

基于数值特征与图像特征融合的调制识别方法*

钱磊^{1,2}, 吴昊¹, 张涛¹, 张江¹

(1.国防科技大学第六十三研究所, 江苏 南京 210007; 2.国防科技大学 电子科学学院, 湖南 长沙 410073)

摘要:为解决低信噪比条件下相移键控和正交幅度调制类信号利用时频图像分类时识别率低的问题,提出一种信号特征融合的方法。首先对接收信号数据进行高阶累积量计算,获取一维数值特征向量;其次采用时频分析方法预处理得到信号时频图,利用卷积神经网络提取其一维图像特征向量;将两类特征向量级联得到一维融合特征向量,基于融合后的特征向量经过全连接网络进一步运算后得出分类识别结果。仿真结果显示,在1 dB条件下,相比于单一图像特征,采用特征融合的方法可将调制信号的识别准确率提高10%~30%。

关键词: 调制识别;高阶累积量;时频分析;特征融合

中图分类号: TN911.72

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.222686

中文引用格式: 钱磊, 吴昊, 张涛, 等. 基于数值特征与图像特征融合的调制识别方法[J]. 电子技术应用, 2022, 48(11): 89-93.

英文引用格式: Qian Lei, Wu Hao, Zhang Tao, et al. Modulation recognition method based on fusion of numerical features and image features[J]. Application of Electronic Technique, 2022, 48(11): 89-93.

Modulation recognition method based on fusion of numerical features and image features

Qian Lei^{1,2}, Wu Hao¹, Zhang Tao¹, Zhang Jiang¹

(1.The 63rd Research Institute of National University of Defense Technology, Nanjing 210007, China;

2.School of Electronic Science, National University of Defense Technology, Changsha 410073, China)

Abstract: In order to solve the problem of low recognition rate of phase shift keying and quadrature amplitude modulation signals when using time-frequency image classification under the condition of low signal-to-noise ratio, this paper proposes a method of signal feature fusion. Firstly, the method calculates the high-order cumulant of the received signal and obtains the one-dimensional numerical eigenvector. Then, the time-frequency diagram of the received signal is obtained by time-frequency analysis, and the one-dimensional image feature vector is extracted by convolution neural network. The two kinds of feature vectors are connected to obtain one-dimensional fusion feature vector. Finally, the fused feature vector is input into the full connection layer and the classification results are output. The simulation results show that under the condition of about 1 dB, the recognition rate of phase shift keying and quadrature amplitude modulation signals can be improved by about 10%~30% compared with the method of single image feature.

Key words: modulation recognition; high-order cumulant; time-frequency analysis; feature fusion

0 引言

在日趋复杂的电磁环境中,通常会接收到各种未知信号,该信号可能是己方的,也可能是敌方的,因此需要对信号的各种参数进行分析,以加强电磁频谱管控,调制样式就是其中一种关键参数。对非协作通信中接收信号的调制样式的识别与确定是频谱安全防护技术的重要一环,在电磁侦察、干扰信号识别、频谱监测等场景中都有着广泛的应用场景和巨大的发展潜力,在中低信噪

比环境下进行增强调制识别率的理论及方法研究是一项很重要的课题。

调制识别可以看作是一类模式识别问题,其原理就是通过提取样本的特征进行分类识别,主要包含三大模块,即预处理、特征提取和分类识别。常见的信号特征提取方法有:瞬时特征^[1]、高阶累积特征^[2]、小波变换^[3]、时频分析^[4]等。决策树^[5]是常用的分类器,该方法易于理解但是泛化能力较差,于是产生了随机森林(Random Forest, RF)^[6]的方法,利用多棵决策树对样本进行训练并预测的,有效地提高了泛化能力,但这两类方法需人工确定节点,较为繁琐。K最邻近(K-Nearest Neighbors, K-NN)^[7]

* 基金项目:军委科技委基础加强计划技术领域基金项目(2019-JCJQ-JJ-221)

算法使用距离度量将新示例与现有的示例比较,以最近的类标进行分类。以上传统的方法结构简单,易于理解,但是存在效率低下、惰性学习等局限性。目前更多地采用积极学习的算法,如支持向量机(Support Vector Machines, SVM)^[8],把结构风险最小化原则应用于分类领域中,擅于处理小样本和二分类问题;神经网络(Neural Networks, NN)^[9],是模拟人脑功能的一种数学模型,在分类问题中表现更好。此外,相比于浅层结构算法,深度学习通过深层非线性网络结构,提取数据的内在特征,在图像识别和语音识别等方面取得了引入瞩目的成绩。调制识别和图像识别及语音信号识别等方面存在很多关联性和相似性,因此采用深度学习的方法来解决调制识别问题是一个切实可行的研究方向。

不同调制样式的信号通常在频率、幅度或相位等方面有着不同的表现。在数值特征提取方面,文献[10]基于高阶累积量提取信号特征,从而实现对 MPSK 和 MQAM 两大类信号的识别。图像特征提取方面,文献[11]将星座图送入卷积神经网络,成功实现了数字调制信号的识别。文献[12]通过短时傅里叶变换获取信号的时频特征对信号进行识别。特征的选择与提取是调制识别的关键,现有的研究方法多采用单一特征,但很难有一种特征能较好地体现信号的所有信息。

本文针对时频图特征对频率信息更敏感,而对相移键控和正交幅度调制类信号识别率低的问题,提出了将时频图特征与高阶累积量数值特征融合的方法,通过特征的优势互补,提高该算法的识别率与鲁棒性。同时基于深度学习提取信号特征并分类,使系统具备自学习的能力,而减少人工干预。对常见的 BPSK、QPSK、16QAM、64QAM、4ASK、2FSK、4FSK 信号进行识别,首先将接收信号分为两路,一路计算信号的高阶累积量得到一维特征参数向量,一路通过平滑伪魏格纳威利分布(Smooth Pseudo Wigner-Villier Distribution, SPWVD)得到特征图像,再将图像送入卷积神经网络得到提取的一维的图像特征向量,最后将两类特征向量首尾相连得到融合的特征,送入分类层进行训练分类。本文所提的将高阶累积量特征和时频图特征融合的方法具有结构清晰、识别率高、抗噪声性能好的优点。相比于单一图像特征,采用特征融合的方法能将调制信号的识别准确率提高约 30%。

1 信号预处理

信号的幅度、频率及相位是较为完善的特征组合,足够将不同的调制样式区分。如图 1 所示,高阶累积量通过计算信号的高阶矩,凝练信号的幅度和相位信息,而时频分布能很好地反映信号的频率信息。在基带信号和中频信号两个不同的维度下,提取高阶累积量特征和时频图像特征,能完整地体现信号的频率、幅度及相位特征。

1.1 数值特征提取

高阶累积量(High-Order Cumulant, HOC)体现信号调




图 1 特征选择示意

制的特征,且高斯白噪声二阶以上的高阶累积量为 0,可以有效地抑制噪声的影响。零均值复随机信号 $X(t)$ 的 $p+q$ 阶混合矩:

$$M_{p,q} = E[X(t)^{(p-q)} X^*(t)^q] \quad (1)$$

其高阶累积量定义为:

$$C_{p,q} = \text{cum}(\underbrace{X, \dots, X}_{p-q \text{ 个}}, \underbrace{X^*, \dots, X^*}_{q \text{ 个}}) \quad (2)$$

其中, cum 表示累积计算。本文提取两个 HOC 特征参数作为 BPSK、QPSK、16QAM、64QAM 识别的依据,其理论值为如表 1 所示。

表 1 高阶累积量理论值

调制信号	$ C_{4,1} / C_{4,2} $	$ C_{4,2} / C_{2,1} ^2$
BPSK	1	2
QPSK	0	1
16QAM	0	0.68
164QAM	0	0.619

1.2 图像特征提取

魏格纳威利分布^[13](WVD)由魏格纳(Wigner)提出,被威利(Ville)首次用于信号处理。在此基础上进一步提出把 WVD 与平滑函数进行卷积的方法得到,接收信号 $x(t)$ 的 SPWVD 分布定义式为:

$$\text{SPWVD}_x(t, v) = \int_{-\infty}^{+\infty} h(\tau) \int_{-\infty}^{+\infty} g(s-t) \cdot x(s+\tau/2) x^*(s-\tau/2) e^{-j2\pi v\tau} ds d\tau \quad (3)$$

其中, $h(\tau)$ 和 $g(s-t)$ 表示窗函数,分别用于时域和频域的平滑; t 和 v 分别表示时间和频率。分布消除交叉项的效果较好,并保持了良好的时频特征。本文采用获取不同信号的时频图,如图 2 所示。

为将三维图像特征进行降维,从而与数值特征进行匹配,还需用卷积神经网络^[14](CNN)对图像特征进行提取。CNN 擅长图片空间特性的提取,可用于对信号时频图像的分类识别,包含输入层、卷积层、池化层、全连接层和输出层。

卷积层是通过滑动卷积核来对输入的图像做卷积操




图2 不同信号的时频图

作。卷积的计算就是用卷积核与窗口矩阵对应位置的值相乘,再加上偏置值得到卷积后的值,可表示为 $Y=WX+b$ 。

池化层原理是对卷积得到的较大特征图进行下采样,可以有效地缩小矩阵尺寸和纬度,进一步减少全连接层中的参数。池化层分为最大池化层和平均池化层,最大池化层取指定矩阵内参量的最大值,平均池化层取矩阵内所有参量的平均值。

全连接层位于输出层之前,卷积层和池化层之后。作用是综合之前学习到的所有特征,并再映射到最后的样本空间。具体来说就是将所有的神经元与上一层的所有神经元相连,输出 $1 \times N$ 的二维矩阵形式。全连接层得到的一维特征向量就是所需要的图像特征。

激活函数(activation function)是非线性函数,将神经元的信息激活并传入下一层,为解决非线性问题提供支撑。本文在卷积层后采用了 ReLU 函数,分类时采用了 Softmax 函数。

ReLU 函数可以用来解决梯度消失问题。当输入为非正数时,输出值全部为 0;当输入为正数时,输出值等于输入值,与卷积层搭配使用提高了神经网络的稀疏表达能力。其表达式为:

$$f=\max(0, x) \quad (4)$$

其中, \max 表示取二者中的最大值。Softmax 函数通常放在 CNN 的最后一层,用于对多种调制信号的分类。它的定义域是全体实数,值域是分布在 0~1 之间。其表达式为:

$$f_{x_j} = \frac{e^{x_j}}{\sum_{k=1}^K e^{x_k}} \quad (5)$$

其中, x_i 为函数输入, x_j 为函数输出。AlexNet^[15]网络是在 2012 年的 ImageNet 竞赛中取得冠军的一个模型。本文以 AlexNet 网络图像为基础设计特征提取的卷积神经网络。图像特征提取部分的网络包含 5 个卷积层、3 个最大池化层和 3 个全连接层,经过最后一个全连接层后得到 256×1 的图像特征向量。改造后的图像特征提取网络如表 2 所示。

表2 图像特征提取的网络结构

网络层	大小	卷积核	步长	通道数
图片	224×224			3
卷积层 1	55×55	11×11	4	48
最大池化	27×27	3×3	2	48
卷积层 2	27×27	5×5	4	128
最大池化	13×13	3×3	2	128
卷积层 3	13×13	3×3	1	192
卷积层 4	13×13	3×3	1	192
卷积层 5	13×13	3×3	1	192
最大池化	6×6	3×3	2	128
全连接 1	4 608×1			1
全连接 2	2 048×1			1
全连接 3	256×1			1

2 特征融合与分类

2.1 特征融合

如图 3 所示,特征融合步骤为:

- (1)对接收信号进行高阶累积量计算,获取一维数值特征向量;
- (2)采用时频分析方法画出接收信号的时频图;
- (3)将图像输入卷积神经网络提取其一维图像特征向量;
- (4)在全连接层将两类特征向量相联得到一维融合特征向量;
- (5)融合后的特征向量经过全连接网络进一步运算后通过分类器输出。




图3 特征融合示意图

其中时频图由中频信号提取,高阶累积量由基带信号获取,因此还需将中频信号进行正交下变频处理得到复基带调制信号。在实际发射和接收时其信号为实信号,首先通过希尔伯特变换得到接收信号 $s(t)$ 的解析信号:

$$z(t)=s(t)+j\hat{s}(t) \quad (6)$$

其中, $\hat{s}(t)$ 表示 $s(t)$ 的希尔伯特变换,再与复载波相乘得到复基带信号,即:

$$f_i(t)=z(t)e^{-j2\pi f_c t} \quad (7)$$

其中, f_c 为信号的载频,可通过分析频谱的峰值得到。经过时频分析和参数计算后,会得到两种不同的特征。其中时频图经过卷积神经网络的特征提取后得到 256×1

的图像特征向量。数值特征参数仅有两个,其长度远小于图像特征向量的长度,因此不能将这两类特征直接串联融合。为此提出了等权重特征融合的方法,将数值特征扩容,每类特征参数取 100 位,组成 200×1 的数值特征向量。在全连接层,图像特征向量与数值特征向量融合,形成 456×1 的融合特征。

2.2 模型训练与分类

特征提取与融合后,还需进行模型与分类器的训练。融合后的特征经过一个 256×1 和一个 6×1 的全连接层以及 Softmax 分类器得到分类的输出。给出该调制识别系统的模型,如图 4 所示。此外要使算法具备调制识别的功能,还需借助数据集进行训练,该网络模型的输入包含三维的图像数据与一维的高阶累积量数值数据,在输出端计算损失函数后,统一对特征提取层与全连接层的权值进行更新。本算法在网络训练时采用了 Adam^[16] (Adaptive Moment Estimation) 优化算法,利用梯度的一阶估计和二阶矩估计动态调整每个参数的学习率。

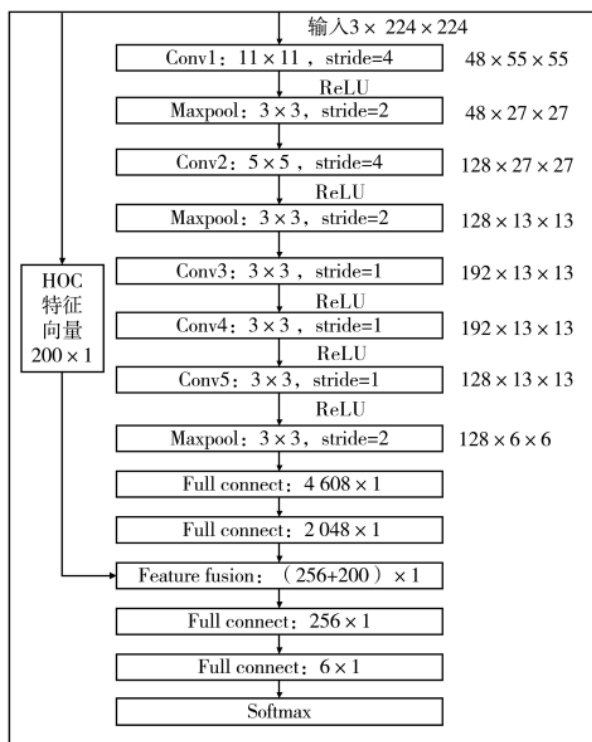


图 4 特征融合后神经网络模型结构示意图

3 仿真分析

本文所采用的信号数据集均由 MATLAB 生成,信号的频率为 10 kHz,采样率为 40 kHz,信号长度为 512。为了测试本文算法是否有提高识别率的效果,同样使用网络对信号变换后的时频图直接进行训练和测试,此外提取 5 个高阶累积量特征参数对这 7 种调制信号进行识别,得到不同信噪比下融合前后的平均识别率对比,如图 5 所示。可以看出,在 1 dB 条件下,经过特征融合平均识




图 5 融合前后识别率对比

别率提高了 10%~30%。

为更加清晰地看出模型对于每一类调制信号的识别效果,引入混淆矩阵。混淆矩阵的纵列表示数据真实类型,横排表示预测类型,对角线的数据即为预测准确率。通过混淆矩阵可以直观地看出算法预测的准确率,以及错判到哪些类型,作为特征选取的依据。首先给出单一图像特征和单一高阶累积量特征在 1 dB 识别的混淆矩阵,如图 6 和图 7 所示。

可以看出,时频图方法虽然对 ASK、FSK 类信号识

真实类别	2FSK	0.98	0.02				
	4FSK		1.00				
	4ASK			1.00			
	16QAM				0.80	0.16	0.04
	64QAM				0.14	0.28	0.40
	BPSK				0.26	0.10	0.48
	QPSK				0.24	0.18	0.36
		预测类别					
		2FSK	4FSK	4ASK	16QAM	64QAM	BPSK

图 6 时频图预测混淆矩阵

真实类别	2FSK	0.39	0.09	0.30		0.18	0.03
	4FSK		0.57	0.38	0.05		
	4ASK	0.02	0.19	0.66	0.11		
	16QAM				0.56	0.43	
	64QAM				0.16	0.84	
	BPSK				0.05	0.95	
	QPSK					0.18	0.82
		预测类别					
		2FSK	4FSK	4ASK	16QAM	64QAM	BPSK

图 7 高阶累积量预测混淆矩阵

别率高,但是对 PSK 和 QAM 类识别效果不理想,预测准确率不到 30%,而高阶累积量的方法对 PSK 和 QAM 的识别效果较好,因此融合高阶累积量特征以提高其整体的识别率。

图 8 为经过特征融合后在 1 dB 时的混淆矩阵,可以看出本文提出的特征融合的方法相比于单一图像特征对 PSK 和 QAM 类的预测平均准确率大幅提升,从不足 50%提高到了 70%以上,相比于单一数值特征,对 FSK 和 ASK 类的识别率提高到了 100%。也由于区分 16QAM 和 64QAM 的特征参数区分度不足,导致 QAM 类的识别率较低,这也是下一步需要改进的方向。实验证明本文算法在利用图像特征保持对 ASK、FSK 类信号较高水平的识别率的同时,通过加入高阶累积量特征进行特征融合,有效地提高了对 PSK 与 QAM 类信号的识别率。

2FSK	1.00						
4FSK		1.00					
4ASK			1.00				
16QAM			0.02	0.98			
64QAM					0.74	0.26	
BPSK						0.71	0.29
QPSK						0.27	0.73
	2FSK	4FSK	4ASK	16QAM	64QAM	BPSK	QPSK

图 8 特征融合后预测混淆矩阵

4 结论

本文对接收数字信号基于高阶累积量计算提取了两种特征参数,并通过时频分布获取时频图像并利用卷积神经网络提取图像特征,基于这两类特征的融合实现了对 7 种调制信号的识别。与仅使用时频图进行分类的算法对比,该算法具有结构清晰、区分度高以及抗噪声性能强的优点,在保持对 FSK 和 ASK 信号的高区分度的同时,明显地提高了低信噪比时的 PSK 与 QAM 类信号识别成功率,整体识别率提高了 10%~30%,在 1 dB 的条件下部分调制的识别准确率达到 100%。

参考文献

- [1] 李佩,王龙龙,陶丽伟,等.基于瞬时特征和 BP 神经网络的数字调制信号自动识别及实现[J].通信技术,2020,53(11):2635-2640.
- [2] 赵知劲,强芳芳,陈颖.利用高阶累积量的数字调制信号识别[J].杭州电子科技大学学报(自然科学版),2016,36(3):1-5.
- [3] PARK C S,CHOI J H,NAH S P,et al. Automatic modulation recognition of digital signals using wavelet features and

SVM[C]//2008 10th International Conference on Advanced Communication Technology. IEEE, 2008, 1: 387-390.

- [4] 徐茂,侯进,吴佩军,等.基于通信信号时频特性的卷积神经网络调制识别[J].计算机科学,2020,47(2):175-179.
- [5] 王志力,王玉文,蒋瑜.基于决策理论的信号调制识别改进算法[J].无线电工程,2014,44(5):30-33.
- [6] ZHANG Z,LI Y B,ZHU X L,et al. A method for modulation recognition based on entropy features and random forest[C]//Proceedings of the 2017 IEEE International Conference on Software Quality, Reliability and Security Companion. Prague: IEEE Press, 2017: 243-246.
- [7] JORDANOV I, PETROV N, PETROZZIELLO A. Supervised radar signal classification[C]//Proceedings of the 2016 International Joint Conference on Neural Networks. Vancouver: IEEE Press, 2016: 1464-1471.
- [8] ZHANG X L, CHEN J, SUN Z G. Modulation recognition of communication signals based on SCHKS-SSVM[J]. Journal of Systems Engineering and Electronics, 2017, 28(4): 627-633.
- [9] POPOOLA J J, OLST R. Automatic classification of combined analog and digital modulation schemes using feedforward neural network[C]//Proceedings of IEEE Africon'11. Livingstone: IEEE Press, 2011: 1-6.
- [10] 丁照雨,黄明,彭召敏,等.基于高阶累积量的数字调制方式识别设计[J].工业技术创新,2018,5(6):30-35.
- [11] WANG Y, LIU M, YANG J, et al. Data-driven deep learning for automatic modulation recognition in cognitive radios[J]. IEEE Transactions on Vehicular Technology, 2019, 68(4): 4074-4077.
- [12] ZENG Y, ZHANG M, HAN F, et al. Spectrum analysis and convolutional neural network for automatic modulation recognition[J]. IEEE Wireless Commun. Letters, 2019, 8(3): 929-932.
- [13] 盛鸿宇.雷达脉内调制信号的时频分析研究[J].湖南科技学院学报,2014,35(5):29-32.
- [14] 翁建新.基于机器学习的调制样式识别算法研究[D].杭州:杭州电子科技大学,2020.
- [15] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]//Advances in Neural Information Processing Systems, 2012: 1097-1105.
- [16] 张胜利,潘继飞,韩振中,等.基于 BP 神经网络的残缺 LFM 信号识别方法[J].电子信息对抗技术,2021,36(5):59-62,106.

(收稿日期:2022-03-01)

作者简介:

钱磊(1997-),男,硕士研究生,主要研究方向:电磁频谱管控技术与应用。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所