

# 基于稀疏自编码器的混合信号符号检测研究

郝崇正 党小宇\* 李赛 王成华

(南京航空航天大学电子信息工程学院 南京 210016)

**摘要:** 基于深度神经网络(DNN)的符号检测器(SD)的结构直接影响检测精度和计算复杂度,然而,已有的工作中并未对DNN符号检测器的结构选择方法开展研究。此外,已知的基于DNN的符号检测器复杂度较高且仅能完成单一调制信号的检测。针对以上问题,该文提出基于误符号率(SER)度量的低复杂度稀疏自编码器符号检测器(SAED)结构选择策略,同时,利用提出的累积量和矩特征向量(CMFV)实现了对混合信号的检测。所设计的符号检测器不依赖信道模型和噪声假设,对不同调制方式的信号具有较好的检测性能。仿真结果表明,该文设计的SAE符号检测器的SER性能接近最大似然(ML)检测理论值,且在频偏、相偏和有限训练样本等非理想条件下具有较强的鲁棒性。

**关键词:** 无线通信; 符号检测; 深度神经网络; 累积量和矩特征向量; 频率和相位偏移

中图分类号: TN911

文献标识码: A

文章编号: 1009-5896(2022)12-4204-07

DOI: 10.11999/JEIT211074

## Research on Symbol Detection of Mixed Signals Based on Sparse AutoEncoder Detector

HAO Chongzheng DANG Xiaoyu LI Sai WANG Chenghua

(College of Electronic Information Engineering, Nanjing University of  
Aeronautics and Astronautics, Nanjing 210016, China)

**Abstract:** The architecture of Deep Neural Network (DNN) based detectors can affect the Symbol Detection (SD) accuracy and computational complexity. However, most of the works ignore the architecture selection method when establishing a DNN-based symbol detector. Moreover, the existing DNN detectors use complex architectures and only perform single-type modulated symbols detection. The Symbol Error Rate (SER) based strategy is proposed to design a low complexity Sparse AutoEncoder Detector (SAED) to tackle this problem. Furthermore, a Cumulant and Moment Feature Vector (CMFV)-based method is introduced for mixed symbols detection. Also, the designed symbol detector does not rely on a comprehensive knowledge of channel models and parameters but has the capability to detect various modulation signals. Simulation results show that the SER performance of the SAE symbol detector is close to the values of the Maximum Likelihood (ML) detection approach and provides a stable performance against phase offsets, frequency offsets, and under a limited training dataset.

**Key words:** Wireless communications; Symbol Detection(SD); Deep Neural Network (DNN); Cumulant and moment feature vector; Frequency and phase offsets

### 1 引言

盲信号检测在合作和非合作通信中发挥着重要的作用,例如民用通信中的频谱管理和认知无线电,军事通信中的电子侦察和电子对抗等。符号检测(Symbol Detection, SD)是盲信号检测中重要且

具有挑战性的任务。SD是指接收机端的检测器根据概率模型对受噪声干扰和信道损伤的发送信号进行重建,从而恢复原始的发送信息<sup>[1]</sup>。传统的符号检测算法完全依赖已知的信道模型和调制方式等参数,然而,实际通信系统中信道模型的建立和准确的参数估计面临较大的挑战。

目前,深度神经网络(Deep Neural Network, DNN)在信号检测和处理中得到了快速的发展<sup>[2-6]</sup>,基于DNN的信号检测方法为解决上述挑战提供了一种途径。文献<sup>[7]</sup>设计了一种基于自编码器架构的最优发射和接收系统,该系统中信道被认为是自编码器神经网络的一层,通过使用准确的条件概率密

收稿日期: 2021-10-08; 改回日期: 2022-02-28; 网络出版: 2022-03-09

\*通信作者: 党小宇 dang@nuaa.edu.cn

基金项目: 国家自然科学基金(62031017, 61971221), 中央高校基本科研业务费(NP2020104)

Foundation Items: The National Natural Science Foundation of China (62031017, 61971221), The Fundamental Research Funds for the Central Universities of China (NP2020104)

度函数进行描述。然而，该结构的检测性能依赖已知的信道模型。文献[8]利用卷积神经网络(Convolutional Neural Network, CNN)实现了二进制相移键控(Binary Phase Shift Keying, BPSK)信号的解调。然而，该检测器仅能完成对BPSK一种调制信号的相位检测。文献[9]利用DNN对理想信道条件下的多输入多输出信号进行检测，并与传统的迫零均衡检测、反馈均衡判决检测、球译码检测等进行了比较，但是，该研究仅对理想信道条件下的检测性能进行了分析。文献[10]提出了一种联合专家知识和DNN的正交频分复用接收机，通过使用DNN结构简化传统接收机的设计。

以上研究中，使用的DNN结构较复杂(包含较多的神经元数目和层数)，导致网络的训练和部署困难，在战场等实际场景下应用受限。其次，研究中大多使用计算机视觉或自然语言处理等领域成熟的DNN架构，然而，通信信号具有区别于图像和语言文本的属性，因此，信号检测中DNN检测器的结构应根据通信信号特点进行设计。此外，已知的DNN符号检测器仅能完成单一调制信号的检测，无法处理混合信号的符号恢复。同时，大多数检测是在理想条件下进行的，忽略了DNN检测器的通用性和信号损伤等因素对检测性能的影响。

与已有工作不同，本文研究了基于稀疏自编码器(Sparse AutoEncoder, SAE)神经网络的混合信号符号检测方法，提出了基于误符号率(Symbol Error Rate, SER)度量的稀疏自编码器检测器(Sparse AutoEncoder Detector, SAED)结构选择策略，通过该方法优化SAED的结构，从而降低网络的复杂度。同时，提出了利用累积量和矩特征向量实现混合信号的符号检测方案。本文设计的SAED不依赖信道模型和噪声假设，在加性高斯白噪声(Additive White Gaussian Noise, AWGN)和Rayleigh衰落信道下对不同调制方式的混合信号均具有较好的检测性能。此外，SAED在频率和相位偏移及有限训练样本下均具有较强的鲁棒性。本文结构安排如下：第2节给出了问题的阐述；第3节给出了SAED结构选择策略和基于特征向量的混合信号检测模型；第4节给出了仿真结果和讨论；第5节进行了复杂度的分析；第6节总结全文。

## 2 问题阐述

调制信号经过信道传播后，接收信号的复基带模型可表示为

$$y(t; \psi_i) = \sum_{n=1}^N x_n^{(i)} e^{j(2\pi\Delta f t + \phi)} g(t - nT_s) + z(t) \quad (1)$$

其中， $n$ 表示发送符号的数量， $x_n^{(i)}$ 是某种调制格式的发送符号且调制方式属于调制类型池 $\mathcal{M} = (m_1, m_2, \dots, m_k)$ ， $i$ 表示调制方式， $\Delta f$ 是频率偏移， $\varphi$ 是相位偏移， $g(t) = h(t) \otimes p(t)$ ，其中 $h(t)$ 是信道冲激响应， $p(t)$ 是脉冲成型函数， $\otimes$ 表示卷积运算， $T_s$ 是符号周期， $z(t)$ 是均值为0，方差为 $\sigma^2$ 的复高斯白噪声。 $\psi_i = [\Delta f^{(i)}, \phi^{(i)}, x_n^{(i)}, i]$ 表示第 $i$ 种调制方式对应的未知参数。第 $i$ 种调制方式的时域信号采样后可表示为： $\mathbf{y}^{(i)} = [\mathbf{y}^{(i)}(0), \mathbf{y}^{(i)}(1), \dots, \mathbf{y}^{(i)}(P)]$ ，其中 $P$ 表示观察周期， $\mathbf{y}^{(i)}(P) = [\mathbf{y}_1^{(i)}(P), \mathbf{y}_2^{(i)}(P), \dots, \mathbf{y}_s^{(i)}(P)]$ 为第 $P$ 个符号周期内的 $s$ 个采样数据。

假定接收机收到两种未知调制方式的采样信号 $\mathbf{y}^{(i)}$ 和 $\mathbf{y}^{(j)}$ ，每个信号经过独立的信道传播， $i, j \in (1, 2, \dots, k)$ 是调制类型池中的任意调制方式。SAED利用采样信号 $\mathbf{y}^{(i)}$ 和 $\mathbf{y}^{(j)}$ 构建最优判别函数，从而在接收端重建发送的符号序列 $\mathbf{x}^{(i)} = [x_1^{(i)}, x_2^{(i)}, \dots, x_n^{(i)}]$ 和 $\mathbf{x}^{(j)} = [x_1^{(j)}, x_2^{(j)}, \dots, x_n^{(j)}]$ 。SAED的符号检测的判别函数可表示为

$$\mathcal{F} = \left\{ f \left[ \tilde{\mathbf{x}}^{(i)}, \tilde{\mathbf{x}}^{(j)} \right] = f_{\theta} \left[ \mathbb{T} \left( \mathbf{y}^{(i)} | \psi_i, \mathbf{y}^{(j)} | \psi_j \right), \theta \in \mathbb{R}^N \right] \right\} \quad (2)$$

其中， $\mathcal{F}$ 表示符号检测的判别函数 $f(\cdot)$ 对应的假设空间， $\tilde{\mathbf{x}}^{(i)} = [\tilde{x}_1^{(i)}, \tilde{x}_2^{(i)}, \dots, \tilde{x}_n^{(i)}]$ 和 $\tilde{\mathbf{x}}^{(j)} = [\tilde{x}_1^{(j)}, \tilde{x}_2^{(j)}, \dots, \tilde{x}_n^{(j)}]$ 是SAED恢复的符号序列， $\mathbb{T}(\cdot)$ 表示信号的预处理操作， $\theta = [\theta_1, \theta_2, \dots, \theta_N]$ 是判别函数中的参数集合，其属于 $N$ 维欧氏空间 $\mathbb{R}^N$ 。

## 3 SAED结构选择方法和混合信号符号检测模型

### 3.1 SAE检测模型

自编码器(AutoEncoder, AE)是一种可以在输出端重建输入信号的深度神经网络结构[11]。已知的AE结构通常包含较多的隐藏层数目，从而导致网络结构复杂[7]。本文利用基于SER度量的SAED结构选择策略对SAE检测器的结构进行设计，从而降低符号检测器的复杂度。

SAED通过式(1)的采样信号，在接收端重建发送符号。该过程即最小化符号检测器的最优判别函数的错误概率。最小化错误概率可等价于最小化符号检测器的损失函数，根据式(2)，最小化判别函数的错误概率问题可表示为

$$\begin{aligned} P &= \arg \min_{\substack{\mathbf{x}^{(i)}, \mathbf{x}^{(j)} \in \mathcal{M} \\ i, j \in (1, 2, \dots, k)}} \left( \left[ \mathbf{x}^{(i)}, \mathbf{x}^{(j)} \right] \right. \\ &\quad \left. - f \left[ \mathbb{T} \left( \mathbf{y}^{(i)} | \psi_i, \mathbf{y}^{(j)} | \psi_j \right) \right] \right) \\ &= \arg \min_{\substack{\mathbf{x}^{(i)}, \mathbf{x}^{(j)} \in \mathcal{M} \\ i, j \in (1, 2, \dots, k)}} J_{\text{SAED}}(\theta) \end{aligned} \quad (3)$$

其中,  $J_{\text{SAED}}(\cdot)$ 是符号检测器的损失函数。进一步, SAED的损失函数可表示为

$$J_{\text{SAED}}(\boldsymbol{\theta}) = J(\boldsymbol{\theta}) + \xi \sum_{h=1}^{S_m} \text{KL}(\rho | \tilde{\rho}_w) + \zeta \sum_{c=1}^M \boldsymbol{\theta}_c^2 \quad (4)$$

其中,  $J(\boldsymbol{\theta})$ 表示交叉熵损失项,  $\xi \sum_{h=1}^{S_m} \text{KL}(\rho | \tilde{\rho}_w)$ 是使用KL散度对隐藏层进行约束以提高SAE的特征表达能力,  $\zeta \sum_{c=1}^M \boldsymbol{\theta}_c^2$ 为权重惩罚项, 避免SAE网络的过拟合。

设  $\{(y^{(1)}, l^{(1)}), (y^{(2)}, l^{(2)}), \dots, (y^{(G)}, l^{(G)})\}$  表示具有 $G$ 个样本的混合信号训练数据集。其中,  $y^{(k)}$ 表示第 $k$ 个采样输入信号,  $l^{(k)} \in (1, 2, \dots, b, \dots, M)$ 表示输入样本对应的标签。输入信号  $(y^{(1)}, y^{(2)}, \dots, y^{(G)})$  经过SAED隐藏层提取特征后, 隐藏层输出信号可以表示为  $\{(\mathcal{V}^{(1)}, l^{(1)}), (\mathcal{V}^{(2)}, l^{(2)}), \dots, (\mathcal{V}^{(G)}, l^{(G)})\}$ ,  $\mathcal{V}^{(k)}$ 表示第 $k$ 个采样信号  $y^{(k)}$  通过隐藏层处理后的输出特征。采样信号经过多个隐藏层提取特征之后的输出数据传递给Softmax层用以训练分类器, Softmax分类器在最优参数  $\boldsymbol{\theta}_s$  下对每个输入数据  $\mathcal{V}^{(k)}$  进行  $P(l^{(k)} = b | \mathcal{V}^{(k)}; \boldsymbol{\theta}_s)$  估计从而获得条件概率分布函数

$$\Lambda(\mathbb{V}; \boldsymbol{\theta}_s) = \begin{bmatrix} P(l^{(k)} = 1 | \mathcal{V}^{(k)}; \boldsymbol{\theta}_s) \\ P(l^{(k)} = 2 | \mathcal{V}^{(k)}; \boldsymbol{\theta}_s) \\ \vdots \\ P(l^{(k)} = M | \mathcal{V}^{(k)}; \boldsymbol{\theta}_s) \end{bmatrix} = \frac{1}{\sum_{b=1}^M \exp(\boldsymbol{\theta}_b \mathcal{V}^{(k)})} \begin{bmatrix} \exp(\boldsymbol{\theta}_1 \mathcal{V}^{(k)}) \\ \exp(\boldsymbol{\theta}_2 \mathcal{V}^{(k)}) \\ \vdots \\ \exp(\boldsymbol{\theta}_M \mathcal{V}^{(k)}) \end{bmatrix} \quad (5)$$

其中,  $(\theta_1, \theta_2, \dots, \theta_M) \in \mathbb{R}^N$  表示Softmax分类层的参数,  $b$ 是标签的类别指数,  $M$ 表示总的标签类别数目。利用式(5)可将交叉熵损失项表示为<sup>[12]</sup>

$$J(\boldsymbol{\theta}) = -\frac{1}{G} \left[ \sum_{k=1}^G \sum_{b=1}^M 1(l^{(k)} = b) \lg \left\{ \text{softmax}(\mathcal{V}^{(k)}) \right\} \right] = -\frac{1}{G} \left[ \sum_{k=1}^G \sum_{b=1}^M 1(l^{(k)} = b) \lg \frac{e^{\boldsymbol{\theta}_b \mathcal{V}^{(k)}}}{\sum_{g=1}^M \exp(\boldsymbol{\theta}_g \mathcal{V}^{(k)})} \right] \quad (6)$$

其中,  $1(\cdot)$ 是指示函数, 当事件为真时, 其值为1; 反之为0。

为了增强SAE隐藏层的特征表达能力, 同时降低网络的复杂度, 设置隐藏层中仅有部分神经元被激活。损失函数式(4)中隐藏层的稀疏约束项可表示为

$$\xi \sum_{h=1}^{S_m} \text{KL}(\rho | \tilde{\rho}_w) = \xi \sum_{h=1}^{S_m} \rho \lg \frac{\rho}{\tilde{\rho}_w} + (1 - \rho) \lg \frac{1 - \rho}{1 - \tilde{\rho}_w} \quad (7)$$

其中,  $\xi > 0$ 是权重因子,  $h$ 是隐藏层中激活神经元个数指数,  $S_m$ 是第 $m$ 个隐藏层上神经元的数目,  $\rho$ 是稀疏系数,  $\tilde{\rho}_w$ 是隐藏层神经元 $w$ 的平均激活度。

根据式(6)和式(7), 式(4)可进一步表示为

$$J_{\text{SAED}}(\boldsymbol{\theta}) = -\frac{1}{G} \left[ \sum_{k=1}^G \sum_{b=1}^M 1(l^{(k)} = b) \lg \frac{e^{\boldsymbol{\theta}_b \mathcal{V}^{(k)}}}{\sum_{g=1}^M \exp(\boldsymbol{\theta}_g \mathcal{V}^{(k)})} \right] + \xi \sum_{h=1}^{S_m} \rho \lg \frac{\rho}{\tilde{\rho}_w} + (1 - \rho) \lg \frac{1 - \rho}{1 - \tilde{\rho}_w} + \zeta \sum_{c=1}^M \boldsymbol{\theta}_c^2 \quad (8)$$

其中,  $\zeta$ 是惩罚因子,  $c$ 是标签类别对应的参数。

通常, 式(8)没有闭合的解析解, 实际求解中使用拟牛顿法(Limited memory-Broyden Fletcher Goldforb Shanno, L-BFGS)或随机梯度下降(Stochastic Gradient Descent, SGD)等迭代算法获得 $\boldsymbol{\theta}$ 最优值。参数的迭代更新过程为

$$\boldsymbol{\theta}^{\text{new}} \leftarrow \boldsymbol{\theta}^{\text{old}} + \nabla_{\boldsymbol{\theta}} J_{\text{SAED}}(\boldsymbol{\theta} | (\mathbf{y}, \mathbf{l})) |_{\boldsymbol{\theta}=\boldsymbol{\theta}^{\text{old}}} \quad (9)$$

其中,  $\nabla_{\boldsymbol{\theta}} J_{\text{SAED}}(\cdot)$ 是每次迭代运算中的梯度值,  $(\mathbf{y}, \mathbf{l})$ 表示训练数据集,  $\boldsymbol{\theta}^{\text{old}}$ 表示更新前的参数,  $\boldsymbol{\theta}^{\text{new}}$ 表示更新后的参数。

### 3.2 基于误符号率度量的SAED结构选择方法

已知的基于DNN的信号检测相关文献中, 大多没有对DNN中每层神经元数目和层数的选择方法开展研究。然而, DNN检测器的结构影响网络的训练、部署、检测精度和计算复杂度。为了简化DNN检测器的结构, 同时保证检测的精度, 本文提出了基于SER度量的SAED节点数目和层数选择策略。设输入层节点数目为 $L$ ,  $N_i$ 表示第 $i$ 个隐藏层上的神经元数目,  $\Delta$ (该值通过实验确定)用以衡量理论SER值 $\kappa_t$ 与SAED计算的SER值 $\kappa_{\text{SAED}}$ 之间的误差。基于SER度量的SAED结构选择策略步骤如下:

步骤1 SAED的输入层节点数目设为 $L$ , 将第1个隐藏层的节点数目 $N_1$ 从 $1 \sim L$ 分别进行迭代训练, 并记录不同节点数目对应的SER值 $\kappa_{\text{SAED}}^{N_1}$ 。从 $\kappa_{\text{SAED}}^{N_1}$ 中选择SER较低, 且对应节点数目 $N_1$ 较少的节点作为第1个隐藏层的候选节点 $N_1^{\text{save}}$ (候选节点的数目通过门限值 $\beta$ 确定)。若 $\min(\kappa_{\text{SAED}}^{N_1}) - \kappa_t > \Delta$ 则需要增加另一个隐藏层;

步骤2 第1个隐藏层中的节点数目 $N_1$ 为步骤1



中候选节点数目，分别改变第2个隐藏层中的节点数目(例如， $N_1 = 5, 6, 7$ 时， $N_2$ 的候选节点数目范围分别为 $1 \leq N_2 \leq 4, 1 \leq N_2 \leq 5$ 和 $1 \leq N_2 \leq 6$ )，按照步骤1中的方法确定第2个隐藏层候选节点的数目 $N_2^{\text{save}}$ ；

步骤3 重复步骤2，直到满足 $\min(\kappa_{\text{SAED}}^{N_i}) - \kappa_t < \Delta$ ，此时得到第 $i$ 个隐藏层的候选节点数目为 $N_i^{\text{save}}$ ；

步骤4 选择SER最低且各隐藏层中节点数目最少的候选节点作为SAED的最优节点配置方案。

表1是基于SER度量的SAED结构选择策略伪代码。输入参数包括：训练数据集 $(\mathbf{y}, l)$ ，SAED的参数 $\rho, \xi, \zeta$ ，输入层节点数目 $L$ ，误差度量 $\Delta$ 和候选节点门限值 $\beta$ 。

### 3.3 基于累积量和矩特征向量的混合信号符号检测

累积量和矩是信号处理的重要工具，用以提取信号的有效特征<sup>[13]</sup>。本文提出一种基于累积量和矩的特征向量(Cumulants and Moments Features Vector, CMFV)方法进行信号的预处理，提取信号的特征以实现混合信号的符号检测。

对于复随机过程 $\{x(n)\}$ ，根据共轭位置不同，其 $u$ 阶矩可定义为<sup>[14]</sup>

$$M_x^{u,v}(\boldsymbol{\tau}) = E \{ \mathbf{x}_1^*, \mathbf{x}_2^*, \dots, m \mathbf{x}_{u-v}^* \mathbf{x}_{u-v+1}, \dots, \mathbf{x}_u \} \quad (10)$$

其中， $u, v$ 分别表示矩的阶数和共轭的次数， $*$ 表示共轭操作， $E\{\cdot\}$ 代表期望， $\mathbf{x}_1 = \mathbf{x}(n), \mathbf{x}_2 = \mathbf{x}(n + \tau_1), \dots, \mathbf{x}_u = \mathbf{x}(n + \tau_{u-1})$ ， $\boldsymbol{\tau} = (\tau_1, \tau_2, \dots, \tau_{u-1})$ 是延迟向量。 $u$ 阶累积量可根据矩-累积量公式定义为

表1 基于SER度量的SAED结构选择策略

输入：	$(\mathbf{y}, l), \rho, \xi, \zeta, L, \Delta, \beta$
输出：	每个隐藏层的候选节点数目 $N_i^{\text{save}}$
(1)	$i \leftarrow 1$
(2)	<b>for</b> $N_i = 1, 2, \dots, L$ <b>do</b>
(3)	根据式(3)—式(9)计算 $\kappa_{\text{SAED}}^{N_i}$
(4)	<b>end for</b>
(5)	<b>while</b> $\min(\kappa_{\text{SAED}}^{N_i}) - \kappa_t > \Delta$
(6)	<b>do</b> $N_i = \arg \min_{N_i \in \{1, 2, \dots, L\}} (\min(\kappa_{\text{SAED}}^{N_i}) + \beta)$
(7)	$N_i^{\text{save}} \leftarrow N_i$
(8)	$L = \max(N_i^{\text{save}})$
(9)	$i = i + 1$
(10)	<b>for</b> $N_i = 1, 2, \dots, L - 1$ <b>do</b>
(11)	根据式(3)—式(9)计算 $\kappa_{\text{SAED}}^{N_i}$
(12)	<b>end for</b>
(13)	<b>end while</b>

$$C_x^{u,v}(\boldsymbol{\tau}) = \sum_{\cup_{p=1}^q I_p = I} \left[ (-1)^{q-1} (q-1)! \prod_{p=1}^q M_x^{u,v}(I_p) \right] \quad (11)$$

其中， $\sum_{\cup_{p=1}^q I_p = I} (\cdot)$ 表示对符号集合 $(I_1, I_2, \dots, I_q)$ 求和，其中， $q = 1, 2, \dots, l$ 是随机过程 $\{x(n)\}$ 的整数符号集 $(1, 2, \dots, l)$ ，例如， $l = 2$ 则整数符号集 $(1, 2)$ 可以分成 $q = 1, I_1 = \{1, 2\}$ ， $q = 2, I_1 = \{1\}, I_2 = \{2\}$ 。

在实际信号处理中，通常需要根据采样的数据样本估计累积量和矩。由式(10)和式(11)可知，累积量和矩的估计可表示为

$$\tilde{C}_y^{u,v}(\boldsymbol{\tau}) = \sum_{\cup_{p=1}^q I_p = I} \left[ (-1)^{q-1} (q-1)! \prod_{p=1}^q \tilde{M}_y^{u I_p, v I_p}(\boldsymbol{\tau}) \right] \quad (12)$$

$$\tilde{M}_y^{u,v}(\boldsymbol{\tau}) = \frac{1}{Q} \sum_{n=0}^{Q-1} y^*(n) y^*(n + \tau_1) \cdots y^*(n + \tau_{u-v-1}) \cdot y(n + \tau_{u-v}) \cdots y(n + \tau_{u-1}) \quad (13)$$

其中， $\tilde{C}_y^{u,v}(\boldsymbol{\tau})$ 和 $\tilde{M}_y^{u,v}(\boldsymbol{\tau})$ 分别表示通过符号采样数据 $\{y(n)\} = \{y_1, y_2, \dots, y_u\}$ 估计得到的累积量和矩的数值，其中， $y_1 = y(n), y_2 = y(n + \tau_1), \dots, y_u = y(n + \tau_{u-1})$ ， $Q$ 表示总的采样点数目。根据式(12)和式(13)可计算得到各阶累积量和矩的估计值，如 $\tilde{M}_y^{4,2}$ 和 $\tilde{C}_y^{6,0}$ 可表示为

$$\tilde{M}_y^{4,2} = \frac{1}{Q} \sum_{n=0}^{Q-1} y_1^* y_2^* y_3 y_4 \quad (14)$$

$$\tilde{C}_y^{6,0} = \tilde{M}_y^{6,0} - 15 \tilde{M}_y^{2,0} \tilde{M}_y^{4,0} + 30 (\tilde{M}_y^{2,0})^3 \quad (15)$$

由式(12)和式(13)，定义本文采用的CMFV为

$$\mathbb{F} = \left[ \tilde{M}_y^{2,0}, \tilde{C}_y^{2,1}, \tilde{M}_y^{4,0}, \tilde{M}_y^{4,2}, \tilde{M}_y^{4,3}, \tilde{C}_y^{6,0}, \tilde{C}_y^{6,1}, \tilde{C}_y^{6,3} \right] \quad (16)$$

基于CMFV的混合信号符号检测模型框图如图1所示。

接收端首先对两种未知调制方式的信号分别进行采样得到混合采样数据 $\mathbf{y} = [\mathbf{y}^{(i)}, \mathbf{y}^{(j)}]^T$ ；其次，混合采样信号分别进行归一化和CMFV预处理，形成SAED的训练数据集；然后，根据式(3)—式(8)利用训练数据集训练SAED，并得到式(9)中SAED的最优参数。训练完成后，SAED可以同时实现对两种未知调制信号的符号检测。图1的符号检测器采用SAE架构，具有1个输入层、2个隐藏层和1个输出层，其中，隐藏层中神经元数目和隐藏层的数目通过基于SER度量的结构选择策略确定。

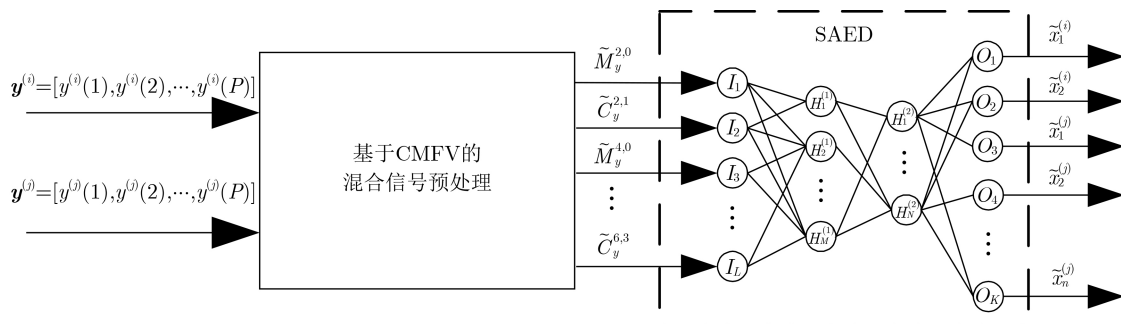


图1 基于CMFV的混合信号符号检测模型框图

#### 4 实验数值仿真和讨论

实验部分分别对SAED的结构选择策略和SAED在不同信道和非理想条件下的混合信号检测性能进行数值仿真。仿真参数设置如下：(1)SAED的结构选择策略仿真中，使用BPSK在AWGN信道下的采样数据分析不同结构对SAED检测性能的影响；(2)符号检测仿真中，在确定SNR下，训练数据集的大小为  $D \times N \times P$ ，其中， $D = L = 8$ 为输入层信号的维度(输入层节点数目与特征向量的数目相同)， $N = 2$ 为混合数据集中信号的种类， $P$ 是符号观察周期。混合信号调制方式包括FSK, PSK和QAM，信道包括AWGN和Rayleigh衰落。仿真中的频率偏移(Frequency Offsets, FO)和相位偏移(Phase Offsets, PO)参照文献[13]设置，其中，归一化最大频偏为  $1.4 \times 10^{-4}$ ，最大相位偏移为  $\pi/8$ 。SAED的符号检测性能与最大似然检测(Maximum Likelihood, ML)进行比较。表2是符号检测中SAED的结构和参数设置。其中，激活函数为Linear, ReLU, Softmax，优化算法为L-BFGS。

**实验1** 为了验证基于SER度量的SAED结构选择策略的有效性，使用BPSK在AWGN信道下的采样数据集作为SAED的输入信号，分析不同结构的SAED误符号率性能。根据表1的SAED结构选择算法，分别验证了隐藏层节点数目和隐藏层数目对SAED符号检测性能的影响。由图2可知，SAED的结构对符号检测性能具有较大的影响。当仅有1个隐藏层时，SAED符号检测性能明显低于BPSK-ML理论值。具体来说，当输入层节点数目为8个，隐藏层节点数目为4个时，SAED的检测性能不稳定，SER曲线的波动较大；当隐藏层节点数目为6个时，SAED在0~5 dB的检测性能与ML相比约有1 dB的损失。这是因为，SAED的隐藏层神经元数目较少时，其无法从输入数据中提取足够的信号特征进行符号的恢复。同时，当SAED具有两个隐藏层时，其符号检测性能接近ML检测理论值，即

表2 SAED结构和参数配置

结构/参数	节点个数/数值
输入层	8
隐藏层1	7
隐藏层2	3
Softmax层	4,10,12
稀疏系数( $\rho$ )	0.9
稀疏惩罚权重( $\xi$ )	3
权重衰减( $\zeta$ )	0.0001




图2 SAED结构对符号检测性能的影响

采用(8,7,3)结构时，SAED误符号率性能与ML理论值最大误差仅为0.3 dB。

**实验2** 图3是SAED在AWGN信道下BFSK和BPSK混合信号的SER性能曲线。原始采样数据经过归一化和CMFV预处理形成BFSK和BPSK混合信号训练数据集，数据集大小为  $8 \times 2 \times 20$  K。由图3可知，在理想条件下，CMFV-SAED-BFSK和CMFV-SAED-BPSK的SER性能几乎可达到ML的理论值。具体来说，CMFV-SAED-BFSK与ML-BFSK的最大性能差约0.2 dB；CMFV-SAED-BPSK与ML-BPSK的最大性能差仅为0.1 dB左右。此外，在频偏条件下，SAED具有较好的鲁棒性，当归一化频偏为  $1.4 \times 10^{-4}$ 时，SAED-BPSK-FO和ML-BPSK在-6~7 dB上的最大性能损失约为0.3 dB。

**实验3** 图4是AWGN信道下16QAM和BFSK

混合信号的SER性能曲线。BFSK和16QAM的符号观察周期均为20 K。由图4可知，SAED对BFSK和16QAM混合信号具有较好的检测性能，CMFV-SAED-BFSK和CMFV-SAED-16QAM的SER性能基本可以达到ML理论值。具体来说，CMFV-SAED-16QAM与ML-16QAM相比，在整个SNR范围内的最大的性能损失约为0.2 dB；CMFV-SAED-BFSK在-6~6 dB上与ML理论值的性能差小于0.1 dB。同时，当最大相位偏移为 $\pi/8$ 时，CMFV-SAED-16QAM-PO比ML-16QAM约有0.3 dB的性能损失。

**实验4** 图5是Rayleigh衰落信道下QPSK和16QAM混合信号的SER性能曲线。QPSK和16QAM混合信号经过CMFV预处理后作为SAED的输入，其中，QPSK的符号观察周期为20 K，16QAM的符号观察周期为30 K。由图5可知，CMFV-SAED-QPSK和CMFV-SAED-16QAM在Rayleigh信道中的SER性能曲线与ML-QPSK和ML-16QAM曲线分别有0.5 dB和1 dB左右性能差异，该性能损失可能是由时变信道和高阶调制引起的。此外，CMFV-SAED-16QAM使用 $8 \times 30$  K样本的SER性能，可以达到原始16QAM采样信号使用 $8 \times 40$  K样本的性能，从而说明，CMFV预处理可以从原始数据中提取更多的信号特征，从而降低SAED符号检测对本数目的需求。

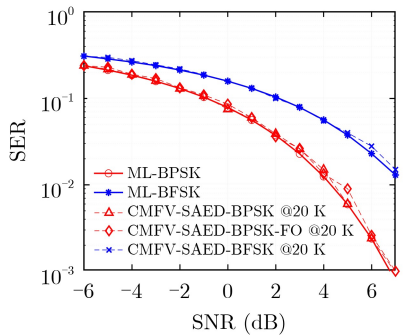


图3 AWGN信道下BFSK和BPSK混合信号的SER性能曲线

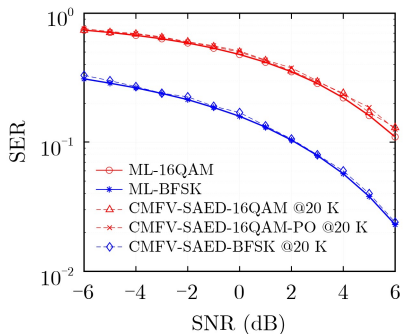


图4 AWGN信道下16QAM和BFSK混合信号的SER性能曲线

## 5 复杂度分析和讨论

为了对DNN符号检测器的复杂度进行分析，本部分将SAED与文献[15]的SD-DNN检测器和文献[16]的SD-DenseNet检测器进行复杂度的对比分析。DNN符号检测器的复杂度分析中，分别从节点数目和1次迭代过程中执行乘法运算的次数两方面进行对比。

表3中， $I$ 是算法的迭代次数， $P$ 表示观察窗口的长度， $N_i^{(in)}$ 和 $N_i^{(out)}$ 表示第 $i$ 个全连接层的输入和输出节点的数目， $\rho$ 是SAE隐藏层的激活参数， $\alpha_i = N_i^{(in)} N_i^{(out)}$ 。为了对比以上3种神经网络检测器的复杂度，下述分析中设 $I = 1, P = 10^3$ 。由文献[15]可知，SD-DNN使用了全连接的深度神经网络结构，包含3个隐藏层、1个输入层和1个输出层，其中 $N_1^{(in)} = 256, N_1^{(out)} = N_2^{(in)} = 500, N_2^{(out)} = N_3^{(in)} = 250, N_3^{(out)} = N_4^{(in)} = 120, N_4^{(out)} = N_5^{(in)} = 16$ 。SD-DNN共包含1142个神经元，执行1次迭代运算时，其需要计算约 $2.8 \times 10^8$ 次乘法运算。由文献[16]可知，SD-DenseNet采用全连接型神经网络结构，其复杂度与节点的数目有关，该符号检测器共包含3层， $N_1^{(in)} = N_3^{(out)} = 56, N_1^{(out)} = N_2^{(in)} = N_2^{(out)} = N_3^{(in)} = 256$ ，共569个节点，1次迭代运算时，其需要计算约 $8 \times 10^7$ 次乘法运算。本文设计的SD-SAED结构包括1个输入层、2个隐藏层和1个输出层。为了降低网络结构的复杂度，隐藏层中设置了稀疏系数，仅有部分神经元被激活。SD-SAED中， $\rho = 0.9, N_1^{(in)} = 8, N_1^{(out)} = N_2^{(in)} = 7, N_2^{(out)} = N_3^{(in)} = 3, N_3^{(out)} = 12$ ，共30个节点，其需要执行约




图5 Rayleigh衰落信道下QPSK和16QAM混合信号的SER性能曲线

表3 SAED复杂度对比分析

检测器类型	节点数目	乘法次数
SD-DNN [15]	1142	$IP \sum_{i=1}^5 N_i^{(in)} N_i^{(out)}$
SD-DenseNet [16]	569	$IP \sum_{i=1}^3 N_i^{(in)} N_i^{(out)}$
SD-SAED	30	$IP(\alpha_1 + \rho^2 \alpha_2 + \rho \alpha_3)$

$1.1 \times 10^5$ 次乘法运算。由以上分析可知,本文提出的SD-SAED的计算复杂度明显低于SD-DNN和SD-DenseNet。

## 6 结论

针对已知的DNN符号检测器结构复杂且无法实现混合信号的符号检测问题,本文首先提出了一种基于误符号率度量的SAED结构选择策略;然后,提出了基于累积量和矩特征向量的混合信号符号检测方法。本文设计的符号检测器不依赖信道模型和噪声假设,通过采样数据可重建发送符号。实验结果表明,SAED在AWGN和Rayleigh信道下符号检测性能接近ML理论值;在频率偏移、相位偏移和有限训练样本条件下具有较好的鲁棒性。此外,相比于已知的DNN符号检测器,本文设计的SAED具有较低的计算复杂度。

## 参考文献

- [1] PROAKIS J G. Digital Communications[M]. New York: McGraw-Hill, 2001: 112–180.
- [2] MENG Fan, CHEN Peng, WU Lenan, *et al.* Automatic modulation classification: A deep learning enabled approach[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(11): 10760–10772. doi: [10.1109/TVT.2018.2868698](https://doi.org/10.1109/TVT.2018.2868698).
- [3] 郭晨, 简涛, 徐从安, 等. 基于深度多尺度一维卷积神经网络的雷达舰船目标识别[J]. *电子与信息学报*, 2019, 41(6): 1302–1309. doi: [10.11999/JEIT180677](https://doi.org/10.11999/JEIT180677).  
GUO Chen, JIAN Tao, XU Congan, *et al.* Radar HRRP target recognition based on deep multi-scale 1D convolutional neural network[J]. *Journal of Electronics & Information Technology*, 2019, 41(6): 1302–1309. doi: [10.11999/JEIT180677](https://doi.org/10.11999/JEIT180677).
- [4] 唐伦, 周钰, 谭颀, 等. 基于强化学习的5G网络切片虚拟网络功能迁移算法[J]. *电子与信息学报*, 2020, 42(3): 669–677. doi: [10.11999/JEIT190290](https://doi.org/10.11999/JEIT190290).  
TANG Lun, ZHOU Yu, TAN Qi, *et al.* Virtual network function migration algorithm based on reinforcement learning for 5G network slicing[J]. *Journal of Electronics & Information Technology*, 2020, 42(3): 669–677. doi: [10.11999/JEIT190290](https://doi.org/10.11999/JEIT190290).
- [5] FARSAFAD N and GOLDSMITH A. Neural network detection of data sequences in communication systems[J]. *IEEE Transactions on Signal Processing*, 2018, 66(21): 5663–5678. doi: [10.1109/TSP.2018.2868322](https://doi.org/10.1109/TSP.2018.2868322).
- [6] LIU Chang, WANG Jie, LIU Xuemeng, *et al.* Deep CM-CNN for spectrum sensing in cognitive radio[J]. *IEEE Journal on Selected Areas in Communications*, 2019, 37(10): 2306–2321. doi: [10.1109/JSAC.2019.2933892](https://doi.org/10.1109/JSAC.2019.2933892).
- [7] O'SHEA T and HOYDIS J. An introduction to deep learning for the physical layer[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2017, 3(4): 563–575. doi: [10.1109/TCCN.2017.2758370](https://doi.org/10.1109/TCCN.2017.2758370).
- [8] ZHANG Min, LIU Zongyan, LI Li, *et al.* Enhanced efficiency BPSK demodulator based on one-dimensional convolutional neural network[J]. *IEEE Access*, 2018, 6: 26939–26948. doi: [10.1109/ACCESS.2018.2834144](https://doi.org/10.1109/ACCESS.2018.2834144).
- [9] SAMUEL N, DISKIN T, and WIESEL A. Learning to detect[J]. *IEEE Transactions on Signal Processing*, 2019, 67(10): 2554–2564. doi: [10.1109/TSP.2019.2899805](https://doi.org/10.1109/TSP.2019.2899805).
- [10] GAO Xuanxuan, JIN Shi, WEN Chaokai, *et al.* ComNet: Combination of deep learning and expert knowledge in OFDM receivers[J]. *IEEE Communications Letters*, 2018, 22(12): 2627–2630. doi: [10.1109/LCOMM.2018.2877965](https://doi.org/10.1109/LCOMM.2018.2877965).
- [11] GOODFELLOW I, BENGIO Y, and COURVILLE A. Deep Learning[M]. Cambridge: MIT Press, 2016: 306–319.
- [12] BISHOP C M. Pattern Recognition and Machine Learning[M]. New York: Springer, 2006: 48–58.
- [13] SWAMI A and SADLER B M. Hierarchical digital modulation classification using cumulants[J]. *IEEE Transactions on Communications*, 2000, 48(3): 416–429. doi: [10.1109/26.837045](https://doi.org/10.1109/26.837045).
- [14] NIKIAS C L and MENDEL J M. Signal processing with higher-order spectra[J]. *IEEE Signal Processing Magazine*, 1993, 10(3): 10–37. doi: [10.1109/79.221324](https://doi.org/10.1109/79.221324).
- [15] YE Hao, LI G Y, and JUANG B H. Power of deep learning for channel estimation and signal detection in OFDM systems[J]. *IEEE Wireless Communications Letters*, 2018, 7(1): 114–117. doi: [10.1109/LWC.2017.2757490](https://doi.org/10.1109/LWC.2017.2757490).
- [16] DÖRNER S, CAMMERER S, HOYDIS J, *et al.* Deep learning based communication over the air[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(1): 132–143. doi: [10.1109/JSTSP.2017.2784180](https://doi.org/10.1109/JSTSP.2017.2784180).

郝崇正: 男, 博士生, 研究方向为智能信号处理、调制识别和MIMO.

党小宇: 男, 博士, 教授, 研究方向为编码调制、深空通信、深度学习信号处理等.

李 赛: 男, 博士生, 研究方向为NOMA、无人机通信、信道测量等.

王成华: 男, 硕士, 教授, 研究方向为通信和信号处理系统设计、硬件安全与技术等.

责任编辑: 余 蓉