

DOI:10.19651/j.cnki.emt.2210805

基于CWD谱图和改进CNN的无线电调制分类*

李宝平 魏坡

(河南理工大学物理与电子信息学院 焦作 454003)

摘要: 针对频率随时间的变化规律是不同调制信号之间最重要的区别,提出一种结合崔-威廉斯分布和改进卷积神经网络模型的无线电调制分类识别方法。在信号预处理阶段,为了更好保留信号的时频特征,引入崔-威廉斯变换将原始时间序列转换成时频图像,进而将调制信号分类问题转化成图像识别问题。在信号识别阶段,通过在卷积神经网络模型中引入残差密集块和全局平均池化层,以克服卷积神经网络模型泛化能力差和训练时间久等缺点。实验结果表明,所提方法可以有效解决梯度消失问题,具有识别率高、泛化能力强等优点。尤其是在低信噪比情况下,表现更为优异,在信噪比为 -4 dB时,8种信号的分类精度便可达到100%。

关键词: 无线电调制分类;崔-威廉斯分布;卷积神经网络;残差密集块

中图分类号: TN911.3 **文献标识码:** A **国家标准学科分类代码:** 510.40

Radio modulation classification based on CWD spectrogram and improved CNN

Li Baoping Wei Po

(School of Physics and Electronic Information, Henan Polytechnic University, Jiaozuo 454003, China)

Abstract: As the variation law of frequency with time is the most important difference between different modulated signals, a radio modulation classification and recognition method combining Choi-Williams distribution and improved convolutional neural network model is proposed. In the signal preprocessing stage, in order to better retain the time-frequency characteristics of the signal, the Choi-Williams transform is introduced to transform the original time series signal into time-frequency image, and then the modulation signal classification problem is transformed into an image recognition problem. In the signal recognition stage, the convolutional neural network model is introduced with residual dense blocks and global average pooling layer to overcome the shortcomings of poor generalization ability and long training time of convolutional neural network model. Experimental results show that the proposed method can effectively solve the problem of gradient disappearance, and has the advantages of high recognition rate and strong generalization ability. Especially in the case of low SNR, the performance is even better. When the SNR is -4 dB, the classification accuracy of 8 kinds of signals can reach 100%.

Keywords: radio modulation classification; Choi-Williams distribution; convolutional neural network; residual dense block

0 引言

无线电调制分类是认知无线电系统频谱资源管理、无线信号检测与定位等非合作无线通信应用的基础。有效的调制分类是实现无线环境感知的重要前提^[1-2]。随着通信调制技术发展及无线通信系统的大规模增长,导致无线环境日益复杂,已让传统大的基于人为设计特征的检测方法^[3]难以为继,识别准确率下降。

自动调制分类(automatic modulation classification, AMC)^[4-5]技术则日趋成熟。AMC是在预先不知道接收到的无线电信号和信道信息的情况下识别信号类型的过程。AMC主要分成两种:基于似然的方法(likelihood-based, LB)^[6]和基于特征(feature-based, FB)^[7-8]的方法。LB方法通过贝叶斯估计实现,需要大量先验知识,计算量大且优化困难,极大限制了识别算法在复杂环境下识别无线电目标的精确度。近些年,随着人工智能发展,深度神经网络已

收稿日期:2022-07-24

* 基金项目:河南省科技攻关项目(212102210557)、河南理工大学博士基金(B2017-55)项目资助

广泛应用于机器翻译、语音识别和图像识别等诸多场景中,深度学习技术也被引入到FB方法中并逐渐成为无线信号分类识别的主流方案。文献[9]将卷积神经网络(convolutional neural network, CNN)应用于AMC中,与传统的手工提取特征方法相比,其在无线电信号识别上表现更加优异。文献[10]通过引入递归神经网络学习信号的时间表征,将信号的识别精度由80%提高到91%。

上述方法虽然对模型有所改进,但在数据处理阶段,始终仅从时间这一维度来获取信号特征,具有一定片面性,这就导致了识别精度在低信噪比(signal-to-noise ratio, SNR)下无法取得突破性进展。近几年,研究学者尝试利用时频转换技术提取信号特征,文献[11]采用崔-威廉斯分布(choi-williams distribution, CWD)提取二维时频图像(time-frequency images, TFIs)的奇异谱熵特征,使得8种信号在SNR为4 dB时识别率达到100%。文献[12]通过CWD从TFIs中提取信号特征,在SNR为-2 dB时准确率达到94.7%。文献[13]提出了连续小波变换,也取得了令人满意的识别效果。但上述文献均在时频转换的基础上通过其他手段来获取信号特征,通过人工设计特征线性组合后再采用各种识别方法来分类,他们并没有把TFIs的本身作为出发点。而文献[14]利用平滑伪Wigner-Ville分布进行TFIs转换,并通过CNN进行信号特征提取和识别,该方法实现了对图像深层次特征进行自动提取,免去了人

工提取的繁琐。但是,平滑伪Wigner-Ville变换通过加窗操作会破坏信号的一些边缘特性,在低SNR条件下,TFIs中仍然存在大量背景白噪声,对信号的纹理特征提取造成严重干扰。总体而言,基于时频域转换的算法通常比传统手工设计特征提供更好的脉内信号特征,具有更好的环境适应性。

基于上述条件和问题,在本工作中,提出了一种新的基于CWD谱图和带有残差结构的CNN的无线电调制分类方法。其中,CWD时频分布在所有未经处理的Co-hen类分布中具有交叉项干扰小的优势,转换后的TFIs拥有高清晰度。在CNN中引入残差密集块(residual dense blocks, RDB)拓展网络深度,实现对TFIs的深层次特征提取。从而达到低SNR环境下提高调制信号识别准确率的目的。先利用CWD变换将原始的一维信号转换为二维TFIs;再将预处理后带有时频特征的数据输入到嵌有RDB的CNN体系结构中进行识别。实验结果表明,与循环谱图、小波变换等TFIs转换方法相比,该方法具有更好的识别准确率,尤其是在低SNR情况下。

1 系统概述

基于CWD谱图和带有RDB的CNN的调制信号识别系统的组成结构如图1所示,该系统包括两个核心部分:数据预处理部分和分类识别网络部分。

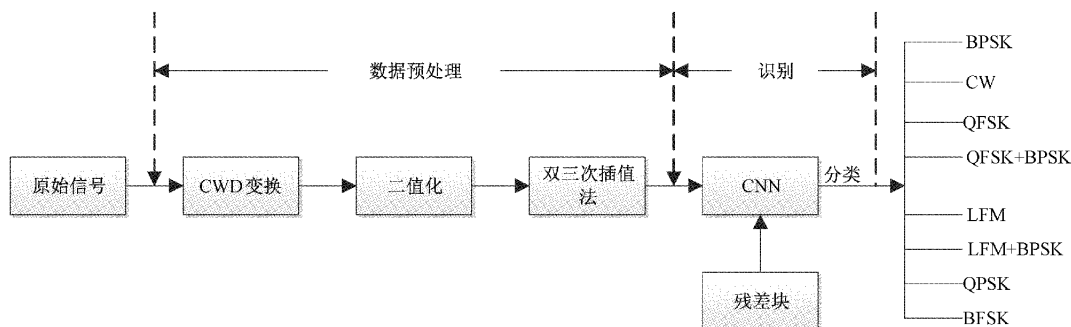


图1 系统结构

在第1部分中,采用CWD变换将无线电调制时间序列信号转换成TFIs,然后通过二值化和双三次插值等图像处理的方法对TFIs图像进行预处理。至此,将无线电信号分类识别问题转换为图像分类识别问题。

在第2部分中,为了避免CNN随着网络深度的增加,系统性能弱化,模型收敛变慢以及过拟合等现象,我们在CNN中设计了一个RDB结构,通过嵌入RDB模块,保证神经网络在提取信号高层次特征的同时,可令任意低层的特征映射直接传播到高层,使模型更易于优化。因此,本文采用RDB结构作为特征提取器,并通过批标准化(batch normalization, BN)处理来加速模型收敛和提升识别精确度。将前面经过预处理的TFIs图像作为模型的输入,通过分类网络来识别调制信号类型。

2 数据的生成与处理

本节将介绍两部分内容:1)信号模型、生成调制信号的详细参数,以及用以生成调制信号数据集。2)CWD时频分析方法,可以将无线电调制时间序列信号转换为TFIs图像。通过二值化和双三次插值法对图像进行预处理,并将结果图像作为分类网络的输入。

2.1 信号模型

调制信号识别技术在无线通信系统中发挥着重要作用。如图2所示,发射器、信道和接收器是无线通信系统的主要组成部分。其中,接收器接收到的调制信号通常表示为:

$$r(t) = s(t) * h(t) \quad (1)$$

其中, $r(t)$ 是用来表示接收器最终接收到的信号类型, $s(t)$ 是源数据经过调制后的信号, 信道效用用 $h(t)$ 来表示, 符号“ $*$ ”代表卷积操作, $n(t)$ 是信道中方差为 σ^2 的加性高斯噪声。




图 2 无线通信系统组成

2.2 信号生成

本文数据集由模拟无线电信号样本组成, 表 1 给出了调制样本的参数描述。所有信号长度均为 1 024, 采样频率为 20 MHz, 为了更加贴近真实环境, 在信号中加入了高斯白噪声。

表 1 调制无线电信号的参数描述

信号类型	参数	范围/MHz
BPSK	载频	[0.2, 5]
CW	载频	[0.2, 5]
QFSK	基准频率	[0.2, 1]
QFSK+BPSK	基准频率	[0.2, 1]
LFM	载频	[0.2, 5]
	带宽	[0.2, 3]
LFM+BPSK	载频	[2, 2.5]
	带宽	[1, 2]
BFSK	基准频率	[0.2, 2]
QPSK	载频	[0.2, 5]

制作数据集包含 8 种调制类型(BPSK、CW、QFSK、QFSK+BPSK、LFM、LFM+BPSK、QPSK 和 BFSK)。在建立数据集时, 在相同 SNR 条件下, 每种信号会随机产生 1 000 个样本, 对每一类信号在 $-10 \sim 10$ dB(步长为 2 dB) SNR 变换范围内共产生 88 000 个样本。每种信号每个 SNR 下拿出 800 个样本用于训练, 剩余的 200 个样本用于测试。

2.3 CWD 时频变换

时频分析是处理非平稳信号的重要方式之一。相较于 STFT 和 WVD 等时频处理方法, CWD 的时频变换具有良好的时频分辨率, 其在保证 TFIs 的时间分辨率和频率分辨率二者可以兼得的前提下, 还可以有效抑制和消除交叉项的影响。CWD 变换公式如下:

$$CWD_s(t, \omega) = \iint \sqrt{\frac{\sigma}{4\pi\tau^2}} e^{\frac{\sigma(u-\tau)}{2}} s(u + \frac{\tau}{2}) \cdot s^*(u + \frac{\tau}{2}) e^{-j\omega\tau} du d\tau \quad (2)$$

其中, t 和 ω 分别表示时间变量和角频率变量 ($\omega = 2\pi f$); σ 为衰减系数, 它与交叉项的振幅成正比, 本文设置为 1。

利用 CWD 变换将 8 种调制信号的时域图转换为 TFIs, 图像尺寸设为 $256 \times 256 \times 3$ 。由此得到单个信号单个 SNR 条件下均包含 1 000 个样本的图像数据集。图 3 显示了 SNR 为 6 dB 时上述 8 种信号经过 CWD 变换后的 TFIs, 由此可直观表明不同信号的 TFIs 可以提供可区分的信号特征。因此, 将计算机视觉图像识别技术应用于无线电调制分类是合理且适宜的。




图 3 信噪比为 6 dB 时 8 种信号的 CWD 时频图像

2.4 图像预处理

经过 CWD 变换后的 TFIs 易受到噪声和交叉项的影响。为了后期分类更加准确, 需要在 TFIs 特征提取之前对其进行预处理, 以便减少干扰项和冗余信息, 从而提高特征提取的有效性。以 QPSK 信号为例, 图 4 是 SNR 为 6 dB 的 QPSK 信号的图像预处理流程。




图 4 时频图像预处理过程

在预处理过程中, 首先对 TFIs 进行二值化处理, 这是为了凸显出信号特征的轮廓, 减少噪声的干扰。为了提高识别效率, 需要对图像进行裁剪以减少计算量, 以往常用双线性插值法来缩小图像尺寸, 但拟合效果不甚理想。本文采用双三次插值法^[15]将 TFIs 尺寸缩放到 64×64 , 双三次插值法不仅可以使缩放后的 TFIs 保留更高的分辨率, 而且可以保证 TFIs 中的边缘更加平滑。

3 嵌入残差块的卷积神经网络

考虑到 TFIs 的分类要求, 设计了一个基于 ResNet 架构的 CNN。底层仍然使用卷积层, 而较高层使用 RDB。这样的网络结构更有利于特征提取和信号分类。

3.1 卷积神经网络

CNN 与传统的浅层神经网络不同之处在于它是一种特殊的深度前馈神经网络, 其通过多层非线性变化从

数据中提取特征,具有很强的学习能力和表征能力。此外,CNN 更加易于对数据进行预处理,适用于模式识别领域。

卷积层通过卷积核对输入的 TFIs 进行特征提取,得到特征图。其中,采用多个卷积核可以同步提取多个不同的时频特征。CNN 最大的优点是通过权值共享和局部连接在显著减少训练参数的同时极大的简化网络。为了减少计算量,降低下一层的输入维数,达到防止出现过拟合现象的目的,在本文中,使用最大池化和全局平均池化(global average pooling, GAP)这两种方法来进行下采样。GAP 用来代替平坦层,它可以进一步减少模型的训练参数,从而提高模型的训练速度。

3.2 RDB 结构

在 CNN 深度学习模型中,梯度消失问题会随着网络深度的增加而变得愈发明显。为了解决这个问题,RDB 让网络中各层直接相连,使各层之间能够最大限度地传输信息。本文基于网络各层之间身份捷径连接的思想,提出利用 RDB 来充分提取 TFIs 中的特征信息,从而使得梯度信号的传输更加高效,由此解决深度网络中梯度消失和模型训练困难的问题。

本文设计的基本残差单元模型如图 5 所示,通过一个捷径连接,将输入数据直接越过两个卷积层与输出相连,这条线路不会有权重产生,故可以避免输入数据特征丢失的问题,从而提升网络的学习性能。若基本残差单元中卷积层的功能用 $F(\cdot)$ 表示,那么基本残差单元的计算公式可以表示:

$$x_{i+1} = \text{ReLU}(F(x_i) + x_i) \quad (3)$$

其中, x_i 表示基本残差单元中第 i 个输入, x_{i+1} 表示基本残差单元的输出,ReLU 表示激活函数,它的作用是通过卷积层输出的特征数据进行非线性运算,其表达式为:

$$\text{ReLU}(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (4)$$

通过链式法则和反向传播算法可以得出,第 i 层基本残差单元的梯度为:

$$\frac{\partial x_{i+1}}{\partial x_i} = \frac{\partial \text{ReLU}}{\partial (F(x_i) + x_i)} \cdot \frac{\partial (F(x_i) + x_i)}{\partial x_i} = \frac{\partial F(x_i)}{\partial x_i} + 1 \quad (5)$$

由此可知,若 $F(\cdot)$ 为 0,与常见的 CNN 结构不同之处在于基本残差单元输出的梯度会多 1,而当 $F(\cdot)$ 不为 0,所获得的基本残差单元的梯度也要优于单纯输入 x 。这就避免了残差变化小时容易出现梯度消失的问题。因此,与常见的 CNN 模型相比,即使网络深度增加,RDB 在获得良好分类效果的同时也能避免梯度消失的问题。




图 5 基本残差单元模型

本文设计的 RDB 结构如图 6 所示,它由 1 个卷积层(卷积核尺寸为 1×1)、两个基本残差单元和一个池化层三部分组成。其中, 1×1 卷积层在起到降维作用的同时也加深了网络的深度,减少网络训练的参数,加快网络的学习速度,增强了模型的表征能力。残差单元主要包含了一个捷径连接和两个卷积层,在每一次卷积过后都需经过 BN 层将输出数据进行归一化,使得下一层可以忽略掉输入数据中的偏移量,让网络更加专注于如何更好的组合特征,从而解决梯度消失和爆炸的问题,增强了网络的非线性表达能力,提高了网络的收敛速度。由于模型中 RDB 里的连接数量过多,因此使用 Dropout 正则化来随机减少参数运算,以避免过拟合,增强网络的泛化能力。最后的池化层本文选择了最大池化,因为它不仅在降低特征维度的同时能够很好的保留时频图像的纹理特征,还具有平移不变性这一优点。



图 6 RDB 结构

3.3 改进的 CNN 模型

本文所设计模型结构如图 7 所示,输入数据首先通过一个过滤器数量为 16 的卷积层,再经过池化层后送入到 5 个残差密集块中,这 5 个残差密集块中过滤器的数量依次为 16、32、64、128 和 256,卷积核的尺寸为 (5,5),池化层的尺寸统一设置为 (2,2),最后经过全局平均池化层、全连接层和 Softmax 函数输出分类结果。模型中用全局平均池化层代替平坦层对特征数据进行降维,这可以有效减少网络参数,并防止网络过拟合,从而提高网络的训练速度。




图 7 本文提出的模型

4 实验结果与分析

本节给出基于本文所设计模型的调制信号识别性能分析。本文采用交叉熵损失函数作为网络的损失函数来刻画模型预测输出概率与真实输出概率的距离。模型将提取到的信号 TFIs 特征输入到 Softmax 层,其后通过反向传播算法来最小化损失函数,也就是让预测样本类型和实际样本类型之间的误差最小。

4.1 实验平台

本文的实验平台:处理器为 Intel(R) Core(TM) i5-3470 CPU@3.20 GHz,基于 Nvidia GeForce RTX 3090 图形处理器进行加速运算。深度学习环境通过 Keras 库来搭建网络,并用 Tensorflow 作为后端。

4.2 网络参数设置

将经过预处理的 TFIs 数据输入到嵌有 RDB 的 CNN 中进行训练。在深度学习中,通常用损失函数和准确率作为评价模型分类性能的指标。为了证明本文所使用的参数具有最优性以及相较于其它优化算法是否具有优势,接下来本文将从优化器、学习率和激活函数的选定等多方面来实验本文所使用参数的优越性。

1)不同优化器的比较

为了证明 Adam 优化器相较于其他优化器能够更加高效地优化本文所设计的模型结构,针对不同优化器对算法识别性能的影响进行了对比实验,实验结果如图 8(a)和(b)所示。其中,学习率设为 0.000 5,动量 Momentum 的值为 0.8。结果表明,SGD 优化器的收敛速度最慢、准确率最低;加动量的 SGD 优化器和 Adagrad 优化器性能相近;RMSprop 优化器和 Adam 优化器相比,在收敛速度和最终准确率上都稍显不足。故本文最终采用 Adam 优化器来优化模型,其收敛速度更快、稳定性更好、准确率最高。

2)不同激活函数的比较

为了验证不同激活函数对模型识别性能的影响,本文对 ReLU、LeakyReLU、Swich、ELU 和 Sigmoid 这五种激活函数进行了对比实验,结果如图 9(a)和(b)所示。由图可知,不论是在损失的收敛效果还是准确率上,ReLU 激活函数都占据着优势,说明使用 ReLU 激活函数可以提升模型的识别效果。

综上所述,本文最终的参数设定如下:激活函数选择 ReLU,优化器选择 Adam,学习率设为 0.000 5,batch_size 设为 64,Dropout 设为 0.5。实验表明,在此状态下的各项参数取值是模型获得最好性能的最优解。图 10(a)和(b)是本文所设计模型在训练和测试过程中损失和准确率的收敛情况。图 10(a)表明训练在经过 50 次迭代后便达到了收敛状态;由图 10(b)可知,模型最终在测试集中分类准确率高达 99.13%,验证了本文所提算法的有效性。

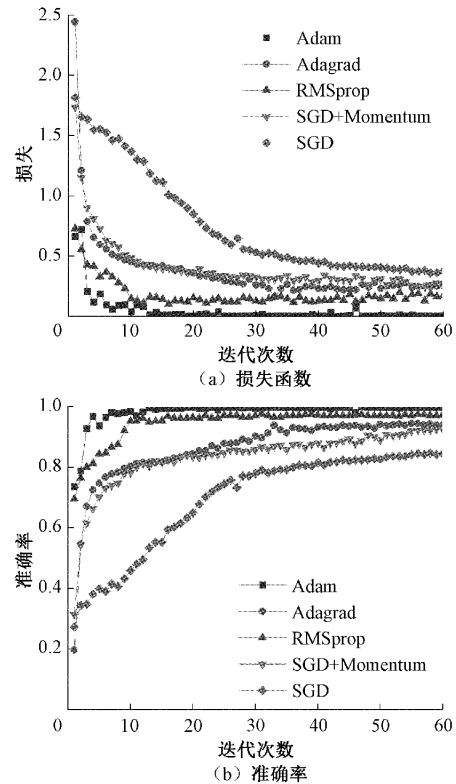


图 8 不同优化器算法对比结果

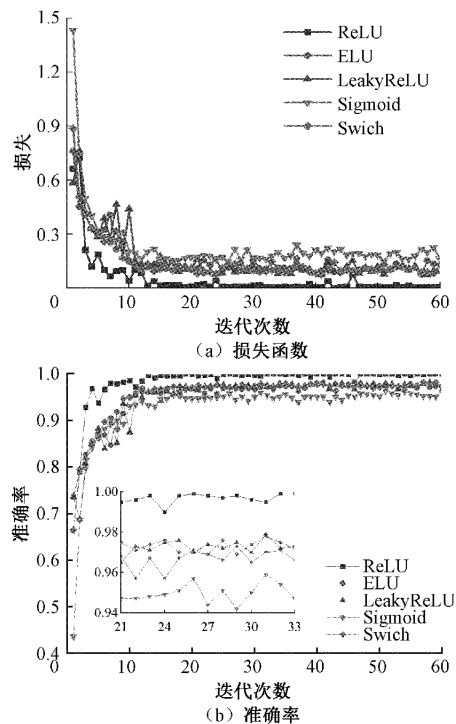


图 9 不同激活函数效果对比

4.3 调制信号的分类结果

分类结果如图 11 所示,用混淆矩阵显示了不同类型信号的最终分类结果。其中,纵轴表示真实标签,横轴是




图 10 训练和测试的历史

预测标签, 对角线上的值为待识别信号被正确分类的概率。对角线上的值越接近 1, 表明相应信号越有可能被正确识别出来。在这个混淆矩阵中, 每个信号识别准确率均在 95% 以上, QFSK+BPSK 信号的识别率为 100%。但还有两个差值较为明显: CW 与 LFM 两者之间易产生混淆。我们注意到 CW 和 LFM 经过 CWD 变换生成的 TFI 具有一定的相似性, 这可以验证两者的差异。此外, 该图还可以表明本文所用方法不仅能够准确地对不同的信号类型进行分类, 还能够区分出复合调制信号类型的个体 QFSK+BPSK 和 LFM+BPSK。由此可见, 该算法在复杂 SNR 条件下具有较好的识别性能。

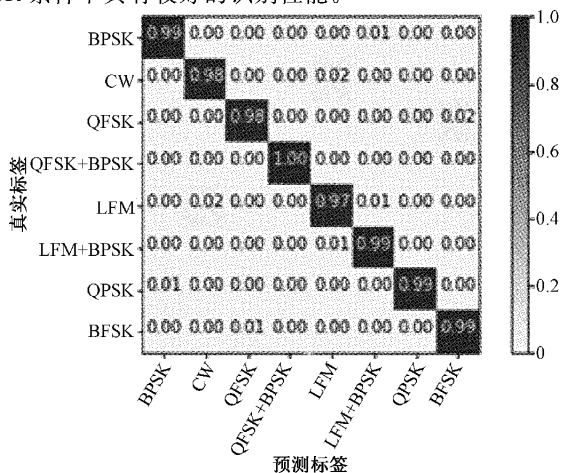


图 11 不同信号类型的分类结果

4.4 与其他模型的对比

为了突出本文所提算法在训练时间、参数量等方面拥有优势, 本文还设计一个拥有 7 层标准卷积的深度 CNN 作为对比, 超参数的设置均一样。结果如表 2 所示, 本文所用模型的参数量比深度 CNN 减少了 25% 左右。其中运行时间表示模型训练过程中每一次 epoch 所需的时间。浮点运算次数 (floating point operations, FLOPs) 是用来衡量模型复杂度的, FLOPs 的值越小表明计算速度越快。本文最终在测试集中的识别准确率也比深度 CNN 提升了 3.67%。由此可知本文所提算法相较于普通 CNN 在训练时间和识别精度等方面有了显著提升。

表 2 模型性能对比

模型	参数	运行时间/s	FLOPs/G	识别准确率/%
本文	8 816 216	32	26.76	99.13
深度 CNN	11 083 528	46	40.72	95.46

为了进一步验证本文所提方法的有效性, 根据已有文献选取最近提出的 3 种与本文拥有相似信号类型或相近识别系统的分类识别方法进行比较: 1) 基于循环谱图的 CNN+GRU 识别方法^[16]; 2) 基于小波变换和 AlexNet 的方法^[17]; 3) 基于 CWD 和模糊函数的支持向量机 (support vector machine, SVM) 方法^[18]。如图 12 所示, 黑色实心正方形曲线是在本文所用方法下的 8 种信号在不同 SNR 下的整体识别准确率, 随着 SNR 的增大, 准确率也随之提升。当 SNR 为 -4 dB 时, 可达到 100% 的精度, 即使 SNR 为 -10 dB 时, 也能达到 91% 的准确率。通过对比可以发现, 在低 SNR 条件下, 文献[16]采用的 STFT 时频转换方法识别率较低, 其原因是随着 SNR 的降低, STFT 无法有效提取到信号的时频特征, 出现了失真现象, 从而影响了分类器最终的识别效果; 文献[17]采用的方法在 SNR 为 -10 ~ -2 dB 时信号的识别率略低于本文所用方法; 文献[18]在改进的时频转换方法的前提下采用了 SVM 作为分类器, 而 SVM 在小样本学习上更有优势, 当面临大规模训练样本和多分类问题时就显得力不从心了, 这也许就




图 12 不同信号识别方法的比较

是它在低 SNR 条件下性能表现不佳的主要原因。通过实验结果对比分析,证明了本文提出的方法相较于其它时频转换方法或分类识别模型在 $-10 \sim 0$ dB 低 SNR 下更有优势。

5 结 论

本文提出了一种基于 CWD 时频图和 CNN 中嵌有 RDB 的新型调制分类方案。将调制信号分类问题转化为图像识别任务,利用深度学习技术对时频图像进行自动特征提取和分类。此外,依托现实环境中常见的信号类型,还建立了一个模拟的调制无线电信号数据集,并对其进行了实验验证。实验结果表明,本文所设计的方法,与其它时频转换方法相比,识别性能有显著提升。

接下来作者将从网络的宽度、深度以及 TFIs 的分辨率等方面同时进行优化,在保证分类精度的同时压缩模型的尺寸和训练时间,从而设计出更好的信号识别方案。此外,作者希望用更复杂的样本和具有挑战性的 SNR 来扩充数据集,并通过优越的网络模型来解决混合信号调制识别的问题。

参考文献

- [1] ZHANG Y, CHEN D, LIU T, et al. Specific emitter identification based on empirical mode decomposition and convolutional neural network [C]. IET International Radar Conference (IET IRC 2020), 2020: 544-548.
- [2] O'SHEA T, HOYDIS J. An Introduction to Deep learning for the physical layer[J]. Transactions on Cognitive communications and Networking, 2017, 3(4): 563-575.
- [3] 郑来芳,张俊生,梁海坚,等.基于时频混合特征提取算法的光纤传感信号识别研究[J].电子测量与仪器学报,2020,34(9):153-159.
- [4] WEBER C, PETER M, FELHAUER T. Automatic modulation classification technique for radio monitoring[J]. Electronics Letters, 2015, 51(10): 794-796.
- [5] NERANDZIC M, BOZOVIC R, OELIC V D. Impact of AWGN estimation on classification performance of AMC algorithms based on higher order cumulants[C]. 2021 29th Telecommunications Forum, 2021: 1-4.
- [6] 普运伟,郭江,刘涛涛,等.基于模糊函数等高线与栈式降噪自编码器的雷达辐射源信号识别[J].仪器仪表学报,2021,42(1): 207-216.
- [7] POULOSE A, HAN D S. Feature-based deep LSTM network for indoor localization using UWB measurements [C]. International Conference on Artificial Intelligence in Information and Communication, 2021: 298-301.
- [8] 郭蕴欣,张越,马宏.基于 CNN 的数字信号调制识别研究[J].电子测量技术,2019,42(14): 112-116.
- [9] GHASEMZADEH P, BANERJEE S, HEMPEL M, et al. A new framework for automatic modulation classification using deep belief networks [C]. 2020 IEEE International Conference on Communications Workshops, 2020: 1-6.
- [10] HONG D, ZHANG Z, XU X. Automatic modulation classification using recurrent neural networks [C]. 2017 3rd IEEE International Conference on Computer and Communications (ICCC), 2017: 695-700.
- [11] 曲志昱,毛校洁,侯长波.基于奇异值熵和分形维数的雷达信号识别[J].系统工程与电子技术,2018, 40(2): 303-307.
- [12] ZHANG M, LIU L, DIAO M, et al. LPI radar waveform recognition based on time-frequency distribution[J]. Sensors, 2016, 16(10): 1682-1706.
- [13] 曹晓航,汪立新,束学渊.基于小波不变矩的雷达辐射源信号识别[J].计算机工程与应用,2020,56(19): 269-272.
- [14] 姚瑶,王战红.基于时频预处理下卷积网络的雷达信号识别[J].探测与控制学报,2018,40(6): 99-105.
- [15] ZHOU D, SHEN X, DONG W. Image zooming using directional cubic convolution interpolation [J]. IET Image Processing, 2012, 6(6): 627-634.
- [16] LIU F, ZHANG Z, ZHOU R. Automatic modulation recognition based on CNN and GRU [J]. Tsinghua Science and Technology, 2022, 27(2): 422-431.
- [17] YANG J, LIU F. Modulation recognition using wavelet transform based on AlexNet [C]. 2019 IEEE 7th International Conference on Computer Science and Network Technology (ICCSNT), 2019: 339-342.
- [18] LI S, QUAN D, WANG X, et al. LPI radar signal modulation recognition with feature fusion based on time-frequency transforms [C]. 2021 13th International Conference on Wireless Communications and Signal Processing (WCSP), 2021: 1-6.

作者简介

李宝平(通信作者),博士,讲师,主要研究方向为计算机视觉和智能信号处理。

E-mail: libaoping@hpu.edu.cn

魏坡,硕士研究生,主要研究方向为调制信号识别。

E-mail: 179474264@qq.com