

基于稀疏分量分析的海量短波电台快速自动识别方法

黄伟庆^{1,2}, 王元坤^{1,2}, 张巧遇^{1,2}, 李 静^{1,2}, 魏 冬^{1,2}

¹中国科学院信息工程研究所 北京 中国 100093

²中国科学院大学网络空间安全学院 北京 中国 100093

摘要 针对短波频段内海量电台的快速自动识别问题, 本文提出一种基于稀疏分量分析的快速识别方法, 该方法基于各电台发射信号时域所具有的独特周期性及稀疏性, 基于高速频谱扫描数据对各信道的多个电台进行自动分离和识别。首先, 针对单信道多电台混合问题, 将信道的功率时间序列建模为包含多个电台成分的混合信号, 并基于混合信号所具有稀疏的性质, 使用稀疏向量分析方法(Sparse Component Analysis, SCA)对混合信号进行自动分离, 实现对同信道上不同电台的识别。在此基础上, 针对短波时变信道衰落下的电台信号进行分离问题, 提出一种基于时间特征聚类的稀疏分量分析的算法, 该算法将时间特征与幅值特征相融合进行聚类, 实现对混合矩阵的估计。最后, 针对混合噪声对分类结果的影响, 在聚类结果基础上, 将信号向类心向量进行投影, 去除时变信道衰落引入的噪声。在仿真实验阶段, 发射源设置不同播放时间, 不同占空比和不同周期, 在8个地点布置信号采集系统, 使用短波预测软件(Voice of American Coverage Analysis Program, VOACAP)对接收功率进行仿真, 该算法的识别正确率为98.1%, 相比聚类稀疏分量分析和快速独立成分分析分别提升了7.3%和16.8%, 能够很好解决短波电台分离和识别的问题。

关键词 短波电台; 信号识别; 信号分离; 稀疏分量分析; 无线电监测

中图分类号 TN92 DOI号 10.19363/j.cnki.cn10-1380/tn.2023.08.13

A Fast Automatic Identification Method of Massive Shortwave Radio Stations Based on Sparse Component Analysis

HUANG Weiqing^{1,2}, WANG Yuankun^{1,2}, ZHANG Qiaoyu^{1,2}, LI Jing^{1,2}, WEI Dong^{1,2}

¹ Institute of Information Engineering, Chinese Academy of Sciences, Beijing 100093, China

² School of Cyber Security, University of Chinese Academy of Sciences Beijing 100049, China

Abstract Aiming at the problem of rapid automatic identification of a large number of radio stations in the high frequency band, a fast identification method based on sparse component analysis is proposed. Based on the unique periodicity and sparseness of each station's transmitted signal in the time domain, the high-speed spectrum scanning data are used to separate and identify multiple radio stations on each channel automatically. First, to solve the single-channel multi-station mixing problem, the power time series of the channel is modeled as a mixed signal containing multiple radio components, and based on the sparse nature of the mixed signal, Sparse Component Analysis (SCA) is used to automatically separate the mixed signal to achieve the same Identification of different stations on a channel. Then, in order to separate the radio signals under shortwave time-varying channel fading, a sparse component analysis algorithm based on time feature clustering is proposed, in which clustering is performed with both the time features and the amplitude features to realize the estimation of the mixing matrix. In addition, in order to solve the problem of mixed noise on the classification results, based on the clustering results, the algorithm projects the signal to the centroid vector to remove the noise introduced by time-varying channel fading. In simulation experiments, the transmitting source is set with different playing times, different duty cycles and different periods, the signal receive system is arranged in 8 locations, and the received power is simulated by using the shortwave prediction software Voice of American Coverage Analysis Program (VOACAP) our algorithm's accuracy rate of station identification is 98.1%, which is 7.3% and 16.8% higher than clustering based sparse component analysis and fast independent component analysis, respectively, providing a good solution to the problem of separation and identification of shortwave radio stations.

通讯作者: 张巧遇, 博士, 工程师, zhangqiaoyu@iie.ac.cn。

本课题得到中国科学院青年创新促进会(No. Y9YY015104)项目资助。

收稿日期: 2021-02-04; 修改日期: 2021-03-25; 定稿日期: 2023-08-10

Key words shortwave radio stations; signal identification; signal separation; sparse component analysis; radio monitoring

1 引言

短波信号主要通过电离层反射实现远距离传输,是军用通信、机载通信、舰载通信和跨国界信息传输及国际广播等通信的重要载体,短波频段内存在来自全球不同位置用途多样且数量巨大的电台信号。为此,短波频段是情报收集、电子战和信息对抗的重要阵地。基于信号监测对短波频段内海量电台进行快速准确识别在军事领域及信息安全领域具有重要意义。

目前,电台识别相关的研究主要涉及调制识别和辐射源识别。调制识别是指基于不同调制方式对电台信号带来的差异性,识别电台信号所采用的调制类型。调制识别需要采集信号时域样本,提取信号特征,训练并使用分类器。常用的特征包括瞬时特征、谱特征、高阶累积量特征、小波变换特征和星座图特征等^[1]。辐射源识别是指依据辐射源的信号特征的差异识别不同辐射源的技术,需要标记辐射源,提取不同辐射源信号特征,训练并使用分类器。使用的特征包括调制参数特征、杂散特征,高阶谱特征和变换域特征等^[2-3]。比如,徐书华^[4]使用矩形积分双谱,对FSK电台识别率达到80%左右;孙娜^[2]通过实验分析比较各种积分双谱的分类性能及分类效率,其中基于矩形积分双谱特征的识别正确率最高,但是训练时间最长;Lida Ding等人^[5]利用压缩后的积分双谱特征训练卷积神经网络(Convolutional Neural Network, CNN),CNN能够有效捕捉高维特征中的隐藏信息,获得相比传统分类器更好的识别效果;Ke Li等人^[6]同样使用积分双谱特征,并提出了基于核半监督鉴别分析的识别方法。另外,徐书华^[4]提取Hilbert谱的灰度图像作为特征,并进行特征降维和特征选择,但识别正确率不足75%;Yingjun Yuan等人^[7]基于Hilbert谱提出了13个细化的特征参数分析暂态信号,可以有效识别不同的手机;Yiwei Pan等人^[8]使用Hilbert谱作为特征,提出了基于深度残差网络(Residual network, ResNet)的辐射源识别方法,残差网络中的残差单元解决了网络退化的问题,提升了识别能力。另外,Taichi Ohtsuji等人^[9]提出了对数功率谱密度和CNN相结合的辐射源识别方法,识别正确率达到99.4%;Yun Lin等人^[10]采用功率谱密度和分数阶傅立叶变换两种方法提取暂态信号的特征,获得了97%的识别准确率。总之,用于辐射源识别的特征虽然众多,但常用特征仅有双谱, Hilbert谱

和功率谱等。

短波电台信号以幅度调制为主,调制方式单一,无需识别信号的调制方式。因此,现有的短波电台识别的研究主要通过辐射源识别的相关技术实现^[11-12]。虽然使用辐射源识别技术能够有效识别电台,然而,在短波频段中存在大量电台及其发射信号,辐射源识别需要采集特定电台的信号,提取特征,标记样本并训练分类器,处理效率很低。

事实上,通常短波电台的发射信道、发射起止时间及时长相对固定,在时域上呈现比较稳定的周期性,为此,可利用该周期性对电台信号进行识别。然而,通常单个短波信道承载多个电台设备,若无法对各电台的发射信号进行分离,则难以识别到具体电台的发射行为;另外,由于短波电台位置分布范围极广,信号传播主要通过电离层反射,远距离接收的信号受到严重的信道时变衰落,并且在传播过程中极易受到环境电磁干扰,对电台发射信号的时域周期性造成一定程度的破坏。

为此,本文提出一种基于稀疏分量分析(Sparse Component Analysis, SCA)^[13]的短波电台快速自动识别方法。首先,针对单信道多电台混合问题,该方法将信道的功率时间序列建模为包含多个电台成分的混合信号,并基于混合信号所具有稀疏的性质,使用SCA对混合信号进行自动分离,实现对同信道上不同电台的识别。在此基础上,针对时变信道衰落问题,提出了一种基于时间特征聚类SCA(Time Features Clustering based Sparse Component Analysis, TFC-SCA)的电台信号分离算法,该算法在求解混合矩阵的过程中融合了信号的时间特征和幅值特征,提升了聚类算法在时变信道衰落情况下的准确率,同时将混合信号向类心向量投影,去除了时变信道衰落对混合信号引入的噪声,减少了时变信道衰落对于信号分离的影响。

本文主要贡献如下:

- 1、在海量数据的频谱监测环境下,提出了基于SCA的短波电台的快速自动识别方法。该方法通过频域数据对短波频段中各个信道上的不同电台进行分离和识别,相比辐射源识别的相关方法,不再面向特定电台,具有很高的识别效率。

- 2、提出了一种基于TFC-SCA的电台信号分离算法,该算法在估计混合矩阵时,融合了信号的时间特征进行聚类,提升了时变信道衰落情况下聚类算法的准确率以及混合矩阵估计的精度。

3、TFC-SCA 结合聚类结果, 基于类心向量投影对混合信号去噪, 提升了时变信道衰落情况下的信号分离效果。

本文后续章节安排如下: 第二部分介绍了短波电台信号分离和识别模型, 第三部分提出了基于 TFC-SCA 的电台信号分离算法, 第四部分进行仿真实验测试和分析, 第五部分对论文进行总结并展望下一步工作。

2 短波电台信号分离和识别模型

本节提出一种短波电台信号快速识别方法, 该方法的总体流程如图 1 所示, 包括信号采集、电台信号分离和识别、电台信息标定三大部分。

(1) 信号采集

首先, 在多个接收点布置信号采集系统, 实现

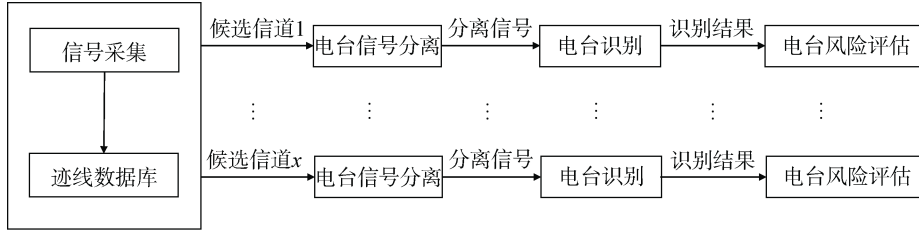


图 1 短波电台分离和识别流程

Figure 1 The process of shortwave radio separation and identification

对于各个分离信号 $y_i(t)$, 根据信号的波形设置阈值 ξ , 识别出当前电台的播放时间:

$$E_i = E_i \cup \{t\}, \forall y_i(t) > \xi \quad (1)$$

(3) 电台风险评估

得到当前信道上各个电台的播放时间的识别结果 E_1, E_2, \dots, E_N , 监测人员可以依据信道的历史识别结果和解调信息情报, 将各个电台识别结果内的电台信号与具体的电台一一对应, 验证电台识别结果的准确性。对于播放时间相比历史记录发生变化的电台以及不在历史记录中的新电台, 可以将其标记为风险电台, 为无线电频谱资源监管提供支持。

3 基于 TFC-SCA 的电台信号分离算法

3.1 基于 C-SCA 的电台信号分离模型

在短波电台识别流程中, 信号分离是最为关键的一个部分, 信号分离的效果直接决定了电台识别的正确率。因此, 本文的研究重点关注电台信号分离问题, 该问题可以建模为如下的盲源分离^[15-16]问题: 其中, N 个源信号 $s_1(t), \dots, s_N(t)$ 是 N 个电台的发射功率时间序列, 它们组成源信号向量 $\mathbf{s}(t)$ 。 M 个混合

信号频谱迹线的采集和存储。每个信号采集系统由天线、接收机和计算机组成, 所有接收机的接收频率范围设置为 3~30MHz, 覆盖整个短波频段。短波电台信号带宽一般为 10KHz, 设定接收机频率分辨率设置为 1KHz, 可以有效地采集到电台信号。各地的频谱迹线数据被存储在计算机的迹线数据库中。

(2) 电台信号分离和识别

基于历史监测的频谱迹线数据, 对每个短波信道的占用度^[14]进行分析, 初步判断每个信道是否被电台占用, 并将被占用信道标记为候选信道。对于每个候选信道, 依次提取该信道在多个接收点的功率时间序列 $x_1(t), \dots, x_M(t)$, 这些信道功率时间序列可视为受多个电台发射行为所影响的混合信号。信号分离的目标是对混合信号进行分离, 得到分离信号 $y_1(t), \dots, y_N(t)$, 每个分离信号对应于占用该信道的一个电台。

信号 $x_1(t), \dots, x_M(t)$ 是在 M 个接收点监测得到的信道功率时间序列, 它们组成混合信号向量 $\mathbf{x}(t)$ 。在短波信道下, 混合信号的生成过程可以表示为:

$$\begin{bmatrix} x_1(t) \\ \vdots \\ x_M(t) \end{bmatrix} = \begin{bmatrix} a_{11} & \dots & a_{1N} \\ \vdots & \ddots & \vdots \\ a_{M1} & \dots & a_{MN} \end{bmatrix} \begin{bmatrix} s_1(t) \\ \vdots \\ s_N(t) \end{bmatrix} + \begin{bmatrix} n_{c1}(t) \\ \vdots \\ n_{cN}(t) \end{bmatrix} + \begin{bmatrix} n_1(t) \\ \vdots \\ n_N(t) \end{bmatrix} \quad (2)$$

使用向量可以表示为:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{n}_c(t) + \mathbf{n}(t) \quad (3)$$

其中, \mathbf{A} 是短波信道对应的混合矩阵, \mathbf{A} 中的元素 a_{ij} 是第 i 个电台到第 j 个接收点的短波信道的功率衰减系数。 $\mathbf{n}_c(t)$ 是时变信道噪声, 表示短波信道衰落在较长时间内存在的不规则变化。 $\mathbf{n}(t)$ 是随机高斯噪声, 表示信号在传输过程中存在的随机干扰。

信号分离的目标是在信号的混合过程未知的情况下, 根据混合信号求解分离矩阵 \mathbf{W} , 进而分离出源信号:

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t) \quad (4)$$

其中, $\mathbf{y}(t)$ 是对源信号的估计信号向量, 也称为分离信号向量, 求解出的分离信号应该尽可能与源信号相似。

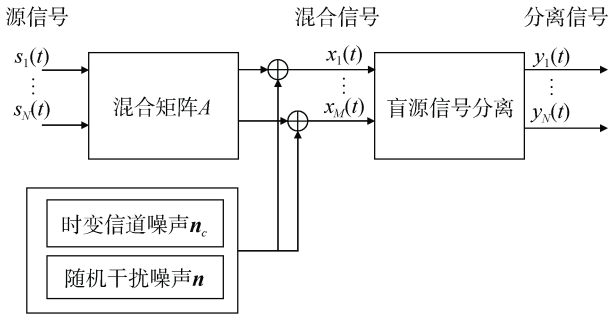


图2 盲源分离模型

Figure 2 Blind source separation model

下面对信号的混合过程进行分析, 尝试求解混合矩阵 A , 并基于 $W = A^{-1}$ 求解分离矩阵 W , 完成最终的信号分离。

记各个电台的播放时间集合分别为 T_1, T_2, \dots, T_N , 总监测时间为 T_S 。所有电台均保持静默的时间称为公共静默时间, 使用 T_0 表示:

$$T_0 = (T_S - T_1) \cap (T_S - T_2) \cap \dots \cap (T_S - T_N) \quad (5)$$

由于电台在播放时间 T_i 内具有较大的发射功率, 在静默时间 $T_S - T_i$ 内功率为 0, 所以源信号满足下式:

$$\begin{cases} s_i(t) \neq 0, t \in T_i \\ s_i(t) = 0, t \in T_S - T_i \end{cases} \quad (6)$$

假设各个电台的播放时间互不重叠:

$$\forall i \neq j, T_i \cap T_j = \emptyset \quad (7)$$

在式(7)的条件下, 结合式(6)和式(2)可知, 混合信号满足下式:

$$\begin{cases} [x_1(t), \dots, x_M(t)]^T = [a_{1i}, \dots, a_{Mi}]^T s_i(t) + n_c(t) + n(t), t \in T_i \\ [x_1(t), \dots, x_M(t)]^T = n(t), t \in T_0 \end{cases} \quad (8)$$

当信道衰落变化较为平缓时, 时变信道噪声较小, 忽略时变信道噪声的影响。此外, 假设随机噪声干扰较小, 忽略随机噪声的影响。此时, 式(8)可以简化为:

$$\begin{cases} [x_1(t), \dots, x_M(t)]^T = [a_{1i}, \dots, a_{Mi}]^T s_i(t), t \in T_i \\ [x_1(t), \dots, x_M(t)]^T = \mathbf{0}, t \in T_0 \end{cases} \quad (9)$$

由上式可知, 在混合信号的幅值特征空间 $(x_1(t), \dots, x_M(t))$ 中, 公共静默时间 T_0 内的混合信号集中分布在零坐标, 电台播放时间 T_i 内的混合信号集中分布在混合矩阵的列向量 $\mathbf{a}_i = [a_{1i}, \dots, a_{Mi}]^T$ 所在的直线上, 具有线性聚类分布的性质。

基于上述分析, 在信道衰落变化较为平缓且忽略随机噪声干扰的情况下, 可以使用聚类 SCA^[17] (Clustering based Sparse Component Analysis, C-SCA)

解决电台信号分离问题, 具体步骤如下:

(1) 首先, 由于公共静默时间 T_0 的混合信号不包含混合矩阵的信息, 所以在聚类之前, 设置阈值 ε , 剔除 T_0 的混合信号样本:

$$\mathbf{c}_0 = \mathbf{c}_0 \cup \{\mathbf{x}(t)\}, \forall \|\mathbf{x}(t)\| < \varepsilon \quad (10)$$

(2) 依据混合信号的幅值特征, 对除了 \mathbf{c}_0 以外混合信号样本进行聚类。聚类所需的距离定义如下:

$$\text{dist}(\mathbf{x}(t_1), \mathbf{x}(t_2)) = \sqrt{\sum_{i=1}^M [x_i(t_1) - x_i(t_2)]^2} \quad (11)$$

(3) 得到类簇 $\mathbf{c}_1, \mathbf{c}_2, \dots, \mathbf{c}_N$ 后, 使用下式计算各个类簇的中心:

$$\bar{\mathbf{c}}_i = \frac{1}{|\mathbf{c}_i|} \sum \mathbf{x}(t), \mathbf{x}(t) \in \mathbf{c}_i \quad (12)$$

(4) 使用类簇中心估计混合矩阵。对于每个类簇中心 $\bar{\mathbf{c}}_i$, 依次进行归一化处理, 作为混合矩阵第 i 列的估计值, 完成对混合矩阵 A 的估计:

$$\hat{\mathbf{a}}_i = \frac{\bar{\mathbf{c}}_i}{\|\bar{\mathbf{c}}_i\|} \quad (13)$$

(5) 计算分离矩阵 $W = A^{-1}$, 使用式(4)求解分离信号向量 \mathbf{y} 。

3.2 基于 TFC-SCA 的电台信号分离算法

短波信号主要依靠电离层反射传播, 电离层受到太阳活动等因素的影响, 在一天中的不同时间段, 一年中的不同季节都会发生变化^[18], 式(3)中的时变信道噪声一般相对较强, 这在一定程度上会影响 C-SCA 的分离效果。为此, 本文针对 C-SCA 进行改进, 提出一种基于 TFC-SCA 的电台信号分离算法。

由式(8)可知, 在时变信道噪声和随机干扰噪声的影响下, 混合信号在不同的电台播放时间 T_i 内会呈现较为发散的分布, 不再满足式(9)中线性聚类分布的特点, 导致聚类算法的准确率下降, 影响混合矩阵的估计精度。针对这一问题, 本文提出融合时间特征聚类的混合矩阵估计方法。

对于短波电台而言, 播放时间 T_i 一般具有周期性特征, 例如每天特定的时间段或者每周若干天特定的时间段, 所以 T_i 内的混合信号样本在时间上的分布较为集中, 在时间上的间隔较为接近。因此, 本文考虑融合信号的时间特征和幅值特征进行聚类, 以此提升聚类算法的准确率。本文将一天内 0:00~24:00 的时间转换为取值范围是 $[0, 24)$ 的小数 t , 为了避免 t 在 0:00 附近产生不连续的突变, 将 t 转换为 t_{\cos} 和 t_{\sin} 两个特征, 映射为时间特征空间 (t_{\cos}, t_{\sin}) 中半径为 λ 的圆:

$$\begin{cases} t_{\cos} = \lambda \cos(\frac{2\pi t}{24}) \\ t_{\sin} = \lambda \sin(\frac{2\pi t}{24}) \end{cases} \quad (14)$$

时间特征空间如图 3 所示, 其中 t_{\cos} 和 t_{\sin} 的时间特征能够很好地描述时间的邻近程度。例如, 对于 0:01 和 23:59 这两个间隔很近的时间来说, 它们在时间特征空间(t_{\cos}, t_{\sin})中位于($\lambda, 0$)附近, 具有很近的距离。

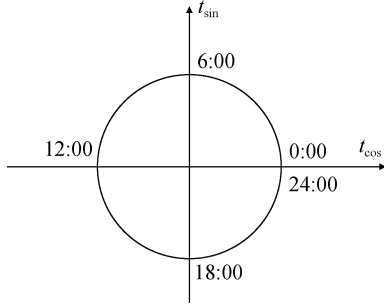


图 3 时间特征空间
Figure 3 Time feature space

聚类算法的输入除了信号的幅值特征以外, 还包括时间特征 t_{\cos} 和 t_{\sin} , 即聚类算法的输入样本为 $[x_1(t), \dots, x_M(t), t_{\sin}, t_{\cos}]^T$ 。此时聚类所需的距离定义如下:

$$\text{dist}(\mathbf{x}(t_1), \mathbf{x}(t_2)) = \sqrt{\sum_{i=1}^M [x_i(t_1) - x_i(t_2)]^2 + [t_{\cos}|_{t_1} - t_{\cos}|_{t_2}]^2 + [t_{\sin}|_{t_1} - t_{\sin}|_{t_2}]^2} \quad (15)$$

利用式(15)的距离定义, 聚类算法能够更准确地将混合信号按照不同的电台播放时间划分为不同的类簇。得到聚类结果后, 去除时间特征, 根据式(13)可以估计出混合矩阵 A 。

当信道衰落变化较为剧烈时, 混合信号会引入较强的时变信道噪声。如果直接使用混合信号进行信号分离, 那么所得的分离信号也会掺杂较强的噪声, 影响信号分离的效果, 因此有必要对混合信号去噪。由式(9)可知, 当噪声较弱时, 不同 T_i 的混合信号样本集中分布在混合矩阵列向量 \mathbf{a}_i 所在的直线上, T_0 的混合信号样本集中分布在零坐标。将每个类簇 c_i 的混合信号样本投影到对应的混合矩阵列向量 \mathbf{a}_i 上, c_0 的混合信号样本平移至零坐标, 可以得到新的混合信号向量 $\mathbf{x}_{new}(t)$:

$$\mathbf{x}_{new}(t) = \begin{cases} < \mathbf{x}(t), \hat{\mathbf{a}}_i > \hat{\mathbf{a}}_i, \mathbf{x}(t) \in c_i, i=1, \dots, N \\ \mathbf{0}, \mathbf{x}(t) \in c_0 \end{cases} \quad (16)$$

新的混合信号向量 $\mathbf{x}_{new}(t)$ 满足式(9)中线性聚类分布的性质, 相比原混合信号 $\mathbf{x}(t)$ 去除了时变信道噪声和随机干扰噪声。最后, 计算分离矩阵 $W = A^{-1}$, 使用新的混合信号向量 $\mathbf{x}_{new}(t)$ 求解分离信号向量:

$$\mathbf{y}(t) = W\mathbf{x}_{new}(t) \quad (17)$$

综合上述讨论, 基于 TFC-SCA 的电台信号分离算法如下:

算法 1. TFC-SCA

输入: 混合信号向量 $\mathbf{x}(t) = [x_1(t), \dots, x_M(t)]^T$, 噪声阈值 ε , 时间特征系数 λ

输出: 分离信号向量 $\mathbf{y}(t) = [y_1(t), \dots, y_N(t)]^T$

1. 所有混合信号进行归一化处理, 即 $x_i(t) \leftarrow \frac{x_i(t) - \min(x_i(t))}{\max(x_i(t)) - \min(x_i(t))}$ 。
2. 根据式(10)从混合信号中筛选出 c_0 , 其余部分记为 \mathbf{x}_1 。
3. 根据式(14)计算混合信号 \mathbf{x}_1 的时间特征, 将时间特征加入 \mathbf{x}_1 , 得到 \mathbf{x}' 。
4. 使用 KMeans 算法对 \mathbf{x}' 进行聚类。
5. 去除 \mathbf{x}' 中的时间特征 t_{\cos} 和 t_{\sin} , 计算 \mathbf{x}' 各个类簇的中心点, 根据式(13)估计混合矩阵 A 。
6. 将 \mathbf{x}' 和 c_0 按照时间顺序重新组合为 $\mathbf{x}(t)$, 将 $\mathbf{x}(t)$ 按照式(16)去噪, 得到 $\mathbf{x}_{new}(t)$ 。
7. 计算分离矩阵 $W = A^{-1}$ 。
8. 使用式(17)求解分离信号向量并返回。

4 仿真实验设计和分析

4.1 仿真实验设计

4.1.1 发射功率参数设置

基于调研^[19-22], 发现短波电台的播放有如下规律:

(1) 每日定时开始播音, 定时结束。持续时间从几十分钟到十几个小时不等, 即周期为 24h。

(2) 每周特定的天数定时开始播音, 定时结束。持续时间不定, 即周期为 7d。

由于电台播放时长不同, 电台发射功率的占比也会不同, 所以影响电台播放的主要指标是周期和占比。

本文所有实验的监测时长均为两周, 采样间隔 3 分钟, 信号总长为 6720。假设有两个短波电台使用同一短波信道播音, 记两个电台的周期分别为 T_{P1} 和 T_{P2} , 占比分别为 D_1 和 D_2 。周期和占比决定了电台的播放规律, 也决定了发射功率的信号波形。为

了综合考察周期和占空比对于分离效果的影响, 本文共设计了 ABCD 四组实验, 每组实验的设计如下:

其中, A 组实验中两个电台的周期和占空比都相等, B 组实验中两电台的周期不同但是占空比相等, C 组实验中两电台的周期相等但是占空比不等, D 组实验中两电台的周期和占空比都不等。另外, 每组实验中都会逐渐增加其中一个电台或两个电台的占空比, 以此来观察占空比对分离效果的影响。

表 1 实验设计

Table 1 Experimental design

组	周期	占空比
A	$T_{p1}=24\text{h}$	$D_1=[0.083, 0.125, 0.167, 0.208, 0.25, 0.292]$
	$T_{p2}=24\text{h}$	$D_2=[0.083, 0.125, 0.167, 0.208, 0.25, 0.292]$
B	$T_{p1}=24\text{h}$	$D_1=[0.083, 0.125, 0.167, 0.208, 0.25, 0.292]$
	$T_{p2}=7\text{d}$	$D_2=[0.083, 0.125, 0.167, 0.208, 0.25, 0.292]$
C	$T_{p1}=24\text{h}$	$D_1=[0.083, 0.167, 0.25, 0.333, 417, 0.5]$
	$T_{p2}=24\text{h}$	$D_2=[0.083, 0.083, 0.083, 0.083, 0.083, 0.083]$
D	$T_{p1}=24\text{h}$	$D_1=[0.083, 0.167, 0.25, 0.333, 417, 0.5]$
	$T_{p2}=7\text{d}$	$D_2=[0.083, 0.083, 0.083, 0.083, 0.083, 0.083]$

采用下式构造电台发射功率的时间序列, 作为电台信号分离问题的源信号:

$$s_i(t) = \begin{cases} P(t) & t \in T_i \\ 0 & t \in T_S - T_i \end{cases} \quad (18)$$

其中, $P(t)$ 是电台的发射功率, 本文中全部设置为 20kW 且保持不变。

4.1.2 接收功率参数设置

由于短波信道是时变衰落信道, 并不属于恒定衰落信道, 所以接收功率不能简单使用混合矩阵进行仿真。为了尽量符合实际的短波通信环境, 本文使用短波预测软件(Voice of Amercian Coverage Analysis Program, VOACAP)^[23]对接收功率进行仿真。VOACAP 是一款针对短波通信的专业预测软件, 该软件根据国际电信联盟(International Telecommunication Union, ITU)建议书和联合方法论原理计算电离层参数, 考虑了太阳活动对电离层的影响, 保证短波通信的预测结果能够尽可能符合实际情况。软件能够预测给定短波通信场景下的最大可用频率、接收信噪比、接收功率和电路可靠性等数据。本文实验中, VOACAP 的仿真时间设置为 2019 年 8 月, 两个电台共同占用的信道的频率为 7.1MHz, 在 8 个地点布置信号采集系统, 电台和接收点的地理位置设置如下:

本文使用下式生成接收功率数据, 单位是 dBW:

$$x_i(t) = \begin{cases} P(t) + n_f(t) & t \in T_S - T_0 \\ n_i(t) & t \in T_0 \end{cases} \quad (19)$$

其中, $P(t)$ 是 VOACAP 软件针对 t 时刻播放的电台到当前接收点的预测接收功率, $n_f(t)$ 是均值为 0, 标准差为 2 的高斯噪声, 模拟短波通信环境中的随机干扰, $n_i(t)$ 是均值为 NO_i , 标准差为 σ_i 的高斯噪声, 模拟各个接收点的噪底功率。本文实验中所有 $NO_i = -150$, $\sigma_i = 2$, 即各接收点的噪底功率设置为 -150dBW。

表 2 电台和接收点地理位置

Table 2 Geographic location of radio stations and receiving points

电台/接收点	所在城市	经度	纬度
电台 1	首尔	126.9	37.4
电台 2	台北	121.6	25
接收点 1	长春	125.4	43.8
接收点 2	北京	116.2	39.7
接收点 3	郑州	113.6	34.7
接收点 4	西安	108.9	34.1
接收点 5	上海	121.6	30.9
接收点 6	武汉	114.3	30.7
接收点 7	广州	113.3	23.2
接收点 8	成都	104.1	30.6

仿真实验有 8 个接收点, 2 个电台, 需要从 8 个接收信号中选择 2 个接收信号作为混合信号。由于本实验中电台发射功率保持不变, 如果信道衰落恒定, 那么接收所得的信道功率值在播放时间段内应保持稳定。为了减少时变信道衰落对信号分离的影响, 应尽量选择信道功率值波动较小的信号作为混合信号。熵是一种衡量变量随机性和不确定性的指标, 对于时间序列而言, 可以对时间序列的值域进行分段来计算熵, 假设分段的个数为 K , 熵的计算公式如下:

$$Entropy(X(t)) = -\sum_{k=0}^K p_k \ln(p_k) \quad (20)$$

其中, p_k 是时间序列 $X(t)$ 的取值落在第 k 个段的比例。熵越小, 信道功率的取值分布范围越集中, 受时变信道衰落的影响越小。所以, 本文从多路接收信号中优先选择熵最小的信号作为混合信号。

综上所述, 仿真实验的步骤如下:

1. 构造电台 1 和电台 2 的发射功率时间序列 $s_1(t), s_2(t)$, 组成源信号向量 $\mathbf{s} = [s_1(t), s_2(t)]^T$ 。
2. 使用 VOACAP 得到接收信号向量 $\mathbf{x} = [x_1(t), \dots,$

$x_i(t), \dots, x_8(t)]^T$, 其中 $x_i(t)$ 是接收点 i 收到的功率时间序列。

3. 基于最小熵原则选择 2 个混合信号, 组成混合信号向量 $\mathbf{x} = [x_1(t), x_2(t)]^T$ 。

4. 使用不同信号分离算法求解分离信号 $y_1(t)$ 和 $y_2(t)$, 组成分离信号向量 $\mathbf{y} = [y_1(t), y_2(t)]^T$ 。

5. 根据上述电台的播放规律, 构造其他播放情况下电台的发射功率时间序列, 重复 1-4。

6. 考察各个实验的分离和识别效果。

4.1.3 TFC-SCA 算法参数设置

TFC-SCA 算法有两个参数, 噪声阈值 ε 和时间特征系数 λ 。其中, ε 的作用是搜索公共静默时间 T_0 的混合信号, 该值的设置与接收点的噪底功率波动水平有关, 本文设置为 0.1。 λ 的几何意义是二维时间特征空间 (t_{\sin}, t_{\cos}) 中的圆半径, λ 决定了 t_{\sin} 和 t_{\cos} 的取值范围, 也决定了时间特征在聚类过程中的相对于幅值特征的权重。应结合混合信号的实际情况设置 λ : 当信道衰落的变化较为平缓, 混合信号受时变信道噪声影响较小时, 可以设置较小的 λ ; 当信道衰落变化较为剧烈, 混合信号受时变信道噪声影响较大时, 可以设置较大的 λ 。根据经验, 本文使用下式设置 λ :

$$\lambda = \begin{cases} \min(1, DBI + 0.1), & DBI \geq 0.4 \\ \max(0.1, DBI - 0.1), & DBI < 0.4 \end{cases} \quad (21)$$

其中, DBI 是指仅依靠幅值特征对混合信号进行聚类的戴维森堡丁指数^[24](Davies Bouldin Index, DBI)。 DBI 是一种衡量聚类效果的指标, 其取值范围是 $[0, 1]$, 取值越小, 说明聚类后各个类簇的分布更加紧凑, 混合信号受时变信道噪声的影响也越小, 反之亦然。

4.2 实验结果及分析

4.2.1 信号分离过程

下面以 A 组实验中的一个实验为例, 说明仿真实验的信号设置以及 TFC-SCA 的信号分离过程, A 组实验中的其他实验和 B、C、D 三组中的所有实验的信号分离过程与此类似, 略去这些实验的信号分离过程。

如表 1 所示, 取 $T_{p1} = T_{p2} = 24h$, $D_1 = D_2 = 0.292$ 的情况, 此时, 电台 1 的播放时间 T_1 为每天 0:00~7:00, 电台 2 的播放时间 T_2 为每天 7:00~14:00, 公共静默时间 T_0 为每天 14:00~24:00, 监测时长 T_S 为两周。为方便展示, 本小节所有波形图仅保留前 4 天的部分。在上述播放设置下, 源信号以及归一化后的混

合信号波形图如下:

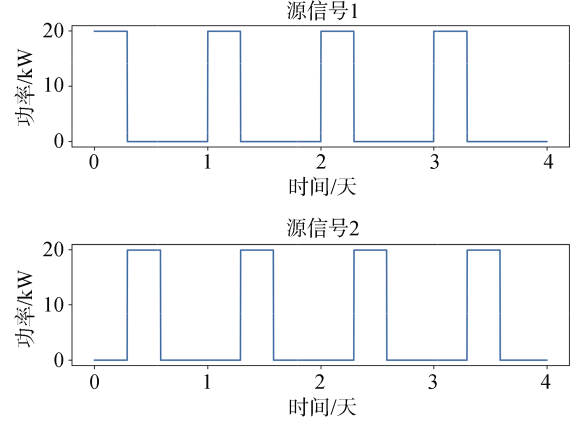


图 4 源信号波形图

Figure 4 Source signals waveform

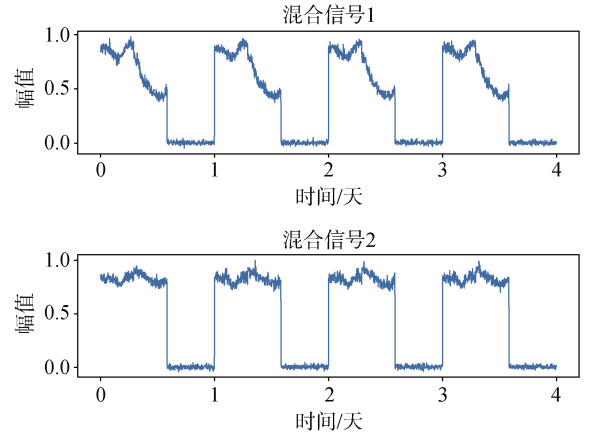


图 5 混合信号波形图

Figure 5 Mixed signals waveform

混合信号在二维平面的散点图如图 6 所示。由图可知, 受时变信道噪声及随机干扰噪声的影响, 当前混合信号在电台播放时间 T_1 和 T_2 内的分布范围较为广泛, 并不符合式(9)中直线分布的情况。在二维幅值特征空间中, 直接使用幅值特征对混合信号聚类, 聚类结果如图 7 所示。此外, 根据式(14)计算时间特征, 融合时间特征及幅值特征的聚类结果如图 8 所示。

比较图 7 和图 8 可知, 只依靠信号的幅值特征进行聚类, 难以准确划分出不同电台播放时间内的混合信号样本。而融合时间特征与幅值特征后, 聚类算法能够比较准确地分离出不同电台播放时间内的混合信号样本。

图 9 是将混合信号进行投影处理后的散点图。图中不同的类簇对应于不同电台播放时间内的混合信号, 且每个类簇的数据分布在直线上, 满足式(9)中直线分布的情况。

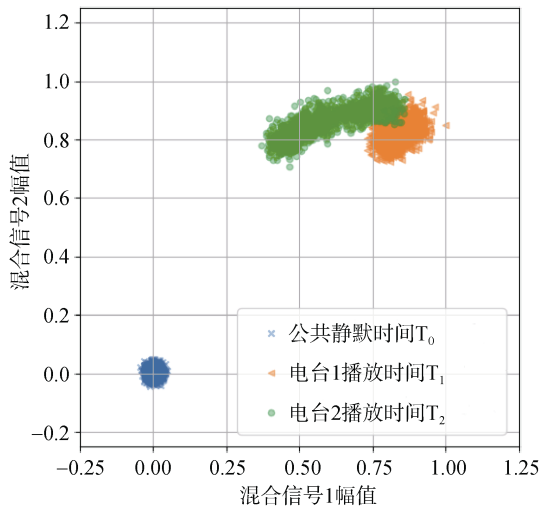


图 6 混合信号散点图

Figure 6 Scatter plot of mixed signals

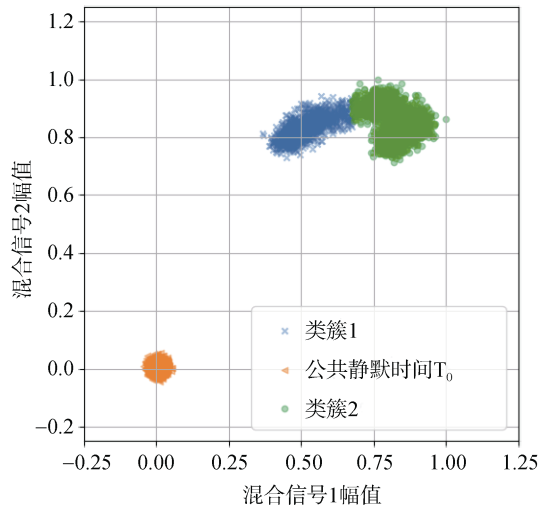


图 7 混合信号聚类结果

Figure 7 Mixed signals clustering results

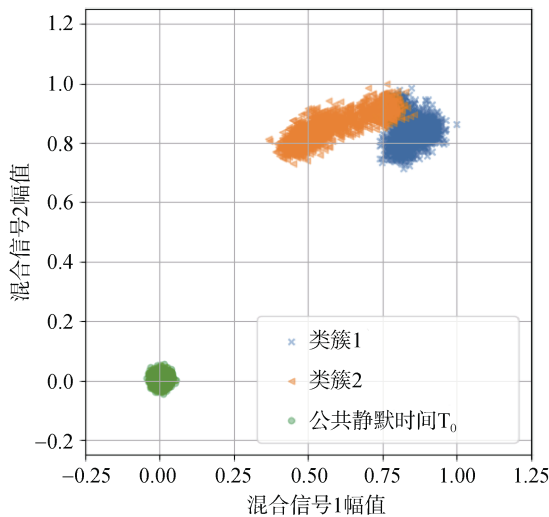


图 8 融合时间特征的混合信号聚类结果

Figure 8 Mixed signals clustering results with time features

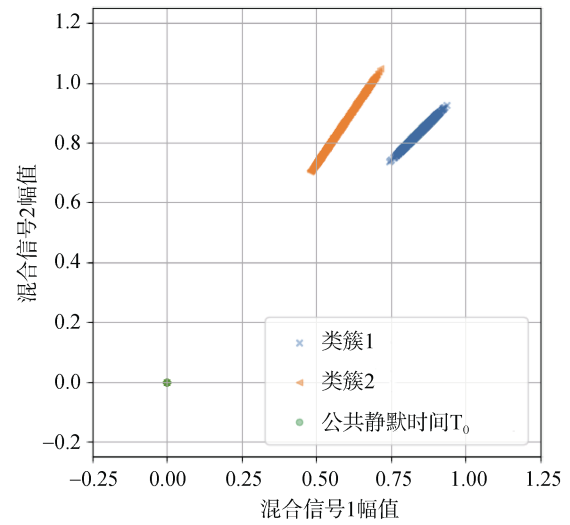


图 9 投影后的混合信号

Figure 9 Mixed signals after projection

在融合时间特征聚类 and 投影处理后, TFC-SCA 最终得到的分离信号如图 10 所示。对比图 4 和图 10 可以看出, TFC-SCA 能够有效地从混合信号中分离出源信号, 具有良好的分离效果。

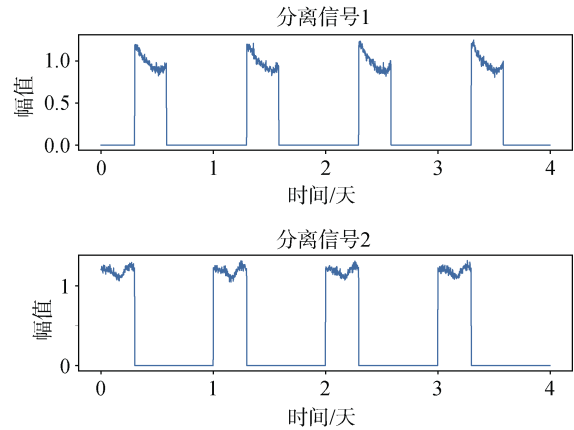


图 10 分离信号

Figure 10 Separated signals

4.2.2 评价指标

为了定量评价算法的分离性能, 使用源信号与分离信号之间的皮尔逊相关系数作为评价指标:

$$|\rho_i| = \frac{\text{cov}(s_i(t), y_i(t))}{\sqrt{\text{var}(s_i(t)) \text{var}(y_i(t))}} \quad (22)$$

其中, $s_i(t)$ 是第 i 个源信号, $y_i(t)$ 是 $s_i(t)$ 对应的分离信号, $\text{cov}(s_i(t), y_i(t))$ 是 $s_i(t)$ 和 $y_i(t)$ 的协方差, $\text{var}(s_i(t))$ 和 $\text{var}(y_i(t))$ 分别是 $s_i(t)$ 和 $y_i(t)$ 的方差。相关系数越大, 越接近于 1, 说明源信号 $s_i(t)$ 和分离信号 $y_i(t)$ 之间的相关性越强, 分离效果越好。

使用平均相关系数评价每次实验的分离效果, 当

分离信号个数为 N 时, 平均相关系数计算公式如下:

$$|\overline{\rho}| = \frac{1}{N} \sum_{i=1}^N |\rho_i| \quad (23)$$

得到分离信号后, 根据式(1)得到各个电台播放时间的识别结果 E_1, E_2, \dots, E_N 。若总监测时间为 T_S , 使用下式得到公共静默时间的识别结果 E_0 :

$$E_0 = (T_S - E_1) \cap (T_S - E_2) \cap \dots \cap (T_S - E_N) \quad (24)$$

若各个电台的实际播放时间分别为 T_1, T_2, \dots, T_N , 实际公共静默时间为 T_0 , 使用下式计算识别正确率:

$$Acc = \frac{|E_0 \cap T_0| + |E_1 \cap T_1| + \dots + |E_N \cap T_N|}{|T_S|} \quad (25)$$

综上所述, 本文使用平均相关系数评价算法的分离性能, 使用识别正确率评价电台识别性能。

4.2.3 分离和识别性能分析

本小节对 C-SCA^[17], 快速独立成分分析^[25](Fast Independent Component Analysis, FastICA)和 TFC-SCA 三种信号分离算法的分离性能以及基于每种算法的电台识别性能进行分析。其中, FastICA 是一种基于信号独立性的盲源分离算法, 它将待分离信号负熵最大化作为优化目标, 运算速度快, 具有较强的鲁棒性和稳定性, 应用场景十分广泛^[26-28]。

表 3 展示了 A 组实验的电台播放设置, 两个电台的周期均为 24 小时, 占空比相等, 从 0.083 到 0.292 不等。

表 3 周期和占空比都相等的播放设置(A 组)

Table 3 Broadcast setting of equal periods and equal duty cycles(Group A)

序号	电台	播放日期	播放时间	播放时长	占空比	平均占空比
1	1	每日	0:00	2h	0.083	0.083
	2	每日	7:00	2h	0.083	
2	1	每日	0:00	3h	0.125	0.125
	2	每日	7:00	3h	0.125	
3	1	每日	0:00	4h	0.167	0.167
	2	每日	7:00	4h	0.167	
4	1	每日	0:00	5h	0.208	0.208
	2	每日	7:00	5h	0.208	
5	1	每日	0:00	6h	0.25	0.25
	2	每日	7:00	6h	0.25	
6	1	每日	0:00	7h	0.292	0.292
	2	每日	7:00	7h	0.292	

A 组实验的仿真结果如图 11 所示。可以看出, FastICA 的平均相关系数在 0.125 时为 0.976, 从平均占空比为 0.167 开始下降到 0.692, 识别正确率在平均占空比大于 0.167 后下降到 68% 以下, 这主要是因为

实验中的源信号是电台发射功率的时间序列, 属于波形较为简单的方波信号, 此类信号相互之间并非严格独立, 这使得 FastICA 在部分占空比的情况下无法对信号做出有效分离, 进而影响电台识别的正确率。

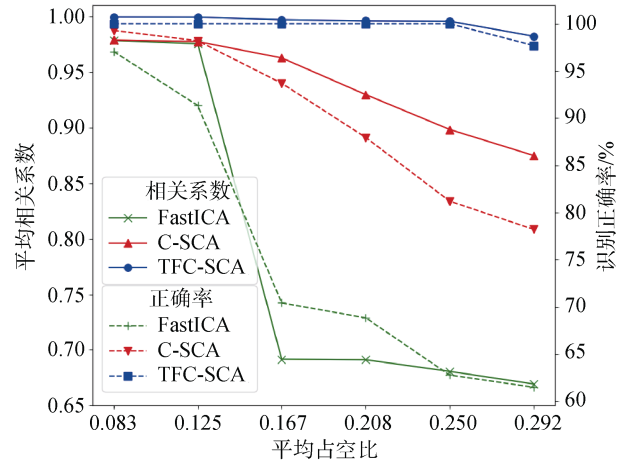


图 11 周期和占空比都相等的分离和识别效果(A 组)
Figure 11 Separation and identification effects of equal periods and equal duty cycles(Group A)

C-SCA 的平均相关系数同样从平均占空比为 0.167 开始出现明显下降, 在平均占空比为 0.292 时下降到 0.875, 电台识别正确率随着平均占空比的增加逐渐下降, 这主要是因为随着平均占空比的增加, 电台的播放时间变长, 短波信道衰落的不确定性也越强, 混合信号中引入了更强的时变信道噪声, 在幅值特征空间中的分布更加随机, 造成了 C-SCA 算法分离效果以及电台识别性能的下降。

TFC-SCA 的平均相关系数接近于 1, 平均识别正确率为 100%, 其分离和识别性能要远远优于 FastICA 和 C-SCA, 这是因为 TFC-SCA 结合了混合信号的幅值特征和时间特征, 能够准确对混合信号进行聚类, 而且还依据聚类的结果对混合信号进行去噪, 因此具有非常优异的分离和识别性能。

表 4 展示了 B 组实验的电台播放设置, 两个电台的占空比相等, 与 A 组实验相同, 不同之处在于两电台周期不同, 电台 1 周期为 24 小时, 电台 2 周期为 7 天。

B 组实验的仿真结果如图 12 所示。可以看出, FastICA 的平均相关系数从平均占空比为 0.167 开始下降到 0.694, 识别正确率在平均占空比大于 0.167 时下降到 67% 以下, 与 A 组实验几乎相同, 这主要是因为 B 组实验与 A 组实验的占空比设置完全相同, 占空比决定了源信号的概率分布和负熵, 而 FastICA 以分离信号负熵最大化作为优化目标, 对于相同负熵的源信号具有基本相同的分离和识别效果。

表 4 周期不等, 占空比相等的播放设置(B 组)
Table 4 Broadcast setting of unequal periods and equal duty cycles(Group B)

序号	电台	播放日期	播放时间	播放时长	占空比	平均占空比
1	1	每日	0:00	2h	0.083	0.083
	2	周三~周五	7:00	4h40min	0.083	
2	1	每日	0:00	3h	0.125	0.125
	2	周三~周五	7:00	7h	0.125	
3	1	每日	0:00	4h	0.167	0.167
	2	周三~周五	7:00	9h20min	0.167	
4	1	每日	0:00	5h	0.208	0.208
	2	周三~周五	7:00	11h40min	0.208	
5	1	每日	0:00	6h	0.25	0.250
	2	周三~周五	7:00	14h	0.25	
6	1	每日	0:00	7h	0.292	0.292
	2	周三~周五	7:00	16h40min	0.292	

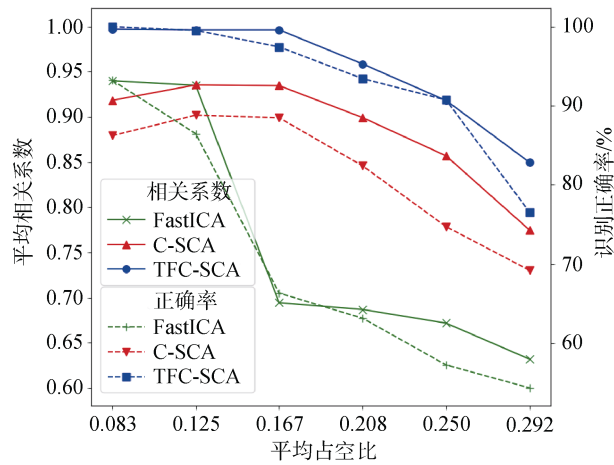


图 12 周期不等, 占空比相等的分离效果(B 组)

Figure 12 Separation and identification effects of unequal periods and equal duty cycles(Group B)

C-SCA 的平均相关系数从平均占空比为 0.208 时出现明显下降, 在平均占空比为 0.292 时下降到 0.775; TFC-SCA 的平均相关系数同样从平均占空比为 0.208 时明显下降, 在平均占空比为 0.292 时下降到 0.85。C-SCA 和 TFC-SCA 两种算法的识别正确率也随着平均占空比的增加逐渐下降, 最低分别下降到 69.2%和 76.6%。B 组实验与 A 组实验相比, 两种 SCA 算法的整体分离和识别性能都出现了一定程度的下降。这主要是因为 B 组实验与 A 组实验相比, 电台 2 的周期由 24 小时改为 7 天, 在占空比保持不变的情况下, 电台 2 的播放次数较少, 单次播放的时间较长, 电台 2 的功率衰减在较长时间段内的不确定性也更强, 这使得混合信号在电台 2 播放时间内引入了更强的时变信道噪声, 造成了两种 SCA 算法中聚类精度的下降以及最终信号分离和识别效果

的下降。

表 5 展示了 C 组实验的电台播放设置, 两个电台的周期均为 24 小时, 与 A 组实验相同, 不同之处在于两个电台的占空比不等, 电台 1 的占空比从 0.083 逐渐增加到 0.5, 而电台 2 的占空比一直保持 0.083 不变。

表 5 周期相等、占空比不等的播放设置(C 组)
Table 5 Broadcast setting of equal periods and unequal duty cycles(Group C)

序号	电台	播放日期	播放时间	播放时长	占空比	平均占空比
1	1	每日	0:00	2h	0.083	0.083
	2	每日	12:00	2h	0.083	
2	1	每日	0:00	4h	0.167	0.125
	2	每日	12:00	2h	0.083	
3	1	每日	0:00	6h	0.25	0.167
	2	每日	12:00	2h	0.083	
4	1	每日	0:00	8h	0.333	0.208
	2	每日	12:00	2h	0.083	
5	1	每日	0:00	10h	0.417	0.25
	2	每日	12:00	2h	0.083	
6	1	每日	0:00	12h	0.5	0.292
	2	每日	12:00	2h	0.083	

C 组实验的仿真结果如图 13 所示。可以看出, FastICA 的平均相关系数整体上要优于 A 组实验和 B 组实验, 位于 0.928~0.979 之间, 识别正确率位于 87.5%~96%之间, 这说明FastICA 的分离效果取决于信号的占空比组合。

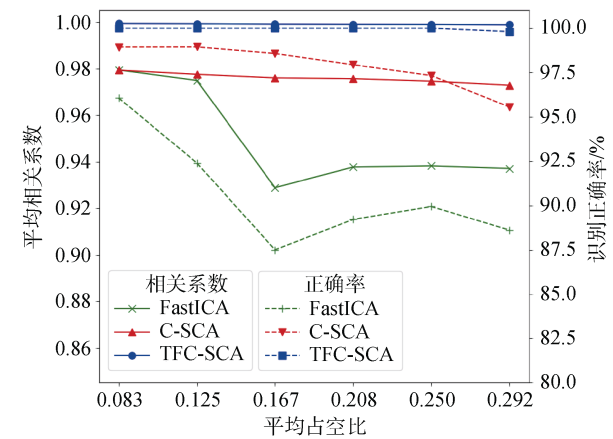


图 13 周期相等、占空比不等的分离效果(C 组)

Figure 13 Separation effect of equal periods and unequal duty cycles(Group C)

C-SCA 的平均相关系数位于 0.973~0.98 之间, 识别正确率位于 95.5%~98.9 之间, 两种指标都随着平均占空比的增加逐渐下降; TFC-SCA 的整体的平

均相关系数接近于 1, 平均识别正确率为 99.9%。C 组实验与 A 组实验相比, C-SCA 算法的整体分离和识别性能有一定程度的提升。这是因为 C 组实验与 A 组实验相比, 电台 2 的占空比一直保持 0.083 不变, 占空比相对较小, 播放时间相对较短, 电台 2 的功率值在短时间内的波动程度相对较小, 时变信道噪声相对较弱, 使得聚类精度以及算法的分离和识别性能有所提升。

表 6 展示了 D 组实验的电台播放设置, D 组实验中, 两个电台的占空比不等, 具体的占空比设置与 C 组完全相同。另外, 两电台的周期不等, 电台 1 周期为 24 小时, 电台 2 周期为 7 天。

表 6 周期和占空比都不等的播放设置(D 组)
Table 6 Broadcast setting of unequal periods and unequal duty cycles(Group D)

序号	电台	播放日期	播放时间	播放时长	占空比	平均占空比
1	1	每日	0:00	2h	0.083	0.083
	2	周三~周五	12:00	4h40min	0.083	
2	1	每日	0:00	4h	0.167	0.125
	2	周三~周五	12:00	4h40min	0.083	
3	1	每日	0:00	6h	0.25	0.167
	2	周三~周五	12:00	4h40min	0.083	
4	1	每日	0:00	8h	0.333	0.208
	2	周三~周五	12:00	4h40min	0.083	
5	1	每日	0:00	10h	0.417	0.25
	2	周三~周五	12:00	4h40min	0.083	
6	1	每日	0:00	12h	0.5	0.292
	2	周三~周五	12:00	4h40min	0.083	

D 组实验的仿真结果如图 14 所示。可以看出, FastICA 的平均相关系数和识别正确率的变化趋势与 C 组实验基本相同, 分别位于 0.917~0.953 和 87.2%~91.5%之间; C-SCA 的平均相关系数和识别正确率随着平均占空比的增加逐渐下降, 分别位于 0.943~0.952 和 88.8%~95.4%之间; TFC-SCA 的平均识别正确率为 99.7%。D 组实验相比 C 组实验的分离和识别效果有一定的下降, 这同样是因为 D 组实验中电台 2 的周期由 24 小时改为 7 天, 占空比不变的情况下单次播放时间更长, 短波信道衰落的变化更加剧烈, 时变信道噪声更强, 对各种算法的分离和识别性能都造成了一定的影响。

综上所述, 三种算法总体上在占空比较小, 单次播放时间较短, 信道衰落变化较小时取得更好的分离和识别效果。三种算法在所有实验中的平均相关系数和平均识别正确率如下表所示:

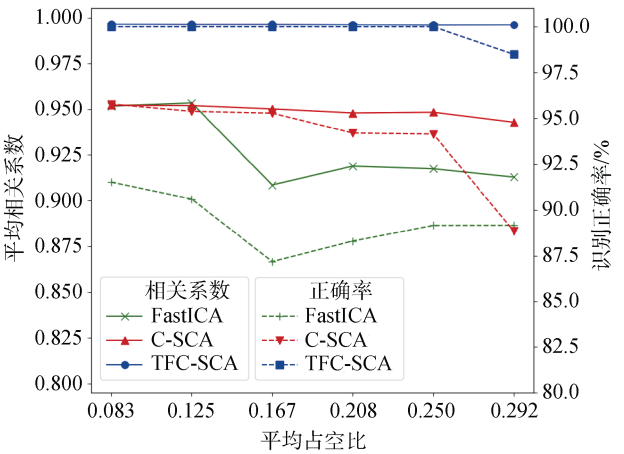


图 14 周期和占空比都不等的分离效果(D 组)
Figure 14 Separation effect of unequal periods and unequal duty cycles(Group D)

表 7 总体实验结果
Table 7 Overall experimental results

	FastICA	C-SCA	TFC-SCA
平均相关系数	0.854	0.935	0.986
平均识别正确率	81.3%	90.8%	98.1%

由表可知, TFC-SCA 在三种算法中平均相关系数最大, 平均识别正确率最高, 相比 C-SCA 和 FastICA 能够更好地解决短波电台信号分离和识别的问题。

4.2.4 投影对于分离效果的影响

为了考察 TFC-SCA 中投影处理对信号分离效果的影响, 在融合时间特征聚类估计混合矩阵的前提下, 本节针对是否投影进行了对比实验, 其中 A 组实验结果如下:

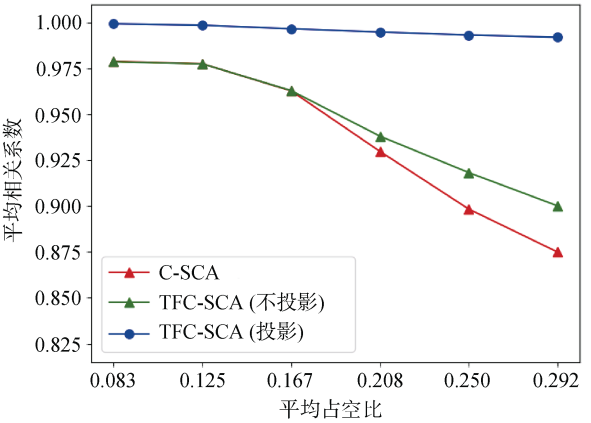


图 15 A 组投影对比
Figure 15 Projection contrast for group A

可以看出, 不投影的 TFC-SCA 的平均相关系数相比 C-SCA 只有少量的提升, 包含投影的 TFC-SCA

相比不投影的 TFC-SCA 的平均相关系数在所有占空比下都有明显提升。说明混合矩阵估计精度的提升对于分离效果的提升作用有限, 时变信道噪声对于信号分离的效果有较大的影响。

此外, 在 ABCD 四组实验中, 包含投影的 TFC-SCA 的总平均相关系数为 0.986, 不包含投影的 TFC-SCA 的总平均相关系数为 0.945。以上实验结果说明, 投影处理能够去除混合信号中的噪声, 显著提升 TFC-SCA 算法的分离效果。

5 总结和下一步工作

本文在频谱监测的环境下, 提出了一种基于 SCA 的短波电台快速自动识别方法。该方法利用频域数据, 根据信道功率对宽频带内不同信道的多个电台进行分离和识别, 相比辐射源识别的相关方法, 具有很高的识别效率。另外, 本文提出了一种基于 TFC-SCA 的电台信号分离算法, 该算法在聚类时融入了信号的时间特征, 有效捕捉到信号的周期性特征, 提升了聚类算法的准确度; 该算法还依据聚类结果对混合信号进行去噪处理, 减少了时变信道衰落对于信号分离的影响。本文使用 VOACAP 对多种周期和占空比的电台播放情况进行了仿真测试。结果显示, 该算法的平均相关系数为 0.986, 基于该算法的电台平均识别正确率为 98.1%, 说明该算法具有优异的分选性能, 能够有效解决短波电台信号分离和识别的问题。

受实际条件所限, 目前所有实验只能通过 VOACAP 软件仿真来完成, 后续可以与相关部门进行深度合作, 采集实际频谱数据, 进一步验证本文所提方法的有效性。此外, 将基于 TFC-SCA 的识别结果与历史监测记录形成的数据库相结合, 可以评估电台的安全风险, 在对风险电台进一步查证后, 查证结果反过来可以丰富并补充数据库的内容, 为保障短波频段的电磁空间安全提供支持。

参考文献

- [1] Dong X. Automatic recognition of modulation signals based on instantaneous information and spectral features[D]. Harbin: Harbin Engineering University.
(董雪. 基于瞬时信息及谱特征的调制方式自动识别[D]. 哈尔滨: 哈尔滨工程大学.)
- [2] Sun N. Study on subtle features of individual communication transmitters[D]. Beijing: Beijing University of Posts and Telecommunications, 2010.
(孙娜. 通信电台细微特征研究[D]. 北京: 北京邮电大学, 2010.)
- [3] Jia Y Q. The research on communication emitters identification technology[D]. Chengdu: University of Electronic Science and Technology of China, 2017.
(贾永强. 通信辐射源个体识别技术研究[D]. 成都: 电子科技大学, 2017.)
- [4] Xu S H. On the identification technique of individual transmitter based on signalprints[D]. Wuhan: Huazhong University of Science and Technology, 2007.
(徐书华. 基于信号指纹的通信辐射源个体识别技术研究[D]. 武汉: 华中科技大学, 2007.)
- [5] Ding L D, Wang S L, Wang F G, et al. Specific Emitter Identification via Convolutional Neural Networks[J]. *IEEE Communications Letters*, 2018, 22(12): 2591-2594.
- [6] Li K, Zhang J Y, Fang Z W. Communication Emitter Identification Based on Kernel Semi-Supervised Discriminant Analysis[C]. *2019 IEEE International Conference on Power, Intelligent Computing and Systems*, 2019: 98-101.
- [7] Yuan Y J, Huang Z T, Wu H, et al. Specific Emitter Identification Based on Hilbert-Huang Transform-Based Time-Frequency-Energy Distribution Features[J]. *IET Communications*, 2014, 8(13): 2404-2412.
- [8] Pan Y W, Yang S H, Peng H, et al. Specific Emitter Identification Based on Deep Residual Networks[J]. *IEEE Access*, 2019, 7: 54425-54434.
- [9] Ohtsui T, Takeuchi T, Soma T, et al. Noise-Tolerant, Deep-Learning-Based Radio Identification with Logarithmic Power Spectrum[C]. *ICC 2019 - 2019 IEEE International Conference on Communications*, 2019: 1-6.
- [10] Lin Y, Jia J C, Wang S, et al. Wireless Device Identification Based on Radio Frequency Fingerprint Features[C]. *ICC 2020 - 2020 IEEE International Conference on Communications*, 2020: 1-6.
- [11] Chen Y, Lei Y K, Li X, et al. Specific Emitter Identification of Communication Radiation Source Based on the Characteristics IQ Graph Features[J]. *Journal of Signal Processing*, 2021, 37(1): 120-125.
(陈悦, 雷迎科, 李昕, 等. 基于 IQ 图特征的通信辐射源个体识别[J]. *信号处理*, 2021, 37(1): 120-125.)
- [12] Li G, Bao C K. Specific Emitter Identification Technology and Applications in Short Wave Radio Recognition[J]. *Information & Communications*, 2016, 29(11): 175-177.
(李刚, 包从开. 辐射源个体特征识别技术及在短波电台识别上的应用[J]. *信息通信*, 2016, 29(11): 175-177.)
- [13] Bofill P, Zibulevsky M. Underdetermined Blind Source Separation Using Sparse Representations[J]. *Signal Processing*, 2001, 81(11): 2353-2362.
- [14] International Telecommunication Union. Spectrum occupancy measurements and evaluation. <https://www.itu.int/pub/R-REP-SM.2256-1-2016>.
- [15] Choi S, Cichocki A, Park H-M, et al. Blind source separation and independent component analysis: A review[J]. *Neural Information Processing-Letters and Reviews*, 2005, 6 (1): 1-57.
- [16] Yu X, Hu D, Xu J. Blind source separation: theory and applications[M]. Beijing: John Wiley & Sons, 2013.
- [17] Li Y Q, Cichocki A, Amari S I. Analysis of Sparse Representation and Blind Source Separation[J]. *Neural Computation*, 2004, 16(6): 1200-1212.

1193-1234.

- [18] Qiao J L. Research on semi-blind frequency selection technology of short-wave communication based on CW signal[D]. Chongqing: Chongqing University of Posts and Telecommunications, 2019. (乔金亮. 基于 CW 信号的短波通信半盲选频技术研究[D]. 重庆: 重庆邮电大学, 2019.)
- [19] 2020 Winter Shortwave Frequency List. <http://www.sangean.com.tw/newsblog/article/26>. (2020 冬季短波频率表.<http://www.sangean.com.tw/newsblog/article/26>.)
- [20] KBS WORLD Radio TIME & FREQUENCY.http://world.kbs.co.kr/service/common/images/about/frequency_201026.pdf.
- [21] NHK WORLD-JAPAN Frequency Schedule.https://www3.nhk.or.jp/nhkworld/ja/information/brochure/pdf/2020/radio_frequency_schedule.pdf.
- [22] VOA Broadcast Frequency Schedules.<https://www.voanews.com/voa-broadcast-frequency-schedules>.
- [23] VOACAP Quick Guide.<https://www.voacap.com/>.
- [24] Davies D L, Bouldin D W. A Cluster Separation Measure[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1979, PAMI-1(2): 224-227.
- [25] Hyvarinen A. Fast and Robust Fixed-Point Algorithms for Independent Component Analysis[J]. *IEEE Transactions on Neural Networks*, 1999, 10(3): 626-634.
- [26] Immanuel J J R, Prabhu V, Christopheraj V J, et al. Separation of Maternal and Fetal ECG Signals from the Mixed Source Signal Using FASTICA[J]. *Procedia Engineering*, 2012, 30: 356-363.
- [27] Shyu K K, Lee M H, Wu Y T, et al. Implementation of Pipelined FastICA on FPGA for Real-Time Blind Source Separation[J]. *IEEE Transactions on Neural Networks*, 2008, 19(6): 958-970.
- [28] Wang L, Gao Q, Zhang K Z, et al. Modulation Classification of Mixed Signals Using Fast Independent Component Analysis[C]. *2016 IEEE Wireless Communications and Networking Conference*, 2016: 1-5.



黄伟庆 现任中国科学院信息工程研究所第四研究室主任、中国计算机学会信息保密专委会秘书长。研究方向为: 无线通信安全、电磁信号处理、网络安全保密技术、物联网安全、云计算安全技术等。Email: huangweiqing@iie.ac.cn



王元坤 于 2018 年在北京工业大学电子信息工程专业获得学士学位。现在中国科学院大学网络空间安全专业攻读硕士学位。研究方向为电磁态势分析, 频谱预测等。Email: wangyuankun@iie.ac.cn



张巧遇 于 2020 年在中国科学院大学信息安全专业获得博士学位。现在中国科学院信息工程研究所电磁安全实验室任高级工程师。主要研究领域为无线通信物理层安全、电磁空间监管等。Email: zhangqiaoyu@iie.ac.cn



李静 于 2020 年在中国科学院信息工程研究所获得硕士学位。现任中国科学院信息工程研究所助理工程师。研究领域为无线通信信息安全。研究兴趣包括调制方式识别、协议解析。Email: lijing1995@iie.ac.cn



魏冬 于 2013 年获得北京邮电大学通信与信息系统专业博士学位。现任中国科学院信息工程研究所第四研究室副研究员。研究领域为无线通信物理层安全、调制识别、信号处理。Email: weidong@iie.ac.cn