

Journal of System Simulation

Volume 33 | Issue 2

Article 27

2-20-2021

Modulation Recognition Algorithm Based on Improved LDA and Autoencoders

Yecai Guo

1. School of Electronic and Information Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China; ;2. Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment, Nanjing University of Information Science & Technology, Nanjing 210044, China;

Haoran Zhang

1. School of Electronic and Information Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China; ;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Modulation Recognition Algorithm Based on Improved LDA and Autoencoders

Abstract

Abstract: The traditional modulation recognition algorithms are based on the Gaussian white noise channel, which significantly degrade recognition performance in complex channel conditions. Aiming at this problem, *a modulation recognition algorithm based on A-ALDA (Anti-alias Linear Discriminant Analysis) and SSDAE (Stacked Sparse Denoising Autoencoders) is proposed. In this algorithm, A-ALDA algorithm reconstructs signal cumulants feature into new features, which has better separability. The combination of original features and new features is input into SSDAE for classification, and SSADE has the ability to extract key information and resist noise.* Simulation results show that recognition accuracy of the proposed algorithm is higher than that of the existing algorithms, and recognition accuracy is improved under the condition of limited signal length and phase and frequency offset interference.

Keywords

complex channels, anti-alias linear discriminant analysis, sparse denoising autoencoders, high order cumulants

Recommended Citation

Guo Yecai, Zhang Haoran. Modulation Recognition Algorithm Based on Improved LDA and Autoencoders[J]. Journal of System Simulation, 2021, 33(2): 494-500.

基于改进 LDA 和自编码器的调制识别算法

郭业才^{1,2}, 张浩然¹

(1. 南京信息工程大学 电子与信息工程学院, 江苏 南京 210044;
2. 南京信息工程大学 江苏省大气环境与装备技术协同创新中心, 江苏 南京 210044)

摘要: 传统调制识别算法是基于高斯白噪声信道的, 在复杂信道条件下识别性能明显下降。针对此问题, 提出基于抗混淆线性判别分析 A-ALDA (*Anti-alias Linear Discriminant Analysis*) 和堆叠稀疏降噪自编码器 SSDAE (*Stacked Sparse Denoising Autoencoders*) 的调制识别算法。该算法中, A-ALDA 算法将信号累积量特征重构为新的特征, 这些特征具有更优的分离性能; 将原始特征与新特征输入 SSDAE 进行分类, SSDAE 具有提取关键信息和抗噪声的能力。结果表明, 本文算法的识别准确率高于已有的算法; 并且在有限信号长度条件下和相位、频率误差干扰情况下, 识别准确率均有提高。

关键词: 复杂信道; 抗混淆线形判别分析; 稀疏降噪自动编码器; 高阶累积量

中图分类号: TP391 文献标志码: A 文章编号: 1004-731X (2020) 02-0494-07

DOI: 10.16182/j.issn1004731x.joss.19-0326

Modulation Recognition Algorithm Based on Improved LDA and Autoencoders

Guo Yecai^{1,2}, Zhang Haoran¹

(1. School of Electronic and Information Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China;
2. Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment, Nanjing University of Information Science & Technology, Nanjing 210044, China)

Abstract: The traditional modulation recognition algorithms are based on the Gaussian white noise channel, which significantly degrade recognition performance in complex channel conditions. Aiming at this problem, a modulation recognition algorithm based on A-ALDA (*Anti-alias Linear Discriminant Analysis*) and SSDAE (*Stacked Sparse Denoising Autoencoders*) is proposed. In this algorithm, A-ALDA algorithm reconstructs signal cumulants feature into new features, which has better separability. The combination of original features and new features is input into SSDAE for classification, and SSDAE has the ability to extract key information and resist noise. Simulation results show that recognition accuracy of the proposed algorithm is higher than that of the existing algorithms, and recognition accuracy is improved under the condition of limited signal length and phase and frequency offset interference.

Keywords: complex channels; anti-alias linear discriminant analysis; sparse denoising autoencoders; high order cumulants

引言

自动调制信号识别 (Automatic Modulation Recognition, AMR) 是接收端解调前的一项复杂且困难的技术, 它在军事和民用领域都有广泛应用。因此, 研究自动调制信号识别具有重要意义。

基于模式识别的 AMR 算法流程为: 信号预处理, 提取信号特征和分类算法。信号特征包括: 瞬时幅度、相位和频率^[1]; 高阶累积量^[2]; 循环谱^[3]; 等。分类算法有: 支持向量机 (Support Vector Machine, SVM)^[4], K 最邻近 (K Nearest Neighbor, KNN)^[5] 和朴素贝叶斯^[6] 等, 但这些算法识别准确率

收稿日期: 2019-07-15 修回日期: 2019-09-11

基金项目: 国家自然科学基金(61673222, 61371131), 江苏省高校自然科学研究重大项目(13KJA510001), 江苏高校品牌专业建设项目(PPZY2015B134)
第一作者: 郭业才(1962-), 男, 博士, 教授, 博导, 研究方向为通信信号处理、自适应盲均衡技术。E-mail: guo-yecai@163.com

较低。众多研究者将之引入 AMR。文献[7]在高斯白噪声和瑞利衰落信道下, 提取信号的瞬时幅度、累积量等特征, 并用 BP (Back Propagation) 网络完成分类; 文献[8]在高斯白噪声信道下, 提取信号的统计特征, 并用 SSAE(Stacked Sparse Autoencoders) 进行分类; 文献[9]在高斯白噪声信道下, 提取信号的累积量特征, 再通过 ANC (Autoencoders with Nonnegativity Constraints) 进行分类; 此外, 文献[10] 在高斯白噪声信道下, 提取信号的累积量特征, 并利用遗传编程算法对特征进行算术组合, 最后用 K 最邻近算法完成分类; 文献[11]在高斯信道下, 提取信号频率特征矩阵, 并用主成分分析算法对特征进行映射, 最后利用 KNN 和 SVM 进行分类。上述算法都取得了较高的识别准确率, 但明显的问题是所识别的对象是高斯白噪声信道或是在个别干扰背景下的信号, 与实际复杂的通信环境不符。其次, 在信号受干扰较多时, 文献[10-11]中的特征优化算法难以取得最佳效果。

针对以上问题, 本文识别的是高斯白噪声和瑞利衰落 2 种信道下的信号, 包括: BPSK, QPSK, 8PSK, 16QAM 和 64QAM, 并仿真多普勒频移效应, 还考虑了相位和频率误差的干扰。为此, 本文提出一种改进的 LDA 算法将特征进行重构, 并利用 SSDAE 网络进行特征学习及分类。实验结果表明, 本文算法识别准确率较优, 且在信号长度受限和存在相位、频率误差的情况下, 也有良好的识别准确率。

1 特征提取

1.1 信号模型

在复杂信道下, 接收端接收到的信号表示为

$$r(t) = x(t) \otimes h(t) + n(t) \quad (1)$$

式中: \otimes 为卷积操作; $r(t)$ 为接收信号; $x(t)$ 为发送信号; $h(t)$ 为复杂信道下的信道效应, 为瑞利衰落、多普勒频移和频率、相位误差; $n(t)$ 为均值为零的高斯白噪声。

1.2 高阶累积量

调制信号的复随机过程 $X(n)$ 为

$$M_{pq} = E[X(n)^p X^*(n)^q] \quad (2)$$

式中: $*$ 为共轭。 $X(n)$ 的二至八阶累积量为

$$C_{20} = M_{20} \quad (3)$$

$$C_{21} = M_{21} \quad (4)$$

$$C_{40} = M_{40} - 3M_{20}^2 \quad (5)$$

$$C_{41} = M_{41} - 3M_{21}M_{20} \quad (6)$$

$$C_{42} = M_{42} - |M_{20}|^2 - 2M_{21}^2 \quad (7)$$

$$C_{60} = M_{60} - 15M_{40}M_{20} + 30M_{20}^3 \quad (8)$$

$$\begin{aligned} C_{61} = M_{61} - 5M_{40}M_{21} - \\ 10M_{20}M_{41} + 30M_{20}^3M_{20}^2 \end{aligned} \quad (9)$$

$$\begin{aligned} C_{63} = M_{63} - 6M_{20}M_{41} - \\ 9M_{42}M_{21} + 18M_{20}^2M_{21} + 12M_{21}^3 \end{aligned} \quad (10)$$

$$\begin{aligned} C_{80} = M_{80} - 28M_{60}M_{20} - \\ 35M_{40}^2 + 420M_{40}M_{20}^2 - 630M_{20}^4 \end{aligned} \quad (11)$$

将各类调制信号代入式(3)~(11)计算出各阶累积量即本文欲提取的特征参数。

2 算法设计

2.1 A-ALDA 算法

LDA 是一种类似主成分分析的降维特征提取算法, 该算法保证了样本在新的子空间有最大的类间距离和最小的类内距离, 即投影后的样本具有最佳可分离性^[12]。

假设共有 m 个样本, n 个类别。即样本和标签集合 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$, x_i 为特征, $y_i \in \{Y_1, Y_2, \dots, Y_n\}$ 为标签, 其中 Y_i 为类别。此外, 定义 $N_j (j=1, 2, \dots, n)$ 为第 j 类样本的个数, $X_j (j=1, 2, \dots, n)$ 为第 j 类样本的集合, $\mu_j (j=1, 2, \dots, n)$ 为第 j 类样本的均值, $\Sigma_j (j=1, 2, \dots, n)$ 为第 j 类样本的协方差矩阵, 则类内散度矩阵 S_w 为

$$S_w = \sum_{j=1}^n S_{wj} = \sum_{j=1}^n \sum_{x \in X_j} (x - \mu_j)(x - \mu_j)^T \quad (12)$$

类间散度矩阵 S_b 为

$$\mathbf{S}_b = \sum_{j=1}^n (\boldsymbol{\mu}_j - \boldsymbol{\mu})(\boldsymbol{\mu}_j - \boldsymbol{\mu})^T \quad (13)$$

式中: $\boldsymbol{\mu}$ 为所有样本的均值。

LDA 多类优化目标函数为

$$\underbrace{\arg \max_{\boldsymbol{\omega}} J(\boldsymbol{\omega})}_{\text{diag}} = \frac{\prod_{\text{diag}} \boldsymbol{\omega}^T \mathbf{S}_b \boldsymbol{\omega}}{\prod_{\text{diag}} \boldsymbol{\omega}^T \mathbf{S}_w \boldsymbol{\omega}} = \prod_{i=1}^d \boldsymbol{\omega}_i^T \mathbf{S}_b \boldsymbol{\omega}_i \quad (14)$$

式(14)最右边是广义瑞利熵的形式, 其最大值即为 $\mathbf{S}_w^{-1} \mathbf{S}_b$ 的最大特征值。此时投影矩阵 $\boldsymbol{\omega}$ 为这最大的 d 个特征值对应的特征向量所张开的矩阵。经过 LDA 投影后的特征参数为

$$\mathbf{y} = \boldsymbol{\omega}^T \mathbf{x} \quad (15)$$

式中: 类间散度矩阵为每类样本均值与所有类样本总均值的协方差矩阵, 投影后的效果为每类样本远离样本总均值。为提高每类样本对周围别类的混淆样本的区别度, 将 A-ALDA 算法的类间散度矩阵 \mathbf{S}_{Ab} 定义为

$$\mathbf{S}_{Ab} = \sum_{j=1}^n w_j^2 (\boldsymbol{\mu}_j - \frac{\boldsymbol{\mu} + \boldsymbol{\mu}_{Aj}}{2})(\boldsymbol{\mu}_j - \frac{\boldsymbol{\mu} + \boldsymbol{\mu}_{Aj}}{2})^T \quad (16)$$

式中: $\boldsymbol{\mu}$ 为所有样本的均值; w_j^2 为每类的权重系数, 为该类样本均值到此类混淆样本欧式距离的倒数平方, $w_j^2 = (1 / \sqrt{(\boldsymbol{\mu}_j - \boldsymbol{\mu}_{Aj})^2})^2$, 即某类样本距离混淆样本越近, 权重越大; $\boldsymbol{\mu}_{Aj}$ 为 $\boldsymbol{\mu}_j$ 周围混淆样本的均值, 定义为

$$\boldsymbol{\mu}_{Aj} = \frac{1}{n_{Aj}} \sum_{i=1}^{n_{Aj}} \mathbf{x}_i^{Aj} \quad (17)$$

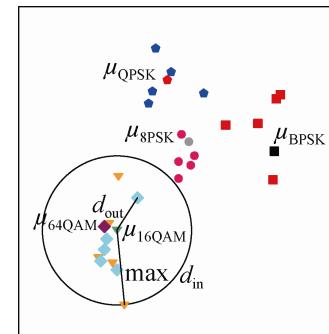
式中: n_{Aj} 为 j 类样本周围的混淆样本的个数, \mathbf{x}_i^{As} 为混淆样本。 n_{Aj} 值的选择直接影响 A-ALDA 的性能和 n_{As} 的取值过程, 如图 1 所示。

图 1(a) 中, 五类样本和每类对应的样本均值均用同一形状、不同颜色在图中标出, $\boldsymbol{\mu}_{16QAM}$ 为 16QAM 样本均值点, 其他信号样本均值同理在图中标出。 $\max d_{in}$ 为类内样本与该类均值的最大欧式距离, d_{out} 为类外样本与该类均值的欧式距离。混淆样本的个数 n_{Aj} 为满足 $d_{out} < \max d_{in}$ 所有类外样本的个数, 即图中圆内不属于 16QAM 样本的个数。但是对于个别信号受噪声较大, 出现图

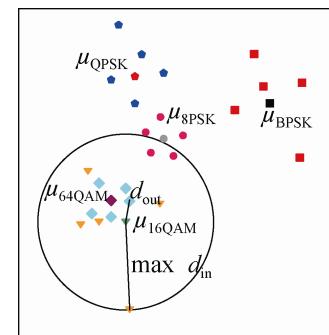
1(b) 情况。由于存在受噪声影响较大的样本, 以 $\max d_{in}$ 为半径的圆包含了本不为混淆样本的其他类信号, 这种情况下, 定义 $\max d_{in}$ 为

$$\max d_{in} = \frac{2 \sum_{s=(n_j+q*n_j)/2}^{n_j} d_s}{(1-q)n_j} \quad (18)$$

式中: n_j 为 j 类样本的个数; $\max d_{in}$ 为 j 类中最远的 $\frac{1}{2} n_j (1-q)$ 个样本点的均值; q 为接近 1 的常数, q 为 1 时, $\max d_{in}$ 为 j 类样本与均值的欧式距离的最大值; d_s 为所有 j 类样本与此类均值的欧式距离, 且按距离递增的顺序排列。由此, 类内样本与该类均值的最大欧式距离为一些较远样本距离的平均, 避免了大噪声点的影响。



(a) 小噪声下样本的分布情况



(b) 大噪声下样本的分布情况

图 1 n_{Aj} 取值的选择
Fig. 1 n_{Aj} value selection

2.2 稀疏降噪自动编码器

传统的单层稀疏自动编码器在学习特征时易丢失样本的深层特征信息, 使特征缺乏鲁棒性, 大大降低了分类的准确率。本文设计的网络如图 2 所示。

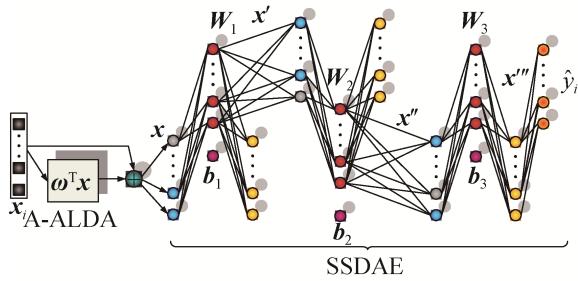


图 2 A-ALDA 和 SSDAE 结构图
Fig. 2 A-ALDA and SSDAE structure diagram

图 2 中, x_i 为原始累积量特征, x 为累积量特征和 A-ALDA 投影后新特征的组合。本文的 SSDAE 网络采用 3 层自编码器结构, 每层输入加入降噪性, 以腐败概率随机将输入神经元置零, 图中输入层的灰色神经元为被置零的神经元。自编码器输出的特征为隐藏层的输出, 为图中红色神经元的输出。 W_1 , W_2 和 W_3 分别表示 3 层 SSDAE 的权重, b_1 , b_2 和 b_3 分别表示 3 层 SSDAE 的偏置项。

3 层自动编码器学习到的特征表示分别为

$$x' = f(W_1 x + b_1) \quad (19)$$

$$x'' = f(W_2 x' + b_2) \quad (20)$$

$$x''' = f(W_3 x'' + b_3) \quad (21)$$

式中: $f(\cdot)$ 为 sigmoid 函数, 即 $f(z) = 1 / (1 + e^{-z})$ 。训练时更新网络权重参数的重构误差代价函数定义为

$$J(W, b) = \frac{1}{m} \sum_{n=1}^m \frac{1}{2} \|x'_n - x_n\|^2 \quad (22)$$

为了提升自编码网络的学习能力, 将自编码器加上稀疏性限制, 即在同一时间, 隐藏层中只有部分神经元是“活跃”的。由此, 引入 KL(Kullback-Leibler divergence) 散度来衡量某个隐藏层中神经元的平均激活度和设定的稀疏性参数之间的相似性。KL 散度定义为:

$$J_{KL}(\rho \parallel \hat{\rho}_j) = \sum_{j=1}^{n'} \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (23)$$

式中: ρ 为稀疏性参数; n' 为隐藏层神经单元的个数; $\hat{\rho}_j$ 为隐藏层神经单元的平均激活度, 定义为:

$$\hat{\rho}_j = \frac{1}{m} \sum_{n=1}^m h_j(x_n) .$$

因此, SSDAE 的代价函数为

$$J_{SAE} = J(W, b) + \beta J_{KL}(\rho \parallel \hat{\rho}_j) \quad (24)$$

式中: β 为稀疏项惩罚系数。

3 仿真实验

3.1 信号产生

本文仿真实验系统为 Ubuntu16.04, 所有仿真采用 Python 编程语言。本文在不同信号长度下各仿真 100 000 个信号的数据样本。其中, 50 000 个样本作为训练集, 50 000 个样本用于测试。仿真条件设置为: (1) 产生二进制序列, 是系数为 0.5 的伯努利分布; (2) 将二进制序列随机调制为 BPSK, QPSK, 8PSK, 16QAM, 64QAM 五类调制信号, 每类数量保持均匀; (3) 在数据符号间插零值, 并用根升余弦滤波器减少码间干扰; (4) 仿真瑞利衰落信道和多普勒频移; (5) 仿真信噪比从 0~20 dB, 步长为 2 dB 的高斯白噪声信道。

3.2 混淆点的选取

在 2.1 节中, 讨论了 n_{Aj} 值的选择方法。 n_{Aj} 为满足 $d_{out} < \max d_{in}$ 所有类外样本的个数, 其中 d_{out} 为确定值, 则直接影响 n_{Aj} 取值的参数为 $\max d_{in}$ 。 $\max d_{in}$ 由参数 q 确定。表 1 给出在信号长度为 512, 信噪比分别为 0, 10 dB 和 20 dB 时, 不同 q 的取值对识别准确率的影响。

表 1 q 的取值对识别准确率的影响

Tab. 1 Influence of the value of q on the recognition accuracy

SNR	q					
	0.90	0.92	0.94	0.96	0.98	1.00
0	0.764	0.768	0.778	0.786	0.794	0.785
10	0.862	0.868	0.872	0.875	0.878	0.877
20	0.872	0.875	0.879	0.882	0.886	0.886

表 1 表明, q 的取值过小, 使 $\max d_{in}$ 的值较小, 满足 $d_{out} < \max d_{in}$ 的样本较少, 排除了较多混淆样本, 导致混淆点选取不合理, 识别准确率较低。当参数 q 的取值为 0.98 时, 不同信噪比下的识别准

确率最高，以此确定的 n_{Aj} 最合适。

3.3 有限信号长度下的仿真实验

现讨论在有限信号长度下，算法的识别准确率随信噪比的变化情况。采用轮廓系数(Silhouette Coefficient)^[13]和 Calinski-Harabaz 指数^[14]2 个指标评价特征分离性，指标数值越大，特征分离性越好。原始特征、LDA 重构特征和 A-ALDA 重构特征的评价得分，如表 2 所示。

表 2 原始特征、LDA 和 A-ALDA 重构特征的评价得分
Tab. 2 Evaluation scores of primitive features, LDA and A-ALDA reconstruction features

算法	Silhouette Coefficient	Calinski-Harabaz index
Primitive	0.112	15.845
LDA	0.299	20.662
A-ALDA	0.320	40.272

从表 2 可知，A-ALDA 的两种指标得分均高于原始特征和 LDA 重构特征的得分，抗混淆线性判别分析取得较好的特征重构效果。

本文对比了 5 种已有的调制识别算法。5 种算法识别准确率如图 3 所示。

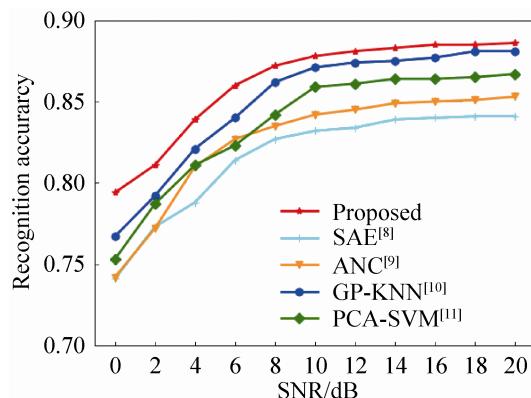


图 3 复杂信道下 5 种算法调制识别准确率
Fig. 3 Five algorithms for complex recognition and modulation accuracy

图 3 表明，在复杂信道下，本文算法在信噪比为 0 dB 时，识别率为 79.4%，较没有特征选择、重构过程的 SAE 和 ANC 算法的平均识别率高出约 5%，较 GP-KNN 和 PCA-SVM 算法的平均识别率高出约 3.5%。在高信噪比 20 dB 时，本文算法识

别率为 88.6%，比 GP-KNN 高出约 0.5%，较 PCA-SVM 提升约 2%。表 3 给出不同信号长度和不同信噪比下，LDA 和 A-ALDA 两种特征重构算法对识别率的影响。

表 3 LDA 和 A-ALDA 算法对识别率的影响
Tab. 3 Influence of LDA and A-ALDA Algorithms on Recognition Rate

算法	SNR	512	1 024	2 048
		0	4	8
LDA	0	0.77±0.02	0.81±0.02	0.82±0.02
	4	0.86±0.02	0.86±0.02	0.88±0.01
	8	0.86±0.02	0.87±0.01	0.90±0.01
	12	0.87±0.01	0.87±0.01	0.91±0.01
	16	0.88±0.01	0.89±0.01	0.92±0.01
A-ALDA	0	0.78±0.02	0.81±0.02	0.83±0.01
	4	0.86±0.02	0.88±0.01	0.89±0.01
	8	0.87±0.01	0.88±0.01	0.93±0.01
	12	0.88±0.01	0.89±0.01	0.93±0.01
	16	0.88±0.01	0.91±0.01	0.94±0.01

表 3 表明，在信号长度为 512 时，A-ALDA 的识别率较 LDA 略有提升，在信号长度为 1 024 时，本文算法识别率较 LDA 平均提升约为 1.4%。在信号长度为 2 048 时，平均提升约为 2%。由此可知，改进的 A-ALDA 算法可提升识别准确率，并且信号长度越长，识别率提升越明显。

3.4 相位、频率误差下的仿真实验

仿真条件设置为 $\text{SNR}=10 \text{ dB}$ ，信号长度为 2 048。这里将相位误差和频率误差分开考虑，首先只考虑载波相位误差存在，载波频率在接收机是已知的。在此情况下，信号的表达式为

$$\mathbf{r}(n) = e^{\alpha\theta_0} \mathbf{s}(n) \otimes \mathbf{h}(n) + \boldsymbol{\omega}(n) \quad (25)$$

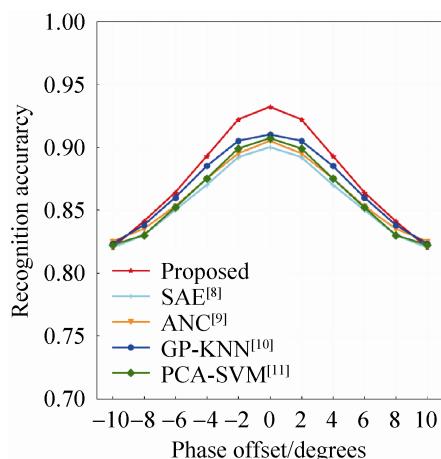
式中： $\alpha = \sqrt{-1}$ ，表示虚数单位。

将相位误差测试范围设置为 $-10^\circ \sim 10^\circ$ ，步长为 2° ，每种信号产生 20 000 个样本。5 种算法在有相位误差影响下的识别准确率，如图 4(a)所示。

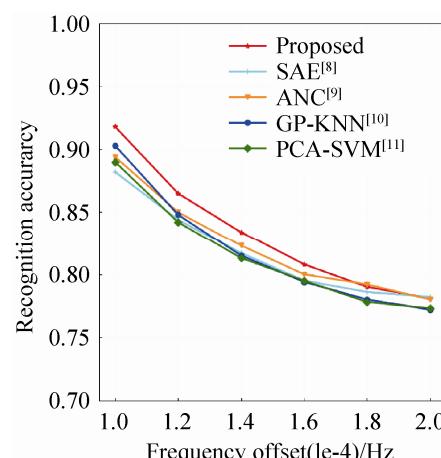
然后考虑频率误差对 2 种算法识别准确率的影响，此时载波相位在接收机是已知的。则信号的表达式为

$$r(n) = e^{-\frac{\alpha \pi n f_0}{f}} s(n) \otimes h(n) + \omega(n) \quad (26)$$

式中: f_0 为频率误差; f_0/f 为相对频率。将频率误差测试范围设置为 $1 \times 10^{-4} \sim 2 \times 10^{-4}$, 步长为 0.2×10^{-4} 。每种信号仍产生 20 000 个样本。5 种算法在有频率误差影响下的识别准确率, 如图 4(b) 所示。



(a) 相位误差下算法的识别准确率



(b) 频率误差下算法的识别准确率

图 4 相位、频率误差下的识别准确率

Fig. 4 Recognition accuracy under phase and frequency offset

图 4 表明, 在 $-4^\circ \sim 4^\circ$ 相位误差之间时, 本文算法的识别准确率比其他算法高, 但在其他范围提高较低。原因是在相位偏移较大时, 各信号累积量特征存在噪声较大, 特征重构混淆样本点增多, A-ALDA 难以做出较好投影变换。相同原因下, 在

频率误差 $1 \times 10^{-4} \sim 2 \times 10^{-4}$ 之间, 本文算法的平均识别准确率较其他算法提高了 2.3%, 但在其他频率偏差段识别率较低。

4 结论

本文研究复杂信道下的调制信号识别, 选取 BPSK, QPSK, 8PSK, 16QAM, 64QAM 的高阶累积量为特征。提出 A-ALDA 算法来构造新特征, 构造过程考虑了调制信号累积量的具体值, 使重构的新特征具有良好的分离性。将 SSDAE 用于信号样本特征的学习和分类。SSDAE 是具有稀疏性的深度神经网络, 能学习到样本的主要成分, 另外降噪性的加入, 防止了网络过拟合, 并减少了神经单元学习到的噪声, 提升了算法的鲁棒性。在复杂信道下该算法较现有的调制信号识别算法在识别率上有提升, 在信号长度受限的条件下和信号存在相位、频率误差的干扰下, 识别率也优于其他算法。

参考文献:

- [1] Zhu Z, Nandi A K. Automatic Modulation Classification: Principles, Algorithms and Applications[M]. New York: John Wiley & Sons, 2015.
- [2] Abdelmutalab A, Assaleh K, El-Tarhuni M. Automatic Modulation Classification based on High Order Cumulants and Hierarchical Polynomial Classifiers[J]. Physical Communication (S1874-4907), 2016, 21(12): 10-18.
- [3] Zhu X, Lin Y, Dou Z. Automatic Recognition of Communication Signal Modulation based on Neural Network[C]// 2016 IEEE International Conference on Electronic Information and Communication Technology (ICEICT). Harbin: IEEE, 2016: 223-226.
- [4] Lü J, Zhang L, Teng X. A Modulation Classification based on SVM[C]// 2016 15th International Conference on Optical Communications and Networks(ICOCN), Hangzhou: IEEE, 2016: 1-3.
- [5] Zhu Z, Aslam M W, Nandi A K. Genetic Algorithm Optimized Distribution Sampling Test for M-QAM Modulation Classification[J]. Signal Processing (S1687-4811), 2014, 94: 264-277.
- [6] Mughal M O, Kim S. Signal Classification and Jamming Detection in Wide-band Radios Using Naïve Bayes

- Classifier[J]. IEEE Communications Letters (S1089-7798), 2018, 22(7): 1398-1401.
- [7] Kim B, Kim J, Chae H, et al. Deep Neural Network-based Automatic Modulation Classification Technique[C]// Information and Communication Technology Convergence (ICTC), 2016 International Conference. Jeju: IEEE, 2016: 579-582.
- [8] Li J, Qi L, Lin Y. Research on Modulation Identification of Digital Signals based on Deep Learning[C]// Electronic Information and Communication Technology (ICEICT), IEEE International Conference. Harbin: IEEE, 2016: 402-405.
- [9] Ali A, Yangyu F. Automatic Modulation Classification Using Deep Learning based on Sparse Autoencoders with Nonnegativity Constraints[J]. IEEE Signal Processing Letters (S1070-9908), 2017, 24(11): 1626-1630.
- [10] Hussain A, Sohail M F, Alam S, et al. Classification of M-QAM and M-PSK Signals Using Genetic Programming (GP)[J]. Neural Computing and Applications (S0941-0643), 2018, 34(3)(1): 1-9.
- [11] Ali A, Yangyu F. Automatic Modulation Classification Using Principle Composition Analysis based Features Selection[C]. Computing Conference. London: IEEE, 2017: 294-296.
- [12] Wen J, Fang X, Cui J, et al. Robust Sparse Linear Discriminant Analysis[J]. IEEE Transactions on Circuits and Systems for Video Technology (S1051-8215), 2018, 29(2): 390-403.
- [13] Aranganayagi S, Thangavel K. Clustering Categorical Data Using Silhouette Coefficient as a Relocating Measure[C]// Conference on Computational Intelligence and Multimedia Applications, 2007. International Conference. Sivakasi: IEEE, 2007, 2: 13-17.
- [14] Atlas R S, Overall J E. Comparative Evaluation of Two Superior Stopping Rules for Hierarchical Cluster Analysis[J]. Psychometrika (S0033-3123), 1994, 59(4): 581-591.