

## 基于判别式受限玻尔兹曼机的数字调制识别

李正权<sup>1,2</sup>, 林媛<sup>1</sup>, 李梦雅<sup>1</sup>, 刘洋<sup>1</sup>, 吴琼<sup>1</sup>, 邢松<sup>3</sup>

(1. 江南大学轻工过程先进控制教育部重点实验室, 江苏 无锡 214122;

2. 北京邮电大学网络与交换技术国家重点实验室, 北京 100876;

3. 加利福尼亚州立大学信息系统系, 洛杉矶 CA90032)

**摘要:** 为了提高大动态信噪比下数字调制识别性能, 提出一种基于高阶累积量和判别式受限玻尔兹曼机的联合调制识别方法。该方法提取数字信号的高阶累积量作为信号特征, 综合利用判别式受限玻尔兹曼机的生成能力和分类能力, 分析了含有高斯噪声、时变相位偏移或瑞利衰落环境下的数字信号识别率。实验结果表明, 与传统识别方法相比, 所提方法的识别性能有明显改善。此外, 利用该模型的生成能力对输入特征进行重构, 可有效提高低信噪比下的信号识别率。

**关键词:** 调制识别; 受限玻尔兹曼机; 高阶累积量; 数据重构

**中图分类号:** TN911.7

**文献标识码:** A

**DOI:** 10.11959/j.issn.1000-436x.2021012

## Digital modulation recognition based on discriminative restricted Boltzmann machine

LI Zhengquan<sup>1,2</sup>, LIN Yuan<sup>1</sup>, LI Mengya<sup>1</sup>, LIU Yang<sup>1</sup>, WU Qiong<sup>1</sup>, XING Song<sup>3</sup>

1. Ministerial Key Laboratory of Advanced Control for Light Industry Processes, Jiangnan University, Wuxi 214122, China

2. State Key Laboratory of Networking and Switching Technology, Beijing University of Posts and Telecommunications, Beijing 100876, China

3. Department of Information Systems, California State University, Los Angeles CA90032, USA

**Abstract:** In order to improve the performance of digital modulation recognition under high dynamic signal-to-noise ratio, a joint modulation recognition method based on high-order cumulant and discriminative restricted Boltzmann machine was proposed, which extracted the high-order cumulant of digital signals as signal features, comprehensively utilized the generation ability and classification ability of the discriminative restricted Boltzmann machine, analyzed the recognition rate of digital signals in environments containing Gaussian noise, time-varying phase offset or Rayleigh fading. Experimental results show that compared with traditional classification methods, the recognition performance of the proposed method is obviously improved. In addition, the use of the model's generation ability to reconstruct the input features can effectively improve the signal recognition rate under low signal-to-noise ratio.

**Keywords:** modulation recognition, restricted Boltzmann machine, high-order cumulant, data reconstruction

收稿日期: 2020-08-19; 修回日期: 2020-11-08

基金项目: 国家自然科学基金资助项目 (No.61571108, No.61801193); 无锡市科技发展资金资助项目 (No.H20191001, No.G20192010); 江苏省研究生科研与实践创新计划基金资助项目 (No.SJ CX20\_0781); 网络与交换技术国家重点实验室 (北京邮电大学) 开放课题资助项目 (No.SKLNST-2020-1-13); 111 引智计划基金资助项目 (No.B12018)

**Foundation Items:** The National Natural Science Foundation of China (No.61571108, No.61801193), The Wuxi Science and Technology Development Fund (No.H20191001, No.G20192010), Postgraduate Research & Practice Innovation Program of Jiangsu Province (No.SJ CX20\_0781), Open Foundation of State Key Laboratory of Networking and Switching Technology (Beijing University of Posts and Telecommunications) (No.SKLNST-2020-1-13), The 111 Project (No.B12018)

## 1 引言

现今,电磁环境日益复杂,不同频段的信号调制类型日益增多,有效识别调制类型可为频谱感知提供更多的用户信息,从而提高频谱和空间资源利用率,因此数字调制识别在认知无线电领域具有较高的应用价值。在认知无线电领域的实际应用中,信号接收机工作环境中的信噪比通常难以保持稳定,而是呈现一种实时大范围快速变化的特点,因此如何在大动态信噪比下保持良好的识别性能具有重要的研究意义<sup>[1]</sup>。

目前,基于信号特征的调制识别已有诸多研究成果,其中高阶累积量具有表征含噪基带信号的星座点分布、抑制高斯噪声的特性,同时在接收信号存在载波相偏和频偏时仍具有较强的稳健性<sup>[2]</sup>,因此被广泛应用于调制识别领域。文献[2]基于四阶累积量设计决策阈值,在多进制数字相位调制(MPSK, multiple phase shift keying)、多进制正交振幅调制(MQAM, multiple quadrature amplitude modulation)和多进制脉冲振幅调制(MPAM, multiple pulse amplitude modulation)等调制方式下,分析了含有频偏、星座旋转等条件下数字信号的识别性能,证明了高阶累积量在分层结构中的有效性。基于分层结构来实现调制识别的方法多采用二、四、六、八阶累积量,根据待识别信号的星座点分布特点设计识别特征,以提高调制类型的辨识度<sup>[3-5]</sup>。对于累积量特征相近的调幅、调相方式,如MQAM的类内识别,文献[5]提出一种降低待识别信号调制阶数的新方法,来提取信号的六阶累积量协助识别。文献[6-7]将高阶累积量与其他特征(如循环谱、瞬时幅度等)联合构成特征模块,实现不同阶数同类调制方式的识别。以上文献分析的场景多为理想的加性白高斯噪声(AWGN, additive white Gaussian noise)信道。针对其他信道情况,文献[8]提出一种用于分布式网络的协作分类方法,协作节点和融合中心共享高阶累积量特征,以提高弱信号或Rayleigh信道中信号的调制识别性能。文献[9]通过分析数字信号的分数低阶循环谱相关系数,实现了非高斯Alpha稳定分布噪声环境下的调制识别。文献[2-9]对多种调制类型进行了深入研究,根据经验选取或设计有效特征,实现调制识别。但此类基于理论分析的决策方法过于依赖研究人员的专业设计,限制较多且易受环境影响。

近年来,机器学习的发展给调制识别带来了智能决策的可能性。文献[10-16]均为基于高阶累积量和机器学习的联合调制识别,分别采用深度神经网络<sup>[10-11]</sup>、支持向量机(SVM, support vector machine)<sup>[12-14]</sup>、自编码器<sup>[14-16]</sup>等作为分类器,实现了AWGN信道中多种数字调制类型的识别。文献[14]结合高阶累积量和SVM分析了多输入多输出(MIMO, multiple-input multiple-output)衰落信道环境中的信号识别性能,表明基于径向基核函数的SVM在调制识别任务中具有一定优势。文献[16]同时分析了AWGN和Rayleigh信道下MPSK、MQAM信号的调制识别率,证明了高阶累积量特征在不同环境下的稳定性。但文献[10-16]是在固定的信噪比下训练分类器,即针对信噪比不同的数据需训练多个模型,影响了算法的识别性能和使用范围,识别性能的分析缺乏实用价值。本文在大动态信噪比-10~18 dB下训练分类器,即训练数据的信噪比在-10~18 dB动态变化,更贴近接收机工作场景。

随着深度学习技术的快速发展,越来越多的学者将更加复杂的网络模型应用到调制识别领域,致力于探索更适于该领域的网络体系。文献[17]采用卷积神经网络(CNN, convolutional neural network)实现端到端的调制识别。文献[18]基于星座图特征和深度学习模型AlexNet和GoogLeNet实现信号调制识别。以上方法虽然有效,但训练成本过高。文献[19]提出相对较小的网络规模,更具有解决调制识别问题的潜力。研究人员发现,深度学习模型在认知无线电领域的表现与图像、语言处理等领域略有不同,其不受网络深度的限制,通过较浅网络即可表现输入数据的特征<sup>[20-21]</sup>。对于复杂的网络模型,其训练成本和对数据集的要求都很高,但在工程实践中数据采集的难度过大,因此,未来调制识别任务的进一步发展更可能来自改进的训练方法和网络结构<sup>[21]</sup>。受限玻尔兹曼机(RBM, restricted Boltzmann machine)作为一种无监督学习模型,通常用于特征提取或预训练其他网络模型。文献[22]将RBM应用到协同过滤中,利用用户是否看过电影作为辅助信息,提出条件RBM,采用对比散度(CD, contrastive divergence)算法从隐含层重构可见层,以预测用户对未知电影的评级。由此可见RBM具有强大的生成能力,但RBM不可以直接作为独立分类器实现决策功能。文献[23]对RBM进行改

进，将调制类型标签作为辅助信息，在 RBM 的基础上对隐层进行分组，每组单元只学习一种信号，最终结合高阶矩和改进的 RBM 实现了 MPSK、MQAM 信号的调制识别，证明改进的 RBM 在调制识别领域具有可行性，但所提模型的训练复杂度过高。文献[24]提出一种基于 RBM 改进的独立分类器——判别式受限玻尔兹曼机 (DRBM, discriminative restricted Boltzmann machine)，该分类器具生成和分类能力，且对含噪数据有一定的稳健性，对大动态信噪比环境有应用潜力。

由于 DRBM 具有生成和分类能力，同时高阶累积量具有可抑制噪声的特性，本文提出一种联合高阶累积量-DRBM 的调制识别方法，该方法可有效识别信噪比动态变化时 AWGN 信道、时变相移 (TPO, time-varying phase offset) 信道以及 Rayleigh 信道环境中二进制相移键控 (BPSK, binary phase shift keying)、正交相移键控 (QPSK, quadrature phase shift keying)、8 相移键控 (8PSK, 8 phase shift keying)、8 正交振幅调制 (QAM, quadrature amplitude modulation)、16QAM、4 脉冲振幅调制 (PAM, pulse amplitude modulation)、连续相位频移键控 (CPFSK, continuous-phase frequency shift keying)、高斯最小频移键控 (GMSK, Gaussian filtered minimum shift keying) 8 种数字调制类型。针对低信噪比下信号识别率过低的问题，本文利用 DRBM 的生成能力来重构样本特征，以提高信号识别性能。

## 2 数字信号数据集

### 2.1 基带符号序列

接收信号经下变频、脉冲成型匹配滤波等预处理得到一个由复包络样本组成的基带序列  $y(n)$ <sup>[2,17]</sup>

$$y(n) = s(n; u_k) + g(n) \quad (1)$$

其中， $s(n; u_k)$  为不含噪的第  $k$  类调制数字信号， $u_k$  为该类已调信号所含参数集合，如频偏、相位抖动、定时偏移以及信道响应等； $g(n)$  为服从  $N \sim (0, \sigma^2)$  分布的加性白高斯噪声。为了便于后续理论分析，假设载频信息已知并已实现定时同步、波形恢复等<sup>[2]</sup>，本文采用的基带符号序列为<sup>[17]</sup>

$$y(n) = \sqrt{P} e^{j\theta} s(n) h(n) + g(n) \quad (2)$$

其中， $s(n)$  为传输符号， $\theta$  为相频偏移， $h(n)$  为信道响应函数。

### 2.2 高阶累积量

对于零均值复平稳随机过程  $y(t)$ ，其二阶累积量定义为

$$\begin{aligned} C_{20} &= \text{cum}(y, y) = E\{y^2(t)\} \\ C_{21} &= \text{cum}(y, y^*) = E\{|y(t)|^2\} \end{aligned} \quad (3)$$

其中，cum 表示高阶累积量，上标\*表示共轭，E 表示数学期望，|| 表示绝对值。进一步根据矩-累积量 (M-C) 转换公式求四、六、八阶累积量。本文将 BPSK、QPSK、8PSK、8QAM、16QAM、4PAM、CPFSK、GMSK 这 8 种调制方式作为待识别调制类型。假设目标调制类型下符号等概率传输<sup>[2]</sup>，经能量归一化，以上 8 种数字调制方式的高阶累积量理论值 (不含噪) 如表 1 所示。

对于所有调制方式，本文直接取高阶累积量的绝对值，以抑制相频偏移的影响。运用以上理论估算基带符号序列  $y(n)$  的累积量，首先需对  $y(n)$  去均值得到  $\tilde{y}(n)$

$$\tilde{y}(n) = y(n) - \frac{1}{N} \sum_{n=1}^N y(n) \quad (4)$$

再估计以上各阶累积量对应的混合矩的值。 $p$  阶混合矩的估计值  $\hat{M}_{pq}$  为

表 1 8 种数字调制方式的高阶累积量理论值 (不含噪)

调制方式	C20	C21	C40	C41	C42	C60	C61	C62	C63	C80
BPSK	1	1	2	2	2	16	16	16	16	272
QPSK	0	1	1	0	1	0	4	0	4	3
8PSK	0	1	0	0	1	0	0	0	4	1
8QAM	0.666 7	1	1	0.888 9	1	4.740 7	4.888 9	4.740 7	4.888 9	54.148 1
16QAM	0	1	0.68	0	0.68	0	2.08	0	2.08	13.980 8
4PAM	1	1	1.36	1.36	1.36	8.32	8.32	8.32	8.32	111.846 4
CPFSK	0.000 8	1	0.013 3	0.001 7	0.990 8	0.000 2	0.067 9	0.009 2	3.958 1	0.002 7
GMSK	0.004 0	1	0.317 1	0.007 2	0.963 4	0.017 5	1.186 9	0.038 6	3.845 4	3.157 7

$$\hat{M}_{pq} = \frac{1}{N} \sum_{n=1}^N \hat{y}(n)^{p-q} \hat{y}^*(n)^q, p > q \quad (5)$$

其中,  $q$  为共轭复数的阶数,  $N$  为信号序列长度。累积量的计算复杂度与  $N$  成正比<sup>[2]</sup>。在实际应用中, 对于含噪调制信号, 在星座能量归一化之前需先去除噪声能量干扰。

本文拟分析 AWGN 信道、TPO 信道和 Rayleigh 信道中基于高阶累积量-DRBM 的调制识别。图 1 分别为 16QAM 在不同信道环境中的星座图。其中, 图 1(a)、图 1(b)分别为 16QAM 在 AWGN 信道中加性信噪比为 18 dB 和 5 dB 时的星座图, 可见加性信噪比越低, 星团越分散, 识别难度越大。图 1(c)为 16QAM 在 TPO 信道中的星座图, 每个传输符号的相位偏移在  $[0, \pi/2]$  随机取值, 加性信噪比为 18 dB。

图 1(d)为 16QAM 在 Rayleigh 信道中的星座图, 路径时延为  $1.5 \times 10^{-4}$  s, 平均路径增益为 3 dB, 最大多普勒频移为 0.01 Hz, 加性信噪比为 18 dB。由图 1 可知, 星座分布均受损严重, 无法轻易识别调制类型。

### 3 调制识别算法

#### 3.1 传统的调制识别算法

##### 1) 基于 DT 的调制识别

根据文献[2]提出的决策理论来设计分类特征和分类阈值, 构成基于高阶累积量的分层结构来识别信号类型。由表 1 可知, QPSK、8PSK、16QAM 的  $|C_{20}|$ 、 $|C_{41}|$ 、 $|C_{60}|$  和  $|C_{62}|$  均为 0; QPSK 和 16QAM 的  $|C_{61}|=|C_{63}|$ ; CPFSK 和 GMSK 的  $|C_{80}|$  差距明显; BPSK、4PAM、8QAM 的  $|C_{40}|=|C_{42}|$ 、 $|C_{61}|=|C_{63}|$ 、

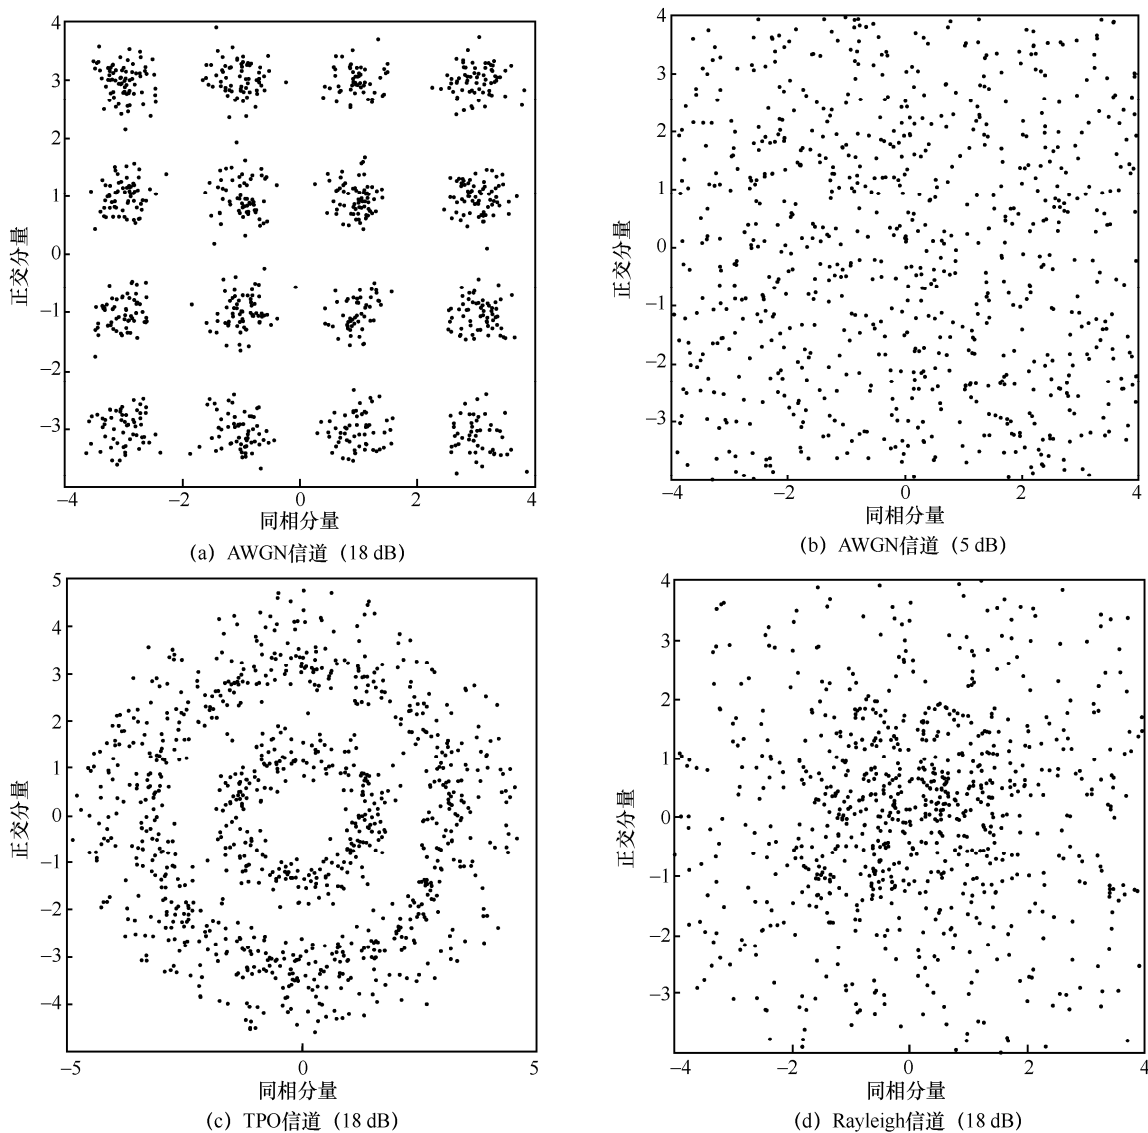


图 1 不同信道环境下 16QAM 的星座图

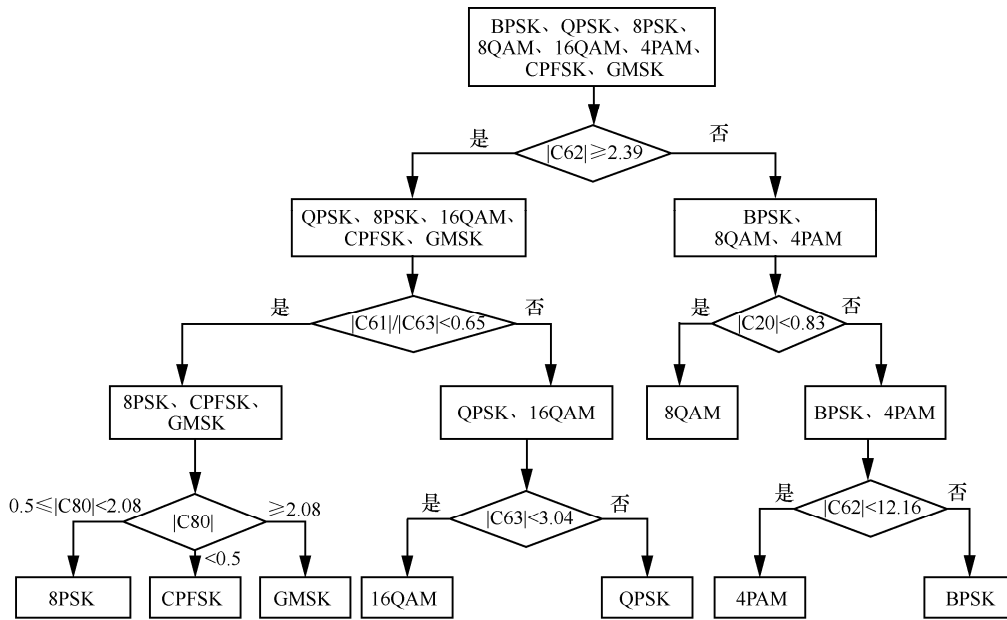


图 2 基于 DT 的调制识别流程

$|C60|=|C62|$ 。根据各种调制类型的各阶累积量表现的特性，选取  $|C62|$ 、 $|C61|/|C63|$ 、 $|C80|$ 、 $|C63|$ 和 $|C20|$ 这 5 种特征来识别信号。对于信号  $y$ ，识别其调制类型的具体步骤如下。

①根据 $|C62|$ 的值可将 8 种调制类型分为两大类。当 $|C62| \geq 2.39$ 时，将  $y$  划分为  $\{BPSK、8QAM、4PAM\}$ ，反之划分为  $\{QPSK、8PSK、16QAM、CPFSK、GMSK\}$ 。

②根据 $|C61|/|C63|$ 的值可将 5 种调制类型分为两大类。当 $|C61|/|C63| < 0.65$ 时，将  $y$  划分为  $\{8PSK、CPFSK、GMSK\}$ ，反之划分为  $\{QPSK、16QAM\}$ 。

③根据 $|C63|$ 的值可以区分 16QAM 和 QPSK。当 $|C63| < 3.04$ 时， $y$  为 16QAM，反之为 QPSK。

④根据 $|C80|$ 的值可以区分 8PSK、CPFSK、GMSK 这 3 种类型。当 $|C80| < 0.5$ 时， $y$  为 CPFSK；当 $|C80| \geq 2.08$ 时， $y$  为 GMSK；否则为 8PSK。

⑤根据 $|C20|$ 的值可将 8QAM、BPSK、4PAM 分为两大类。当 $|C20| < 0.83$ 时， $y$  为 8QAM，反之为  $\{BPSK、4PAM\}$ 。

⑥根据 $|C62|$ 的值可以区分 4PAM 和 BPSK。当 $|C62| < 12.16$ 时， $y$  为 4PAM，反之为 BPSK。

因此，基于 DT 的调制识别流程如图 2 所示。

### 2) 基于高阶累积量-SVM 的调制识别

SVM 作为一种高效的监督学习模型，具有很强的泛化能力，结合高阶累积量抑制噪声的特性，可有效实现调制识别。采用文献[14]提出的一对一最

小二乘 SVM 模型，选用径向基核函数，将高阶累积量构成的特征向量  $[|C20|, |C40|, |C41|, |C42|, |C60|, |C61|, |C62|, |C63|]^T$  经标准化预处理后，作为 SVM 的输入，训练该多分类模型，实现对 8 种调制方式的识别。

### 3.2 基于高阶累积量-DRBM 的调制识别算法

DRBM 在 RBM 的结构基础上将可见层分为输入层  $\mathbf{x}=(x_1, \dots, x_i, \dots, x_j)$  和输出标签层  $y \in \{1, 2, \dots, C\}$  两部分， $i$  表示第  $i$  个输入层单元， $C$  表示调制类型。其模型结构如图 3 所示，输入层  $\mathbf{x}$ 、标签层  $y$  分别和隐含层  $\mathbf{h}=(h_1, \dots, h_j, \dots, h_l)$  对称连接， $j$  表示第  $j$  个隐含层单元。但是层内以及层间无连接，即输入层  $\mathbf{x}$ 、标签层  $y$  和隐含层  $\mathbf{h}$  在给定状态的条件是独立的<sup>[24]</sup>。




图 3 DRBM 的模型结构

基于此模型定义能量函数  $E(y, \mathbf{x}, \mathbf{h})$  为  $E(y, \mathbf{x}, \mathbf{h}) = -\mathbf{h}^T \mathbf{W} \mathbf{x} - \mathbf{b}^T \mathbf{x} - \mathbf{c}^T \mathbf{h} - \mathbf{d}^T \mathbf{e}_y - \mathbf{h}^T \mathbf{U} \mathbf{e}_y$  (6)

其中,  $\mathbf{W}=(W_{11}, \dots, W_{ji}, \dots, W_{JJ})$  为输入层  $\mathbf{x}$  与隐含层  $\mathbf{h}$  之间的权重,  $\mathbf{U}=(U_{11}, \dots, U_{jy}, \dots, U_{JC})$  为标签层  $y$  与隐含层  $\mathbf{h}$  之间的权重,  $\mathbf{b}=(b_1, \dots, b_i, \dots, b_I)$ 、 $\mathbf{c}=(c_1, \dots, c_j, \dots, c_J)$ 、 $\mathbf{d}=(d_1, \dots, d_y, \dots, d_C)$  分别为  $\mathbf{x}$ 、 $\mathbf{h}$ 、 $y$  的偏置。各部分联合概率分布  $P(y, \mathbf{x}, \mathbf{h})$  为

$$P(y, \mathbf{x}, \mathbf{h}) = \frac{\exp(-E(y, \mathbf{x}, \mathbf{h}))}{\sum_{y, \mathbf{x}, \mathbf{h}} \exp(-E(y, \mathbf{x}, \mathbf{h}))} \quad (7)$$

利用二值随机隐含层单元  $\mathbf{h}$ , 对输入的信号特征向量  $\mathbf{x}$  和其对应的输出标签  $y$  的联合概率分布  $P(y, \mathbf{x})$  建模, 有

$$P(y, \mathbf{x}) = \sum_{\mathbf{h}} P(y, \mathbf{x}, \mathbf{h}) = \sum_{\mathbf{h}} \frac{e^{-E(y, \mathbf{x}, \mathbf{h})}}{\sum_{y, \mathbf{x}, \mathbf{h}} e^{-E(y, \mathbf{x}, \mathbf{h})}} = \frac{e^{-\sum_i b_i x_i + \sum_y e_y + \sum_j \log(1 + \exp(c_j + \sum_i W_{ji} x_i + U_{jy} e_y))}}{\sum_{y, \mathbf{x}} e^{-\sum_i b_i x_i + \sum_y e_y + \sum_j \log(1 + \exp(c_j + \sum_i W_{ji} x_i + U_{jy} e_y))}} = \frac{e^{-F(y, \mathbf{x})}}{\sum_{y, \mathbf{x}} e^{-F(y, \mathbf{x})}} \quad (8)$$

其中,  $F(\mathbf{x}, y)$  为自由能函数。此监督学习模型最终通过已知输入求输出的条件概率函数  $P(y|\mathbf{x})$  实现调制类型决策。

$$P(y|\mathbf{x}) = \frac{\sum_{\mathbf{h}} P(y, \mathbf{h}, \mathbf{x})}{\sum_{\mathbf{h}, y^*} P(y^*, \mathbf{h}, \mathbf{x})} = \frac{e^{-d_y + \sum_j \log(1 + e^{o_{yj}(\mathbf{x})})}}{\sum_{y^* \in \{1, \dots, C\}} e^{-d_{y^*} + \sum_j \log(1 + e^{o_{y^*j}(\mathbf{x})})}} \quad (9)$$

其中,  $o_{yj}(\mathbf{x}) = c_j + \sum_i W_{ji} x_i + U_{jy}$ 。取概率值最大的索引为目标调制类型。

本文选用的输入特征向量  $\mathbf{x}$  为  $[[C20], [C40], [C41], [C42], [C60], [C61], [C62], [C63]]^T$ 。由于 DRBM 为基于伯努利受限玻尔兹曼机的改进模型, 对于实值向量  $\mathbf{x}$  需进行最大最小值归一化, 将输入取值缩放到  $[0, 1]$ <sup>[25]</sup>。对 8 种调制方式设计标签并进行编码, 如表 2 所示。

表 2 调制方式标签及编码

调制方式	$y$	$e_y$
BPSK	1	00000001
QPSK	2	00000010
8PSK	3	00000100
8QAM	4	00001000
16QAM	5	00010000
4PAM	6	00100000
CPFSK	7	01000000
GMSK	8	10000000

RBM 作为一种无监督、重构原始数据的生成模型, 可将输入转化为输出, 再从输出反向重构输入, 其在输入特征下有特定的概率分布, 对输入构建概率函数  $P(\mathbf{x})$ , 可用于训练此无监督网络。DRBM 在 RBM 的基础上进行改进, 将可见层分为输入  $\mathbf{x}$  和输出标签  $y$  两部分, 实现监督式学习, DRBM 可对  $\mathbf{x}$ 、 $y$  的联合分布概率建模, 因此生成目标函数  $P(y, \mathbf{x})$  是一个可选择的训练目标, 即

$$L_{\text{gen}}(S_{\text{train}}) = - \sum_{t=1}^{|S_{\text{train}}|} \log P(y_t, \mathbf{x}_t) \quad (10)$$

其中,  $S_{\text{train}} = \{(\mathbf{x}_t, y_t)\}_{t=1}^{|S_{\text{train}}|}$  为信号特征集,  $\mathbf{x}_t$  和  $y_t$  分别为输入样本和对应的输出标签, 下标  $t$  为数据集中第  $t$  个样本。采用随机梯度下降算法训练模型, 求取网络参数  $\theta \in \{\mathbf{b}, \mathbf{d}, \mathbf{c}, \mathbf{W}, \mathbf{U}\}$  的偏导为

$$\nabla \theta = \frac{\partial \log P(y_t, \mathbf{x}_t)}{\partial \theta} = - \frac{\partial F(y_t, \mathbf{x}_t)}{\partial \theta} + \sum_{y, \mathbf{x}} P(y, \mathbf{x}) \frac{\partial F(y, \mathbf{x})}{\partial \theta} \quad (11)$$

其中,  $\nabla$  表示梯度更新, 即参数偏导。式(11)中  $\sum_{y, \mathbf{x}} P(y, \mathbf{x})$  的计算复杂度很高, 采用 CD- $k$  算法 ( $k$  表示吉布斯采样次数) 降低梯度的计算难度, 即用  $k$  步吉布斯采样生成的样本点估计值作为期望的近似值

$$\nabla \theta \approx - \frac{\partial F(y_t, \mathbf{x}_t)}{\partial \theta} + \frac{\partial F(y^{(k)}, \mathbf{x}^{(k)})}{\partial \theta} \quad (12)$$

已有的实验结果表明通常取  $k=1$ , 即进行一步吉布斯采样就能对输入数据达到较好的拟合效果<sup>[22, 24]</sup>。最后, 批量更新网络参数  $\theta = \theta - \eta \frac{1}{M} \sum_M \nabla \theta$ , 其中  $\eta$  为学习率,  $M$  为每批数据量大小。由全概率公式可知  $\log P(\mathbf{x}, y) = \log P(y|\mathbf{x}) + \log P(\mathbf{x})$ , 即生成目标函数同时对输入  $\mathbf{x}$  的边缘概率  $P(\mathbf{x})$  和条件概率  $P(y|\mathbf{x})$  进行建模<sup>[24]</sup>, 在使用随机梯度下降算法基于生成目标函数训练 DRBM 网络时, 网络参数更新的过程会同时对输入的概率分布和判别式条件概率进行拟合, 即训练使 DRBM 学习到输入数据的统计规律并预测其标签, 因此 DRBM 同时具有生成能力和分类能力<sup>[25]</sup>。本文主要利用基于生成目标函数的 DRBM (简称为 DRBM\_gen) 重构数据, 以提高低信噪比下信号的识别性能, 重构过程如算法 1 所示。

**算法 1** 基于 DRBM\_gen 的数据重构算法

**输入** 特征向量  $\mathbf{x}^{(0)}=[|C20|, |C40|, |C41|, |C42|, |C60|, |C61|, |C62|, |C63|]^T$ , 标签  $y^{(0)}$ , 学习率  $\eta$

**输出** 更新的网络参数  $\theta$ , 重构数据  $\mathbf{x}_{\text{rec}}$

1) 采样  $\mathbf{h}^{(0)} \sim \text{sigmoid}(\mathbf{c} + \mathbf{W}\mathbf{x}^{(0)} + \mathbf{U}_{y^{(0)}})$

2) 采样  $\mathbf{x}^{(1)} \sim \text{sigmoid}(\mathbf{b} + \mathbf{W}^T \mathbf{h}^{(0)})$

3) 采样  $y^{(1)} \sim \frac{\exp(\mathbf{d}_{y^{(0)}} + \mathbf{U}_{y^{(0)}}^T)}{\sum_y \exp(\mathbf{d}_y + \mathbf{U}_y^T)}$

4) 计算  $\mathbf{h}^{(1)} \sim \text{sigmoid}(\mathbf{c} + \mathbf{W}\mathbf{x}^{(1)} + \mathbf{U}_{y^{(1)}})$

5) 根据式(12)更新网络参数  $\theta$

**重构数据** 基于完成训练的模型, 计算  $\mathbf{h}_{\text{rec}}$ ,

最后获得  $\mathbf{x}_{\text{rec}}$

算法 1 中, 上标(0)表示原数据, 上标(1)表示经过一步吉布斯采样后所得数据。在后续的仿真实验中, 设训练 DRBM\_gen 时的学习率为 0.01, 批量数为 100, 迭代次数为 200, 均采用一步吉布斯采样。

由文献[24]可知, 生成目标函数消耗一部分能力用于边缘概率  $P(\mathbf{x})$  的建模, 从而导致分类效率不够理想。因此本文选择判别式目标函数(简称为 DRBM\_disc)训练分类器网络, 实现最终的调制识别

$$L_{\text{disc}}(S_{\text{train}}) = - \sum_{t=1}^{|S_{\text{train}}|} \log P(y_t | \mathbf{x}_t) \quad (13)$$

由式(13)可知, 判别式目标函数更专注监督学习部分, 因此更适用于本文的调制识别任务。同样, 基于此目标函数, 利用随机梯度下降, 求取网络参数  $\theta \in \{\mathbf{d}, \mathbf{c}, \mathbf{W}, \mathbf{U}\}$  的偏导为

$$\nabla \theta = \frac{\partial \log P(y_t | \mathbf{x}_t)}{\partial \theta} = - \frac{\partial F(y_t, \mathbf{x}_t)}{\partial \theta} + \sum_y P(y | \mathbf{x}_t) \frac{\partial F(y, \mathbf{x}_t)}{\partial \theta} \quad (14)$$

由于  $P(y|\mathbf{x})$  的计算不涉及  $\mathbf{x}$  的偏置  $\mathbf{b}$ , 因此  $\mathbf{b}$  的梯度更新为 0。由于本文提取的特征向量维度较低, 因此计算复杂度不高。基于 DRBM\_disc 的调制识别如算法 2 所示。

**算法 2** 基于 DRBM\_disc 的调制识别算法

**输入** 特征向量  $\mathbf{x}^{(0)}=[|C20|, |C40|, |C41|, |C42|, |C60|, |C61|, |C62|, |C63|]^T$  或  $\mathbf{x}_{\text{rec}}$ , 标签  $y^{(0)}$ , 学习率  $\eta$

**输出** 更新的网络参数  $\theta$

**训练过程** 根据式(14)更新网络参数  $\theta$

**分类** 计算  $P(y|\mathbf{x}_t)$ , 取最大值索引为目标类型在后续的仿真实验中, 训练 DRBM\_disc 时采

用 adam 优化器<sup>[26]</sup>, 一般设置初始学习率为 0.09 或 0.009, 批量数为 100 或 1 000, 迭代次数为 250 或 500, 并将 DRBM\_disc 作为独立分类器实现调制识别。

## 4 实验验证与分析

### 4.1 基于高阶累积量-DRBM 的调制识别

本文分别对 AWGN 信道、TPO 信道和 Rayleigh 信道中 BPSK、QPSK、8PSK、8QAM、16QAM、4PAM、CPFSK、GMSK 这 8 种调制类型进行调制识别。3 种信道环境的基本设置如下。

1) AWGN 信道: 含加性白高斯噪声, 信噪比范围为  $[-10, 18]$  dB, 输入信号的均方功率为 1 W。

2) TPO 信道: 含有随机时变相位偏移, 每个传输符号的相位偏移在  $[0, \pi/2]$  随机取值, 信噪比范围为  $[-10, 18]$  dB。

3) Rayleigh 信道: 路径时延为  $1.5 \times 10^{-4}$  s, 平均路径增益为 3 dB, 最大多普勒频移为 0.01 Hz, 信噪比范围为  $[-10, 18]$  dB。

信号序列长度均设置为 100。对于基于 DT 的调制识别算法, 设计  $|C80|$ 、 $|C61|/|C63|$ 、 $|C63|$ 、 $|C20|$ 、 $|C62|$  为信号特征, 分析特定信噪比  $-10$  dB,  $-8$  dB,  $\dots$ ,  $10$  dB,  $\dots$ ,  $18$  dB 下的信号识别率。一共随机生成 120 000 个符号序列样本, 每种调制类型的符号序列对应每种特定信噪比生成 1 000 个样本。

对于基于高阶累积量-DRBM 的调制识别算法, 模型权重初始化采用 Glorot 均匀分布初始化器<sup>[27]</sup>, 偏置初始化为 0, 隐含层单元个数为 32。将经过预处理的  $|C20|$ 、 $|C40|$ 、 $|C41|$ 、 $|C42|$ 、 $|C60|$ 、 $|C61|$ 、 $|C62|$ 、 $|C63|$  作为输入特征向量。数据集的基本设置如下<sup>[17]</sup>。

1) 训练集共有 160 000 个样本, 每种调制方式含 20 000 个样本, 每个符号序列的平均信噪比为  $[-10, 18]$  dB 的随机值。

2) 验证集共有 16 000 个样本, 每种调制方式含 2 000 个样本, 每个符号序列的平均信噪比为  $[-10, 18]$  dB 的随机值。

3) 测试集共有 120 000 个样本, 每种调制类型的信号对应每种特定信噪比 ( $-10$  dB,  $-8$  dB,  $\dots$ ,  $10$  dB,  $\dots$ ,  $18$  dB) 生成 1 000 个样本。

3 种信道环境下训练集和验证集的信噪比均在  $[-10, 18]$  dB 范围内随机动态变化, 总体信噪比取值满足均匀分布。基于高阶累积量-SVM 的调制识别算法与 DRBM 使用同一数据集。SVM 选用径向基

核函数，内核系数为 0.01。高阶累积量-DRBM 算法与传统算法的识别率对比如图 4 所示。对于高阶累积量-DRBM 算法，本节分析了该网络基于 2 种不同目标函数的识别性能。




图 4 高阶累积量-DRBM 算法与传统算法的识别率对比

图 4(a)为 AWGN 信道中识别率对比。由图 4(a)可知,DT 在 12~18 dB 达到 91.26%以上的识别率,但总体识别率与 SVM、DRBM\_disc 相比明显偏低。

当信噪比为 8~18 dB 时, SVM 达到 92.4%以上的识别率, DRBM\_disc 达到 95.15%以上的识别率。在 -4~6 dB, DRBM\_disc 的识别率明显优于 SVM, 约高出 5.05%~10.83%。DRBM\_gen 识别性能不稳定, 且效果差。图 4(b)为同时存在时变随机相移和高斯加性噪声的 TPO 信道中识别率对比。由图 4(b)可知, DT 性能最差, DRBM\_gen 依旧不理想但略优于 DT。在 -2~6 dB, DRBM\_disc 的识别率比 SVM 约高 3.96%~9.30%。图 4(c)为同时含有平坦频率衰落和高斯加性噪声的 Rayleigh 信道中识别率对比。由图 4(c)可知, DRBM\_disc 识别率略优于 SVM, DT 最差, DRBM\_gen 识别率与 DRBM\_disc 的差距有所减小但仍不理想。

由以上分析可知, DT 仅在 AWGN 信道中高信噪比情况下有较好表现, 在其他 2 种信道中已不再具备调制识别的能力, 可见基于理论分析的决策算法在信号受较强干扰时, 特征取值受损严重, 根据理想情况下特征人工设计的阈值已经失去了分类作用。DRBM\_gen 的识别性能不理想, 是因为基于生成目标函数的 DRBM 模型耗费部分能力来拟合输入分布, 从而训练的拟合方向受到一定的干扰, 较大地影响了识别性能, 训练集数据的信噪比在大范围内动态变化, 生成目标函数的两部分训练相互影响, 导致训练收敛性差, 识别精度不稳定, 相邻信噪比间的识别率曲线不够平滑。通过观察 3 种信道环境下的识别率曲线发现, 环境越复杂, DRBM\_gen 的识别性能越稳定, 在训练过程中偏向拟合受损数据。由图 4 易知, DRBM\_disc 在 3 种信道下识别率均为最优, 本文中模型的训练集数据信噪比为动态变化的, 且考虑了含有相偏或瑞利衰落干扰情况下的算法识别率, 在动态信噪比以及含有其他干扰的条件下, DRBM\_disc 在调制识别任务上仍然保持一定的识别精度和有效性, 可见该模型具有一定的稳健性, 且在动态信噪比环境中进行调制识别具有一定优势。

为了更直观地分析信噪比对高阶累积量-DRBM 算法识别精度的影响, 图 5 展示了 AWGN 信道中不同信噪比下 DRBM\_disc 的混淆矩阵, 图 5(a)和图 5(b)分别为信噪比为 18 dB 和 -2 dB 下的混淆矩阵。

由图 5 可知, 18 dB 下的调制识别率为 AWGN

信道中最高，-2 dB 下识别率降至 60%以下，因此用来分析噪声对识别精度的影响，从图 5 的混淆矩阵可分析识别误差来源。由图 5(a)可知，18 dB 时识别误差主要来自 8PSK 和 CPFSK、GMSK 之间的误识别，QPSK 和 16QAM 之间的误识别，其中 8PSK 只有 89%的正确识别率，其约 9%的样本被误识别为 CPFSK。由表 1 可知，以上调制方式高阶累积量的分布特征近似性大，即使在高信噪比下也很难获得 100%的识别率，始终存在一些混淆现象。随着信噪比下降，信号受到更强的干扰，-2 dB 下 QPSK 和 8PSK、16QAM 之间的误识别对总体识别率影响最大，QPSK 甚至只有 7%的正确识别率，约 66%的样本被误识别为 8PSK。QPSK 和 8PSK 属于调相方式的类内识别，本身信号构造具有一定相似性，信噪比下降导致特征取值受损，2 种信号的特征分布近似，识别难度加大。由以上分析可知，低信噪比下 QPSK、8PSK 和 16QAM 受噪声干扰严重，识别性能较差，未来可进一步研究此类信号的特征分布，降低噪声带来的影响。

### 4.2 基于重构数据-DRBM 的调制识别

虽然基于 DRBM\_disc 可有效实现动态信噪比下的调制识别，但当信噪比较低时，识别率颇不理想。DRBM 同时具有生成能力和分类能力<sup>[25]</sup>。因为 DRBM\_gen 在对输入和输出标签的条件概率分布进行建模的同时，能够对输入数据的边缘分布进行建模，所以具有一定的生成能力，理论上，利用生成目标函数 $-\log P(\mathbf{x}, \mathbf{y})$ 来训练网络，可有效拟合输入向量的概率分布。因此，本节首先利用生成目标函数来训练 DRBM，观测重构误差判断模型对输入分布的拟合程度，对完成预训练的 DRBM 网络参数进行保存，再利用 CD- $k$  算法，从隐含层  $h$  重构输入层  $\mathbf{x}$  和对应的输出标签层  $\mathbf{y}$ ，将此时获得的重构数据  $\mathbf{x}_{rec}$  作为 DRBM\_disc 的输入（该算法用“DRBM\_gen+disc”表示）。在预训练过程中，标签  $\mathbf{y}$  其实是一种已知的辅助信息，对数据重构起约束作用，以提高模型性能。

仿真实验中，取 CD- $k$  算法中的  $k$  为 1，基于生成目标预训练 DRBM（网络结构设置与 4.1 节相同），保存网络参数，重构训练集、验证集和测试集，且将保存的网络参数作为后续 DRBM\_disc 模型的初始化参数。基于重构数据和原始数据的识别率对比如图 6 所示。

3 种信道中的识别性能均出现两级分化严重的现象。图 6(a)为 AWGN 信道中的识别率对比。由图 6(a)可知，在-10~-2 dB 的信噪比情况下，与原始数据相比，重构数据识别率有明显提高，-10 dB 下约提高 24.4%，但是 0~18 dB 性能下降严重。同样，图 6(b)为 TPO 信道中的识别率对比，在-10~-2 dB 下，重构数据识别率性能提升明显。图 6(c)为 Rayleigh 信道下的识别率对比，在-10~2 dB 下重构数据识别率均有提升，2 dB 下提高约 3.9%。由以上仿真结果可知，重构数据仅提高了信号在低信噪比下的识别率，但随着信噪比的提高，此算法对信号识别率不再有优化作用。且 AWGN 信道中高信噪比下信号识别率的损失值高于其他 2 种更加复杂的信道。可见，基于生成目标函数对于 DRBM 的预训练偏向拟合受损较严重的输入向量的概率分布，整体网络参数更新牺牲了高信噪比下的识别率，偏向拟合受损数据，从而提高了低信噪比下的识别率，即预训练过程中网络偏向拟合严重受损数据，对其有恢复、抗干扰的作用，但牺牲了高信噪比下信号的高识别率。

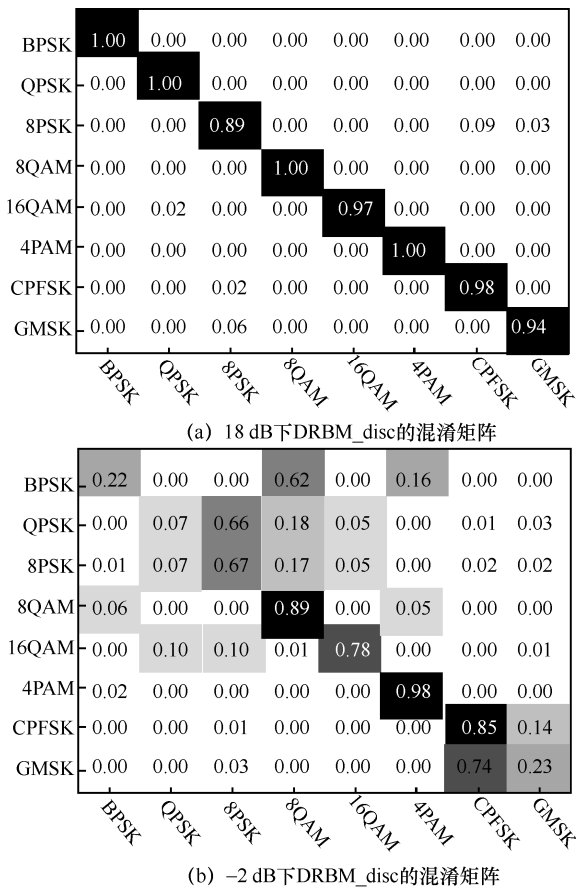


图 5 AWGN 信道中不同信噪比下 DRBM\_disc 的混淆矩阵

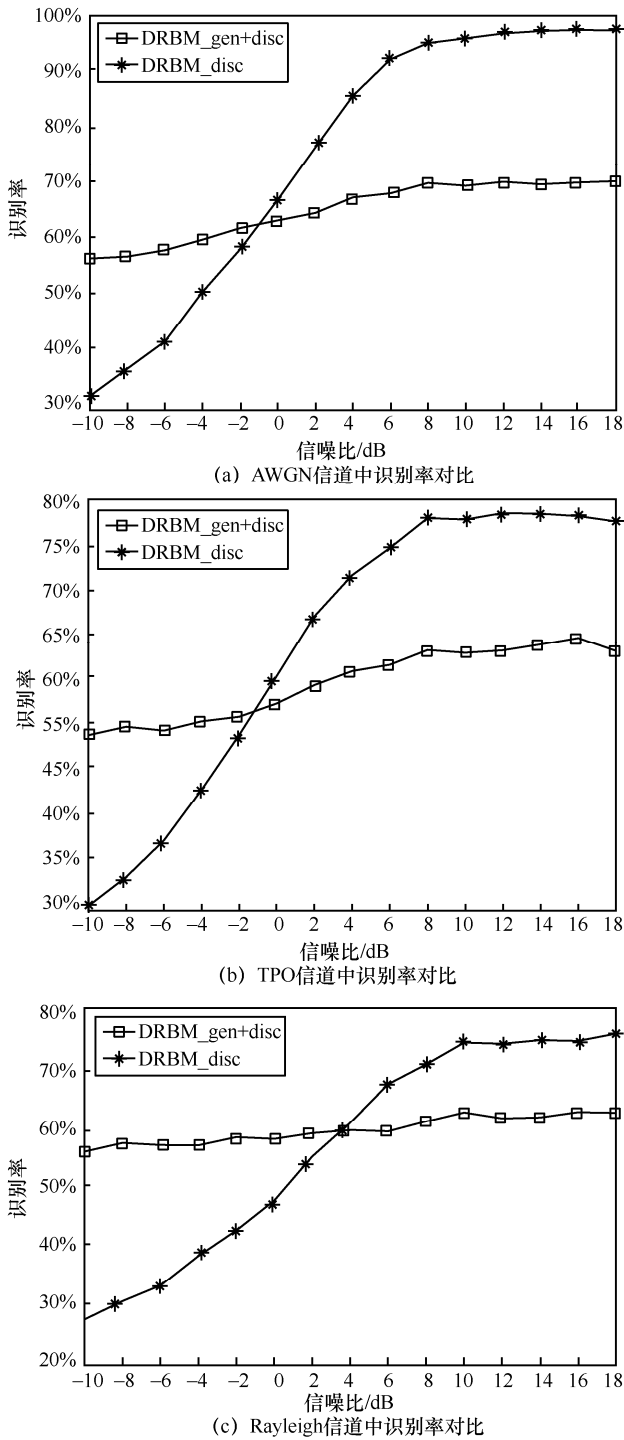


图 6 基于重构数据和原始数据的识别率对比

## 5 结束语

本文提出了一种基于高阶累积量和判别式受限玻尔兹曼机的联合调制识别方法，分析了在含高斯噪声、随机时变相移、平坦瑞利衰落的 3 种信道环境下对 BPSK、QPSK、8PSK、8QAM、16QAM、4PAM、CPFSK、GMSK 这 8 种调制信号的识别效

果。结果表明，基于判别目标函数的 DRBM 模型，可有效识别大动态信噪比下的数字调制类型，其识别性能在 3 种信道下均高于传统的识别方法，且保持一定的稳定性。针对低信噪比下信号识别率过低的问题，本文利用 DRBM 的生成能力，通过生成目标函数来预训练 DRBM 模型，重构输入的特征向量，再利用判别目标函数来训练模型，从而识别调制类型，有效提高了低信噪比下信号的识别率。

本文提出的高阶累积量-DRBM 方法的识别率虽然在大动态信噪比环境中优于传统方法且具有一定的稳健性，但当信噪比过低或含有瑞利衰落时，总体的识别率还有很大的提升空间。下一步工作将进一步研究数字调制方式的特征，提取更有辨识度的信号特征，改进 DRBM 网络，提高复杂环境下的识别性能。

## 参考文献:

- [1] 何继爱, 张文启. 通信信号调制识别技术及其发展[J]. 高技术通讯, 2016, 26(2): 157-165.  
HE J A, ZHANG W Q. The technology for modulation recognition of communication signals and its development[J]. High Technology Letters, 2016, 26(2): 157-165.
- [2] SWAMI A, SADLER B M. Hierarchical digital modulation classification using cumulants[J]. IEEE Transactions on Communications, 2000, 48(3): 416-429.
- [3] WANG A, LI R. Research on digital signal recognition based on higher order cumulants[C]//2019 International Conference on Intelligent Transportation, Big Data & Smart City. Piscataway: IEEE Press, 2019, doi: 10.1109/ICITBS.2019.00146.
- [4] ZHANG Y, WU G, WANG J, et al. Wireless signal classification based on high-order cumulants and machine learning[C]//2017 International Conference on Computer Technology, Electronics and Communication. Piscataway: IEEE Press, 2017, doi: 10.1109/ICCTEC.2017.00127.
- [5] PAJIC M S, VEINOVIC M, PERIC M, et al. Modulation order reduction method for improving the performance of AMC algorithm based on sixth-order cumulants[J]. IEEE Access, 2020, 8: 106386-106394.
- [6] 张华娣, 楼华勋. MQAM 信号调制方式自动识别方法[J]. 通信学报, 2019, 40(8): 200-211.  
ZHANG H D, LOU H X. Automatic modulation recognition algorithm for MQAM signal[J]. Journal on Communications, 2019, 40(8): 200-211.
- [7] 张茜. 基于高阶统计特性的调制信号识别[D]. 成都: 电子科技大学, 2018.  
ZHANG X. Recognition of digital modulation signals based on high-order statistical characteristics[D]. Chengdu: University of Electronic Science and Technology of China, 2018.
- [8] ABDELBAR M, TRANTER W H, BOSE T. Cooperative cumulants-based modulation classification in distributed networks[J]. IEEE Transactions on Cognitive Communications and Networking, 2018, 4(3): 446-461.

- [9] 刘明骞, 李兵兵, 曹超凤, 等. 认知无线电中非高斯噪声下数字调制信号识别方法[J]. 通信学报, 2014, 35(1): 82-88.  
LIU M Q, LI B B, CAO C F, et al. Recognition method of digital modulation signals over non-Gaussian noise in cognitive radio[J]. Journal on Communications, 2014, 35(1): 82-88.
- [10] 赵雄文, 郭春霞, 李景春. 基于高阶累积量和循环谱的信号调制方式混合识别算法[J]. 电子与信息学报, 2016, 38(3): 674-680.  
ZHAO X W, GUO C X, LI J C. Mixed recognition algorithm for signal modulation schemes by high-order cumulants and cyclic spectrum[J]. Journal of Electronics & Information Technology, 2016, 38(3): 674-680.
- [11] XIE W, HU S, YU C, et al. Deep learning in digital modulation recognition using high order cumulants[J]. IEEE Access, 2019, 7: 63760-63766.
- [12] 吴少华. 基于人工蜂群算法的通信信号调制识别研究[D]. 南京: 南京邮电大学, 2016.  
WU S H. The research on recognition of communication modulation signal based on artificial bee colony algorithm[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2016.
- [13] YANG F, HAO B, YANG L, et al. A method of high-precision signal recognition based on higher-order cumulants and SVM[C]//2018 5th International Conference on Systems and Informatics. Piscataway: IEEE Press, 2018, doi: 10.1109/ICSAI.2018.8599313.
- [14] 宁暑光. 基于特征提取与学习的无线通信数字调制方式自动识别方法研究[D]. 合肥: 合肥工业大学, 2019.  
NING S G. Research on automatic recognition method of wireless communication digital modulation mode based on feature extraction and learning[D]. Hefei: Hefei University of Technology, 2019.
- [15] 杨安锋, 赵知劲, 陈颖. 利用稀疏自编码器的调制样式识别算法[J]. 信号处理, 2018, 34(7): 833-842.  
YANG A F, ZHAO Z J, CHEN Y. Modulation recognition algorithm based on sparse auto-encoder[J]. Journal of Signal Processing, 2018, 34(7): 833-842.
- [16] ZHANG Z, HUA Z, LIU Y. Modulation classification in multipath fading channels using sixth-order cumulants and stacked convolutional auto-encoders[J]. IET Communications, 2017, 11(6): 910-915.
- [17] 雷志坤. 基于深度学习的调制识别技术研究[D]. 成都: 电子科技大学, 2019.  
LEI Z K. Research on deep learning based modulation recognition technologies[D]. Chengdu: University of Electronic Science and Technology of China, 2019.
- [18] PEND S, JIANG H, WANG H, et al. Modulation classification based on signal constellation diagrams and deep learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30: 718-727.
- [19] SANG Y, LI L A. Application of novel architectures for modulation recognition[C]//2018 IEEE Asia Pacific Conference on Circuits and Systems. Piscataway: IEEE Press, 2018, doi: 10.1109/APCCAS.2018.8605691.
- [20] XU Y, LI D, WANG Z, et al. A deep learning method based on convolutional neural network for automatic modulation classification of wireless signals[J]. Wireless Networks, 2017, 25(7): 3735-3746.
- [21] WEST N E, O'SHEA T. Deep architectures for modulation recognition[C]//2017 IEEE International Symposium on Dynamic Spectrum Access Networks. Piscataway: IEEE Press, 2017: 1-6.
- [22] SALAKHUTDINOV R, MNH A, HINTON G. Restricted Boltzmann machines for collaborative filtering[C]//2007 International Conference on Machine Learning. New York: ACM Press, 2007: 791-798.
- [23] 杨安锋. 基于深度学习的调制样式识别算法研究[D]. 杭州: 杭州电子科技大学, 2018.  
YANG A F. Research on modulation type recognition algorithm based on deep learning[D]. Hangzhou: Hangzhou Dianzi University, 2018.
- [24] LAROCHELLE H, MANDEL M, PASCANU R, et al. Learning algorithms for the classification restricted Boltzmann machine[J]. Journal of Machine Learning Research, 2012, 13(1): 643-669.
- [25] CHEN C L P, FENG S. Generative and discriminative fuzzy restricted Boltzmann machine learning for text and image classification[J]. IEEE Transactions on Cybernetics, 2018, 50(5): 2237-2248.
- [26] KINGMA D P, BA J. Adam: a method for stochastic optimization[C]//2015 International Conference on Learning Representations. [S.n.:s.l.], 2015: 1-13.
- [27] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks[C]//2010 International Conference on Artificial Intelligence and Statistics. Piscataway: IEEE Press, 2010: 249-256.

#### [作者简介]



李正权 (1976- ), 男, 湖北利川人, 博士, 江南大学教授, 主要研究方向为大规模 MIMO 等。

林媛 (1995- ), 女, 安徽铜陵人, 江南大学硕士生, 主要研究方向为信号处理。

李梦雅 (1997- ), 女, 安徽淮北人, 江南大学硕士生, 主要研究方向为 NB-IoT 的海量接入。

刘洋 (1988- ), 男, 江苏无锡人, 博士, 江南大学副教授, 主要研究方向为无线信道建模和网络编码。

吴琼 (1986- ), 男, 江苏徐州人, 博士, 江南大学副教授, 主要研究方向为无人驾驶。

邢松 (1964- ), 男, 江苏扬州人, 博士, 加利福尼亚州立大学教授, 主要研究方向为 5G 移动通信。