

# 利用并联 CNN-LSTM 的调制样式识别算法

翁建新<sup>1</sup> 赵知劲<sup>1,2</sup> 占锦敏<sup>1</sup>

(1. 杭州电子科技大学通信工程学院, 浙江杭州 310018;

2. 中国电子科技集团第 36 研究所通信系统信息控制技术国家级重点实验室, 浙江嘉兴 314001)

**摘要:** 为了提高基于卷积神经网络的调制样式识别算法性能, 利用 CNN 的空间特征提取能力和 LSTM 时序特征提取能力, 设计了 CNN-LSTM 并联网, 上支路由一层卷积层和一层池化层组成, 下支路使用单层 LSTM 网络。直接将同向分量和正交分量作为输入数据, 上下支路提取信号的空间和时间特征, 提高特征表达能力。对 BPSK、QPSK、8PSK、16QAM、32QAM、16APSK、32APSK 等 7 种信号的调制样式识别仿真实验结果表明: 算法无需人为设计特征参数, 减少人为因素影响, 同时该算法在低信噪比下具有较好的识别性能。

**关键词:** 调制样式识别; 卷积神经网络; 循环神经网络; 并联

中图分类号: TN91 文献标识码: A DOI: 10.16798/j.issn.1003-0530.2019.05.019

**引用格式:** 翁建新, 赵知劲, 占锦敏. 利用并联 CNN-LSTM 的调制样式识别算法[J]. 信号处理, 2019, 35(5): 870-876. DOI: 10.16798/j.issn.1003-0530.2019.05.019.

**Reference format:** Weng Jianxin, Zhao Zhijin, Zhan Jinmin. Modulation Recognition Algorithm By Using Parallel CNN-LSTM[J]. Journal of Signal Processing, 2019, 35(5): 870-876. DOI: 10.16798/j.issn.1003-0530.2019.05.019.

## Modulation Recognition Algorithm By Using Parallel CNN-LSTM

Weng Jianxin<sup>1</sup> Zhao Zhijin<sup>1,2</sup> Zhan Jinmin<sup>1</sup>

(1. School of Communication Engineering, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China;

2. State Key Lab of Information Control Technology in Communication System, The 36<sup>th</sup> Research Institute of China Electronics Technology Group Corporation, Jiaxing, Zhejiang 314001, China)

**Abstract:** To improve the performance of modulation type recognition algorithm based on convolutional neural network, CNN-LSTM parallel network is designed by CNN spatial feature extraction ability and LSTM Time series feature extraction ability. The upper branch consists of a pooling layer and a convolution layer, and the lower branch uses a single-layer LSTM network. The in-phase component and quadrature component are directly used as input data, and the upper and lower branches extract the spatial and temporal characteristics of the signal respectively, to improve the feature expression ability. The experimental results of modulation type recognition for 7 kinds of signals, such as BPSK, QPSK, 8PSK, 16QAM, 32QAM, 16APSK and 32APSK, show that the algorithm does not need to artificially design the characteristic parameters and reduces the influence of human factors. At the same Time, the algorithm has good recognition performance at lower SNR.

**Key words:** modulation type recognition; convolutional neural network; deep learning; parallel

## 1 引言

调制样式识别 (Modulation Type Recognition, MTR) 是非协作通信过程中重要环节, 是完成解调进而获取信息前提, 常用于电子侦察、电子干扰、非

法频谱监管等。近年来深度学习<sup>[1]</sup> (Deep Learning, DL) 方法由于其优异的性能广泛用于计算机视觉、自然语言处理以及数据挖掘等领域。DL 能逼近任意线性、非线性函数, 能自动从信号中提取具有区分度的特征, DL 在 MTR 应用引起研究人员关注。

文献[2]利用信号眼图和卷积神经网络(Convolution Neural Network, CNN)识别 DPSK 等四种信号, Li J 等[3]利用循环谱和深度自编码器识别 FSK、PSK、ASK、QAM 和 MSK 5 种调制信号, 文献[4]利用星座图和 CNN 识别三种 QAM 信号, Zhao Z J 等[5]利用信号的高阶累积量特征和三阶受限玻尔兹曼机识别 2ASK、4ASK、QPSK、8PSK、2FSK、16QAM 等六种信号, 周龙梅[6]利用短时傅里叶变换和受限玻尔兹曼机识别 GFSK、16QAM、2ASK、4ASK、2FSK、OQPSK 六种调制样式, 文献[7]利用高阶累积量和自编码器对 BPSK、QPSK、8PSK、16QAM、32QAM、16APSK、32APSK 七种信号进行识别, G. J. Mendis 等[8]利用谱相关函数和深度信念网络(Deep Belief Network, DBN)识别 4FSK、16QAM、BPSK、QPSK 和 OFDM 等五种信号, Byeoungdo Kim 等[9]提取 21 种信号特征参数, 利用深度神经网络(Deep neural network)完成了 BPSK、QPSK、8PSK、16QAM、64QAM 五种调制信号识别。但是文献[3-9]算法需对信号进行预处理, 可扩展性受限。文献[10]和[11]直接利用正交解调的 I、Q 信号和卷积神经网络进行信号识别, 文献[12]应用单层、堆栈长短期记忆网络(Long Short-term Memory, LSTM)网络和原始信号数据识别 BASK、4ASK、BFSK、4FSK、BPSK、QPSK 和 16QAM 等七种信号。上述研究主要利用单种网络, 卷积神经网络具有良好的空间特征学习提取能力, 长短期记忆网络[13]具有很强的时间序列处理能力。文献[14]采用两层卷积层后级联一层长短期记忆层结构, 在 -4 dB 信噪比时, 对 8PSK、AM-DSB、AM-SSB、BPSK、CPFSK、GFSK、PAM4、QAM16、QAM64、QPSK、WBFM 平均识别率能达到 90%。但是时间信号经过卷积层后会丢失部分时序特征, 且使用两层卷积层提取空域特征会大大增加模型的复杂度, 导致训练时间增长。对此, 本文提出一种 CNN-LSTM 并联的 MTR 算法(简记为 CLP 算法)。将信号的同向分量( $I(t)$ )和正交分量( $Q(t)$ )并行输入 CNN 网络和 LSTM 网络, 经过 CNN 提取输入信号的空间特征, 由 LSTM 网络获取信号时域特征, 将两路输出特征融合再送入输出层, 完成 MTK。对 BPSK、QPSK、8PSK、16QAM、32QAM、16APSK、32APSK 等 7 种信号识别的仿真实验结果表明: 本文算法无需人为设计特征, 低信噪比(Signal To Noise Ratio, SNR)下对相位调制和幅相调制信号的识别率较高。

## 2 CNN-LSTM 并联网络模型及参数更新

在接收端, 经过符号速率估计、载波估计、下变频得到复基带信号  $R(t)$ , 其实部、虚部分别为同向分量  $I(t)$  和正交分量  $Q(t)$ 。将 I 路和 Q 路原始数据的  $2 \times N$  维矩阵作为网络输入, 所提出的 CLS 算法网络如图 1 所示, 由四部分组成, 第一部分为网络输入部分, 其次是并联层, 第三部分为特征融合部分, 第四部分为输出层(包括全连接层和分类器)。




图 1 CLP network model diagram

输入层主要完成输入数据信息的收集。每个输入样本为  $2 * 128$  大小的矩阵, 128 代表 I 路、Q 路的采样点个数, 用  $I_{2,128}$  表示,  $I_{2,128}$  中元素用  $I(i, j)$  表示。

第二部分由 CNN 与单层 LSTM 并联构成。上支路为卷积层、池化层(平均池化)构成的 CNN 网络, 主要实现对原始输入信号样本的空间特征提取, 与输入层之间采取局部连接。卷积层使用 96 个大小为  $2 * 6$  的卷积核(以下简称核)与输入进行卷积操作, 得到卷积层输出:

$$y_m^{(1)}(j) = f\left(\sum_{j=1}^2 \sum_{i=1}^6 I(j, (j-1)+i) \times \ker_m^{(1)} + b_m^{(1)}\right) \quad (1)$$

其中  $y_m^{(1)}(j)$  为第  $m$  个卷积核与输入进行卷积操作后的第  $j$  个神经元输出,  $\ker_m^{(1)}$  为卷积层第  $m$  个尺寸为  $2 * 6$  的核,  $b_m^{(1)}$  为卷积层的第  $m$  个偏置;  $f(\cdot)$  是激活函数(Activation Function, AF), 卷积层使用 Relu 函数作为 AF, Relu 函数如式(2)所示:

$$\text{Relu}(x) = \begin{cases} x & \text{if } x \geq 0 \\ 0 & \text{else} \end{cases} \quad (2)$$

输入经二维卷积操作变成一维矢量形式的特征图, 输入池化层。池化操作能减少全连层中的参数数量, 加快计算速度且能防止陷入过拟合。本文使用的池化窗大小为  $1 * 2$ , 步长设置为 4。输入特征图经过池化后输出为:

$$y_m^{(2)}(j) = \frac{1}{2}(y_m^{(1)}(4j) + y_m^{(1)}(4(j-1))) \quad (3)$$

池化输出经过 Flatten 层处理后,输入下一层。

下支路为单层 LSTM 网络,用于提取信号的时序特征。LSTM 的网络拓扑图如图 2 所示。




图 2 LSTM 网络拓扑图

Fig. 2 LSTM network topology

LSTM 网络由一个记忆单元 (Memory Cell, 以下简称 Cell) 和三个控制单元组成,即忘记门 (Forget Gate, FG)、输入门 (Input Gate, IG)、输出门 (Output Gate, OG), 每个控制单元都是大小一样的两层全连接网络。FG 决定是否从 Cell 状态中保留历史信息, IG 通过对输入乘上  $[0, 1]$  之间的记忆因子决定当前输入数据对 Cell 状态的影响程度, OG 决定输出信息<sup>[15]</sup>。图 2 中, LSTM 在当前  $t$  时刻将接收信号  $x_t$ 、 $t-1$  时刻输出  $h_{t-1}$  作为输入, 经过 FG 得到忘记因子  $f_t$ :

$$f_t = \delta(W_f[h_{t-1}, x_t] + b_f) \quad (4)$$

其中,  $W_f$  为输入与 FG 之间连接权重矩阵,  $b_f$  为连接偏置,  $\delta$  为“sigmoid”函数, 表达式为:

$$\delta = \frac{1}{1 + \exp(-x)} \quad (5)$$

当  $f_t$  为 0 时, 完全忘记 Cell 里面的历史信息; 当  $f_t$  为 1 时, 记住全部历史信息。然后, IG 根据输入和 Cell 历史信息进行状态更新如下:

$$i_t = \delta(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (7)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (8)$$

其中,  $W_i$ 、 $W_c$  分别为 IG 连接权值与 tanh 层权值,  $b_i$ 、 $b_c$  为对应偏置,  $\tilde{C}_t$  为 tanh 层产生的候选值, 参与 Cell 信息  $C_t$  的更新过程。由 OG 得到输出控制因子  $O_t$  如式(9)所示, 其决定是否输出 Cell 信息, 即得到  $t$  时刻输出  $h_t$ , 如式子(10)所示:

$$O_t = \delta(W_o[h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = O_t * \tanh(C_t) \quad (10)$$

其中,  $W_o$  为输入与 OG 之间连接矩阵,  $b_o$  为偏置,  $O_t$

为输出控制因子, 其控制机理同 FG。

第三部分为特征融合层, 将上支路卷积网络提取的信号空间信息与下支路单层 LSTM 提取的时序信息融合, 两路特征串接成新的特征, 送入到下一部分。

第四部分为 softmax 分类输出层, 利用融合层融合的两支路特征进行分类输出, 该层为普通全连接层, 节点设置为 7, 以 7 维概率向量形式输出, 最大值对应的索引号为对应的分类结果。

将式(4)、(6)、(7)、和(9)中的  $\ker_m^{(1)}$ 、 $W_f$ 、 $W_i$ 、 $W_c$ 、 $W_o$ 、和  $b_m^{(1)}(j)$ 、 $b_f$ 、 $b_i$ 、 $b_c$ 、 $b_o$  都统一分别表示为参数集  $W$  和  $b$ 。上述模型的优化目标函数为实际输出标签和真实标签值之间的交叉熵函数, 如式(11)所示, 其中  $\tilde{y}$  和  $y$  分别是实际输出标签和真实标签值。  $W$  和  $b$  更新包括信息前向、反向两个传播过程, 使用梯度下降法对参数  $W$  和  $b$  按式(12)和(13)所示进行更新<sup>[6]</sup>。

$$J(W, b, x, y) = -y \ln \tilde{y} - (1-y) \ln(1-\tilde{y}) \quad (11)$$

$$W^l = W^l - \eta \frac{\partial J(W, b, x, y)}{\partial W^l} \quad (12)$$

$$b^l = b^l - \eta \frac{\partial J(W, b, x, y)}{\partial b^l} \quad (13)$$

为了保证网络能够有效训练和收敛, 对网络各层的权值  $W$  用服从  $N(0, 1)$  分布的随机数初始化, 偏置  $b$  初始化为 0。

### 3 算法仿真及性能分析

#### 3.1 仿真数据集及环境

待识别信号集包括 BPSK、QPSK、8PSK、16QAM、32QAM、16APSK 和 32APSK。信号参数设置为: 载波速率为 24 kHz, 采样速率为 60 kHz; 16APSK 信号半径为  $R_1 = 1$ 、 $R_2 = 2.7$ , 32APSK 信号半径为  $R_1 = 1$ 、 $R_2 = 2.70$ 、 $R_3 = 5.71$ 。仿真使用高斯白噪声, SNR 从 -4 dB 至 18 dB, 间隔 2 dB, 信号样本采样点数为 128, 采用一个  $7 \times 1$  向量表示样本标记, 根据 1 出现的位置标识不同的信号调制样式。

本文使用 matlab 编程语言完成信号预处理等过程, 生成实验数据集, 在 Ubuntu 16.04 64 位操作系统上完成算法仿真。使用 python、keras 框架完成网络的搭建、训练、测试等整个过程, 涉及的依赖库主要是 CUDA、cudnn 等加速库。实验硬件使用华硕

主板, 配备四核 Intel 酷睿 i7 7700 CPU, 搭载 Nvidia GTX1080 8G 显存的显卡, 配置了 8G 运行内存和 480G 固态存储硬盘。

### 3.2 算法性能分析

**实验 1** 训练迭代次数 Epoch 对识别性能影响。

Epoch 参数对识别性能起关键作用, Epoch 过多或过少模型都难达到最优。Epoch 过少, 模型没有充分学习到信号的特征, 导致误差函数偏大, 从而识别性能差; Epoch 过多不仅导致网络训练时间 (Network Training Time, 简记为 Time) 过长而且容易陷入过拟合, 从而使得识别性能下降。本文用不同的训练迭代次数训练网络, 然后进行信号调制样式识别测试, 得到 7 种信号平均正确识别率 (Average Correct Recognition Accuracy, 简记为 Acc) 和 Time 分别如图 3 和图 4 所示。从图 3 可以看出, 当 Epoch 小于 50 时, 信号平均正确识别率近似呈分段线性增长, 当 Epoch 为 50 时达到最大值, 此后增加 Epoch, Acc 稍有减小, 说明当网络训练到一定程度时单纯增加 Epoch 并不能提升识别性能, 甚至会产生过拟合, 使得识别性能下降。由图 4 可见, 随着 Epoch 的增加 Time 几乎呈现线性增长, 说明 Epoch 是影响训练快慢的重要因素。综合考虑 Acc 和 Time, 下文仿真均选取 Epoch 为 50。

**实验 2** 上支路卷积层数对识别性能影响。

为了分析上支路卷积层层数对调制样式识别性能的影响, 固定并联网络其他结构不变, 只改变卷积层的个数, 只对最后一个卷积层输出加池化层, 且由于经第一层卷积之后, 信号变成一维向量, 故对卷积层数大于 2 的卷积核尺寸都采用  $1 \times 3$ , 在




图 3 不同 Epoch 对 Acc 影响

Fig. 3 Average recognition accuracy of different epoch




图 4 不同 Epoch 对 Time 影响

Fig. 4 Network training time of different epoch

训练样本相同、训练迭代次数相同情况下, 得到不同网络模型的 7 种信号 Acc 和 Time 如表 1 所示。由表 1 可以看出: 当采用一层卷积层和一层池化层时网络有最高的识别精度和最短的训练时间; 当增加卷积层后, 网络性能下降, 说明当网络采用一层卷积层时, 卷积层提取的特征已经可以很好的反映调制样式信息, 继续增加卷积层数只会提取一些冗余特征, 使模型变得复杂, 泛化性能下降。故上支路选择一层卷积层和一层池化层

表 1 上支路不同卷积层数对 Acc 及 Time 影响

Tab. 1 Average recognition accuracy and network training time of different convolutional layer signals in the upper branch

网络模型	卷积层个数	Acc	Time
模型 1	1	97.13%	187 s
模型 2	2	95.64%	251 s
模型 3	3	96.19%	314 s

**实验 3** 上支路核尺寸与池化窗大小对识别性能的影响

CNN 的卷积核尺寸大小决定输入信号的识别粒度, 卷积核尺寸过大会造成信号的一些细节信息丢失, 尺寸过小又会使得卷积操作转化特征能力降低, 不能很好提取特征。池化层的作用是对卷积操作后的特征图进行去冗余处理, 如窗口太大会使得重要信息丢失, 若窗口太小则达不到去冗余的效果。在实验 1 和 2 基础上, 改变卷积核和池化窗口的大小, CLP 算法对本文 7 种信号的平均正确识别率和模型训练时间如表 2 所示。

由于本文算法的输入数据的维度为  $2 * 128$ , 因

此本文卷积层的卷积核尺寸都为  $2 \times$ 。从表 2 平均正确识别率数据可以看出,在网络其他参数相同时,随着卷积核尺寸增加信号平均正确识别率先增加后减少,所以核太大和太小都不利于网络模型的学习,故核大小选为  $2 \times 6$ 。当确定核大小时,可以看出,池化窗口选择为  $1 \times 2$  时网络有最好的 Acc,且 Time 最少。故下文仿真中选取卷积层核尺寸为  $2 \times 6$ 、池化窗口设置为  $1 \times 2$ 。

表 2 不同核尺寸网络的 Acc 和 Time

Tab.2 Average recognition accuracy and model training time for different kernel size networks

卷积层核尺寸	池化窗大小	Acc	Time
2×5	1×2	96.75%	194 s
2×5	1×3	96.97%	190 s
2×5	1×4	96.84%	196 s
2×6	1×2	97.13%	187 s
2×6	1×3	96.74%	192 s
2×6	1×4	96.71%	196 s
2×7	1×2	96.9%	171 s
2×7	1×3	95.9%	192 s
2×7	1×4	95.89%	192 s

#### 实验 4 下支路 LSTM 层数对识别性能的影响

第一层 LSTM 提取的初步时序特征为输入后,多层 LSTM 网络进一步提取时序特征。LSTM 层数过少可能特征提取不完全,从而识别结果较差;过多则会达到一个饱和状态,继续增加层数只会造成网络臃肿,性能难以提升。本实验设置下支路第一层 LSTM 控制门大小为 48,当层数大于 1 时设置为 24。下支路采用不同层数 LSTM 网络对 7 种信号的平均正确识别率和模型训练时间如表 3 所示。

表 3 下支路不同 LSTM 层数网络对 Acc 及 Time 影响

Tab.3 Average recognition accuracy and model training time of different LSTM layer networks in the lower branch

网络模型	LSTM 层数	Acc	Time
模型 1	单层	97.13%	187 s
模型 2	双层	96.41%	147 s
模型 3	三层	96.39%	174 s

由表 3 可以看出,下支路采用一层 LSTM 网络时,平均正确识别率最高,当层数增加时,Acc 下降。说明下支路仅仅采用一层 LSTM,就能充分提取信号的时序信息,故本文在其他实验中下支路采用一

层 LSTM 网络。

#### 实验 5 不同算法性能分析

本实验分析比较本文 CLP 算法、文献[14]应用级联形式网络(CNN+CNN+LSTM)的 CLS 算法、文献[11]应用 CNN 网络的 CNN 算法和文献[12]应用 LSTM 网络的 LSTM 算法;CLS 算法第一卷积层使用 128 个大小为  $1 \times 3$  的核,第二卷积层使用 32 个大小为  $2 \times 3$  的核,LSTM 控制门大小选取 128;其他算法参照图 1 所示参数选取。四种算法对 7 种信号的 Acc 如图 5 所示,四种算法在整个测试集上的平均正确识别率如表 4 所示,四种算法所需训练参数个数及时间如表 5 所示。由图 5 可见,本文 CLP 算法识别性能最好,其次是 CLS 算法,LSTM 算法相对较差。当 SNR 为  $-4$  dB 时,CLP、CLS、CNN 和 LSTM 算法的 Acc 分别达到 87%、85%、82% 和 75%;随着 SNR 增大,CLP、CLS、CNN 和 LSTM 算法的 Acc 分别稳定在 98%、97%、96.5%、86%;从表 4 可以看出,CLP 算法在整个测试集上的平均正确识别率最高,比 CNN 算法高 1.48 个百分点。这是由于不同信号具有不同幅度、相位和星座图特征,因此具有不同的空间特征和时序特征;并联 CNN-LSTM 网络能提取信号的时间和空间特征;级联网络中,信号经过卷积操作后,已丢失了原始信号时序特性;CNN 网络和 LSTM 网络特征提取不如前二者。

由表 5 可以看出,本文提出的 CLP 算法训练时间远远低于文献[14]提出的 CLS 算法,四种算法中,LSTM 算法训练时间最短,CLP 算法次之,CNN 算法最长,但 LSTM 算法的 Acc 相对其他三种算法最低,识别性能最差。




图 5 四种算法 Acc 比较

Fig. 5 Comparison of four algorithm average recognition accuracy

表 4 四种算法平均正确识别率比较

Tab.4 Average accuracy comparison of four algorithms

算法	CLP	CLS	CNN	LSTM
平均正确识别率/%	97.13	96.08	95.74	85.02

表 5 四种算法所需训练参数个数及时间

Tab.5 Comparison of training parameters and time of four algorithms

算法	CLP	CLS	CNN	LSTM
参数个数	1065543	2123687	2643055	132478
训练时间/s	187	287	370	106

### 实验 6 CLP 算法识别性能分析

当 SNR 为 -4 dB 至 18 dB 时,四种算法对七种信号的正确识别率分别如图 6、图 7、图 8 和图 9 所示。对比四幅图可以看出,SNR 大于 2 dB 时,CLP 算法对 7 种信号的正确识别率在 90% 以上,CLS 算法在 85% 以上,CNN 算法在 70% 以上,LSTM 算法最差。




图 6 CLP 算法单个信号正确识别率曲线

Fig.6 Single signal Acc curve of CLP




图 7 CLS 算法单个信号正确识别率曲线

Fig.7 Single signal Acc curve of CLS




图 8 CNN 算法单个信号正确识别率曲线

Fig.8 Single signal Acc curve of CNN




图 9 LSTM 算法单个信号正确识别率曲线

Fig.9 Single signal Acc curve of LSTM

除 LSTM 算法外,CLP 算法、CLS 算法和 CNN 算法对 BPSK、QPSK、16QAM、32APSK 和 16APSK 识别性能相当,单个信号正确识别率基本都达到 97% 以上。CLP 算法对 32QAM 和 8PSK 信号的正确识别率达到 90 以上,优于其他算法,且相对其他算法曲线波动小。

## 4 结论

针对人工提取信号特征复杂及识别性能受特征参数影响大的问题,本文提出一种基于信号数据的 CLP 调制样式识别算法。将接收信号的同向分量和正交分量构造数据集,利用 CNN、LSTM 并行提取信号的空间特征、时间特征,进而完成信号识别。计算机仿真结果验证了算法的有效性,该算法具有实际应用价值。

## 参考文献

- [1] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313(5786): 504-509.
- [2] Wang D, Zhang M, Li Z, et al. Modulation format recognition and OSNR estimation using CNN based deep learning[J]. *IEEE Photonics Technology Letters*, 2017, 29(19): 1667-1670.
- [3] Li J, Qi L, Lin Y. Research on modulation identification of digital signals based on deep learning[C]//2016 IEEE International Conference on Electronic Information & Communication Technology. IEEE, 2016.
- [4] 彭超然, 刁伟鹤, 杜振宇. 基于深度卷积神经网络的数字调制方式识别[J]. *计算机测量与控制*, 2018, 26(8): 222-226.  
Peng Chaoran, Yan Weihe, Du Zhenyu. Digital Modulation Recognition Based on Deep Convolution Neural Network[J]. *Computer Measurement & Control*, 2018, 26(8): 222-226. (in Chinese)
- [5] Zhao Zhijin, Gu Jiawei. Recognition of digital modulation signals based on hybrid three-order restricted Boltzmann machine[C]//IEEE 16th International Conference on Communication Technology(ICCT). IEEE, 2016.
- [6] 周龙梅. 基于深度学习的通信信号识别技术研究[D]. 北京: 北京邮电大学, 2018.  
Zhou Longmei. Research on Communication Signal Recognition Technology Based on Deep Learning[D]. Beijing: Beijing University of Posts and Telecommunications, 2018. (in Chinese)
- [7] 杨安锋, 赵知劲, 陈颖. 利用稀疏自编码器的调制样式识别算法[J]. *信号处理*, 2018, 34(7): 833-842.  
Yang Anfeng, Zhao Zhijin, Chen Ying. Modulation Pattern Recognition Algorithm Using Sparse Self-Encoder[J]. *Journal of Signal Processing*, 2018, 34(7): 833-842. (in Chinese)
- [8] Gihan J, Mendis, Jin Wei, Arjuna Madanayake. Deep learning-based automated modulation classification for cognitive radio[C]//2016 IEEE International Conference on Communication Systems(ICCS). IEEE 2016.
- [9] Byeoungdo Kim, Jaekyum Kim, Hyunmin Chae, et al. Deep neural network-based automatic modulation classification technique[C]//2016 International Conference on Information and Communication Technology Convergence (ICTC). IEEE, 2016.
- [10] Karra K, Kuzdeba S, Petersen J. Modulation recognition

using hierarchical deep neural networks[C]//IEEE International Symposium on Dynamic Spectrum Access Networks, 2017.

- [11] O'Shea T J, Corgan J, Clancy T C. Convolutional Radio Modulation Recognition Networks[J]. *Engineering Applications of Neural Networks*, 2016, 6(29): 213-226.
- [12] 周江. 基于神经网络的通信信号调制识别研究及实现[D]. 成都: 电子科技大学, 2018.  
Zhou Jiang. Research and implementation of communication signal modulation recognition based on neural network[D]. Chengdu: University of Electronic Science and Technology, 2018. (in Chinese)
- [13] Felix A. Gers, Nicol N. Schraudolph, Jürgen Schmidhuber. Learning precise timing with LSTM recurrent network[J]. *Journal of Machine Learning Research*, 2002, 3(1): 115-143.
- [14] Wu Y, Li X, Fang J. A Deep learning approach for modulation recognition via exploiting temporal correlations[C]//2018 IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). IEEE, 2018.
- [15] 黄婷婷, 余磊. SDAE-LSTM 模型在金融时间序列预测中的应用[J]. *计算机工程与应用*, 2019, 55(1): 142-148.  
Huang Tingting, Yu Lei. Application of SDAE-LSTM model in financial time series prediction[J]. *Computer Engineering and Applications*, 2019, 55(1): 142-148. (in Chinese)

## 作者简介



翁建新 男, 1993 年生, 江西上饶人。杭州电子科技大学硕士研究生, 研究方向为信号处理。

E-mail: m15180433431@163.com



赵知劲 女, 1959 年生, 浙江宁波人。西安电子科技大学博士, 杭州电子科技大学教授, 博士生导师, 研究方向为自适应信号处理、通信与语音信号处理等。

E-mail: zhaozj03@hdu.edu.cn



占锦敏 女, 1995 年生, 江西上饶人。杭州电子科技大学硕士研究生, 研究方向为信号处理。

E-mail: 122956262@qq.com