

## 基于矢量图的特定辐射源识别方法

潘一苇\* 杨司韩 彭华 李天昀 王文雅

(战略支援部队信息工程大学信息工程学院 郑州 450001)

**摘要:** 发射机的指纹特征具有复杂性, 现有的认识水平制约了特定辐射源识别(SEI)的性能。为此, 该文提出一种基于矢量图的SEI方法, 应用深度学习技术实现了多种复杂特征的联合提取。该文首先分析了多种发射机畸变在矢量图上的视觉表现; 在此基础上, 以矢量图灰度图像作为信号表示, 构建深度残差网络提取图像中的视觉特征。该方法克服了现有认知的局限, 兼具高信息完整性和低计算复杂度。实验结果表明, 与现有算法相比, 该方法能够显著改善SEI的性能, 识别增益约为30%。

**关键词:** 特定辐射源识别; 矢量图; 深度残差网络; 视觉特征; 信息完整性

中图分类号: TN911.7

文献标识码: A

文章编号: 1009-5896(2020)04-0941-09

DOI: 10.11999/JEIT190329

## Specific Emitter Identification Using Signal Trajectory Image

PAN Yiwei YANG Sihan PENG Hua LI Tianyun WANG Wenya

(Institute of Information System Engineering, Information Engineering University, Zhengzhou 450001, China)

**Abstract:** The radio frequency fingerprinting of the emitter is complex, and the performance of Specific Emitter Identification (SEI) is subjected to the present expertise. To remedy this shortcoming, this paper presents a novel SEI algorithm based on signal trajectory image, which realizes joint extraction of multiple complex fingerprints using deep learning architecture. First, this paper analyses the visual characteristics of multiple emitter imperfections in the signal trajectory image. Thereafter, signal trajectory grayscale image is used as the signal representation. Finally, a deep residual network is constructed to learn the visual characteristics reflected in the images. The proposed method overcomes the limitations of existing knowledge, and combines high information integrity with low computational complexity. Simulation results demonstrate that, compared with the existing algorithms, the proposed one can remarkably improve the SEI performance with a gain of about 30%.

**Key words:** Specific Emitter Identification (SEI); Signal trajectory image; Deep residual network; Visual characteristic; Information integrity

### 1 引言

特定辐射源识别(Specific Emitter Identification, SEI)即通过提取接收信号上能够体现辐射源个体差异的射频指纹特征, 实现对目标个体的识别<sup>[1]</sup>。由于指纹特征不依赖通信内容, 且难以伪造, SEI技术在战场频谱管理和无线网络安全等领域均具有重要的应用价值<sup>[2,3]</sup>。

SEI的关键在于提取有效的射频指纹特征。根据来源不同, 现有特征主要分为推测特征和预定特征<sup>[1]</sup>。前者不具备明确的物理意义, 是在处理过程

中根据个体差异推测得到的; 后者是依据已知的特征机理预先定义的。推测特征来源于数学变换: 起初, 学者们利用Fourier变换得到了积分双谱<sup>[4]</sup>等特征; 后来, Wavelet变换<sup>[5]</sup>和Hilbert-Huang变换<sup>[6]</sup>也逐渐用于特征提取。特别地, EM<sup>2</sup>算法<sup>[6]</sup>以Hilbert时频谱的能量熵和多阶矩作为特征, 取得了良好效果; 基于此, 文献<sup>[7]</sup>提出了谱的亮度和平坦度等特征。预定特征更易于理解: 文献<sup>[8]</sup>从星座图上提取了6种调制域特征, 对138个无线设备的识别率超过了99%; 文献<sup>[9,10]</sup>对调制域特征进行了更为深入的研究。然而, 无论预定特征还是推测特征都受限于现有的认知水平。前者受制于有限的变换方法, 难以完整地描述特征; 后者则依赖于专家经验对特征机理的认识, 难以理解复杂的特征。

近年来, 深度学习在图像识别中取得了众多突破。

收稿日期: 2019-05-07; 改回日期: 2019-07-23; 网络出版: 2019-09-29

\*通信作者: 潘一苇 novakd@163.com

基金项目: 国家自然科学基金(61401511, U1736107)

Foundation Items: The National Natural Science Foundation of China (61401511, U1736107)

受其鼓舞，深度神经网络也逐渐应用到信号处理领域，在调制识别<sup>[11,12]</sup>等问题中取得了显著成果。文献<sup>[13]</sup>将信号I/Q波形直接输入卷积神经网络(Convolutional Neural Network, CNN)，实现了特征提取和分类识别。文献<sup>[3]</sup>以时域复基带残差信号的波形作为输入，利用CNN对7个ZigBee设备的识别率达到了92.29%。需要指出，CNN的网络架构对图像具有更强的针对性和适用性，文献<sup>[3,13]</sup>以波形作为输入的做法难以充分发挥CNN强大的自学习能力。文献<sup>[14]</sup>算法以降维后的双谱图像作为信号表示，利用CNN提取特征并识别，算法性能明显优于传统方法。

由于发射机的复杂性，射频信号往往携带多种畸变导致的指纹特征。然而，上述方法联合提取多种畸变特征的能力难以令人满意：文献<sup>[8-10]</sup>算法仅针对I/Q调制器畸变，无法求解多种畸变共存时的非线性方程；文献<sup>[3-7,13,14]</sup>算法的信号表示形式均难以同时有效地呈现出多种畸变造成的个体差异。为此，本文提出了一种基于矢量图的SEI方法，应用深度学习技术实现了多种复杂特征的联合提取。

## 2 畸变模型及其视觉表现

图1给出了I/Q正交调制发射机的典型结构<sup>[15]</sup>，本节将分别给出I/Q调制器、滤波器、振荡器和功放的畸变模型，并分析各种畸变在基带信号矢量图上的视觉表现。

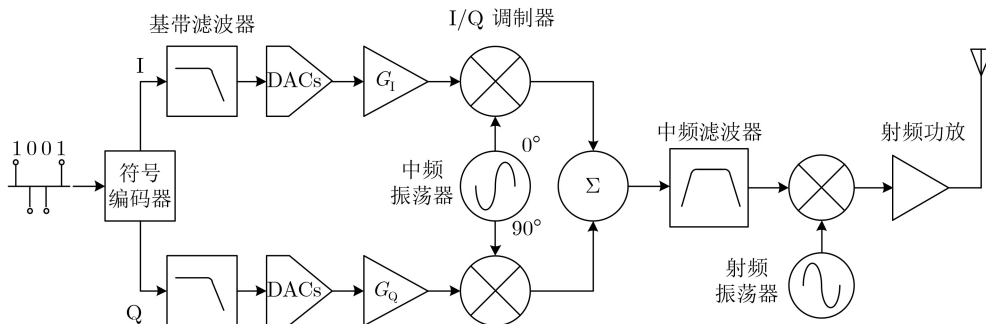


图1 I/Q正交调制发射机

### 2.1 I/Q调制器

I/Q调制器的畸变始终备受关注<sup>[8-10]</sup>，主要表现为：(1)增益失配，即I/Q两路信号的幅度增益不相等；(2)正交错误，即两路的相位差并非90°；(3)直流偏置，即两路的混频器发生了载波泄露。假设 $s_{b,I}(t)$ 和 $s_{b,Q}(t)$ 分别为I/Q两路的基带波形，则理想的基带信号为

$$s_0(t) = s_{b,I}(t) + j s_{b,Q}(t) \tag{1}$$

而携带I/Q调制器畸变的基带信号可以表示为

$$s(t) = (1 - g)(s_{b,I}(t) + c_1) + j(1 + g)(s_{b,Q}(t) + c_2)e^{j\phi} \tag{2}$$

其中， $g = \frac{G_Q - G_I}{G_Q + G_I}$ 为增益失配， $G_I$ 和 $G_Q$ 分别为两路的幅度增益， $\phi$ 为正交错误的相位偏差， $c_1$ 和 $c_2$ 分别为两路混频器产生的直流分量。式(2)表明： $g$ 表现为信号轨迹的幅度沿I/Q方向上的拉伸或收缩，使得4个星座点从正方形变为矩形； $\phi$ 表现为轨迹的Q轴分量向I轴的旋转，将矩形进一步变为平行四边形； $c_1$ 和 $c_2$ 表现为轨迹的整体平移，轨迹中心从(0,0)移至点 $(c_1, c_2)$ 。对于理想信号， $g, \phi, c_1$ 和 $c_2$ 均为0。

图2以QPSK调制为例，给出了携带I/Q调制器畸变的信号矢量图。可以看出，两个辐射源的星座点均偏离了理论位置，轨迹形状也随之相应改变；图2(a)的星座点表现为矩形，信号轨迹移向第I象限，图2(b)的星座点呈现为平行四边形，轨迹移向第III象限。

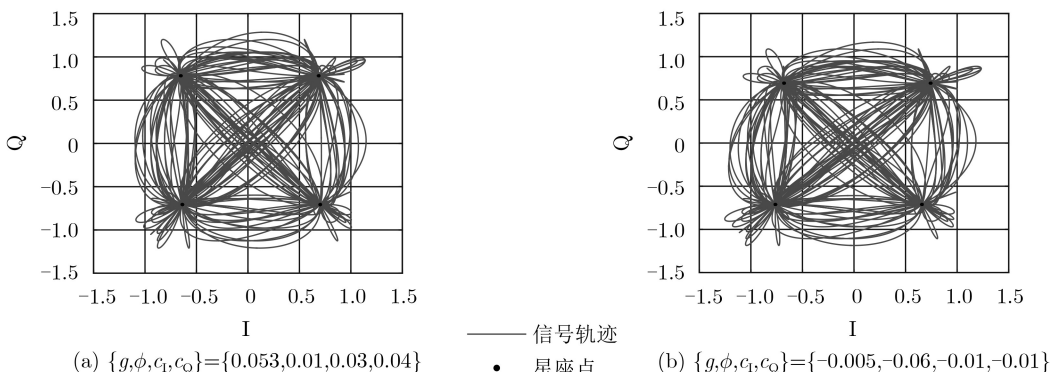


图2 I/Q调制器畸变的视觉表现

## 2.2 中频滤波器

滤波器的畸变主要表现为：(1)幅频响应的倾斜和波纹；(2)群时延的波动<sup>[15]</sup>。假设理想的基带成型滤波器为 $g(t)$ ，则理想的发射信号为

$$s_0(t) = e^{j(2\pi f_c t + \theta)} \sum_{k=1}^L a_k g(t - kT_0 - \tau) \quad (3)$$

其中， $f_c$ 为载频， $\theta$ 为初相， $\tau$ 为时延， $\{a_k\}$ 为发送符号序列， $T_0$ 为符号周期。令 $G(f)$ 为 $g(t)$ 的频率响应，则畸变滤波器的频率响应<sup>[9]</sup>可以表示为

$$H(f) = G(f) A(f) e^{j\phi(f)} \quad (4)$$

其中， $A(f) = a_0 + a_n \cos(2\pi\alpha_n f)$ 表示幅度畸变， $\phi(f) = 2\pi b_0 f + b_n \sin(2\pi\beta_n f)$ 为相位畸变， $a_0$ 和 $b_0$ 为线性增益， $a_n$ 和 $b_n$ 为波动增益， $\alpha_n$ 和 $\beta_n$ 取决于幅度波纹和时延波动的周期，则携带滤波器畸变的信号可以表示为

$$s(t) = e^{j(2\pi f_c t + \theta)} \sum_{k=1}^L a_k h(t - kT_0 - \tau) \quad (5)$$

其中， $h(t) = \int_{-\infty}^{\infty} H(f) e^{j2\pi f t} df$ 为畸变的基带成型滤波器。对于理想信号， $a_0 = 1$ ， $a_n$ ， $b_0$ 和 $b_n$ 均为0。

考察幅度畸变 $A(f)$ 对 $h(t)$ 的影响。将式(4)代入 $h(t)$ 得

$$h(t) = \int_{-\infty}^{\infty} G(f) \left( a_0 + \frac{a_n}{2} (e^{j2\pi\alpha_n f} + e^{-j2\pi\alpha_n f}) \right) \cdot e^{j\phi(f)} e^{j2\pi f t} df \quad (6)$$

令 $g'(t) = \int_{-\infty}^{\infty} G(f) e^{j\phi(f)} e^{j2\pi f t} df$ ，则式(6)可以表示为

$$h(t) = a_0 g'(t) + \frac{a_n}{2} g'(t + \alpha_n) + \frac{a_n}{2} g'(t - \alpha_n) \quad (7)$$

显然， $A(f)$ 相当于在基带波形 $g'(t)$ 上叠加了一对增益为 $\frac{a_n}{2}$ 、时延为 $\pm\alpha_n$ 的衍生波形。将 $\phi(f)$ 代入 $g'(t)$ ，考察相位畸变 $\phi(f)$ 对 $h(t)$ 的影响

$$g'(t) = \int_{-\infty}^{\infty} G(f) e^{j b_n \sin(2\pi\beta_n f)} e^{j2\pi f(t+b_0)} df \quad (8)$$

根据Bessel函数， $e^{j b_n \sin(2\pi\beta_n f)} = J_0(b_n) + \sum_{i=1}^{\infty} J_i(b_n) \left( e^{j(i \sin(2\pi\beta_n f))} + (-1)^i e^{-j(i \sin(2\pi\beta_n f))} \right)$ ，当 $2\pi\beta_n f$ 很小时，有 $e^{j(i \sin(2\pi\beta_n f))} \approx e^{j(i 2\pi\beta_n f)}$ 成立，则式(8)可以改写为

$$g'(t) \approx J_0(b_n) g(t + b_0) + \sum_{i=1}^{\infty} J_i(b_n) \cdot \left( g(t + b_0 + i\beta_n) + (-1)^i g(t + b_0 - i\beta_n) \right) \quad (9)$$

显然， $\phi(f)$ 不仅改变了 $g(t)$ 的幅度和时延，还引入了一组复杂的衍生波形。将式(9)代入式(7)得

$$h(t) \approx a_0 \left( J_0(b_n) g(t + b_0) + \sum_{i=1}^{\infty} J_i(b_n) \cdot \left( g(t + b_0 + i\beta_n) + (-1)^i g(t + b_0 - i\beta_n) \right) \right) + \frac{a_n}{2} \left( J_0(b_n) g(t + \alpha_n + b_0) + \sum_{i=1}^{\infty} J_i(b_n) \cdot \left( g(t + \alpha_n + b_0 + i\beta_n) + (-1)^i \cdot g(t + \alpha_n + b_0 - i\beta_n) \right) \right) + \frac{a_n}{2} \left( J_0(b_n) g(t - \alpha_n + b_0) + \sum_{i=1}^{\infty} J_i(b_n) \cdot \left( g(t - \alpha_n + b_0 + i\beta_n) + (-1)^i \cdot g(t - \alpha_n + b_0 - i\beta_n) \right) \right) \quad (10)$$

式(10)表明：滤波器畸变的效果类似于多个路径的延时相加， $g(t)$ 在时间上被展宽，造成了时延扩展，从而引入微量的码间串扰。图3给出了携带滤波器畸变的信号矢量图。可以看出，两个辐射源的星座点均出现了不同程度的发散。此外，信号轨迹的差异也是滤波器畸变在矢量图上的视觉表现。

## 2.3 振荡器

振荡器畸变主要表现为载频附近的相位噪声。对于形如式(3)的理想信号，假设相位噪声为 $\varphi(t)$ ，则携带振荡器畸变的信号可以表示为

$$s(t) = e^{j(2\pi f_c t + \theta + \varphi(t))} \sum_{k=1}^L a_k g(t - kT_0 - \tau) \quad (11)$$

$\varphi(t)$ 相当于在 $f_c$ 上添加了时变的加性因子。通常采用1阶自回归模型<sup>[16]</sup>对 $\varphi(t)$ 进行刻画

$$\varphi(t) = (1 - c_0) \varphi(t - 1) + c_0 \nu(t) \quad (12)$$

其中 $\varphi(0) = 0$ ， $\nu(t)$ 为单位方差的高斯白噪声， $c_0$ 反映发射机的个体差异。式(12)表明： $c_0$ 越大， $\varphi(t)$ 越随机，对 $f_c$ 的扰动越明显；反之， $\varphi(t)$ 的相关性越大，信号载频的稳定度越高。对于理想信号， $c_0 = 0$ 。

图4给出了携带振荡器畸变的信号矢量图。与图4(a)相比，图4(b)信号轨迹的随机性更强。此外，振荡器畸变的视觉特征还表现为星座点沿圆切线方向上的抖动。这是因为相位噪声不改变信号幅度，只是在标准相位的附近进行摆动。

## 2.4 射频功率放大器

功放的畸变主要表现为：(1)幅度/幅度(AM/AM)的压缩效应，即信号幅度在饱和区域被压缩；(2)幅度/相位(AM/PM)的转换效应，即信号幅度

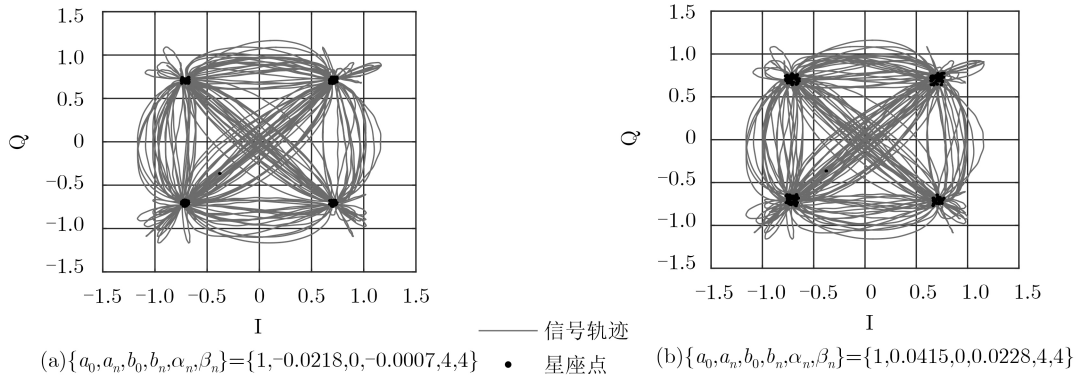


图3 滤波器畸变的视觉表现




图4 振荡器畸变的视觉表现

在非饱和区域产生了附加相位<sup>[15]</sup>。对于窄带功放，通常采用Taylor级数模型进行描述。假设输入功放的理想信号为

$$s_0(t) = \rho(t) e^{j(2\pi f_c t + \theta)} \quad (13)$$

其中， $\rho(t) = s_{b,I}(t) + j s_{b,Q}(t)$ 为理想的复基带波形，则携带功放畸变的信号可以表示为

$$\begin{aligned} s(t) &= \sum_{k=1}^K \lambda_{2k-1} (s_0(t))^k (s_0^*(t))^{k-1} \\ &= \lambda_1 \rho(t) e^{j(2\pi f_c t + \theta)} \\ &\quad + \sum_{k=2}^K \lambda_{2k-1} |\rho(t)|^{2k} \rho(t) e^{j(2\pi f_c t + \theta)} \end{aligned} \quad (14)$$

其中， $\{\lambda_1, \lambda_3, \dots, \lambda_{2K-1}\}$ 为Taylor级数的系数， $\lambda_1 = 1$ 。通常， $\lambda_3 < 0$ ，且 $|\lambda_k|$ 随 $k$ 的增加而减小。因此式(14)的第2项主要表现为 $\lambda_3$ 的特性，从而削弱输入信号的幅度，造成AM/AM压缩效应。当 $\lambda_k$ 为复数时，信号幅度会转化为附加相位，导致AM/PM转换效应。对于理想信号， $\{\lambda_3, \lambda_5, \dots, \lambda_{2K+1}\}$ 均为0。

图5给出了携带功放畸变的信号矢量图。为了方便对比，对信号幅度进行了归一化。可以看出，图5(a)信号轨迹带有顺时针的旋转，这是信号幅度转化为了附加相位；图5(b)轨迹被明显压缩，这是AM/AM压缩效应的视觉表现。此外，图5(b)幅度

越大的位置(越接近于饱和区域)，轨迹的压缩形变就越明显。需要指出，对于MPSK等恒幅调制，由于信号增益未知，只观察星座点是无法分辨出发射机的功放差异。因此，信号轨迹的形状是功放畸变在矢量图上不可忽视的视觉特征。

### 3 方法

#### 3.1 预处理

在传播过程中，信号会受到诸多因素的影响，以致幅度、时延、载频和相位等存在差异。这些差异并不稳定，不便作为指纹特征。因此，在训练网络之前，有必要对信号进行预处理，消除无关因素的干扰，从而保证神经网络真正学习到辐射源固有的指纹特征。

针对幅度的差异，需要对信号幅度进行归一化。针对载频、初相和时延的差异，需要进行参数估计和相应的补偿。此外，由第2节可知，滤波器和振荡器的畸变都在星座点的聚散程度上有所体现。为了消除时延差异对星座点聚散的干扰，需要对接收信号 $r(n)$ 的采样序列进行时间对齐，使得对齐后信号 $r(m)$ 的采样序列包含每个符号周期的最佳采样点，且其余采样点均与固定的时延对齐。设 $N$ 和 $M$ 分别表示 $r(n)$ 和 $r(m)$ 的过采倍数，则 $M$ 应为整数，且满足 $M \leq N$ 。

### 3.2 信号表示

根据第2节的分析，我们以矢量图作为信号表示。

假设矢量图的表示范围为 $\{(x, y) \mid |x| \leq P, |y| \leq P\}$ ，图像矩阵 $\mathbf{I}$ 的大小为 $D \times D$ ， $\mathbf{I}$ 中第 $(i, j)$ 个元素 $I_{i,j}$ 表示信号轨迹经过对应区域 $\left\{ (x, y) \mid \frac{2i-2-D}{D}P \leq x \leq \frac{2i-D}{D}P, \frac{D-2j}{D}P \leq y \leq \frac{D-2j+2}{D}P \right\}$ 的次数。显然， $I_{i,j} \geq 0$ 。在星座点附近的区域，信号轨迹相对密集，矩阵 $\mathbf{I}$ 对应元素的数值较大；而在其它区域，对应元素的数值则相对较小。为了避免 $I_{i,j}$ 的极端分布，对其进行平坦化处理，处理后的元素 $H_{i,j}$ 为

$$H_{i,j} = \lg(I_{i,j} + 1) \quad (15)$$

为了方便网络训练，进一步将矢量图转化为灰度图像。设 $G_{i,j}$ 表示灰度图像第 $(i, j)$ 个像素， $\zeta$ 为图像的量化位数， $\lfloor \cdot \rfloor$ 表示向下取整，则 $G_{i,j}$ 可以通过映射得到

$$G_{i,j} = \left\lfloor (2^\zeta - 1) \frac{H_{i,j}}{\max\{H_{i,j}\}} \right\rfloor \quad (16)$$

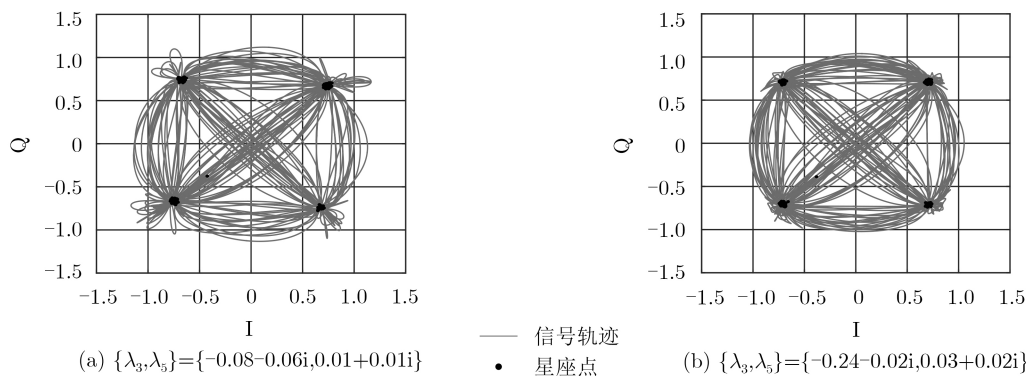


图5 功率放大畸变的视觉表现

图6给出了携带上述4类畸变的信号矢量图灰度图像，其中 $D = 300, P = 1.5, \zeta = 8$ 。可以看出，图6(a) I/Q调制器和滤波器的畸变比较明显，图6(b)振荡器和功放畸变相对较大。作为信号表示，灰度图像不仅能够清晰地呈现出信号轨迹，还可以通过明暗变化有效地反映出星座点的聚散程度，完整地保留了上述4类畸变在矢量图上的视觉特征。

### 3.3 网络结构

卷积神经网络能够自动学习并整合低维/中维/高维的特征，有望克服人为认识的局限性。

网络性能与其深度密切相关。研究表明，随着网络层数的加深，训练难度急剧增加。梯度弥散制约着网络的规模。为了解决该问题，本文采用深度残差网络<sup>[17]</sup>提取指纹特征。图7给出了所用残差网络的网络结构，其中包含6个残差单元，共14层。将矢量图的灰度图像作为输入，图片大小为 $300 \times 300$ 。除输出层使用Softmax函数之外，其它层的激活函数均采用PRReLU。在每次的卷积之后、激活函数之前，均采用批量标准化提高网络的训练效率。

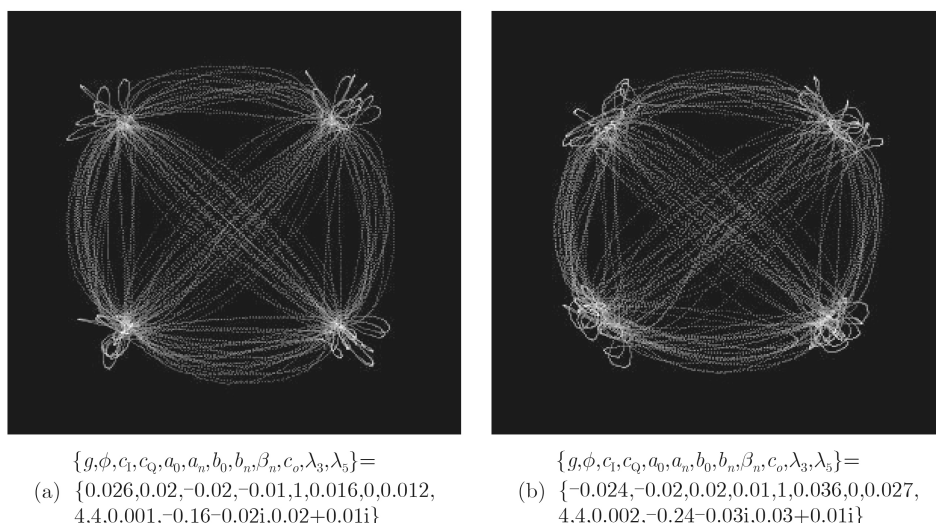


图6 矢量图灰度图像

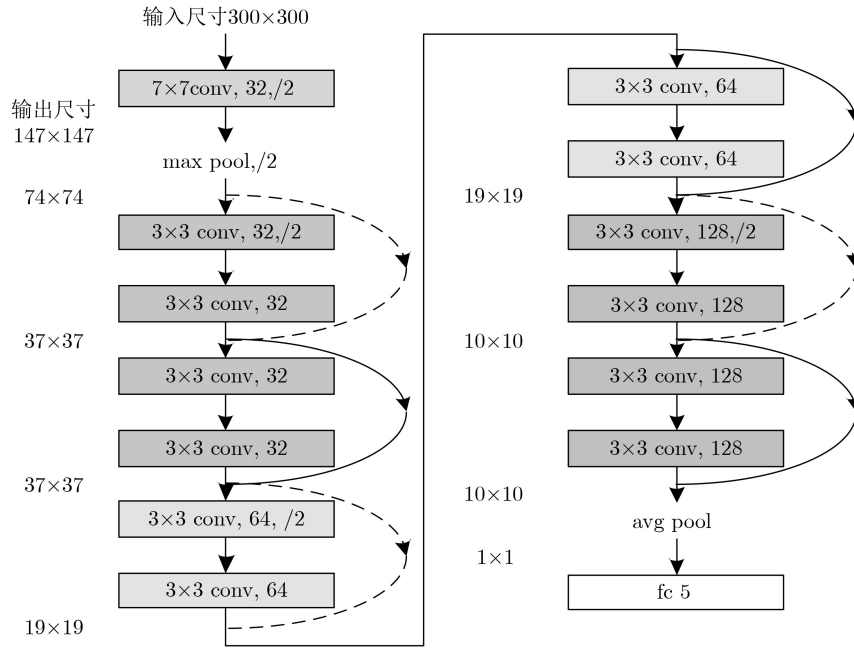


图7 深度残差网络的网络结构

## 4 性能与复杂度分析

### 4.1 性能分析

在特征提取的过程中，信号所携信息不可避免地丢失，因此特征提取的过程也是信息丢失的过程。实际上，指纹信息的完整程度决定了算法性能的上界。本节将从信息完整性的角度对本文算法与文献[6,8-10,14]方法进行对比分析。

文献[6]EM<sup>2</sup>算法以Hilbert时频谱图的能量熵和多阶矩作为指纹特征，该特征仅从一致性的角度对谱图进行描述，没能理解并提取图像呈现出的其它特征，造成了指纹信息的丢失。文献[8-10]从星座图上提取多种调制域特征(尽管文献[10]算法以差分星座轨迹图作为信号表示，但仍只关注了星座点的聚类特征)，均忽视了信号轨迹所蕴含的丰富指纹信息。此外，文献[9]还对特征向量进行了降维：去除冗余的同时，也造成了部分细节的丢失，进一步削弱了信息的完整性。文献[14]利用CNN从压缩的双谱图像上提取特征。需要指出：作为信号表示，由3阶累积量得到的双谱只能表征信号中部分非高斯的特性，而丢失了大量其它的指纹信息；对双谱进行压缩同样破坏了信息完整性。

在本文算法中，预处理只是消除了不稳定的随机干扰，没有造成指纹信息的丢失；矢量图灰度图像能够完整地保留多种畸变的视觉特征，具有高度的信息完整性；深度残差网络不仅克服了专家经验

的局限性，还能够有效地缓解梯度弥散，减少了信息的丢失。综上，本文算法充分规避了现有算法的缺点，在预处理、信号表示和网络结构上均力求指纹信息的完整，具备更优的识别性能。

### 4.2 复杂度分析

由于网络的训练过程可以离线进行，本文算法的计算量主要来源于预处理和信号表示。尽管预处理涉及多个步骤，但其复杂度与数据量呈线性关系，即 $O(ML)$ ，其中 $M$ 为过采倍数， $L$ 为符号个数。对于信号表示，式(15)、式(16)的复杂度均为 $O(S)$ ，其中 $S = D^2$ 为图像大小。故本文算法的复杂度为 $O(ML) + O(S)$ 。

表1给出了相同条件下(其中文献[14]估计双谱时，将信号分割成可重叠的 $P$ 段，每段 $Q$ 个采样点)不同算法的复杂度。可以看出，文献[8-10]算法提取简单的经验特征，复杂度最低；本文算法次之；文献[6,14]算法涉及复杂变换，复杂度最高。

## 5 仿真实验

实验条件设置如下：QPSK调制，符号个数 $L = 200$ ，符号速率100 kBaud，载波频率350 kHz，采样率10 MHz，采用滚降系数0.35的升余弦成型滤波器。7个辐射源，根据第2节的畸变模型仿真产生，其中默认 $\{a_0, b_0, \alpha_n, \beta_n\} = \{1, 0, 4, 4\}$ ，其余参数见表2。在每个信噪比 $E_s/N_0$ 下，每个辐射源包

表1 不同算法的复杂度对比

算法	文献[6]算法	文献[8]算法	文献[9]算法	文献[10]算法	文献[14]算法	本文算法
复杂度	$O(ML \lg(ML)) + O(S)$	$O(ML) + O(L)$	$O(ML) + O(L)$	$O(ML) + O(L)$	$O(PQ \lg Q) + O(S)$	$O(ML) + O(S)$

含2000个样本，随机选取1000个样本训练，剩余样本测试。图像相关参数 $D = 300, P = 1.5, \zeta = 8$ 。利用Python在TensorFlow 1.3.0上实现网络，使用NVIDIA Titan Xp GPU训练网络，每个批次训练300张图像。

5.1 网络结构对识别性能的影响

实验1 考察残差单元个数RN对识别性能的影响。不同RN的网络结构如表3所示。图8给出了不同RN对应的识别效果。可以发现，当RN = 2

时，识别率最低，这说明较浅的网络对图像视觉特征的学习程度还不够充分。当 $RN \geq 6$ 时，不同网络之间的识别率已经非常接近。表3还给出了不同网络的参数量和单批次训练时间。对比发现，随着RN的增加，参数量和训练时间逐渐增加。为了平衡性能与复杂度，在后续实验中，统一采用 $RN = 6$ 的网络。

5.2 信号参数对识别性能的影响

实验2 考察符号个数L对识别性能的影响。图9

表2 不同辐射源的畸变参数

辐射源	1	2	3	4	5	6	7
$g$	0.0299	0.0188	0.0081	-0.0025	-0.0128	-0.0230	-0.0329
$\phi$	0.0137	0.0093	0.0050	0.0006	-0.0038	-0.0081	-0.0125
$c_1$	0.0142	0.0097	0.0052	0.0007	-0.0038	-0.0083	-0.0128
$c_Q$	0.0147	0.0102	0.0057	0.0012	-0.0033	-0.0078	-0.0123
$a_n$	-0.0640	-0.0429	-0.0218	-0.0007	0.0204	0.0415	0.0627
$b_n$	-0.0740	-0.0498	-0.0256	-0.0014	0.0228	0.0470	0.0713
$c_o$	0.0002	0.0010	0.0018	0.0026	0.0034	0.0042	0.0050
$\lambda_3$	-0.2915-0.0079i	-0.0003-0.0004i	-0.4371-0.0092i	-0.1459-0.0066i	-0.5827-0.0096i	-0.0731-0.0042i	-0.3643-0.0085i
$\lambda_5$	0.0295+0.0005i	0.0001+0.0004i	0.0821+0.0048i	0.0338+0.0014i	0.0537+0.0029i	0.0571+0.0035i	0.0484+0.0022i

表3 网络结构及其参数量和单批次训练时间

RN	2	4	6	8	10
conv1	7×7, 32, stride2				
max pool	3×3, stride 2				
conv2_x	$\begin{bmatrix} 3 \times 3, 32 \\ 3 \times 3, 32 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 32 \\ 3 \times 3, 32 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 32 \\ 3 \times 3, 32 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 32 \\ 3 \times 3, 32 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 32 \\ 3 \times 3, 32 \end{bmatrix} \times 2$
conv3_x	—	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$
conv4_x	—	—	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$
conv5_x	—	—	—	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$
conv6_x	—	—	—	—	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$
avg pool	5-d fc, softmax				
参数量	$3.9 \times 10^4$	$1.7 \times 10^5$	$6.8 \times 10^5$	$2.7 \times 10^6$	$1.1 \times 10^7$
训练时间 (s)	0.3516	0.3858	0.4019	0.4262	0.4584




图8 残差单元个数对识别性能的影响




图9 符号个数对识别性能的影响

给出了不同 $L$ 对应的识别效果。可以发现,当 $L=50$ 时,识别率最低;随着 $L$ 的增加,识别率逐渐提高,最终趋于稳定。从视觉特征的角度分析,当 $L$ 较少时,图像中的信号轨迹较短,难以有效地体现出畸变的视觉特征;随着 $L$ 的增加,视觉特征愈发明显,识别率随之提高。从参数估计的角度分析,指纹特征的估计精度与数据量有关, $L$ 的增加带来了识别性能的改善。

**实验 3** 考察过采样倍数 $M$ 对识别性能的影响。图10给出了不同 $M$ 对应的识别效果。可以发现,不同条件下的识别率差距并不明显。这说明本文算法对 $M$ 的要求不高,能够反映出信号轨迹的大致轮廓即可。

### 5.3 算法性能对比

**实验 4** 利用仿真信号对识别性能进行测试。对比方法包括文献[6,8–10,14]算法,其中文献[6,8–10]是基于经验特征的传统方法,文献[14]是基于深度学习的方法。传统方法统一使用支持向量机进行分类,基于深度学习的方法统一采用RN=6的残差网络。图11给出了不同算法的识别性能。可以发现,本文算法显著改善了识别效果,在不同信噪比下至少约有30%的识别增益。实验结果验证了4.1节性能分析的正确性。




图 10 过采样倍数对识别性能的影响




图 11 不同算法的识别性能

## 6 结束语

本文提出了一种基于矢量图的SEI方法,应用深度学习技术实现了多种复杂特征的联合提取。作为信号表示,矢量图灰度图像能够完整地呈现多种畸变的视觉特征,避免了指纹信息的丢失;深度残差网络能够有效地学习提取复杂特征,克服了现有认知的局限。实验结果表明,与现有算法相比,本文方法能够显著改善SEI的性能。后续研究可以从以下两个方面展开:(1)探讨如何提高本文算法在复杂信道环境下的适应性;(2)针对网络结构的鲁棒性进行研究,以满足大规模SEI的实际需要。

### 参考文献

- [1] DANEV B, ZANETTI D, and CAPKUN S. On physical-layer identification of wireless devices[J]. *ACM Computing Surveys*, 2012, 45(1): 1–29. doi: 10.1145/2379776.2379782.
- [2] SPEZIO A E. Electronic warfare systems[J]. *IEEE Transactions on Microwave Theory and Techniques*, 2002, 50(3): 633–644. doi: 10.1109/22.989948.
- [3] MERCHANT K, REVAY S, STANTCHEV G, et al. Deep learning for RF device fingerprinting in cognitive communication networks[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(1): 160–167. doi: 10.1109/JSTSP.2018.2796446.
- [4] HAN Jie, ZHANG Tao, REN Dongfang, et al. Communication emitter identification based on distribution of bispectrum amplitude and phase[J]. *IET Science, Measurement & Technology*, 2017, 11(8): 1104–1112. doi: 10.1049/iet-smt.2017.0024.
- [5] BERTONCINI C, RUDD K, NOUSAIN B, et al. Wavelet fingerprinting of radio-frequency identification (RFID) tags[J]. *IEEE Transactions on Industrial Electronics*, 2012, 59(12): 4843–4850. doi: 10.1109/TIE.2011.2179276.
- [6] ZHANG Jingwen, WANG Fanggang, DOBRE O A, et al. Specific emitter identification via Hilbert-Huang transform in single-hop and relaying scenarios[J]. *IEEE Transactions on Information Forensics and Security*, 2016, 11(6): 1192–1205. doi: 10.1109/TIFS.2016.2520908.
- [7] SATIJA U, TRIVEDI N, BISWAL G, et al. Specific emitter identification based on variational mode decomposition and spectral features in single hop and relaying scenarios[J]. *IEEE Transactions on Information Forensics and Security*, 2019, 14(3): 581–591. doi: 10.1109/TIFS.2018.2855665.
- [8] BRIK V, BANERJEE S, GRUTESER M, et al. Wireless device identification with radiometric signatures[C]. The 14th ACM International Conference on Mobile Computing and Networking, San Francisco, USA, 2008: 116–127.
- [9] HUANG Yuanling and ZHENG Hui. Radio frequency fingerprinting based on the constellation errors[C]. The 18th

- Asia-Pacific Conference on Communications, Jeju Island, South Korea, 2012: 900–905.
- [10] 彭李宁, 胡爱群, 朱长明, 等. 基于星座轨迹图的射频指纹提取方法[J]. 信息安全学报, 2016, 1(1): 50–58. doi: [10.19363/j.cnki.cn10-1380/tn.2016.01.007](https://doi.org/10.19363/j.cnki.cn10-1380/tn.2016.01.007).
- PENG Linning, HU Aiqun, ZHU Changming, *et al.* Radio fingerprint extraction based on constellation trace figure[J]. *Journal of Cyber Security*, 2016, 1(1): 50–58. doi: [10.19363/j.cnki.cn10-1380/tn.2016.01.007](https://doi.org/10.19363/j.cnki.cn10-1380/tn.2016.01.007).
- [11] O'SHEA T J, ROY T, and CLANCY T C. Over-the-air deep learning based radio signal classification[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(1): 168–179. doi: [10.1109/JSTSP.2018.2797022](https://doi.org/10.1109/JSTSP.2018.2797022).
- [12] KULIN M, KAZAZ T, MOERMAN I, *et al.* End-to-end learning from spectrum data: A deep learning approach for wireless signal identification in spectrum monitoring applications[J]. *IEEE Access*, 2018, 6: 18484–18501. doi: [10.1109/ACCESS.2018.2818794](https://doi.org/10.1109/ACCESS.2018.2818794).
- [13] RIYAZ S, SANKHE K, IOANNIDIS S, *et al.* Deep learning convolutional neural networks for radio identification[J]. *IEEE Communications Magazine*, 2018, 56(9): 146–152. doi: [10.1109/MCOM.2018.1800153](https://doi.org/10.1109/MCOM.2018.1800153).
- [14] DING Lida, WANG Shilian, WANG Fanggang, *et al.* Specific emitter identification via convolutional neural networks[J]. *IEEE Communications Letters*, 2018, 22(12): 2591–2594. doi: [10.1109/LCOMM.2018.2871465](https://doi.org/10.1109/LCOMM.2018.2871465).
- [15] Agilent Technologies. Agilent technologies wireless test solutions application note 1313: Testing and troubleshooting digital RF communications transmitter designs[EB/OL]. <http://literature.cdn.keysight.com/litweb/pdf/5968-3578E.pdf>, 2016.
- [16] SRIDHARAN G. Phase noise in multi-carrier systems[D]. [Master dissertation], University of Toronto, 2010: 9–44.
- [17] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Deep residual learning for image recognition[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 770–778.
- 潘一苇: 男, 1990年生, 博士生, 研究方向为通信信号处理、特定辐射源识别.
- 杨司韩: 男, 1990年生, 硕士生, 研究方向为通信信号处理、深度学习.
- 彭 华: 男, 1973年生, 教授, 研究方向为通信信号处理、软件无线电.
- 李天昀: 男, 1979年生, 副教授, 研究方向为通信信号处理、软件无线电.
- 王文雅: 女, 1991年生, 硕士生, 研究方向为通信信号处理、可见光通信.