

一种结合 EWT 和成分分析的无线 电指纹提取方法

张敏¹, 罗正华², 黄建刚²

(1. 电信科学技术第五研究所有限公司, 成都 610020;

2. 成都学院 信息科学与工程学院, 成都 610106)

摘要: 无线电台信号个体识别主要是提取无线电信号中的杂散成分, 通过对杂散成分进行分析达到个体识别的效果; 针对线电信号杂散成分具有非线性、非平稳性的特点, 将经验小波变换 (EWT) 和信号成分分析结合起来, 提出了一种新的信号特征提取方法; 该方法首先利用 EWT 对信号进行自适应的分解处理, 通过选取部分能够表征个体差异的信号成分进行特征值谱分析, 并以信号成分的归一化特征值谱的差异为依据进行信号指纹特征的提取, 再根据指纹特征对信号进行识别; 仿真结果表明, 该方法与希尔伯特黄变换 (HHT) 和局部积分双谱分析方法相比, 具有更加优越的识别性能, 并且具有更加优良的特征稳定性, 同时受信噪比的影响较小。

关键词: 无线电指纹识别; EWT; 成分分析; 特征值分析; 特征提取

A Radio Fingerprint Extraction Method Combining EWT and Component Analysis

Zhang Min¹, Luo Zhenghua², Huang Jiangan²

(1. Fifth Institute of Telecommunications Science and Technology, Chengdu 610020, China;

2. School of Information Science and Engineering, Chengdu University, Chengdu 610106, China)

Abstract: Individual identification of radio signals is mainly to extract the stray components of radio signals, and achieve the effect of individual identification by analyzing the stray components. Aiming at the non-linear and non-stationary characteristics of the spurious components of line signals, this paper combines the empirical wavelet transform (EWT) with the signal component analysis, and proposes a new signal feature extraction method. Firstly, the EWT is used to decompose the signal adaptively, and the eigenvalue spectrum is analyzed by selecting some signal components which can represent individual differences. Then the fingerprint feature is extracted based on the difference of normalized eigenvalue spectrum of signal components, and then the signal is identified according to the fingerprint feature. The simulation results show that the proposed method has better recognition performance than HHT and local integral bispectrum analysis method, and has better characteristic stability, and is less affected by signal-to-noise ratio.

Keywords: radio fingerprint identification; EWT; component analysis; eigenvalue analysis; feature extraction

0 引言

无线电通信个体识别在无线网络监控和安全中起着重要的作用^[1-3]。它可以通过无线电信号识别不同的个体, 通过双向的个体识别可以提高通信的安全性。研究发现, 因为集成无线电的组件、电路或芯片在制造上存在差异性, 所以即使是由同一管道产生出来的相同类型的无线电, 也可能存在特性差异, 这些特性差异即为无线电的“指纹特征”——硬件差异。这些特征差异是无线电“与生俱来”的, 是不能被篡改的特性。由于这些特性, 无线电“指纹

特征”方面的个体研究也越来越受到关注。

目前, 无线电的“指纹特征”个体研究根据研究信号的类别主要可以分为瞬态信号的研究和稳态信号的研究两个方面。瞬态信号的研究主要是研究当无线电打开或关闭瞬间, 它产生的瞬态信号上携带的个体差异特征^[3]。瞬态信号是没有承载数据信息的, 它只与无线电的硬件特性有关。但是瞬态信号的持续时间非常短, 对信号的起始点的检测精确度要求极高。由于无线电通信的非合作性, 瞬态信号不易获得, 所以研究起来存在很大的困难。

因此, 人们将无线电的“指纹特征”个体研究视线移到了稳态信号的研究上。稳态信号特征的引入主要是在信号的调制阶段, 由于硬件存在的差异性, 信号在进行调制时会产生很多的杂散信号成分, 这些杂散信号即为个体调制信号。个体调制信号会因硬件差异的不同而不同, 且其具有非线性、非平稳性的特点。所以研究者们试图从杂

收稿日期: 2018-09-17; 修回日期: 2018-11-01。

基金项目: 四川省科技计划项目(2018GZ0072); 省院省校合作项目(2018JZ0065)。

作者简介: 张敏(1992-), 女, 硕士, 主要从事信号处理方向的研究。

散信号的研究上找到无线电的“指纹特征”个体研究的突破点。但是由于现代电子设备设计和制造的逐步规范化, 个体间的差异越来越小, 同时也越来越难以提取, 而且, 当无线电之间建立了稳定的通信时, 稳态信号远高于个体调制信号和系统噪声信号, 此时的个体差异更难获得。也就是说, 稳态信号为主要成分, 将个体差异掩盖在无线电信号的深处。因此, 通过稳定信号来识别无线电个体是一个难题。目前在该类研究方法的领域中, 现有的方法有双谱法、小波分析、Wigner-Ville 分布 (Wigner-Ville distribution, WVD)、希尔伯特黄变换 (HHT) 等, 这些算法都存在缺点, 主要是计算复杂度高、存在交叉项干扰、所需设备昂贵或识别性能有限等问题^[4-7]。

为能更好地对无线电个体进行识别, 找到一种性能优异的基于稳定信号的无线电个体“指纹特征”提取方法就显得尤为迫切。本文提出了一种结合 EWT 和成分分析的无线电“指纹特征”提取方法, 该方法与希尔伯特黄变换 (HHT) 和局部积分双谱分析方法相比, 具有更加优越的识别性能和更加优良特征稳定性, 同时具有受信噪比的影响较小的特点。实测数据实验结果表明了所提方法的有效性。

1 理论和算法

考虑到个体调制信号的非线性、非平稳性特点, 常用的且具有一定代表性的时频分析方法有希尔伯特黄变换 (HHT) 和局部积分双谱。其中, 希尔伯特黄变换 (HHT) 首先利用经验模态分解 (EMD) 方法将信号分解成若干个固有模态函数 (IMF) 分量, 再对 IMF 分量进行 Hilbert 变换, 得到信号的 Hilbert 谱, 根据提取到的信号的 Hilbert 谱特征对进行信号的区分。但是由于 EMD 的理论基础不够完善, 存在模态混叠、端点效应、过包络、欠包络等问题, 信号经 EMD 分解后会有很多的虚假分量产生, 使得计算量变大, 提取到的 Hilbert 谱特征的准确度降低, 从而造成个体识别率降低。

局部积分双谱时频分析方法则是利用双谱自身具有的时移不变性、相位保持性和尺度变换性特点, 它能够将除线性相位外所有的信号信息完备的保留下来, 而且对高斯

噪声具有抑制作用, 使得此方法在个体识别领域的应用很广泛。但是, 由于直接对信号进行双谱计算的运算量极大, 所以人们采用将信号局部化的方法, 提取局部信号的双谱特征进行个体识别, 虽然极大程度地降低了计算量, 但是计算量大的问题依然存在。

针对特征提取在这些方面的不足, 文章引入了 EWT 信号处理方法, 对信号的傅里叶谱进行自适应的划分, 构建自适应的滤波器组, 提取出固有模态分量。通过固有模态分量对信号进行无线电的“指纹特征”, 此方法不存在虚假分量问题, 而且计算量小。

1.1 EWT 经验小波变换

EWT 经验小波变换是将小波分析的理论框架和 EMD 分解的特点结合起来的一种新的信号处理方法。它是先对信号进行傅里叶变换, 同时, 对得到的傅里叶频谱进行自适应分割划分, 然后构造与每个划分区域相适应的小波函数和尺度函数, 并生成一组带通滤波器组并对傅里叶频谱进行处理, 最终实现复杂信号频率成分不同模态的分离^[8]。

令复杂信号的傅里叶变换为 $F(\omega)$, 将相应规范化频率范围为 $[0, \pi]$ 的傅里叶频谱划分为 N 个频带。将分割的每个区间定义为 $\Lambda_n = [\omega_{n-1}, \omega_n]$, $n=1, 2, \dots, N$, ω_n 为频带边界的中心频率^[9]。以每一个 ω_n 为中心, 定义一个宽度为 $T_n=2\tau_n$ 过渡段, 这样就需要 $N+1$ 个边界, 除去第一条边界为 $0 (\omega=0)$, 最后一条边界为 $\pi (\omega=\pi)$, 另外还需要 $N-1$ 条边界, 如图 1 所示。




图 1 频谱分割图

在确定每个后, 根据 Littlewood-Paley 和 Meyer 小波的方式构建经验小波, 则经验尺度函数和经验小波函数分别为:

$$\hat{\Phi}_n(\omega) = \begin{cases} 1 & |\omega| < \omega_n - \tau_n \\ \cos\left[\frac{\pi}{2} \beta\left(\frac{1}{2\tau_n}(|\omega| - \omega_n + \tau_n)\right)\right] & \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ 0 & \text{其他} \end{cases} \quad (1)$$

$$\hat{\psi}_n(\omega) = \begin{cases} 1 & \omega_n + \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ \cos\left[\frac{\pi}{2} \beta\left(\frac{1}{2\tau_{n+1}}(|\omega| - \omega_{n+1} + \tau_{n+1})\right)\right] & \omega_{n+1} - \tau_{n+1} \leq |\omega| \leq \omega_{n+1} + \tau_{n+1} \\ \sin\left[\frac{\pi}{2} \beta\left(\frac{1}{2\tau_n}(|\omega| - \omega_n + \tau_n)\right)\right] & \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ 0 & \text{其他} \end{cases} \quad (2)$$

设 $\tau_n = \gamma\omega_n$, 在式 (1)、(2) 中,

$$0 < \gamma < \min_n \left[\frac{(\omega_{n+1} - \omega_n)}{(\omega_{n+1} + \omega_n)} \right],$$

$$\beta(x) = x^4(35 - 84x + 70x^2 - 20x^3).$$

借鉴经典小波变换的构造方法构造经验小波变换, 可以得到它的细节系数和近似系数通分别为:

$$\omega_f^s(n, t) = \langle f, \psi_n \rangle = \int f(\tau) \overline{\psi_n(\tau - t)} d\tau = (\hat{f}(\omega) \overline{\hat{\psi}_n(\omega)}) \quad (3)$$

$$\omega_f^s(0, t) = \langle f, \Phi_1 \rangle = \int f(\tau) \overline{\Phi_1(\tau - t)} d\tau = (\hat{f}(\omega) \overline{\hat{\Phi}_1(\omega)}) \quad (4)$$

在式 (3)、(4) 中, $\hat{\psi}_n(\omega)$ 、 $\hat{\Phi}_1(\omega)$ 分别为 $\psi_n(t)$ 、 $\Phi_1(t)$ 的傅里叶变换函数; $\overline{\hat{\psi}_n(\omega)}$ 、 $\overline{\hat{\Phi}_1(\omega)}$ 分别为 $\psi_n(t)$ 、 $\Phi_1(t)$ 的复共轭函数; $\langle \cdot, \cdot \rangle$ 表示内积计算。

信号重构的结果为:

$$f(t) = \omega_f^s(0, t) \cdot \Phi_1(t) + \sum_{n=1}^N \omega_f^s(n, t) \cdot \psi_n(t) = (\hat{\omega}_f^s(0, \omega) \hat{\Phi}_1(0, \omega) + \sum_{n=1}^N \hat{\omega}_f^s(n, \omega) \hat{\psi}_n(\omega)) \quad (5)$$

由以上公式可得经验模态函数 f_k 的公式为:

$$f_0(t) = \omega_f^s(0, t) * \Phi_1(t) \quad (6)$$

$$f_k(t) = \omega_f^s(k, t) * \psi_k(t) \quad (7)$$

在式 (6)、(7) 中, $*$ 为卷积。

1.2 EMD 分解算法

EMD 经验模态分解是通过算法的过程来定义的, 它利用信号的局部均值信息来真实的反映信号的内在结构和波动模式。该算法步骤如下:

1) 首先找到输入信号 $x(t)$ 的所有极大值点和极小值点, 接着用曲线将极大值点和极小值点分别串联起来, 得到输入信号 $x(t)$ 上包络曲线 $f_{\max}(x)$ 和下包络曲线 $f_{\min}(x)$, 然后求取上包络曲线和下包络曲线的均值曲线, 最后用输入信号减去均值曲线, 得到差值曲线包络。令 $m(t)$ 为 $f_{\max}(x)$ 和 $f_{\min}(x)$ 的平均值。记输入信号 $x(t)$ 与 $m(t)$ 的差值为 $h_1(t)$, 即:

$$h_1(t) = x(t) - m(t) \quad (8)$$

若 $h_1(t)$ 不是基本模式分量 (不满足基本模式分量的两个基本条件: ①模态分量的极大值点和极小值点数 N 与过零点相等或最多相差 1; ②任意时刻, 极大值包络曲线 $f_{\max}(x)$ 与极小值包络曲线 $f_{\min}(x)$ 的平均值为零), 则将 $h_1(t)$ 作为 ‘新’ 的输入信号 $x'(t)$, 重复以上的求差值操作, 直到 $h_1(t)$ 满足基本模式分量的两个条件, 为基本模式分量, 记作 $c_1(t)$, 即:

$$c_1(t) = h_1(t) \quad (9)$$

2) 用输入信号 $x(t)$ 减去 $c_1(t)$ 得到余下的信号分量, 即:

$$x_1(t) = x(t) - c_1(t) \quad (10)$$

将 $x_1(t)$ 视为新的 $x(t)$, 对 $x_1(t)$ 做类似处理。其算法过程可以表述为:

$$\begin{cases} x_2(t) = x_1(t) - c_2(t) \\ x_3(t) = x_2(t) - c_3(t) \\ \vdots \\ x_n(t) = x_{n-1}(t) - c_n(t) \\ x_n(t) = r_n(t) \end{cases} \quad (11)$$

有式 (11) 可以看出, 对输入信号 $x(t)$ 进行了 n 此分解, 直到余下的分量不能再进行分解 (通常是限制两个连续的分解分量之间的标差满足在 $0.2 \sim 0.3$, 则将剩下的原始输入信号的余下分量作为残差 $r_n(t)$, 不再进行分解)。即将输入信号 $x(t)$ 被分解为 n 个基本分量 $c_i(t)$, $i=1, 2, \dots, n$ 和一个余项 $r_n(t)$ 的线性和, 即:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (12)$$

1.3 基于成分分析的信号特征提取

无线电信号可以划分为 3 种成分: 无线电的自身调制信息成分, 无线电的个体特征成分, 系统噪声成分。即可以表示为:

$$X = S + Z + N \quad (13)$$

在式 (8) 中, X 表示无线电信号, S 表示信号自身调制信息成分, Z 表示个体特征成分, N 表示系统噪声成分。这 3 种成分的能量大小关系满足 $\|S\| \gg \|Z\| \gg \|N\|$, 即 S 为主要成分, Z 为次要成分, 无线电的个体差异主要是由次要成分体现出来的。

受到机器学习中 ‘特征脸’ 的启发^[10-13], 为了提取到无线电的个体差异, 我们将采用成分分析方法, 将个体差异放大, 达到识别的效果。成分分析方法的步骤如下:

- 1) 记提取的单个样本信号表示为 $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})$, 则 n 个样本组成采样矩阵可以表示为 $X = [x_1, x_2, \dots, x_n]$ 。
- 2) 求采样矩阵的协方差阵 Σ 。

$$\begin{aligned} \Sigma &= \frac{1}{n} \sum_{i=1}^n (x_i - m)(x_i - m)^T = \\ &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})(x_i - \bar{X})^T \end{aligned} \quad (14)$$

在式 (9) 中, $m = \frac{1}{n} \sum_{i=1}^n x_i \bar{X} = [m, m, \dots, m]$

- 3) 对协方差矩阵作 Σ 进行特征值分解。

$$\sum \alpha_i = \lambda \alpha_i, i = 1, 2, \dots, p \quad (15)$$

- 4) 对求得的特征值从大到小进行排列, 即 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$

- 5) 记第 k 个特征值对应的特征向量对应的变换矩阵为: $A = [\alpha_k]$ 。

- 6) 样本 x_i 在第 k 个特征值对应的特征向量上的投影为:

$$\xi_k = A^T x_i \quad (16)$$

- 7) 样本 x_i 的第 k 个成分可以表示为:

$$\bar{x}_{ik} = A \xi_k \quad (17)$$

1.4 多分类支持向量机算法

支持向量机 (SVM) 是一种以结构风险最小理论

(SRM) 和 VC 维理论为基础, 能有效解决小样本、非线性、高维模式分类识别等问题的一种机器学习方法^[14-15]。但是 SVM 是针对二分类问题的解决算法, 对于多分类问题并不适用, 为了实现多类别分类需要对 SVM 算法进行一些改进。

1.4.1 SVM 算法

SVM 算法主要是求得一个最优的划分平面, 将两个不同种类的样本分离开。令 U 为一个可分的二分类的样本集。 $U = \{ (x_i, y_i) \}$, 其中, $i=1, 2, \dots, n$, n 为样本的数目。 x_i 为待分类样本数据, $y_i \in \{-1, 1\}$ 为类别属性。

若能够找到一个划分平面 $\omega^T * x + b = 0$, 其中, $\omega = (\omega_1, \omega_2, \dots, \omega_n)$, 将上述的二分类样本集准确无误的划分开, 则可以认定该训练集是线性可分的, 即满足:

$$\begin{cases} \omega^T * x + b \geq 1, y_i = 1 \\ \omega^T * x + b \leq -1, y_i = -1 \end{cases}, \quad i = 1, 2, \dots, n \quad (18)$$

在样本集中, 有一些离划分平面距离很近的样本点, 这些样本点即为支持向量。SVM 的最优划分平面就是在满足式 (14) 的前提下使两类样本的支持向量距离最大化。即将求最优划分平面问题转化为凸二次规划问题:

$$\begin{cases} \min_{\omega, b} \frac{1}{2} \omega^T \omega \\ s. t. \quad y_i * (\omega^T * x + b) \geq 1, \quad i = 1, 2, \dots, n \end{cases} \quad (19)$$

利用拉格朗日乘子法对式 (15) 进行分析, 可得:

$$\begin{cases} \max_{\alpha} \sum_{i=0}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j x_i^T x_j \\ s. t. \quad \sum_{i=1}^n \alpha_i y_i = 0, \alpha_i \geq 0, i = 1, 2, \dots, n \end{cases} \quad (20)$$

其中: $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)^T$ 为拉格朗日乘子向量, 可以用 SMO 算法进行求解。利用 α 可以求得 ω 和 b , 即可以得到最优的划分平面。

1.4.2 多分类支持向量机算法

由于 SVM 只能解决二分类问题, 为了能够进行多类别的分类, 引入有向无环图 (DAG) 算法, 将一系列的二元支持向量机进行组合实现多个类别的分类^[16]。DAG 算法是通过逐一排除所有的可能类别从而实现分类的。当种类的类别数为 n 时, 由 DAG 算法的原理可知只需要用到 $\frac{n(n-1)}{2}$ 个分类器, 因此算法的效率还是很高的。

如图 2 所示为 DAG-SVM 算法的 6 分类示意图。将一个待分类的信号, 首先通过 SVM_{1,6} 分类器判断该信号是否为类别 1 和类别 6, 如果不是类别 1 信号则进入 SVM_{2,6} 分类器继续进行分类判别, 否则进入 SVM_{1,5} 分类器继续进行分类判别……以此类推, 直到能够完全判别确定信号的种类, 最复杂的情况是需要到达分类节点的最低层才能够确认信号的种类, 但是从总体分析可以得出该分类器的分类效率能够满足需求。

2 EWT 算法的有效性验证

为了对 EWT 算法的有效性进行验证, 构造如下仿真信号:




图 2 DAG-SVM 算法 6 分类

$$\begin{cases} x_1(t) = 6t \\ x_2(t) = \cos(8\pi t) \\ x_3(t) = 0.5\cos(40\pi t) \\ x_4(t) = x_1(t) + x_2(t) + x_3(t) \end{cases} \quad (21)$$

由式 (13) 可知, 仿真信号 $x_1(t)$ 是由一个线性信号 $x_1(t)$ 、一个 4 Hz 的余弦信号、一个 20 Hz 的余弦信号组成。然后给 $x_1(t)$ 添加高斯白噪声, 信噪比设置为 10 dB。

首先对仿真信号进行 EWT 分解。EWT 是用一个尺度函数和 N 个小波函数分别对输入信号进行自适应滤波分解的信号处理方法, 即对信号的频谱进行自适应分割。对此仿真信号取 $N=3$, 即将仿真信号的频谱自适应的划分成 4 个频带。仿真信号经 EWT 分解后得到 4 个信号分量 C_1 、 C_2 、 C_3 与 C_4 , 如图 3 所示, 这 4 个信号分量是按照频率由低到高依次排列的。由图 3 可以看出 EWT 分解得到的 4 个分量分别对应仿真信号的线性信号分量、两个余弦信号分量和高斯噪声信号分量, 即仿真信号成分都被有效的分解出来了。由此可以看出 EWT 对信号的分解准确性很高。




图 3 仿真信号的 EWT 分解结果

其次, 对仿真信号进行 EMD 分解。EMD 是依据数据自身的时间尺度特征进行信号分解 (局部平稳化), 而无须预先设定任何的基函数的信号处理方法, 即利用信号的局部信息反映真实信号的内在结构和波动方式。仿真信号的 EMD 分解结果如图 4 所示。信号分量按照频率由高到低的顺序排列, 可以看到, 仿真信号经 EMD 分解后的分量有 10 个之多。将图 3 和图 4 进行对比可得, 信号经 EMD 分解后

明显有很多的虚假分量产生，而这些分量在仿真信号的组成成分中并不存在。可见 EMD 对仿真信号的分解的准确度不高。




图 4 仿真信号的 EMD 分解结果

3 实验过程与分析

本文根据短波电台信号采集的实测数据进行实验研究，实验信号数据采集自同一型号同一批次的 4 部短波电台 No. 1~4，信号的实测载频 8.067 MHz，采样频率 39.2 kHz，调制方式 2 PSK，时长 1 s，信噪比为 20 dB。

首先研究的是结合 EWT 和成分分析的无线电指纹提取方法，采样样本长度取 $L=1000$ ，参数设置为 $p=100$ ， $n=1024$ 。从实测数据中任意选取一个样本，对其进行 EWT 分解，取 $N=7$ ，得到的结果如图 5 所示。由于 EWT 分解得结果分量的频率是由低到高的，个体调制信号成分可能位于后面的分量中，因此，选取得到的 $c_3 \sim c_7$ 分量的归一化特征值谱作为无线电的“指纹特征”用于个体识别分类。




图 5 信号的 EWT 方法分解结果

依次选取 4 部短波电台 No. 1~4 的一个信号样本进行 EWT 分解处理。然后对 EWT 分解的 $c_3 \sim c_7$ 分量进行成分分析，得到 No. 1~4 无线电信号的归一化特征值谱结果如

图 6 所示。从图 6 可以看到 4 部短波电台的 $c_3 \sim c_7$ 分量的归一化特征值谱的差异明显，特别是 c_6 、 c_7 分量的特征值曲线，低频率分量的特征值曲线的差异较小，可以证明前面的推测个体调制信号成分位于后面的分量中是正确的。以此作为无线电的“指纹特征”是可行的。




图 6 No. 1~4 无线电信号特征值谱

其次研究的是结合 EWT 和成分分析的无线电指纹提取方法的识别性能。选取 No. 1 电台的 100 个样本，每个样本长度为 1024，将其中一半样本作为训练集，另一半样本作为测试集。根据成分分析的方法和特征值曲线的差异大小的情况，用 DAG-SVM 多类别分类器对 c_7 、 c_6 、 c_7+c_6 、 c_7+c_5 、 c_6+c_5 、 $c_3 \sim c_7$ 这 6 种成分分量的特征值曲线特征进行分类识别实验，得到的识别率如表 1 所示。

表 1 7 种成分分量的特征识别率

成分名称	识别率/%
c_7	70.4
c_6	65.7
c_7+c_6	88.2
c_7+c_5	81.6
c_6+c_5	75.8
$c_3 \sim c_7$	92.5

从表 1 的结果可以看出组合分量的识别率明显高于单一分量的识别率，而 $c_3 \sim c_7$ 的组合分量的识别率最高。说明杂散分量主要分布在高频率段，使得低频率段的信号差异不大，区分效果不明显。

最后研究的是结合 EWT 和成分分析的无线电指纹提取识别方法与其他识别方法的性能效果对比。对 No. 1~4 电台分别选取 100 个样本，每个样本长度为 1024，将其中一半样本作为训练集，另一半样本作为测试集。通过估计信噪比的方法分别测出信号在 15 dB、10 dB、5 dB 条件下的数据，利用 DAG-SVM 多类别分类器，分别运用本文提出方法、HHT 和局部积分双谱分析方法进行识别分类，得到的识别结果如图 7 所示。由图 7 可以得出结论，EWT 成分分析的识别方法不仅优于基于经验模态分解的成分分析方法，而且优于双谱分析方法。可以看出此种方法受信噪比影响较小，在信噪比很低的情况下仍然识别效

果良好。




图 7 不同信噪比下不同方法的识别率

4 结论

无线电指纹识别在电子对抗领域具有很大的应用前景。本文提出了一种结合 EWT 和成分分析的无线电指纹提取方法, 该方法首先对信号进行成分分离, 然后选取其中能反映个体差异的分解成分进行信号的特征值分析和识别。实测数据实验结果表明, 该方法不仅优于 HHT 分析方法, 而且优于局部积分双谱分析方法, 在信噪比很低的情况下仍然识别效果良好, 可以看出此方法对噪声不敏感。

参考文献:

[1] Bertoncini C, Rudd K, Nousain B. Wavelet Fingerprinting of radio-frequency identification (RFID) Tags [J]. IEEE Transactions on Industrial Electronics, 2012, 59 (12): 4843-4850.

[2] 汤 博, 许士敏, 闻年成. 通信电台个体识别技术研究 [J]. 舰船电子工程, 2011, 31 (4): 15-17.

[3] Tekbas O H, Serinken N, Ureten O. An experimental performance evaluation of a novel radio-transmitter identification system under diverse environmental conditions [J]. Canadian Journal of Electrical & Computer Engineering, 2004, 29 (3): 203-209.

[4] 温玉仓, 孙严冬, 朱荣法. 基于指纹识别的通信电台识别仿真算法研究 [J]. 计算机仿真, 2012, 29 (3): 198-201.

(上接第 91 页)

作效果更好, 对网络更好的运营起到很好的保障作用。

4 总结与展望

由于信息造成的社会问题越来越严重, 网络给了人们畅所欲言的平台, 人们可以快速地获取大量信息, 但是也可以随意发布信息, 网上虚假信息越来越多, 而目前却缺少有效的惩治手段。智能设备为网络虚假信息散布提供了更大的空间, 如果不及时识别网络信息中的虚假信息, 采取有效手段进行控制, 就会造成社会的不安。由于网络信息的特殊性, 目前对网络虚假信息整治方面的研究很少。本文分别分析了一种虚假信息识别技术和控制技术, 通过构建识别模型和控制模型来整治网络环境, 杜绝虚假信息大规模扩散。本文对于网络安全有重要意义。

参考文献:

[1] 祁家榕, 张昌伟. 行为识别技术的研究与发展 [J]. 智能计算

[5] 钱祖平, 许 渊, 邵 尉. 基于高阶谱和时域分析的电台稳态特征提取算法 [J]. 电子与信息学报, 2013, 35 (7): 1599-1605.

[6] 赵国庆, 彭 华, 王 彬. 一种基于小波和分形理论的电台个体识别方法 [J]. 信息工程大学学报, 2012, 13 (1): 76-81.

[7] 赵颖颖, 许 刚. 基于经验小波变换的变压器振动信号特征提取 [J]. 电力系统自动化, 2017, 41 (20): 63-69.

[8] Jiang Y, Zhu H, Li Z. A new compound faults detection method for rolling bearings based on empirical wavelet transform and chaotic oscillator [J]. Chaos Solitons & Fractals, 2016, 89: 8-19.

[9] Jouny I. Scattering centers extraction using EWT for target identification [C]. Antenna Measurements & Applications, IEEE, 2017: 1-3.

[10] 阎 馨, 付 华, 屠乃威. 基于 PCA 和案例推理的煤与瓦斯突出动态预测 [J]. 传感技术学报, 2015, 29 (7): 545-551.

[11] Yan X, Fu H, Tu N W. Dynamic prediction of coal and gas outburst based on PCA and CBR [J]. Journal of Sensing Technology, 2015, 29 (7): 545-551.

[12] 王雨虹, 付 华, 张 洋. 基于 KPCA 和 CIPSO-PNN 的煤与瓦斯突出强度辨识模型 [J]. 传感技术学报, 2015 (2): 271-277.

[13] 付 华, 李海霞, 卢万杰. 一种改进的极限学习机煤与瓦斯突出预测模型 [J]. 传感技术学报, 2016, 29 (1): 69-74.

[14] 张 鹏, 谢晓尧. 基于模糊熵特征选择算法的 SVM 在漏洞分类中的研究 [J]. 计算机应用研究, 2015, 32 (4): 1145-1148.

[15] 高 猛. 基于递归和 SVM 的特征选择方法研究 [J]. 电子测试, 2010 (9): 26-29.

[16] 陈洪科. 基于多分类支持向量机算法的 PCB 焊点检测研究 [J]. 机电技术, 2018 (3).

[1] 李学军. 立法规制网络传播虚假信息行为——解读《新疆维吾尔自治区防范和惩治网络传播虚假信息条例》 [J]. 新疆人大 (汉文), 2017, 26 (1): 28-29.

[2] 陈 伟, 霍俊阁. 论恶意转发网络虚假信息的司法认定 [J]. 重庆大学学报 (社会科学版), 2017, 23 (5): 90-100.

[3] 陈修志, 陈春江. 利用网络虚假信息实施寻衅滋事罪相关问题的理解与适用 [J]. 特区法坛, 2017, 22 (8): 39-41.

[4] 王馨冉. 网络虚假信息传播的危害性及应对措施 [J]. 神州, 2018, 32 (1): 269-269.

[5] 段大高, 谢永恒, 盖新新, 等. 基于神经网络的微博虚假消息识别模型 [J]. 信息安全学报, 2017, 63 (9): 134-137.

[6] 杨丹凤. 自媒体时代的网络信息监管 [J]. 信息安全研究, 2017, 3 (12): 1102-1107.

[7] 郁赛君. 网络热点事件的信息生成、传播及自净机制——以“罗尔事件”为例 [J]. 青年记者, 2017, 23 (14): 80-81.

[8] 林 睿, 李 丰, 陆国生, 等. 基于 CA 技术的网络信息安全系统设计及实现 [J]. 电子设计工程, 2017, 25 (11): 157-159.