

文章编号: 2096-1618(2024)04-0430-06

# 基于人工智能的无线电信号调制方式识别

吴嘉巍<sup>1</sup>, 何杰<sup>2</sup>, 唐雨淋<sup>3</sup>

(1. 成都信息工程大学电子工程学院, 四川 成都 610255; 2. 四川天府新区科技创新和人才服务局, 四川 成都 624000; 3. 四川省无线电监测站, 四川 成都 610000)

**摘要:** 近年来越来越多无线电业务和机构的出现, 加剧了无线电电磁环境的恶化, 因此对无线电信号调制方式的识别是一个重要的研究方向。提出一种基于人工智能的无线电信号调制方式的识别方法, 通过利用不同的无线电信号在时频分析图上的特征差异, 使用 ResNet50 深度学习模型完成对无线电信号调制方式的识别分类, 在测试集上的识别准确率达 95%。通过对比此前基于传统神经网络的无线电调制方式的识别方法, 验证了识别结果的准确性和可靠性。实验结果表明, 该方法对于无线电信号调制方式的识别具有重要的参考意义。

**关键词:** 无线电信号; 人工智能; 调制识别; 时频分析

**中图分类号:** TP301.6

**文献标志码:** A

**doi:** 10.16836/j.cnki.jcuit.2024.04.006

## 0 引言

随着国家信息化战略的逐步推进, 无线通信广泛应用于各个领域, 但由于无线电终端和物联网设备的飞速增长, 导致无线电电磁环境恶劣。那么, 如何提高无线电信号监测的精度和稳定是一个极为重要的研究方向。

信号的调制是将某一波形的特征经过处理, 转变为另一种波形的过程。在这一过程中, 信号可通过调整振幅、频率和相位等参数, 从而实现适应不同传输媒介和通信环境的需求, 以提高信号的传输效率和可靠性。信号调制方式还可用于区分不同性质的通信信号, 若想正确实现解调和接收的无线电信号, 那么就得正确识别信号的调制方式, 从而进一步选择相应的解调方法。

近几年, 深度学习飞速发展, 并在图像领域<sup>[1]</sup>, 语音识别<sup>[2]</sup>以及自然语言处理取得了巨大成功。其中卷积神经网络(convolutional neural network, CNN)是图像领域和语音识别领域的强大特征提取器, 但由于更深层次的卷积神经网络很难训练, 因此 He 等<sup>[3]</sup>提出残差网络来简化更深层次网络的训练。

20 世纪 90 年代, 因为机器学习模型对无线电信号的识别具有良好的泛化性, 使传统机器学习模型在调制识别领域中成为主流, 但其过于依赖专家设计的特征。而近几年深度学习在人工智能领域的飞速发展, 许多学者将其与调制识别技术相结合<sup>[4-5]</sup>。2016 年, Q'shea 等<sup>[6]</sup>首次将 CNN 网络应用于调制识别领

域, 利用卷积神经网络框架对通信信号在 11 种调制方式下的信号进行调制方式识别, 相较于传统的机器学习模型, 识别率虽然有了极大的提升, 但信号在低信噪比时识别效果仍旧有待提高; 也有学者<sup>[7-10]</sup>将无线电信号的循环谱图或星座图作为信号特征, 并作为卷积神经网络的输入, 通过卷积层和子采样层交替进行对循环谱图或星座图的特征提取, 最后完成信号的调制识别, 但在识别精度上略显不足。因此本文提出一种通过提取无线电信号的时频分析图作为信号特征, 并选取残差神经网络(residual network, ResNet)对时频分析图进行特征提取的方法完成无线电信号调制方式的识别和分类。该方法在低信噪比下仍旧保持不错的识别精度, 识别原理如图 1 所示。

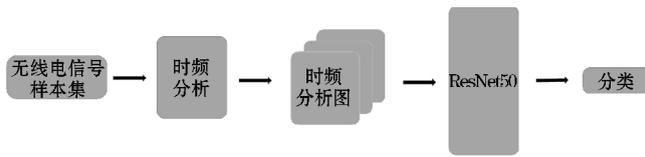


图 1 基于人工智能的无线电信号调制识别方法

## 1 无线电信号仿真

在实际应用中, 无线电接收机接收到的信号模型:

$$x(t) = s(t) + n(t) \quad (1)$$

式中,  $x(t)$  为接收到的无线电信号,  $s(t)$  为理想无线电信号,  $n(t)$  为噪声。

根据该模型, 对 LFM, NLFM, 2FSK, QPSK, AM 这 5

种调制方式无线电信号进行仿真建模。以线性调频信号(LFM)为例,LFM信号因其具有良好的速度分辨率和距离分辨率而多用于雷达信号,其公式如下:

$$s(t) = Ae^{j2\pi(f_c + \frac{1}{2}kt^2 + \varphi)} \quad (2)$$

式中, $A$ 为幅度, $f_c$ 为载波频率, $k$ 为调频斜率, $k = T/B$  ( $B$ 为信号带宽, $T$ 为脉冲宽度), $\varphi$ 为初相位。其理想时域、频域波形如图2所示。根据式(1)的模型对实际接收到的LFM信号建模,则接收到的实际LFM信号的时域和频域如图3所示。从图3可以看出,由于信号的时域和频域被噪声严重干扰。如果考虑将频域图作为信号调制方式的识别特征,那么会导致对信号调制方式的识别难度增大。

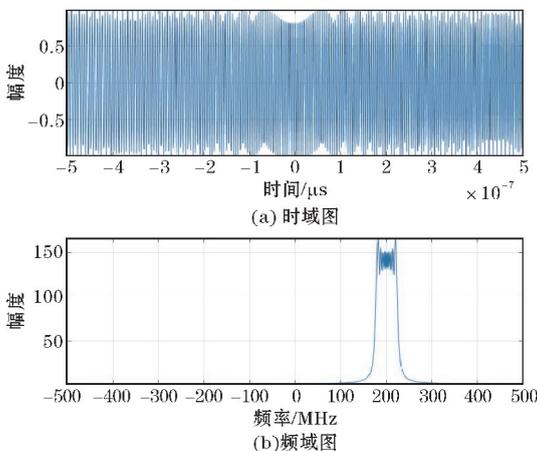


图2 LFM信号时域图和频域图

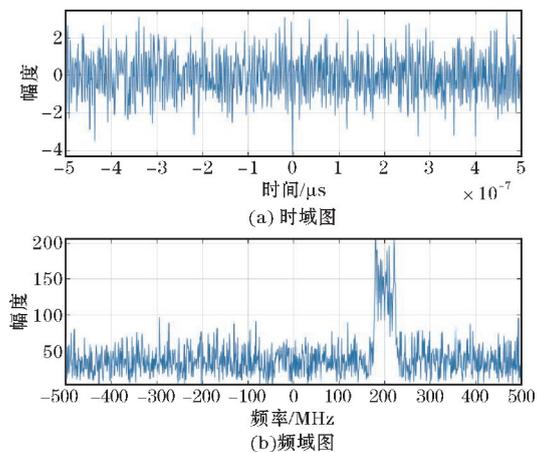


图3 加噪后LFM信号时域图和频域图

## 2 无线电信号特征分析及调制识别

### 2.1 时频分析

在对信号进行特征的提取和分析时,时频域往往比时域或频域更具有优势,因为时频域能更好地反映

信号频率随时间的变化规律,具备对信号进行局部分析的能力,因此本文以时频分析法为主要研究内容。

时频分析法是通过构造一个时频联合的函数来表示不稳定信号,该函数可准确地表现信号的频谱信息在时域和频域中分布的规律。以时频分析中的Wigner-Ville分布和Choi-Williams分布作为主要研究方向。

#### 2.1.1 Wigner-Ville分布

Wigner-Ville分布(WVD)作为时频能密度函数中重要的一员,有着良好的时频聚集性和时频分辨率<sup>[11]</sup>,因此WVD是一种实用的非平稳信号分析工具。相较于短时傅里叶变换(STFT)和小波变换,WVD能将信号的能量集中到特征平面当中。对于信号 $s(t)$ 的Wigner-Ville分布如下:

$$\text{WVD}_s(t, \omega) = \int_{-\infty}^{+\infty} s(t + \frac{\tau}{2}) s^*(t - \frac{\tau}{2}) e^{-j\omega\tau} d\tau \quad (3)$$

式中, $\tau$ 为时间延迟, $r_s(t, \tau)$ 是信号的时间自相关函数。

#### 2.1.2 Choi-Williams分布

由于在实际应用中信号是多分量叠加组成的,WVD会在多分量信号之间产生互时频分布,即交叉项,造成一些虚假信息的干扰<sup>[12]</sup>,严重影响信号的分析,如果信号分量增加,则交叉项的影响更为严重,这便是WVD最大的缺陷。而Cohen类分布很好地解决了这一问题,本文选取Cohen类分布中的Choi-Williams分布(CWD),CWD相较于WVD,其对交叉项的具有很好的抑制作用,对不同时域或频域信号具有较高的分辨能力。信号 $s(t)$ 的Choi-Williams分布表达式如下:

$$\text{CWD}_s(t, \omega) = \iint \frac{1}{\sqrt{\tau^2/\sigma}} \exp(-\frac{(t-u)^2}{4\tau^2/\delta}) s(u + \frac{\tau}{2}) s^*(u - \frac{\tau}{2}) du d\tau \quad (4)$$

核函数公式如下:

$$\Phi_{\text{CWD}}(\theta, \tau) = \exp(-\frac{\theta^2 \tau^2}{\sigma}) \quad (5)$$

式中, $\sigma$ 为常数,可通过调节 $\sigma$ 来控制交叉项相对下降。 $\sigma$ 的大小与Choi-Williams分布对交叉项的抑制成反比, $\sigma$ 越大,核函数越平缓,对交叉项的抑制作用较小,信号的时频聚集变高;而 $\sigma$ 越小,核函数在原点处便可达到峰值,两侧则迅速下降,对交叉项的抑制作用较大,但信号的时频聚集性变低<sup>[13]</sup>。

以载频 $f_1$ 为200 MHz, $f_2$ 为250 MHz的2FSK仿真信号为例,由于2FSK信号具有两个频率分量,若使用WVD进行时频分析,那么很明显能在图4看出200 MHz和250 MHz之间存在着交叉项。

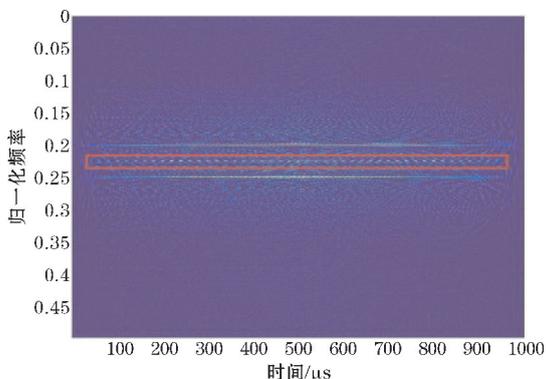


图4 2FSK 信号的WVD图

作为对比,同样以上述的2FSK为例,用CWD对其进行时频分析后,交叉项得到了很好的抑制,如图5所示。

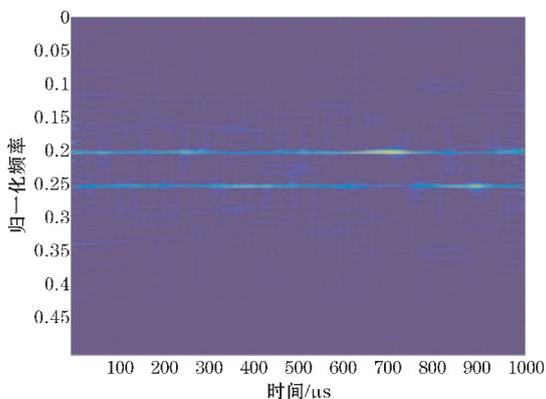


图5 2FSK 信号的CWD图

## 2.2 信号的调制识别

### 2.2.1 ResNet 残差神经网络

传统卷积神经网络会随着网络深度的增加导致退化问题的出现,即随着网络深度加深,出现训练集准确率下降的现象。而残差神经网络 ResNet 引入残差网络单元,通过在残差网络单元包含了跨层连接<sup>[3]</sup>,如图6所示。图6中的曲线可直接将输入跨层传输,进行了同等的映射,最后和卷积操作的结果相加。

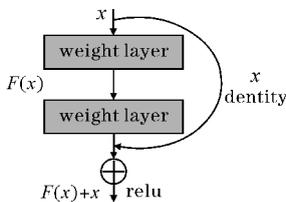


图6 残差网络单元

本文选取 ResNet 系列中的 ResNet50 网络模型作为信号调制识别模型。ResNet50 网络包含了 49 个层卷积层,1 个全连接层。整个网络结构可分为 7 个部分:第 1 部分,不含残差块,主要负责对输入数据进行卷积、正则化、激活函数、最大池化等计算;第 2~5 部分均包含了残差块,且每个残差块有 3 层卷积;然后将

经过这 5 部分卷积计算的结果送入第 6 部分池化层,将其转化为一个特征向量;最后由第 7 部分的分类器通过对这个特征向量进行计算输出类别概率。其网络结构如图 7 所示。

layer name	output size	50-layer
conv1	112×112	7×7,64, stride2
conv2_x	56×56	3×3, max pool, stride2
		$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$
conv4_x	14×14	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$
conv5_x	7×7	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax

图7 ResNet50 网络结构图

### 2.2.2 数据集

本文主要以雷达信号和短波信号为主要研究对象,这两类信号所采用的主要调制方式如表 1 所示。

表1 两类信号的调制方式

信号种类	调制方式
雷达信号	LFM, QPSK, NLFM
短波信号	AM, 2FSK

根据这两类信号的调制方式分别进行仿真。为了使训练出的模型更具有健壮性,还加入了 900 个非上訴调制方式的干扰信号并构造了复杂的电磁环境,即向仿真信号中加入热噪声、高斯白噪声、气象噪声进行干扰,使得仿真信号数据的信噪比为-5~5 dB 总计仿真出 5680 个加噪后的无线电信号样本,如表 2 所示。对所有仿真信号样本数据集进行时频分析,将时频分析图分辨率设为 224×224,如图 8 所示。

表2 仿真信号的数量

调制类型	数量
LFM	1100
NLFM	700
QPSK	1000
2FSK	1100
AM	880
干扰信号	900

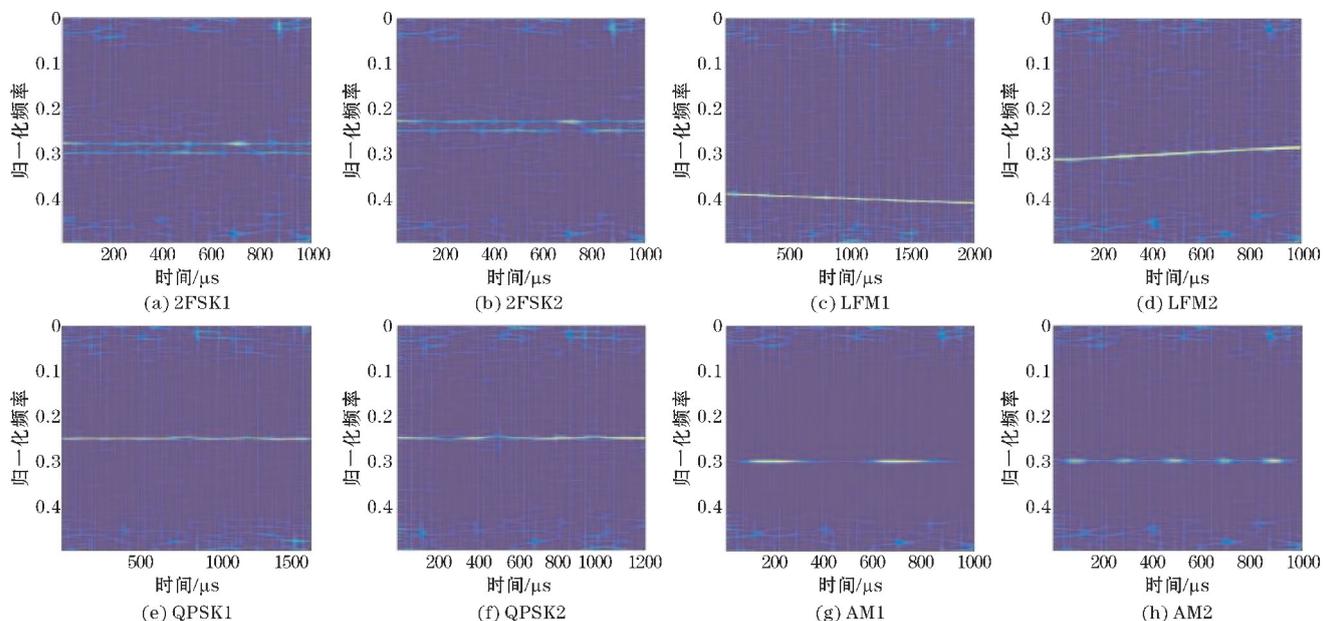


图 8 部分无线电信号仿真信号的 CWD 图

再将无线电信号数据集进行划分,其中训练集数量为 4000 个,测试集数量为 1680 个。

### 2.2.3 模型训练

实验在 TensorFlow2.10 版本的深度学习框架下采用 ResNet50 完成对无线电信号的调制识别,运行环境为:Windows11,NVIDIA Geforce RTX 3060,CUDA 11.6,Memory 32GB。实验步骤如下:

步骤 1 数据预处理,首先对 CWD 图进行旋转、翻转、缩放等操作实现数据增强,再对图像数据进行归一

化、色域变换等操作,最后对图像数据进行裁剪操作;

步骤 2 设置模型超参,将 Batch size 设为 20,迭代次数为 200 次,学习率为 0.001,优化器为 Adam,学习率下降方式为 cos;

步骤 3 训练网络,训练出 ResNet 模型的权重,训练时间约 5 小时;

步骤 4 使用训练好的网络对无线电信号进行预测,预测结果如图 9 所示。

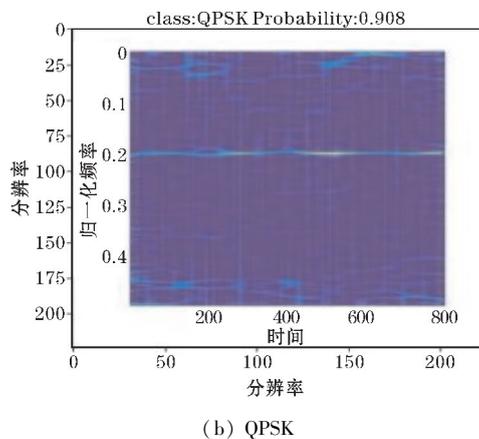
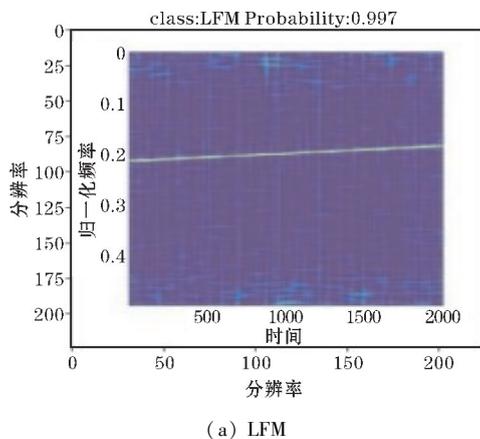


图 9 预测结果

## 3 实验结果及分析

为验证残差神经网络对于低信噪比信号调制识别上的优越性,对无线电信号数据集分别采用经典传统卷积神经网络模型 VGG16 和残差神经网络模型 ResNet50 进行对比实验。分别使用上述两种模型训练出的.h5 权重文件,对同一批信噪比低于 5 dB 无线电信号仿真的

CWD 时频分析图进行检测,结果如表 3 所示。

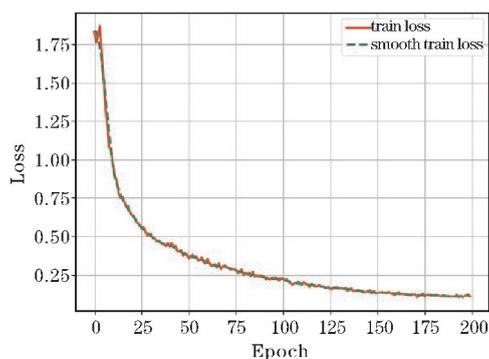
表 3 实验结果对比 单位:%

算法模型	VGG16	ResNet50
WVD	82.19	87.73
CWD	89.85	95.03

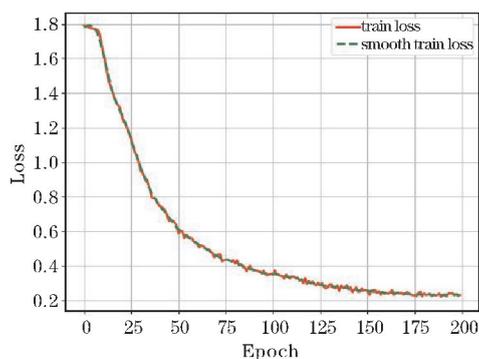
从损失函数图(图 10)可以看出,ResNet50 对于低信噪比的无线电信号调制方式的识别效率及损失函数

的收敛速度要高于传统卷积神经网络。从表3可以看出,在识别结果上 ResNet50 相较于 VGG16 提升6.8%左右的准确率。因此,残差神经网络对于低信噪比的

无线电信号调制识别的精度上有了提升,验证了残差神经网络在无线电信号调制识别上的优越性。



(a) ResNet50



(b) VGG16

图10 ResNet50、VGG16的loss函数图

此外,还将此前仿真的5680个无线电信号进行WVD时频分析,并对比CWD和WVD两者识别的差异。从表3看出,CWD的识别率高于WVD的原因:首先是CWD很好地抑制了交叉项所带来的干扰,避免跟某些干扰信号类似,使识别准确率提升;其次是噪声的干扰对于WVD的影响极其严重,导致以WVD图为识别特征时,模型的识别准确率不高。以LFM信号为例,在处于低信噪比时,由于整个图已经被噪声所淹没(图11),导致识别率不高,而CWD则不然。从表3可以看出,无论那种模型,CWD的识别率均高于WVD的识别率。

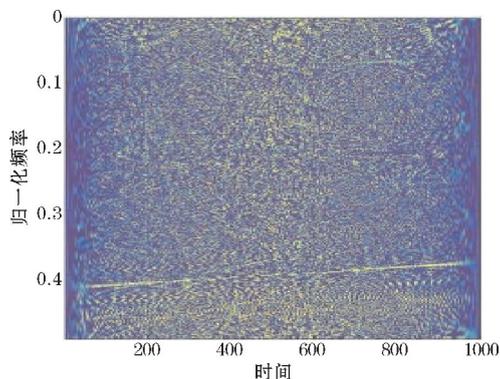
实验结果进一步验证了采用Choi-Williams分布这一时频分析方法对无线电信号进行特征分析及提取并结合ResNet50模型,能够有效完成在低信噪比情况下对无线电信号调制方式的识别。因此在面对大量无线电信号样本数据时,基于人工智能的无线电信号调制识别在准确率和效率上是具有极大优势的,而且还避免了传统方法依赖人为选取特征的问题,具有强大的特征提取能力。

## 4 结束语

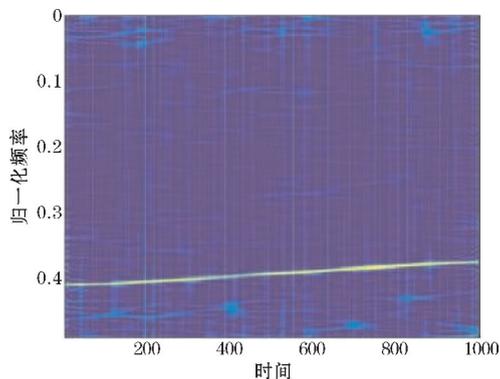
无线电信号调制方式识别作为无线通信领域的一重要研究方向,在各领域都得到广泛应用。针对不同调制方式的无线电信号在时频分析上特征的不同展开研究,结合现有的深度学习算法,建立基于ResNet50的无线电信号调制识别方法。通过将CWD图分别作为输入数据,利用ResNet残差网络对其进行特征提取,最后利用全连接层和softmax分类器完成对无线电调制方式的识别,准确率高达95.03%。该方法相对于传统的卷积神经网络,能够在低信噪比下更好地识别出无线电的调制方式,有效地解决低信噪比下无线电信号的调制识别问题。但研究仍具备一定的局限性:首先,数据为仿真数据,导致数据不如实际数据具有多样性;其次,只采用了时频分析图作为特征,特征单一。在未来的工作中应收集真实无线电信号数据做进一步的研究,同时尝试将信号的频域、时域特征的参数作为深度学习模型的输入。

## 参考文献:

[1] Deng J, Dong W, Socher R, et al. ImageNet: A



(a) WVD



(b) CWD

图11 低信噪比下的WVD图和CWD图

- large-scale hierarchical image database [C]. 2009: 248–255.
- [2] Sainath T N, Weiss R J, Senior A, et al. Learning the speech front-end with raw waveform CLDNNs [C]. Conference of the International Speech Communication Association. ISCA, 2015.
- [3] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 2016.
- [4] Wang Yu, Guo Liang, Zhao Yu, et al. Distributed Learning for Automatic Modulation Classification in Edge Devices [J]. IEEE Wireless Communications Letters, 2020, 9(12): 2177–2181.
- [5] Kato Nei, Mao Bomin, Tang Fengxiao, et al. Ten Challenges in Advancing Machine Learning Technologies toward 6G [J]. IEEE Wireless Communications, 2020, 27(3): 96–103.
- [6] O’Shea, Timothy J Corgan, Johnathan Clancy, et al. Convolutional Radio Modulation Recognition Networks [C]. 17th International Conference on Engineering Applications of Neural Networks, 2016.
- [7] 何江. 数字信号调制方式的识别 [D]. 南京: 南京邮电大学, 2013.
- [8] 樊昌信, 曹丽娜. 通信原理 [M]. 北京: 国防工业出版社, 2012: 176–177.
- [9] Vitetta G M, Taylor D P. Multi-Sampling receivers for uncoded and coded PSK signal sequences transmitted over Rayleigh frequency-flat fading channels [J]. IEEE Transactions on Communications, 1996, 44(2): 686–695.
- [10] Levanon N. Multifrequency complementary phase-coded radar signal [J]. IEE Proceeding S-Radar Sonar And Navigation, 2000, 147(6): 276–284.
- [11] Flandrin P, Rioul O. Affine smoothing of the Wigner-Ville distribution [C]. 1990 International Conf On Acoustics, Speech And Signal Processing, 1990.
- [12] Liu Y, Xiao P, Wu H, et al. LPI radar signal detection based on radial integration of choi-williams time-frequency image [J]. Journal of Systems Engineering and Electronics, 2015, 26(5): 973–981.
- [13] Lazorenko O V. Ultrawideband Signals and Choi-Williams Transform [C]. International Conference on Ultrawideband and Ultrashort Impulse Signals, Sevastopol, Ukraine, 2006: 300–302.

## Recognition of Wireless Radio Signal Modulation Methods based on Artificial Intelligence

WU Jiawei<sup>1</sup>, HE Jie<sup>2</sup>, TANG Yulin<sup>3</sup>

(1. College of Electronic Engineering, Chengdu University of Information Technology, Chengdu 610225, China; 2. Sichuan Tianfu New Area Science and Technology Innovation and Talent Service Bureau, Chengdu 624000, China; 3. Sichuan Provincial Radio Monitoring Station, Chengdu 610000, China)

**Abstract:** In recent years, the proliferation of wireless radio businesses and organizations has exacerbated the degradation of the electromagnetic environment. Therefore, the identification of modulation methods for wireless radio signals has become a crucial research focus. This paper proposes an AI-based method for recognizing modulation methods of wireless radio signals. By leveraging the distinctive features of different wireless radio signals in time-frequency analysis plots, the ResNet50 deep learning model is employed for the classification of modulation methods. The recognition accuracy on the test set reaches 95%. Comparative analysis with traditional neural network methods validate the accuracy and reliability of the proposed approach. Experimental results indicate the significance of this method in the recognition of wireless radio signal modulation methods.

**Keywords:** radio signal; artificial intelligence; modulation recognition; time-frequency analysis