

复杂电磁环境下通信辐射源个体细微特征提取方法

雷迎科^{1,2}

(1. 电子工程学院, 合肥, 230037; 2. 通信信息控制和安全技术重点实验室, 嘉兴, 314033)

摘要: 针对实际复杂电磁环境下通信辐射源个体细微特征提取面临的标签样本缺失问题, 将半监督学习理论引入到通信辐射源细微特征提取, 提出一种半监督框架下的局部近邻保持正则化判别分析方法。该方法在双谱估计的基础上, 通过向线性判别模型中有效融入由无标签样本所提供的流形结构信息, 从而将线性判别方法扩展到半监督学习。在实际采集的同种型号、同种厂家、相同批次以及相同工作模式的不同 FM 通信电台数据集上的实验结果表明, 该方法能够获得更优的分类识别性能。

关键词: 通信辐射源; 细微特征; 双谱; 局部近邻保持正则化; 半监督学习

中图分类号: TP181 文献标志码: A

Novel Fine Feature Extraction Method for Identifying Communication Transmitter in Complex Electromagnetic Environment

Lei Yingke^{1,2}

(1. Electronic Engineering Institute, Hefei, 230037, China; 2. Science and Technology on Communication Information Security Control Laboratory, Jiaxing, 314033, China)

Abstract: To cope with the problem that the traditional fine feature extraction methods for identifying communication transmitters suffer from the lack of the labeled samples in real complex electromagnetic environment, an efficient fine feature extraction method, called locally neighborhood preserving regularized semi-supervised discriminant analysis, is proposed for communication transmitter recognition. Based on the bispectrum estimation, manifold structure information is incorporated into the linear discriminant model by unlabeled samples, which extends the linear discriminant analysis to the semi-supervised learning. Extensive experiments on the real-world database sampled from different FM communication radios with the same model, manufacturer, manufacturing lot, and work pattern demonstrate that the proposed method can obtain better recognition performance.

Key words: communication transmitter; fine feature; bispectrum; locally neighborhood preserving regularization; semi-supervised learning

引 言

现有的通信辐射源个体细微特征提取方法大体上可划分为暂态信号特征提取方法和稳态信号特征

提取方法^[1]。暂态信号特征提取方法主要是指通信辐射源在非稳定工作条件下根据辐射源个体开关机等暂态提取信号细微特征的方法^[1, 2]。稳态信号特征提取方法主要是指通信辐射源在稳定工作条件下根据辐射源个体噪声特性、杂散特征以及频率源不稳定性等在信号相关频率上的影响提取通信辐射源个体细微特征的方法^[3-9]。无论是暂态信号特征提取方法还是稳态信号特征提取方法,其研究的前提都是假定能够获得大量已知类别的通信辐射源发射信号观测样本,然而在实际复杂的电磁环境条件下,尤其是战时,对于每个通信辐射源而言,人们很难获取充裕的已知类别的辐射源观测样本数据,即在实际复杂电磁环境下,常常面临标签样本缺失条件下通信辐射源细微特征提取问题。显然,如果直接采用上述提出的基于充分样本的细微特征方法,其性能必将受到严重影响。在传统的有监督的维数约简(如线性判别分析(Linear discriminant analysis, LDA)^[10]和最大边缘判决(Maximum margin criterion, MMC)^[11])方法中,学习模型通常需要对大量有标签样本进行训练,才能实现细微特征的提取。当有标签样本的数量较少时,所获得的特征提取模型往往很难有好的泛化性能。因此,在使用这些维数约简方法之前,需要借助合成虚样本、训练样本局部化等技巧对样本进行预处理。但是通信辐射源个体观测样本信号都是非线性、非平稳和非高斯信号,这些人为的预处理过程很难客观地反应通信辐射源观测样本的真实变化,只有通过实际采集获取的观测样本才能最忠实地反应通信辐射源数据的本质分布结构。随着数字信号处理技术的逐步提高,获取无标签的通信辐射源观测样本变得越来越容易,如何利用大量的未标签数据来改善标签样本缺失条件下通信辐射源细微特征提取方法的性能,已经成为实际复杂电磁环境下通信辐射源细微特征提取研究中最受关注的问题之一。

本文拟将半监督学习理论引入到通信辐射源细微特征提取,旨在研究有标签样本较少条件下试图利用大量无标签本来改善通信辐射源个体的分类识别性能。本文提出一种半监督框架下的局部近邻保持正则化判别分析方法(Locally neighborhood preserving regularized semi-supervised discriminant analysis, LNPRSDA),从而为实际复杂电磁环境下通信辐射源个体细微特征提取提供一条新的解决途径。

1 基于局部近邻保持正则化半监督判别分析的通信辐射源个体细微特征提取

1.1 线性判别分析

已知属于 c 类的 l 个样本 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_l \in \mathbf{R}^n$, 定义样本类内散度矩阵 \mathbf{S}_w 和类间散度矩阵 \mathbf{S}_b , 有

$$\mathbf{S}_w = \sum_{k=1}^c \left(\sum_{i=1}^{l_k} (\mathbf{x}_i^{(k)} - \boldsymbol{\mu}^{(k)}) (\mathbf{x}_i^{(k)} - \boldsymbol{\mu}^{(k)})^T \right) \quad (1)$$

$$\mathbf{S}_b = \sum_{k=1}^c l_k (\boldsymbol{\mu}^{(k)} - \boldsymbol{\mu}) (\boldsymbol{\mu}^{(k)} - \boldsymbol{\mu})^T \quad (2)$$

式中: l_k 是第 k 类的样本个数, $\mathbf{x}_i^{(k)}$ 是第 k 类中第 i 个样本, $\boldsymbol{\mu}^{(k)}$ 为第 k 类的均值, $\boldsymbol{\mu}$ 表示所有样本的均值, c 为样本的类别数。LDA^[10]的目标函数为

$$\mathbf{A}_{\text{opt}} = \arg \max_{\mathbf{A}} \frac{\text{tr}(\mathbf{A}^T \mathbf{S}_b \mathbf{A})}{\text{tr}(\mathbf{A}^T \mathbf{S}_w \mathbf{A})} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_d] \quad (3)$$

定义总体散度矩阵 $\mathbf{S}_t = \sum_{i=1}^l (\mathbf{x}_i - \boldsymbol{\mu}) (\mathbf{x}_i - \boldsymbol{\mu})^T$, 有 $\mathbf{S}_t = \mathbf{S}_b + \mathbf{S}_w$ 。式(3)关于 LDA 的目标函数等价于

$$\mathbf{A}_{\text{opt}} = \arg \max_{\mathbf{A}} \frac{\text{tr}(\mathbf{A}^T \mathbf{S}_b \mathbf{A})}{\text{tr}(\mathbf{A}^T \mathbf{S}_t \mathbf{A})} \quad (4)$$

目标函数式(4)可以转化为如下的广义特征值分解

$$\mathbf{S}_b \mathbf{a}_i = \lambda \mathbf{S}_w \mathbf{a}_i \quad i = 1, 2, \dots, d \quad (5)$$

不失一般性,假定 $\boldsymbol{\mu} = 0$, 则有

$$\mathbf{S}_b = \sum_{i=1}^c l_k (\boldsymbol{\mu}^{(k)}) (\boldsymbol{\mu}^{(k)})^T = \sum_{i=1}^c l_k \left(\frac{1}{l_k} \left(\sum_{k=1}^{l_i} \mathbf{x}_i^{(k)} \right) \left(\sum_{k=1}^{l_i} \mathbf{x}_i^{(k)} \right)^T \right) = \sum_{k=1}^c \mathbf{X}^{(k)} \mathbf{L}^{(k)} (\mathbf{X}^{(k)})^T$$

其中, $\mathbf{L}^{(k)}$ 是所有元素为 $1/l_k$ 的 $l_k \times l_k$ 矩阵, $\mathbf{X}^{(k)} = [\mathbf{X}_1^{(k)}, \dots, \mathbf{X}_{l_k}^{(k)}]$ 表示第 k 类的数据矩阵。

令输入数据矩阵 $\mathbf{X} = [\mathbf{X}^{(1)}, \dots, \mathbf{X}^{(c)}]$, 矩阵 $\mathbf{L}_{l \times l}$ 定义为

$$\mathbf{L}_{l \times l} = \begin{bmatrix} L^{(1)} & 0 & \dots & 0 \\ 0 & L^{(2)} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & L^{(c)} \end{bmatrix} \quad (6)$$

有

$$\mathbf{S}_b = \sum_{k=1}^c \mathbf{X}^{(k)} \mathbf{L}^{(k)} (\mathbf{X}^{(k)})^T = \mathbf{X} \mathbf{L}_{l \times l} \mathbf{X}^T \quad (7)$$

因此, LDA 的目标函数式(4)可以重新描述为

$$\mathbf{A}_{\text{opt}} = \arg \max_{\mathbf{A}} \frac{\text{tr}(\mathbf{A}^T \mathbf{S}_b \mathbf{A})}{\text{tr}(\mathbf{A}^T \mathbf{S}_t \mathbf{A})} = \arg \max_{\mathbf{A}} \frac{\text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{L}_{l \times l} \mathbf{X}^T \mathbf{A})}{\text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{X}^T \mathbf{A})} \quad (8)$$

1.2 局部近邻保持正则化半监督判别分析

通过上述分析,不难发现 LDA 仅仅依赖于有标签的样本集寻找最优的投影方向。实际上经常获取的是大量无标签的样本。为了有效利用大量的无标签样本,通过向 LDA 模型中有效融入由无标签样本所提供的流形结构信息,从而将 LDA 方法扩展到半监督学习。

LDA 旨在寻找投影矩阵 \mathbf{A} 使得 $\text{tr}(\mathbf{A}^T \mathbf{S}_b \mathbf{A})$ 和 $\text{tr}(\mathbf{A}^T \mathbf{S}_t \mathbf{A})$ 的比值达到最大。当缺乏充裕的、有标签的训练样本时, LDA 经常会产生过拟合现象。阻止这一现象发生的典型方法是对 LDA 的目标函数进行正则化。LDA 的正则化版本为

$$\max_{\mathbf{A}} \frac{\text{tr}(\mathbf{A}^T \mathbf{S}_b \mathbf{A})}{\text{tr}(\mathbf{A}^T \mathbf{S}_t \mathbf{A}) + \alpha J(\mathbf{A})} \quad (9)$$

式中参数 α 是控制模型复杂度与经验损失的调节参数,最常用的正则化项 $J(\mathbf{A})$ 是 Tikhonov 正则化,即

$$J(\mathbf{A}) = \|\mathbf{A}\|^2$$

正则化项 $J(\mathbf{A})$ 提供了一种融入先验信息的方式。当能够获得大量无标签样本时,可以据此构造一个融入流形结构信息的正则化项 $J(\mathbf{A})$ 。给定样本集合 $\{\mathbf{x}_i\}_{i=1}^m$, 能够通过一个重构权值矩阵来构造该样本集当中近邻点之间的连接关系,具体地,对于每个样本点 \mathbf{x}_i 和它的邻域集合 $\{\mathbf{x}_j, \mathbf{x}_j \in \mathbf{N}_i\}$, 样本点 \mathbf{x}_i 与近邻点 \mathbf{x}_j 之间的重构权值 W_{ij} 可以通过极小化如下的目标函数获得,即有

$$\epsilon(\mathbf{W}) = \sum_{i=1}^m \left\| \mathbf{x}_i - \sum_{j=1}^m W_{ij} \mathbf{x}_j \right\|^2 \quad (10)$$

式中权值 W_{ij} 反映了样本点 \mathbf{x}_j 对 \mathbf{x}_i 的重构贡献大小。在 $\sum_j W_{ij} = 1$ 的约束条件下,利用拉格朗日乘子法对式(10)求解,可获得重构权值矩阵 \mathbf{W} 的封闭解。

重构权值矩阵 \mathbf{W} 描述了流形局部的几何结构。受谱聚类和各种基于图的半监督学习方法^[12,13]的启发,可以将正则化项定义为在原始数据观测空间和低维嵌入空间保持每个样本点的近邻重构系数不变,从而在通信辐射源细微特征提取过程中保持整个数据的流形结构,即极小化如下的损失函数

$$J(\mathbf{A}) = \sum_{i=1}^m \left\| \mathbf{A}^T \mathbf{x}_i - \sum_{j=1}^m W_{ij} \mathbf{A}^T \mathbf{x}_j \right\|^2 \quad (11)$$

令 $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_m]$, 有

$$J(\mathbf{A}) = \sum_{i=1}^m \left\| \mathbf{A}^T \mathbf{x}_i - \sum_{j=1}^m W_{ij} \mathbf{A}^T \mathbf{x}_j \right\|^2 = \sum_{i=1}^m \left\| \mathbf{A}^T \mathbf{X} \mathbf{I}_i - \mathbf{A}^T \mathbf{X} \mathbf{W}_i \right\|^2 = \sum_{i=1}^m \left\| \mathbf{A}^T \mathbf{X} (\mathbf{I}_i - \mathbf{W}_i) \right\|^2 = \text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{M} \mathbf{X}^T \mathbf{A}) \quad (12)$$

式中: \mathbf{I}_i 和 \mathbf{W}_i 分别是单位阵 \mathbf{I} 和 \mathbf{W} 的第 i 列, $\mathbf{M} = (\mathbf{I} - \mathbf{W})^T (\mathbf{I} - \mathbf{W})$, 元素 $M_{ij} = \delta_{ij} - W_{ij} - W_{ji} + \sum_k W_{ki} W_{kj}$ 。由式(9,12)得到基于局部近邻保持正则化的半监督判别分析目标函数,即

$$\max_{\mathbf{A}} \frac{\text{tr}(\mathbf{A}^T \mathbf{S}_b \mathbf{A})}{\text{tr}(\mathbf{A}^T (\mathbf{S}_t + \alpha \mathbf{X} \mathbf{M} \mathbf{X}^T) \mathbf{A})} \quad (13)$$

最大化目标函数式(13)可以转化为如下的广义特征值分解

$$\mathbf{S}_b \mathbf{a}_i = \lambda (\mathbf{S}_t + \alpha \mathbf{X} \mathbf{M} \mathbf{X}^T) \mathbf{a}_i \quad i = 1, 2, \dots, d \quad (14)$$

1.3 通信辐射源个体细微特征提取

基于局部近邻保持正则化半监督判别分析的通信辐射源个体细微特征提取方法主要分为两步:第一步通过双谱分析获取通信辐射源个体发射信号细微特征参数的完备集合,通过双谱变换将通信辐射源的时域信号投影到高维观测空间。第二步通过局部近邻保持正则化半监督判别分析挖掘通信辐射源个体高维观测数据的本质细微特征。

1.3.1 双谱变换

假设 $x(t)$ 为辐射源个体稳定工作状态下接收的辐射源发射信号,其 k 阶谱定义为

$$F_{kx}(\omega_1, \dots, \omega_{k-1}) = \sum_{\tau_1 = -\infty}^{+\infty} \dots \sum_{\tau_{k-1} = -\infty}^{+\infty} c_{kx}(\tau_1, \dots, \tau_{k-1}) e^{-j \sum_{i=1}^{k-1} \omega_i \tau_i} \quad (15)$$

式中 c_{kx} 为 $x(t)$ 的 k 阶累积量。其中双谱(三阶谱)是常用的高阶谱,定义如下

$$B_x(\omega_1, \omega_2) = \sum_{\tau_1 = -\infty}^{+\infty} \sum_{\tau_2 = -\infty}^{+\infty} c_{3,x}(\tau_1, \tau_2) e^{-j(\omega_1 \tau_1 + \omega_2 \tau_2)} \quad (16)$$

双谱的优势在于:(1)保持通信辐射源个体信号的相位和幅度信息;(2)对加性高斯噪声鲁棒性。本文主要利用双谱变换将通信辐射源的时域信号投影到高维观测空间,使得每个通信辐射源时域样本可以表示成高维观测空间中的一个点。

令 $x(1), x(2), \dots, x(N)$ 为输入通信辐射源观测数据, f_s 为采样速率, $\Delta_s = f_s/N$ 为双谱分析区域水平和垂直方向上的频率分辨率。双谱估计算法^[7]基本步骤如下。

(1)将所给输入数据分成 K 段,每段包含 M 个观测点,即 $N = KM$,并且对每段数据去均值化。

(2)计算 DFT 系数

$$Y^{(i)}(\lambda) = \frac{1}{M} \sum_{n=0}^{M-1} x^{(i)}(n) e^{-j2\pi n \lambda / M} \quad \lambda = 0, 1, \dots, M/2; i = 1, 2, \dots, K \quad (17)$$

式中 $\{x^{(i)}(n), n = 1, 2, \dots, M-1\}$ 是第 i 段数据。

(3)计算离散傅里叶变换系数的三阶相关值:

$$\hat{b}_i(\lambda_1, \lambda_2) = \frac{1}{\Delta_s^2} \sum_{k_1 = -L_i}^{L_i} \sum_{k_2 = -L_i}^{L_i} Y^{(i)}(\lambda_1 + k_1) Y^{(i)}(\lambda_2 + k_2) Y^{(i)}(-\lambda_1 - \lambda_2 - k_1 - k_2) e^{-j2\pi n \lambda / M} \quad (18)$$

式中: $0 \leq \lambda_2 \leq \lambda_1 + \lambda_2 \leq f_s/2$

(4)输入数据的双谱估计为 K 段双谱变换的均值

$$B_x(\omega_1, \omega_2) = \frac{1}{K} \sum_{i=1}^K \hat{b}_i(\omega_1, \omega_2) \quad (19)$$

式中: $\omega_1 = (2\pi f_s/N_s) \lambda_1; \omega_2 = (2\pi f_s/N_s) \lambda_2$ 。

1.3.2 算法步骤

根据上面的分析,基于局部近邻保持正则化半监督判别分析的通信辐射源个体细微特征提取算法流程如图 1 所示,其主要步骤如下。




图 1 基于 LNPRSDA 的通信辐射源个体细微特征提取算法

Fig. 1 Fine feature extraction for identifying communication transmitter based on LNPRSDA

(1) 对每个采集的通信辐射源时域信号样本,根据式(19)估计信号的双谱。

(2) 构造所有样本的连接图。根据式(10)构建所有样本的重构权值矩阵 \mathbf{W} , 并计算矩阵 $\mathbf{M} = (\mathbf{I} - \mathbf{W})^T(\mathbf{I} - \mathbf{W})$ 。

(3) 构造带有标签样本的连接图。设计如下权值矩阵 $\mathbf{L} \in \mathbf{R}^{m \times m}$ 有

$$\mathbf{L} = \begin{bmatrix} \mathbf{L}_{l \times l} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix}$$

其中 $\mathbf{L}_{l \times l} \in \mathbf{R}^{l \times l}$ 如式(6)所示。定义

$$\tilde{\mathbf{I}} = \begin{bmatrix} \mathbf{I} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix}$$

其中 \mathbf{I} 是大小为 $l \times l$ 的单位阵。

(4) 特征分解。计算如下形式的广义特征值所对应的特征向量

$$\mathbf{X}\mathbf{L}\mathbf{X}^T \mathbf{a}_i = \lambda \mathbf{X}(\tilde{\mathbf{I}} + \alpha \mathbf{M})\mathbf{X}^T \mathbf{a}_i \quad (20)$$

式中 $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_l, \mathbf{x}_{l+1}, \dots, \mathbf{x}_m]$; $i = 1, 2, \dots, d$ 。

(5) 令 $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_d]$ 表示 $n \times d$ 维的变换矩阵,则样本集 \mathbf{X} 在 d 维子空间的投影 $\mathbf{Y} = \mathbf{A}^T \mathbf{X}$ 。

令 $\mathbf{X}_l = [\mathbf{x}_1, \dots, \mathbf{x}_l]$ 表示有标签的数据矩阵,很容易验证 $\mathbf{X}\mathbf{L}\mathbf{X}^T = \mathbf{X}_l \mathbf{L}_l \mathbf{X}_l^T = \mathbf{S}_0$ 和 $\tilde{\mathbf{X}}\tilde{\mathbf{I}}\tilde{\mathbf{X}}^T = \mathbf{X}_l \mathbf{X}_l^T = \mathbf{S}_1$, 因此,式(20)的特征分解问题等价于式(14)。

为了得到式(20)的稳定解,矩阵 $\mathbf{X}(\tilde{\mathbf{I}} + \alpha \mathbf{M})\mathbf{X}^T$ 通常要求是非奇异的,然而在小样本条件下该要求通常无法得到满足。为了解决该问题,采用正则化思想将式(20)转化为如下形式的广义特征值问题,即

$$\mathbf{X}\mathbf{L}\mathbf{X}^T \mathbf{a}_i = \lambda (\mathbf{X}(\tilde{\mathbf{I}} + \alpha \mathbf{M})\mathbf{X}^T + \beta \mathbf{I}) \mathbf{a}_i \quad i = 1, 2, \dots, d \quad (21)$$

式中 $\beta > 0$, 则矩阵 $\mathbf{X}(\tilde{\mathbf{I}} + \alpha \mathbf{M})\mathbf{X}^T + \beta \mathbf{I}$ 是非奇异的。

2 实验结果分析

本实验所采用的电台时域信号样本取自于同种型号、同种厂家、相同批次和相同工作模式的 10 部不同 FM 电台的实际采样零中频 IQ 正交数据,采集参数如表 1 所示。每部电台采样 9 个样本信号,共有 90 个原始样本信号,如表 2 所示。为了验证本文所提出方法的性能,将双谱+局部近邻保持正则化半监督判别分析(BiSpectrum + LNPRSDA)与双谱(BiSpectrum)、双谱+主分量分析(BiSpectrum + PCA)方法进行实验比较,其中第二种方法涉及到 PCA 处理,为了保持 100% 信号能量,选择所有非零特征值所对应的主分量。在 LNPRSDA 算法中, α 和 β 均设置为 0.1。为了考察特征提取方法的性能,在实验中分类器仅选用简单的 1 近邻分类器。

实验过程包括 3 步:首先计算所有样本的双谱估计;其次利用 3 种不同的方法计算基于训练样本的

表 1 信号采集参数
Tab. 1 Parameters of signal sample

中心频率/MHz	信号带宽/MHz	接收机信道带宽/MHz	采样频率/MHz	采样点数	信号样式
160	25	100	204.8	1 023 658	FM

特征子空间;最后采用 1 近邻分类器对测试样本进行分类识别。

2.1 3 个电台细微特征提取

从电台 5 号、电台 6 号和电台 7 号样本中分别随机选择 7 个样本构成训练样本集,其余样本作为测试样本集。对于每个电台的 7 个训练样本,分别考虑两种情况:第一种情况是只有 1 个样本有标签,其余 6 个样本无标签;第二种情况是 4 个样本有标签,其余 3 个样本无标签。实际上针对第一种情况,不难发现样本的类间散度矩阵与总体散度矩阵相同,因此原始的 LDA 算法将失效。

分别采用 BiSpectrum, BiSpectrum + PCA, BiSpectrum + LNPRSDA 方法对训练样本集进行细微特征提取,在此基础上通过 1-近邻分类器对测试样本集进行分类识别。计算 20 次独立实验的平均识别率。BiSpectrum, BiSpectrum + PCA 和 BiSpectrum + LNPRSDA 三种方法在电台 5~7 号样本数据上的平均识别率与特征空间维数变化曲线如图 2 所示,从图中可以看出,特征空间维数的变化将影响这 3 种方法的平均识别率;对于 BiSpectrum + PCA 和 BiSpectrum + LNPRSDA 方法,特征空间维数上界分别为 3(类别数)和 20(训练样本数目减 1),并且它们能够很快获得最大平均识别率。

表 3 和表 4 分别显示了每个电台有 1 个标签样本和 4 个标签样本时 20 次重复实验的最大平均识别率。从表 2 和表 3 可以看出,在这 3 种方法中, BiSpectrum + LNPRSDA 明显优于其他两种方法。

2.2 5 个电台细微特征提取

从电台 3 号至电台 7 号样本中,每个电台随机选择 7 个样本作为训练集,其余样本作为测试集。对于每个电台的 7 个训练样本,同样考虑两种情况:第一种情况是只有 1 个样本有标签,其余 6 个样本无标签;第二种情况是有 4 个样本有标签,其余 3 个样本无标签。其他实验设置如 2.1 节。图 3 显示了 BiSpectrum, BiSpectrum + PCA 和 BiSpectrum + LNPRSDA 三种方法在电台 3~7 号样本数据上的平均识别率与特征空间维数变化关系,从图中不难看出,这 3 种方法的平均识别率均随着特征空间维数的变化而变化;对于 BiSpectrum + PCA 和 BiSpectrum + LNPRSDA 方法,随着特征空间维数的增加,平均识别率达到最大值之后呈下降趋势,这表明并不是特征空间维数越高,平均识别率越大。

表 2 90 个原始时域样本信号分布情况说明

Tab. 2 Brief introduction of 90 original time domain signal samples

序号	说话人	频率/MHz	电台
样本 1	说话人 1	160	电台 1 号
样本 2	说话人 1	160	电台 1 号
样本 3	说话人 1	160	电台 1 号
样本 4	说话人 2	160	电台 1 号
样本 5	说话人 2	160	电台 1 号
样本 6	说话人 2	160	电台 1 号
样本 7	说话人 3	160	电台 1 号
样本 8	说话人 3	160	电台 1 号
样本 9	说话人 3	160	电台 1 号
⋮	⋮	⋮	⋮
样本 82	说话人 1	160	电台 10 号
样本 83	说话人 1	160	电台 10 号
样本 84	说话人 1	160	电台 10 号
样本 85	说话人 2	160	电台 10 号
样本 86	说话人 2	160	电台 10 号
样本 87	说话人 2	160	电台 10 号
样本 88	说话人 3	160	电台 10 号
样本 89	说话人 3	160	电台 10 号
样本 90	说话人 3	160	电台 10 号

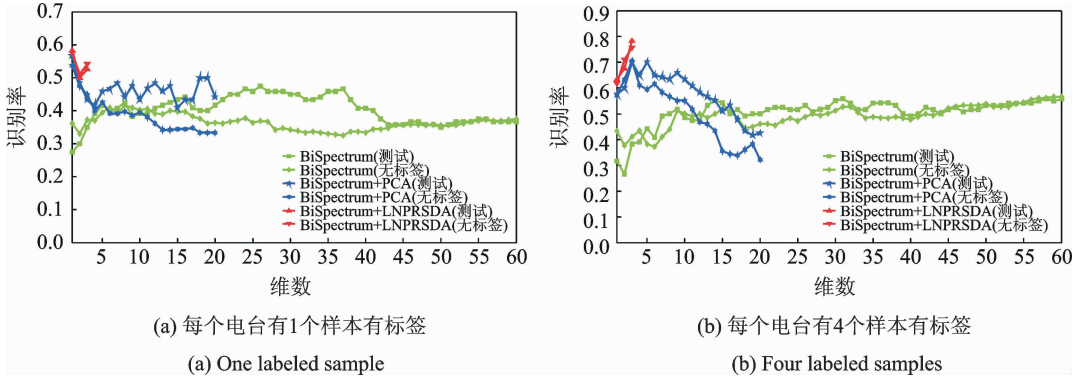


图 2 3种方法在电台5~7号样本数据上的平均识别率

Fig. 2 Average recognition rates of three methods on the samples from 5—7 radios

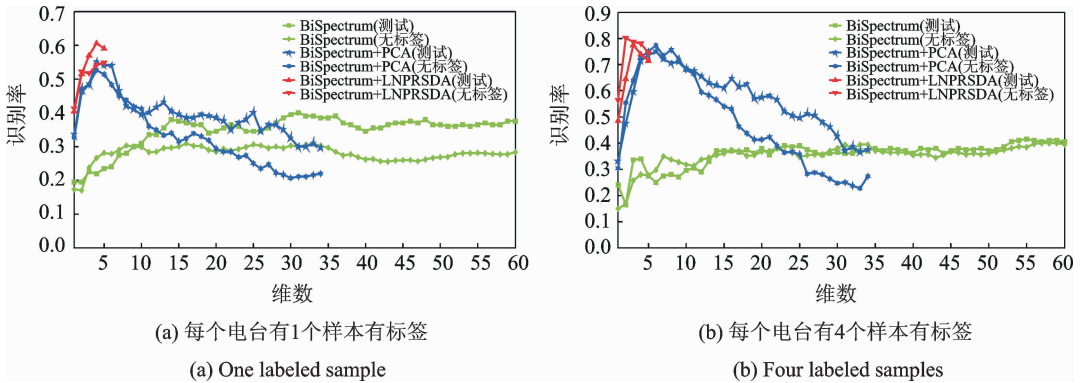


图 3 3种方法在电台3~7号样本数据上的平均识别率

Fig. 3 Average recognition rates of three methods on the samples from 3—7 radios

表 3 3种方法在电台5~7号样本数据上进行20次实验的平均识别率(每个电台有1个样本有标签)

Tab. 3 Average recognition rates with 20 experiments for three methods on the samples from 5—7 radios (One labeled sample for every radio)

方法	无标签训练样本识别率/%	测试样本识别率/%
BiSpectrum	53.33	56.67
BiSpectrum + PCA	53.61	56.67
BiSpectrum + LNPRSDA	57.50	58.33

表 4 3种方法在电台5~7号样本数据上进行20次实验的平均识别率(每个电台有4个样本有标签)

Tab. 4 Average recognition rates with 20 experiments for three methods on the samples from 5—7 radios (Four labeled samples for every radio)

方法	无标签训练样本识别率/%	测试样本识别率/%
BiSpectrum	72.22	73.33
BiSpectrum + PCA	70.56	70.00
BiSpectrum + LNPRSDA	75.56	78.33

表 5 和表 6 分别显示了每个电台有 1 个标签样本和 4 个标签样本时 20 次重复实验的最大平均识别率。在所有情况下 BiSpectrum + LNPRSDA 均获得了最佳的分类识别性能。

表 5 3 种方法在电台 3—7 号样本数据上进行 20 次实验的平均识别率(每个电台有 1 个样本有标签)

Tab. 5 Average recognition rates with 20 experiments for three methods on the samples from 3—7 radios (One labeled sample for every radio)

方法	无标签训练样本识别率/%	测试样本识别率/%
BiSpectrum	50.17	57.00
BiSpectrum + PCA	52.67	55.00
BiSpectrum + LNPRSDA	54.83	60.50

表 6 3 种方法在电台 3—7 号样本数据上进行 20 次实验的平均识别率(每个电台有 4 个样本有标签)

Tab. 6 Average recognition rates with 20 experiments for three methods on the samples from 3—7 radios (Four labeled samples for every radio)

方法	无标签训练样本识别率/%	测试样本识别率/%
BiSpectrum	69.33	69.00
BiSpectrum + PCA	77.33	75.00
BiSpectrum + LNPRSDA	80.00	77.50

2.3 10 个电台细微特征提取

本小节实验样本包括电台 1 号~电台 10 号观测样本,实验设置如 2.1 节。3 种方法在 10 个电台样本数据上的平均识别率与特征空间维数变化曲线如图 4 所示。从图中可以看出,随着特征空间维数的增加,首先这 3 种方法的平均识别率呈上升趋势,当它们达到最大平均识别率后,随着特征空间维数的进一步增加,平均识别率开始下降。表 7 和表 8 分别显示了每个电台有 1 个标签样本和 4 个标签样本时 20 次重复实验的最大平均识别率。从表中可以看出在这 3 种方法中,BiSpectrum + LNPRSDA 获得了最佳的分类识别性能。

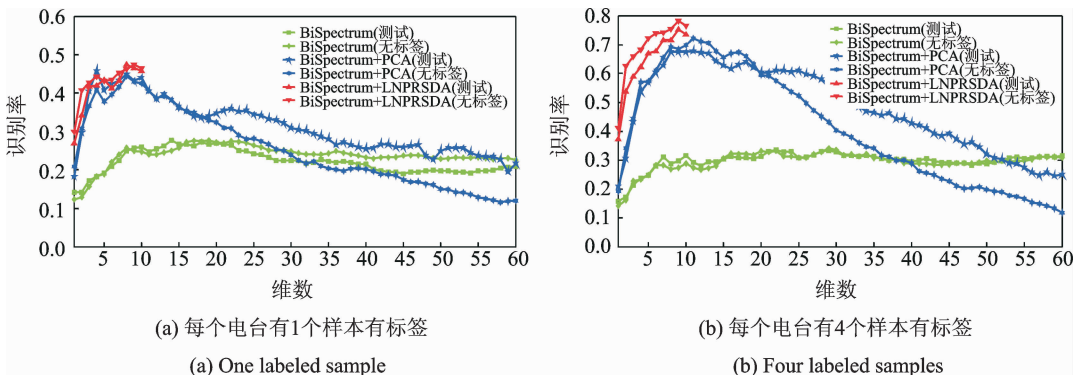


图 4 3 种方法在电台 1—10 号样本数据上的平均识别率

Fig. 4 Average recognition rates of three methods on the samples from 1—10 radios

表 7 3 种方法在电台 1~10 号样本数据上进行 20 次实验的平均识别率(每个电台有 1 个样本有标签)

Tab. 7 Average recognition rates with 20 experiments for three methods on the samples from 1—10 radios (One labeled sample for every radio)

方法	无标签训练样本识别率/%	测试样本识别率/%
BiSpectrum	40.50	39.75
BiSpectrum + PCA	44.42	45.75
BiSpectrum + LNPRSDA	47.50	47.50

表 8 3 种方法在电台 1~10 号样本数据上进行 20 次实验的平均识别率(每个电台有 4 个样本有标签)

Tab. 8 Average recognition rates with 20 experiments for three methods on the samples from 1—10 radios (Four labeled samples for every radio)

方法	无标签训练样本识别率/%	测试样本识别率/%
BiSpectrum	61.67	55.50
BiSpectrum + PCA	72.17	67.75
BiSpectrum + LNPRSDA	78.17	75.25

2.4 讨论

本文 3 个、5 个与 10 个电台细微特征提取的实验结果表明:BiSpectrum + LNPRSDA 算法在绝大多数实验条件下实现了显著的最优分类识别性能。这主要源于 LNPRSDA 方法有效融入了通信辐射源观测数据的流形结构信息。在实验中,选择了每个电台样本只有 1 个类别标签的极端不利情况和每个电台有 4 个类别标签的一般情况,通过引入半监督机制,有效利用大量无标签样本保持原始观测空间和低维嵌入空间每个样本点的近邻重构系数不变,同时根据有标签样本寻找最优的分类投影方向,从而确保提取通信辐射源的本质细微特征。在实验中所处理的通信电台数据是从实际无线传播信道中采集的,它具有明显的非平稳性和非线性特点,应用基于局部近邻保持正则化半监督判别分析的特征提取方法能够有效地探测到这些本征特征。从这个意义来讲, LNPRSDA 方法明显优于其他传统的线性特征提取方法。

3 结束语

针对实际复杂电磁环境下通信辐射源个体细微特征提取面临的标签样本缺失问题,本文提出一种基于局部近邻保持正则化半监督判别分析的通信辐射源个体细微特征提取方法。在基于双谱分析获取通信辐射源个体发射信号细微特征参数完备集合的基础上,本文方法通过向线性判别模型中有效融入由无标签样本所提供的流形结构信息,从而将线性判别方法扩展到局部近邻保持正则化半监督判别分析,实现对通信辐射源个体高维观测数据的本质细微特征提取。在实际采集的同种型号、同种厂家、相同批次和相同工作模式的不同 FM 通信电台数据集上的实验结果验证了 LNPRSDA 方法的有效性。

参考文献:

- [1] Toonstra J, Kinsner W. Transient analysis and genetic algorithms for classification[C]// WESCANEX 95 Communications, Power, and Computing. [S. l.]:IEEE, 1995, 2: 432-437.
- [2] Luigi C D, Jauffre C. Estimation and classification of FM signals using time frequency transforms [J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(2): 421-437.
- [3] Turkboylari M, Stuber G L. An efficient algorithm for estimating the signal-to-interference ratio in TDMA cellular systems

- [J]. IEEE Transactions on Communications, 1998, 46(6): 728-731.
- [4] 陈志伟,徐志军,王金明,等.一种基于循环谱切片的通信辐射源识别方法[J].数据采集与处理,2013,28(3):284-288.
Chen Zhiwei, Xu Zhijun, Wang Jinming, et al. Emitter identification method based on cyclic spectrum density slice [J]. Journal of Data Acquisition and Processing, 2013, 28(3): 284-288.
- [5] 徐玉龙,王金明,徐志军,等.基于小波熵的辐射源指纹特征提取方法[J].数据采集与处理,2014,29(4):631-635.
Xu Yulong, Wang Jinming, Xu Zhijun, et al. Fingerprint feature extraction method for emitters based on wavelet entropy [J]. Journal of Data Acquisition and Processing, 2014, 29(4): 631-635.
- [6] 江立伟,袁红林,严燕,等.一种低信噪比下的高精度射频指纹变换方法[J].数据采集与处理,2015,30(5):1036-1042.
Jiang Liwei, Yuan Honglin, Yan Yan, et al. High-accuracy radio frequency fingerprint transform method in low SNR environment [J]. Journal of Data Acquisition and Processing, 2015, 30(5): 1036-1042.
- [7] Zhang X D, Shi Y, Bao Z. A new feature vector using selected bispectra for signal classification with application in radar target recognition [J]. IEEE Transactions on Signal Processing, 2001, 49(9): 1875-1885.
- [8] Delprat N. Asymptotic wavelet and Gabor analysis; Extraction of instantaneous frequencies [J]. IEEE Transactions on Information Theory, 1992, 38(3): 644-664.
- [9] Liedtke F F. Computer simulation of an automatic classification procedure modulation communication signals with unknown parameters [J]. Signal Processing, 1984, 6: 311-323.
- [10] Fisher R. The use of multiple measurements in taxonomic problems [J]. Annals of Eugenics, 1936, 7(2): 179-188.
- [11] Li H, Jiang T, Zhang K. Efficient and robust feature extraction by maximum margin criterion [J]. IEEE Trans Neural Networks, 2006, 17(1): 157-165.
- [12] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290: 2323-2326.
- [13] Saul L K, Roweis S T. Think globally, fit locally: Unsupervised learning of low dimensional manifold [J]. J Machine Learning Research, 2003, 4: 119-155.

作者简介:



雷迎科(1975-),男,博士,
副教授,研究方向:机器学习、
通信信号处理,E-mail:
leiyingke@163.com。

(编辑:刘彦东)

