的 CRC 在精度上有着不错的提升, 甚至高出了传统的 SRC 方法框架。验证了第 2.2 节中关于在声频传感器网络下进行车辆识别中, 引入 $\|\hat{\beta}_i\|_2$ 可以提高识别精度的分析, 并且有着不错的效果。

5.2.2 实验二

由于局部适配参数 S 在不同的分类器和样本集上会有不同的尺度和对应值, 实验中将 WSRC、WCRC、Manhattan-WCRC 的 S 值统一设为以下的尺度范围值: $S = 0.001, 0.005, 0.01, 0.05, 0.1, 0.5, 1, 5, 10$ 。并且基于以上实验设置, 给出了 WSRC、WCRC、Manhattan-WCRC 不同 S 值下, 训练集大小为 $n = 20, 30, 40, 50, 60, 70$ 时的识别率。识别精度趋势图分别如图 3~5 所示。

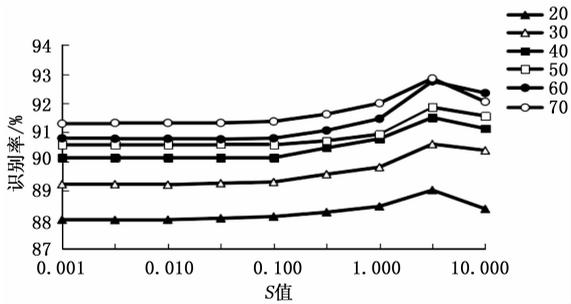


图 3 不同 S 值下 WSRC 识别率趋势图

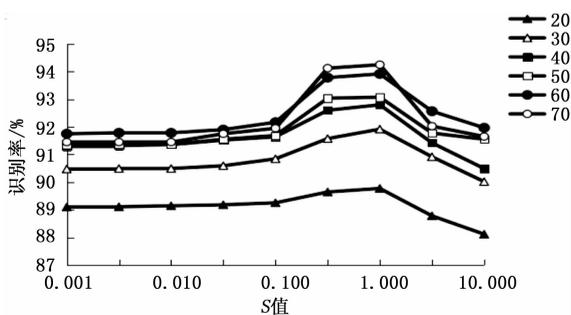


图 4 不同 S 值下 WCRC 识别率趋势图

由以上实验可以看出: 在训练集大小 n 为 20、30、40、50、60、70 时, WSRC 的识别率在 $S=5$ 附近取得较好的效果; 在训练集大小 n 为 20、30、40、50、60、70 时, WCRC 在 $S=1$ 左右效果较好; 在训练集大小 n 为 20、30、40 时, Manhattan-WCRC 在 $S=1$ 附近取得较好精度, 在

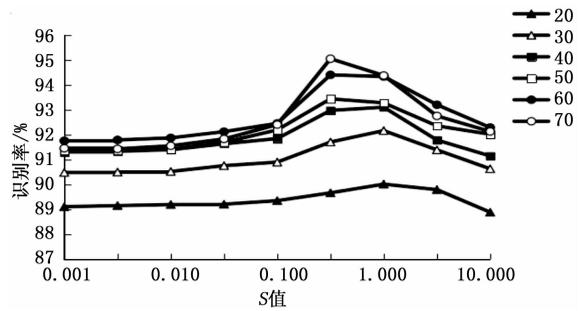


图 5 不同 S 值下 Manhattan-WCRC 识别率趋势图

训练集大小 n 为 50、60、70 时, Manhattan-WCRC 在 $S=0.5$ 附近取得较好精度。

5.2.3 实验三

由实验二可以得到 WSRC、WCRC、Manhattan-WCRC 不同的 S 值。在本实验中, WSRC 在 n 为 20、30、40、50、60、70 时的 S 值设为 5, WCRC 在 n 为 20、30、40、50、60、70 时的 S 值设为 1, Manhattan-WCRC 在 n 为 20、30、40 时的 S 值设为 1, 在 n 为 50、60、70 时的 S 值设为 0.5。

下面给出了 SRC、CRC、WSRC、WCRC、Manhattan-WCRC 在每一类训练集大小 n 分别为 20、30、40、50、60、70 时的识别率 (单位为 %), 如表 2 所示。

表 2 不同分类算法的识别率 %

分类算法	训练集大小					
	20	30	40	50	60	70
SRC	88.01	89.23	90.13	90.58	90.80	91.30
CRC	89.10	90.46	91.26	91.35	91.75	91.45
WSRC	89.02	90.60	91.51	91.86	92.75	92.85
WCRC(本文)	89.77	91.92	92.80	93.08	93.92	94.25
Manhattan-WCRC(本文)	90.01	92.16	93.10	93.44	94.40	95.05

从以上实验结果可以看出, 本文提出的基于 WCRC 的声频车辆目标识别方法的识别精度均优于 WSRC, CRC, SRC。其中 WCRC 对于 CRC 有着较大的识别精度提升, 证明了将保局性 (上述加权编码方法) 引入 CRC 方法框架是可行并且有效的。另外, WCRC 在对比 WSRC 上也有着不错的精度提升。分析认为, 在实验一中证明在 CRC 中引入 $\|\hat{\beta}_i\|_2$ 可以提升声频车辆目标的识别精度, 那么以上实验结果表明, 在 WCRC 算法框架内, 引入 $\|\hat{\beta}_i\|_2$ 对残差进行判别, 对于提升车辆识别的精度仍然有效。同时, 本文进一步提出的基于 Manhattan-WCRC 的车辆识别方法在实验中达到了最高的识别率。对比 WCRC 在不同训练集大小下都有一定精度的提升, 证明了在 WCRC 中引入曼哈顿距离来取代欧氏距离进行加权编码的可行性和优势。

接下来, 给出 SRC、CRC、WSRC、WCRC、Manhattan-WCRC 在 n 分别为 20、30、40、50、60、70 时, 平均一个测试信号的识别速度 (单位为 ms), 如表 9 所示。其中 CRC 类型算法中的矩阵 P 是可以根据训练集提前计算的

(只需要在识别时输入即可), 因此矩阵 P 的计算在实验中不计入识别所消耗时间。

表 3 不同分类算法的识别速度 ms

分类算法	训练集大小					
	20	30	40	50	60	70
SRC	16.10	21.06	24.99	29.30	34.40	38.07
CRC	0.19	0.23	0.26	0.29	0.30	0.35
WSRC	16.42	21.51	25.49	30.13	35.52	39.27
WCRC(本文)	0.46	0.66	0.88	1.12	1.33	1.67
Manhattan—WCRC(本文)	0.47	0.65	0.88	1.09	1.36	1.64

从以上实验结果可以看出, 本文提出的在声频无线传感器网络下基于 WCRC 的车辆识别方法的识别速度明显快于 WSRC、SRC, 接近于 CRC (比 CRC 略差, 主要是因为 WCRC 引入加权编码, 增加了小部分的计算负担, 这一点在 WSRC 对比于 SRC 的运算时间损耗也可以看出), 从而验证了 WCRC 对于 WSRC、SRC 的计算速度优势。同时, 本文进一步所提的基于 Manhattan—WCRC 的车辆识别方法在仿真实验中的识别速度和 WCRC 非常接近, 证明了 Manhattan—WCRC 在车辆识别中仍然拥有很好的实时性。

6 总结

本文提出的声频传感器网络下基于加权协同表示分类 (WCRC) 的车辆识别方法相比于传统的 CRC 方法精度上有了较大幅度的提升, 并且在识别速度上没有太大的影响 (接近于 CRC 的识别速度)。与此同时, WCRC 相较于 WSRC、SRC 在运算速度上有着非常明显的加速, 以及不错的精度提升。以上结果验证了将局部加权编码引入 CRC 的可行性和优势。同时, 本文进一步提出的声频传感器网络下基于曼哈顿距离加权协同表示分类 (Manhattan—WCRC) 的车辆识别方法也有很好的表现, 对比 WCRC, WSRC, CRC, SRC 取得了最高的识别精度, 同时识别速度和 WCRC 非常接近 (明显快于 WSRC、SRC), 验证了将曼哈顿距离引入加权编码的可行性和优势。在 Matlab 仿真模拟实验中, Manhattan—WCRC, WCRC 在拥有较好的识别精度下, 又拥有非常快的识别速度。这对于在实际的声频传感器网络下进行车辆类型的识别是非常有益的, 可以在既保证精度的情况下, 又能很好地加强识别的实时性, 在推广到实际应用中将会有不错的应用前景。

参考文献:

[1] 程淑红, 高 许, 周 斌. 基于多特征提取和 SVM 参数优化的车型识别 [J]. 计量学报, 2018, 39 (3): 348-352.
 [2] 董恩增, 魏魁祥, 于 晓, 等. 一种融入 PCA 的 LBP 特征降维车型识别算法 [J]. 计算机工程与科学, 2017, 39 (2): 359-363.
 [3] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation [J]. IEEE Transactions on Pattern A-

nalys and Machine Intelligence, 2009, 31 (2): 210-227.
 [4] Wen Y. A novel dictionary based SRC for face recognition [A]. 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) [C]. IEEE, 2017; 2582-2586.
 [5] 张永玲, 姜梦洲, 俞佩仕, 等. 基于多特征融合和稀疏表示的农业害虫图像识别方法 [J]. 中国农业科学, 2018, 51 (11): 2084-2093.
 [6] Wang K, Wang R, Feng Y, et al. Vehicle recognition in acoustic sensor networks via sparse representation [A]. 2014 IEEE International Conference on Multimedia and Expo Workshops (ICMEW) [C]. IEEE, 2014; 1-4.
 [7] Zhang L, Yang M, Feng X. Sparse representation or collaborative representation: Which helps face recognition? [A]. 2011 IEEE international conference on Computer vision (ICCV) [C]. IEEE, 2011; 471-478.
 [8] Zhang L, Yang M, Feng X, et al. Collaborative representation based classification for face recognition [J]. arXiv preprint arXiv: 1204. 2358, 2012.
 [9] Yang W, Wang Z, Yin J, et al. Image classification using kernel collaborative representation with regularized least square [J]. Applied Mathematics and Computation, 2013, 222; 13-28.
 [10] 李占利, 崔磊磊, 刘金璋. 基于协同表示的步态识别 [J]. 计算机应用研究, 2016, 33 (9): 2878-2880.
 [11] 王 瑞, 刘 宾, 周天润, 等. 基于协同表示的声振传感器网络车辆分类识别 [J]. 上海交通大学学报, 2018, 1: 018.
 [12] Lu C Y, Min H, Gui J, et al. Face recognition via weighted sparse representation [J]. Journal of Visual Communication and Image Representation, 2013, 24 (2): 111-116.
 [13] 郑建炜, 杨 平, 王万良, 等. 组加权约束的核稀疏表示分类算法 [J]. 计算机研究与发展, 2016, 53 (11): 2567-2582.
 [14] Wei J, Lv J C, Yi Z. Robust classifier using distance-based representation with square weights [J]. Soft Computing, 2015, 19 (2): 507-515.
 [15] Timofte R, Van Gool L. Adaptive and weighted collaborative representations for image classification [J]. Pattern Recognition Letters, 2014, 43: 127-135.
 [16] Waqas J, Zhang Y, Zhang L. Graph-based features extraction via datum adaptive weighted collaborative representation for face recognition [J]. International Journal of Pattern Recognition and Artificial Intelligence, 2014, 28 (2).
 [17] Xiong M, Ran Q, Li W, et al. Hyperspectral Image Classification Using Weighted Joint Collaborative Representation [J]. IEEE Geosci. Remote Sensing Lett., 2015, 12 (6): 1209-1213.
 [18] 罗 涛, 冯玉田, 唐子成, 等. 基于加权稀疏表示分类的车辆识别 [J]. 电子测量技术, 2018, 6: 005.
 [19] 刘桂林, 孔祥维, 刘 航. 基于无线传感器网络的车辆检测识别算法研究 [J]. 传感器与微系统, 2010 (2): 9-12.
 [20] Lu C, Feng J, Yan S, et al. A unified alternating direction method of multipliers by majorization minimization [J]. IEEE transactions on pattern analysis and machine intelligence, 2018, 40 (3): 527-541.