

# 基于通信信号时频特性的卷积神经网络调制识别

徐茂 侯进 吴佩军 刘雨灵 吕志良

西南交通大学信息科学与技术学院 成都 611756

(369434765@qq.com)



**摘要** 在通信环境日益密集、信号调制样式层出不穷的情况下,信号的调制识别变得愈加困难。寻求一种高精度、时效性好的自动调制识别新方法,对无线电通信应用领域有重大意义。对此,文中提出了一种结合通信信号时频特性的卷积神经网络(Convolutional Neural Network Based on Time-Frequency Characteristics, TFC-CNN)调制识别算法。首先,采集大量调制信号,将信号的时频特征通过短时傅里叶变换转换成图像特征,并将其作为网络的输入;然后,设计一种特征提取能力更强、参数更少的卷积神经网络,通过改进网络中不同层的连结方式来增加网络的特征提取能力,同时通过减小卷积核的尺度、使用全局均值池化层来减少模型参数,提高了模型的时效性;最后,在网络中添加批归一化(Batch Normalization, BN)层,在增加模型稳定性的同时防止模型出现过拟合。实验结果表明,所提算法在参数和训练时间上比传统方法明显减少,同时有更高的准确率,体现了所提算法的优越性。

**关键词:** 调制识别;时频特性;卷积神经网络;短时傅里叶变换

中图分类号 TP183

## Convolutional Neural Networks Based on Time-Frequency Characteristics for Modulation Classification

XU Mao, HOU Jin, WU Pei-jun, LIU Yu-ling and LV Zhi-liang

School of Information Science and Technology, Southwest Jiaotong University, Chengdu 611756, China

**Abstract** In the situation of increasingly dense communication environment and endless modulation patterns of signals, the modulation classification becomes more and more difficult. It is very important for the application of radio communication to seek a new method of automatic modulation classification (AMC) with high accuracy and good timeliness. Based on this, a novel convolutional neural network based on time-frequency characteristics (TFC-CNN) for AMC was proposed. Firstly, a large number of modulation signals are collected, and the time-frequency features of the signals are converted into image features by short-time Fourier transform, which are used as the input of the network. Secondly, a convolutional neural network with stronger feature extraction ability and fewer parameters is designed, and the feature extraction ability of the network is enhanced by improving the connection mode of different layers in the network. At the same time, the model parameters are reduced by reducing the scale of the convolution kernel and using the global average pooling, the timeliness of the model is improved. Finally, adding batch normalization layers to network can increase the stability of the model and prevent overfitting. The experiment results show that the proposed algorithm is significantly less in parameters and training time than the traditional methods, and has higher accuracy, which shows the superiority of the proposed algorithm.

**Keywords** Modulation classification, Time frequency characteristics, Convolutional neural network, Short-time Fourier transform

### 1 引言

自动调制识别主要分为统计模式识别<sup>[1-2]</sup>和机器学习识别两种。Zhu等<sup>[3]</sup>利用一种新的非参数似然函数对具有未知噪声方差和分布的调制信号进行识别。Ozdemir等<sup>[4]</sup>提出了基于广义期望最大化算法的新型混合最大似然分类方案。随

着机器学习在学术界和工业界掀起的研究热潮,越来越多的人尝试利用机器学习的方法来进行调制识别。K近邻算法(K-Nearest Neighbor, KNN)<sup>[5]</sup>、神经网络<sup>[6]</sup>及支持向量机(Support Vector Machine, SVM)<sup>[7]</sup>等技术都相继被人们用来作为通信信号调制识别的新尝试。

近年来,随着计算机处理速度和存储能力的提高,卷积神

收到日期:2018-12-19 返修日期:2019-04-23 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:浙江大学CAD&CG国家重点实验室开放课题(A1823);成都市科技项目(2015-HM01-00050-SF)

This work was supported by the Research on Modulation Recognition Technology based on Deep Learning, CAD&CG National key Laboratory of Zhejiang University(A1823) and Automatic detection and identification of lane lines and signs of intelligent vehicles, Chengdu science and technology project(2015-HM01-00050-SF).

通信作者:侯进(jhou@swjtu.edu.cn)

神经网络(Convolutional Neural Network, CNN)<sup>[8-12]</sup>的设计和实现已逐渐成为发展趋势。越来越多的 CNN 模型被用于调制识别的相关研究<sup>[13-15]</sup>。文献[16-17]采用一维的 CNN 模型直接对信号的 IQ 数据进行识别;文献[18]使用信号的星座图作为 CNN 模型的输入来实现调制识别;文献[19]采用一个具有两个卷积层的 CNN 来对信号的时频图进行调制识别。基于已有研究,本文在文献[19]的基础上进行了改进,提出了一种 CNN 模型——TFC-CNN(Convolutional Neural Network Based on Time-Frequency Characteristics)。该模型通过改变卷积核的大小来提高模型的特征提取能力;增加网络层数来提高模型对模型输入与输出间映射的拟合能力;改进残差连接来优化模型训练,减少模型参数,在提高调制识别精度的同时,缩短了模型的训练时间和识别时间。实验结果表明,本文算法能够对多种调制方式的识别达到较高的精度,同时具有较好的时效性。

## 2 TFC-CNN 算法及框架

本文算法的主要过程为:首先,采集大量已知调制方式的通信信号,经过短时傅里叶变换,将信号的时频特征转化为图片特征;然后,通过本文提出的 TFC-CNN 来对这些图片进行大量训练;最后,通过不断调整模型参数,来得到最优模型,从而实现对通信信号的调制识别。系统整体框图如图 1 所示。




图 1 系统结构框图

Fig. 1 System block diagram

### 2.1 数据采集

若要能够准确地识别调制信号,建立一个高质量的数据库必不可少。本文通过 E4438 信号源来产生不同调制参数、不同调制方式的调制信号,并用 ESMD 接收机来对调制信号进行接收和采集。本文的固定信号的滤波带宽为 150kHz,固定其频点为 583M,固定其采样率为 320K,采集信号时本文选取每帧 IQ 数据的长度为 4096 个点。本文所识别的调制方式主要有 AM, 2PSK, 4QAM, FM, 16PSK, 2FSK, 4FSK, 8FSK, 2ASK 及 MSK 等。细分的调制参数有调制深度、调制率、频偏、频谱带宽及码率等。为了使模型具有较强的泛化能力,本文还在部分信号中加入了一些干扰。本文通过大量数据采集获得了 90GB 左右的 IQ 数据,以供后期 CNN 模型进行训练测试。

### 2.2 数据特征转换

文献[16-17]直接采用信号的 IQ 数据作为 CNN 模型的输入,但是由于信号的复杂性, IQ 数据通常难以体现调制信号的调制特征。为了能更好地让 CNN 模型准确提取信号的调制特征,本文采用短时傅里叶变换来对信号进行特征转换。信号的时频图不仅能够表现出信号的时域特征,同时还能表现出信号的频域特征。

### 2.3 卷积神经网络 TFC-CNN 的设计

本文提出了一种更深的模型 TFC-CNN,来对调制信号

的时频图进行识别, TFC-CNN 模型的网络结构如图 2 所示。该模型首先通过一个  $3 \times 3$  的卷积层和一个最大池化层来对特征图进行特征提取及降采样,然后通过 TFC 结构将数据特征转化成高维特征,最后通过全局均值池化并使用 SoftMax 函数产生分类结果。相比文献[19]中的 CNN,本文提出的 TFC-CNN 有以下几点改进。

(1)使用更小的卷积核。为了提高模型对输入数据的特征提取能力,本文采用  $3 \times 3$  和  $1 \times 1$  的卷积核来代替文献[19]中所使用的  $9 \times 9$  和  $7 \times 7$  的卷积核,采用较小的卷积核不仅能够提高模型提取数据特征的能力,减少模型中的特征冗余,同时还能够大大减少模型参数,使得模型的收敛速度更快、训练时间更短、效果更好。

(2)采用一种全新的 TFC 堆叠结构,将网络前层特征转化为高维特征,提高模型的特征提取效率,使得模型能够更好地拟合输入与输出间的映射。

(3)使用全局均值池化层来代替文献[19]中所使用的全连接层,大量减少了模型的参数,从而提高了模型的时效性,降低了模型对硬件设备的依赖。

(4)增加 CNN 中的卷积层数量,使得更深的 TFC-CNN 能够更好地提取信号数据的特征;增加网络层数来提高模型对模型输入与输出间映射的拟合能力,进而提高模型的识别效果。

(5)在模型中使用激活函数 ReLU<sup>[20]</sup>,采用的优化算法为动量(Momentum)算法,能够有效地避免模型在训练的过程中陷入局部最优。同时使用了批归一化算法<sup>[21]</sup>使得模型训练更加稳定,防止模型过拟合。




图 2 TFC-CNN 模型结构图

Fig. 2 Structure of TFC-CNN

#### 2.3.1 网络堆叠结构的设计

##### (1)残差结构

较深的 CNN 通常能取得更好的效果,但是盲目地增加网络层数容易导致网络梯度爆炸以及优化困难,文献[22]所提出的残差结构较好地解决了这一问题。残差结构最大的特点是引入了恒等映射,降低了拟合函数的复杂度。残差结构如图 3 所示。




图 3 残差结构

Fig. 3 Residual block

假设需要拟合的复杂函数为  $F(X)$ ,把  $F(X)$  分解成两个

更简单的函数  $D(X)$  和  $G(X)$ , 让原拟合函数变为  $D(X)$ , 当  $G(X)$  为  $X$  时,  $F(X)$  可以通过恒等映射来实现, 这使得模型优化更加容易。若将模型中第  $l$  层的输出表示为  $X_l$ , 则第  $l$  层的输出表示如式(1)所示:

$$X_l = D(X_{l-1}) + X_{l-1} \quad (1)$$

其中, 所使用的恒等映射没有引入参数, 这使得学习不仅更简单、更稳定, 而且还大大减少了网络参数。残差结构使得网络在加深的时候, 不易出现退化问题。

## (2) TFC 结构

为了提高模型的特征提取能力, 本文改进了文献[22]中的残差结构, 增加了模型中不同卷积层之间的连结, 能够增强模型的特征提取能力, 同时, 将残差结构的恒等映射连结方式改为了通道叠加的方式, 使得数据的特征信息能够更好地传递。模块结构如图 4(a) 所示。图 4(a) 中的矩形部分都采用如图 4(b) 所示的卷积块, 该卷积块由两个  $1 \times 1$ 、一个  $3 \times 3$  大小的卷积层组成, 并且使用 ReLU 作为激活函数。这种结构的参数量比采用  $9 \times 9$  的卷积核结构减少了 86%, 比采用  $7 \times 7$  的卷积核结构减少了 77%。同时, 该结构引入了两个  $1 \times 1$  的卷积核, 不仅可以增加网络的非线性, 还可以增加网络的深度, 提高模型的特征提取能力。

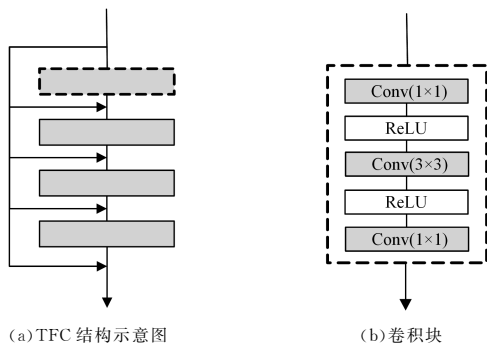


图 4 TFC 模块的结构示意图

Fig. 4 Structure of TFC block

本文所使用的模型中第  $l$  个卷积块的输入都只与当前模块输入和第  $l-1$  层的卷积块输入有关, 若用  $X_m$  表示第  $n$  个模块的初始输入, 则 TFC-CNN 每个模块中第  $l$  层的输出如式(2)所示:

$$X_l = D(X_{l-1}) + X_m \quad (2)$$

从式(1)、式(2)中可以看出, 相较于残差结构, 本文所提

出的 TFC 结构的前后连接更加紧密, 使用通道叠加的方式不仅能够使得特征图信息在网络中的传递更加充分, 进而提高模型的特征提取效率, 使得模型对特征的提取更加充分, 还能够避免模型在训练过程中出现梯度消失以及优化问题, 使得模型更加鲁棒。

## 2.3.2 批归一化算法

随着网络层数的增加, 模型的复杂度变高, 复杂度高的模型容易出现过拟合问题。为此, 本文在网络中添加了批归一化层来防止模型在训练时出现过拟合。BN 算法如式(3)、式(4)所示:

$$\hat{x}^{(k)} = \frac{x^k - E[x^k]}{\sqrt{\text{Var}[x^k]}} \quad (3)$$

$$y^{(k)} = \gamma^k \hat{x}^{(k)} + \beta^{(k)} \quad (4)$$

式(3)中,  $x^k$  表示输入数据的第  $k$  维,  $E[x^k]$  表示该维数据的均值,  $\sqrt{\text{Var}[x^k]}$  表示该维数据的标准差。式(3)将每一层的输入数据分布归一化为均值为 0, 方差为 1 的分布。由于数据经过式(3)处理之后会破坏之前学到的特征, 因此需要经过 BN 的第二步处理, 即式(4), 其中设置了两个可学习的变量  $\gamma$  和  $\beta$ , 然后用这两个变量来还原上一层应该学到的数据分布。BN 通过对每一层的输入进行归一化, 来保证每层的输入数据的分布是稳定的, 从而达到加速训练的目的。

## 3 实验结果与分析

本文使用的权重参数化方法同文献[23]所用方法一致, 使得模型在训练过程中能够更快地学习收敛。本文对实验中的 CNN 模型的学习率采用手动调节的方式, 学习率初始值为 0.01, 每 10 个周期降低为原来的 1/10, 同时, 权重衰减因子设置为 0.0002, 训练集的图片批处理数量为 32。

### 3.1 时频图的生成

本文所采集的实验数据集包含 10 种调制方式, 同时将该数据集分为了训练集和测试集。其中, 训练集每类包含 10000 张特征图, 测试集每类包含 1000 张特征图, 所有特征图的大小均为  $150 \times 150$ , 且均为 RGB 格式。实验中所生成的部分时频图如图 5 所示, 图中显示了 10 类不同调制信号通过短时傅里叶变换生成的时频图, 其调制方式分别为 AM, 2PSK, 4QAM, FM, 16PSK, 2FSK, 4FSK, 8FSK, 2ASK, MSK。本文所有实验结果均基于该数据集。

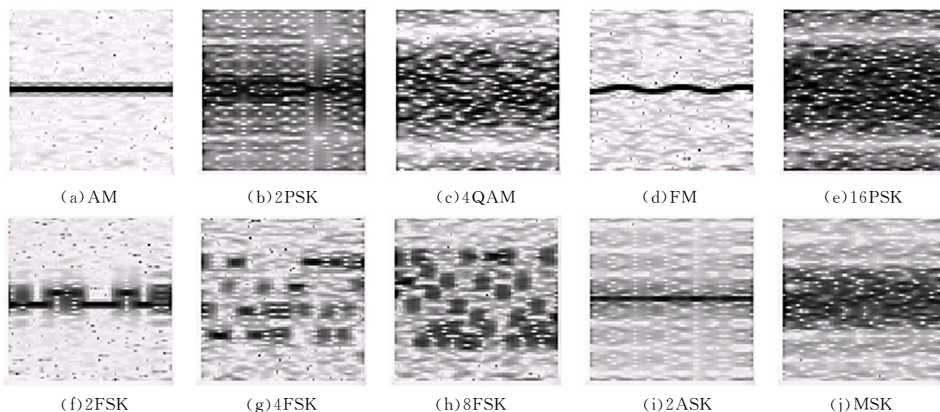


图 5 10 种调制信号的时频图

Fig. 5 Time-frequency diagrams of 10 types of modulated signals

### 3.2 不同数据类型输入模型的对比

采用时频图作为模型的输入能够使得模型更加容易提取信号的调制特征,进而提高识别效果。为了验证该方法的有效性,本文采用了两种 CNN 模型进行实验对比,一种是采用本文所提出的 TFC-CNN 模型来对信号的时频图进行识别,另一种是采用文献[17]提出的 CNN 模型来对信号的原始 IQ 数据进行识别。图 6 给出了两种 CNN 模型训练时的测试精度曲线,实验结果显示,本文方法比文献[17]所用的方法中的模型训练更加稳定,收敛速度更快。同时,本文方法的精度高达 88.9%,比文献[17]高出 12.1%,可以证明使用时频图作为模型的输入的方法相比直接读原始的 IQ 数据更具有优势。




图 6 两种不同数据输入模型的测试精度曲线

Fig. 6 Test accuracy curves of two different data input models

### 3.3 与传统调制 CNN 的对比


本文通过使用更小的卷积核来提取数据特征,并增加更多的卷积层,改进了卷积层之间的连接方式;使用全局池化层来减少模型参数,使得模型比传统的调制识别模型有着更好的性能。为此,本文用该模型同文献[19]中的模型进行了对比实验,其中两种 CNN 模型的结构配置如表 1 所列。从表 1 中可以看出,本文所提模型的网络卷积层数更多,网络参数更少,同时模型的计算复杂度仅为文献[19]的 34.5%。

表 1 不同类型的 CNN 模型结构配置表


Table 1 Configuration of CNN models of different types

模型	卷积层数	模型参数	计算复杂度/M
文献[19]中的模型	2	257 226	60.2
TFC-CNN	5	14 698	20.8

图 7 给出了两个模型在网络训练时的测试精度曲线和损失曲线。



(a) 测试精度曲线



(b) 训练损失函数曲线

图 7 两种 CNN 模型的实验结果

Fig. 7 Training curve of two CNN models

从图中可以看出,随着训练周期的增加,模型损失值快速下降,正确率迅速上升,经过 16 个训练周期后,模型得以收敛,而本文提出的模型比文献[19]提出的模型的收敛速度更快,同时识别精度更高,比文献[19]的 86%高出了 2.9%,证明了本文算法的有效性。

### 3.4 模型深度对调制识别的影响

为了探究不同 CNN 模型深度对识别精度的影响,本文将几种不同深度的 CNN 模型进行了对比实验,几种 CNN 的结构细节如表 2 所列。本文主要通过控制网络 TFC 模块的卷积块的堆叠数量来控制模型的深度,其中,TFC-CNN-1 中有 1 个卷积块,TFC-CNN-4 中有 4 个卷积块,TFC-CNN-8 中有 8 个卷积块。实验结果如图 8 所示。

表 2 不同深度的 TFC-CNN 模型结构配置表

Table 2 Structural details of TFC - CNN models with different depths

TFC-CNN-1	TFC-CNN-4	TFC-CNN-8
	3×3 conv	
	Max pooling	
$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \\ 1 \times 1 \text{ conv} \end{bmatrix} \times 1$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \\ 1 \times 1 \text{ conv} \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \\ 1 \times 1 \text{ conv} \end{bmatrix} \times 8$
	1×1 conv	
	Average pooling	
	Global average pooling	
	10D Fully-connected SoftMax	




图 8 不同深度的 TFC-CNN 模型的测试精度曲线

Fig. 8 Test accuracy of TFC-CNN models with different depths

实验结果显示,随着 TF-CNN 深度的增加,模型的识别精度和收敛速度都有着一定的提升,其中,TFC-CNN-8 的识别精度高达 92.1%,比 TFC-CNN-1 高出 3.2%,比文献[17]高出 15.3%,比文献[19]高出 6.2%。可以看出,加深 TFC-CNN 模型的深度能够取得更好的效果。在此实验基础上,本文进一步用更深的 TFC-CNN 同文献[22]提出的 CNN 模型进行了实验对比,实验结果如表 3 所列。

表 3 TFC-CNN-40 模型与文献[22]的模型的训练结果

Table 3 Training results of TFC-CNN and ResNet

模型	训练时间	识别精度/%
ResNet-40[22]	6 小时 42 分	92.1
TFC-CNN-40	1 小时 56 分	92.6

实验结果显示,两种 CNN 在层数相同的情况下,TF-CNN-40 的识别精度比文献[22]所提 40 层的 ResNet 高出了 0.5%,但是模型的训练时间却比文献[22]所提模型的训练时间缩短了 71%,这证明了本文所提的 TFC-CNN 有着更好的时效性,减少了对硬件设备的依赖。与此同时,TFC-CNN-40 与 ResNet-40 的识别精度相差无几,说明了当模型的深度增加到一定程度之后模型的性能将无法提升。

**结束语** 本文通过改进传统调制识别 CNN 模型,结合了通信信号时频特性来识别不同的调制方式,利用信号的时频图作为模型的输入,更改 CNN 网络卷积核的大小,改进卷积层之间读的连结方式,用全局均值池化层代替全连接层,提高了模型的特征提取与识别能力。实验结果证明,对比传统的 CNN 网络,本文提出的模型不仅有着更少的参数和更好的时效性,同时也有着更好的识别精度。但是,本文方法还存在着一定的不足,其仅结合了信号的时频特性进行识别,导致对一些相位调制方式的识别效果较差。本文后续还会针对这些不足来添加信号的相位特征,从而进一步提高模型对相位调制方式信号的识别精度。

### 参考文献

- [1] MAREY M, DOBRE O A. Blind Modulation Classification Algorithm for Single and Multiple-Antenna Systems Over Frequency-Selective channels[J]. IEEE Signal Processing Letters, 2014, 21(9): 1098-1102.
- [2] AMURU S D, DA SILVA C R C M. A Blind Preprocessor for Modulation Classification Applications in Frequency-Selective Non-Gaussian Channels[J]. IEEE Transactions on Communications, 2015, 63(1): 156-169.
- [3] ZHU Z, NANDI A K. Blind Digital Modulation Classification Using Minimum Distance Centroid Estimator and Non-Parametric Likelihood Function[J]. IEEE Transactions on Wireless Communications, 2014, 13(8): 4483-4494.
- [4] OZDEMIR O, WIMALAJEewa T, DULEK B, et al. Asynchronous Linear Modulation Classification with Multiple Sensors via Generalized EM Algorithm[J]. IEEE Transactions on Wireless Communications, 2015, 14(11): 6389-6400.
- [5] ASLAM M W, ZHU Z, NANDI A K. Automatic Modulation Classification Using Combination of Genetic Programming and KNN[J]. IEEE Transactions on Wireless Communications, 2012, 11(8): 2742-2750.
- [6] HAN L, XUE H, GAO F, et al. Low Complexity Automatic Modulation Classification Based on Order Statistics[C]// Vehicular Technology Conference. Montreal: IEEE Computer Society Press, 2016: 1-5.
- [7] YANG F, YANG L, WANG D, et al. Method of Modulation Recognition Based on Combination Algorithm of K-Means Clustering and Grading Training SVM[J]. China Communications, 2018, 15(12): 55-63.
- [8] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet Classification with Deep Convolutional Neural Networks[C]// Proceedings of the 25th International Conference on Neural Information Processing Systems. New York: ACM, 2012: 1097-1105.
- [9] SIMONYAN K, ZISSERMANZ A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. arXiv: 1409.1556, 2014.
- [10] SZEGEDY C, LIU W, JIA Y Q, et al. Going Deeper with Convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society, 2015: 1-9.
- [11] CHOLLET F. Xception: Deep Learning with Depthwise Separable Convolutions[J]. arXiv: 1610. 02357, 2016.
- [12] HUANG G, LIU Z, WEINBERGER K Q, et al. Densely Connected Convolutional Networks[J]. arXiv: 1608. 06993, 2016.
- [13] WEST N E, O'SHEA T J. Deep Architectures for Modulation Recognition[C]// IEEE International Symposium on Dynamic Spectrum Access Networks. Piscataway: IEEE, 2017: 1-6.
- [14] WEST N E, HARWELL K, MCCALL B. DFT Signal Detection and Channelization With a Deep Neural Network Modulation Classifier[C]// IEEE International Symposium on Dynamic Spectrum Access Networks. Piscataway: IEEE, 2017: 1-3.
- [15] VANHOY G, THURSTON N, BURGER A, et al. Hierarchical Modulation Classification Using Deep Learning[C]// Military Communications Conference. Los Angeles: IEEE, 2018: 20-25.
- [16] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional Radio Modulation Recognition Networks[C]// International Conference on Engineering Applications of Neural Networks. Berlin: Springer, 2016: 213-226.
- [17] HAUSER S C, HEADLEY W C, MICHAELS A J. Signal Detection Effects on Deep Neural Networks Utilizing Raw IQ for Modulation Classification[C]// Military Communications Conference. Baltimore: IEEE, 2017: 121-127.
- [18] PENG S, JIANG H, WANG H, et al. Modulation Classification Using Convolutional Neural Network Based Deep Learning Model[C]// Wireless and Optical Communication Conference. Newark: IEEE Computer Society, 2017: 1-5.
- [19] ZHANG J, LI Y, YIN J. A Novel Modulation Classification Method for Frequency Modulation Signals Based on the Time-Frequency Distribution and CNN[J]. IET Radar, Sonar & Navigation, 2017, 12(2): 244-249.
- [20] NAIR V, HINTON G E. Rectified Linear Units Improve Restricted Boltzmann Machines[C]// International Conference on Machine Learning. Madison: Omni, 2010: 807-814.
- [21] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift[C]// Proceedings of the 32nd International Conference on Machine Learning. New York: ICML, 2015: 448-456.
- [22] HE K M, ZHANG X Y, REN S Q, et al. Deep Residual learning for Image Recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.
- [23] HE K M, ZHANG X Y, REN S Q, et al. Delving Deep into Rectifiers: Surpassing Human-Level Performance on Imagenet Classification[C]// Proceedings of the IEEE International Conference on Computer Vision. Los Alamitos: IEEE Computer Society, 2015: 1026-1034.



**XU Mao**, born in 1993, postgraduate. His main research interests include machine learning, deep learning and artificial intelligence.



**HOU Jin**, born in 1969, Ph.D. Her main research interests include machine learning and so on.