

文章编号: 2095-4980(2021)04-0617-06

基于卷积神经网络与循环谱图的调制识别方法

林心桐^{1,2}, 张琳^{*1,2}, 吴志强¹, 姜军¹

(1.西藏大学 信息科学与技术学院, 西藏 拉萨 850000; 2.中山大学 电子信息与工程学院, 广东 广州 510006)

摘要: 为提高调制分类识别精确度, 降低计算复杂度, 提出了一种基于卷积神经网络(CNN)与红绿蓝(RGB)循环谱二维图的智能调制识别方法。基于循环谱特征可识别调制类型的机理, 为了降低计算复杂度, 将三维的循环谱转换为二维平面的 RGB 循环谱图, 并将其用于构建数据集; 将一种计算复杂度较低的 CNN 作为调制类型分类识别器。仿真结果表明, 所提出的智能调制识别方法能够以较低的计算复杂度, 获得更高的分类精确度。

关键词: 智能调制识别; 卷积神经网络; 循环谱二维图; 深度学习

中图分类号: TN911

文献标志码: A

doi: 10.11805/TKYDA2021122

Modulation recognition method based on convolutional neural network and cyclic spectrum images

LIN Xintong^{1,2}, ZHANG Lin^{*1,2}, WU Zhiqiang¹, JIANG Jun¹

(1.College of Information Sciences and Technology, Tibet University, Lhasa Tibet 850000, China;

2.School of Electronic Information and Engineering, Sun Yat-sen University, Guangzhou Guangdong 510006, China)

Abstract: An intelligent modulation recognition method based on the Convolutional Neural Network(CNN) and two-dimensional Red-Green-Blue(RGB) cyclic spectrum images is proposed in order to improve the modulation recognition accuracy and reduce the computational complexity. The cyclic spectrum can be employed to identify the modulation type. The three-dimensional cyclic spectra are converted to two-dimensional RGB cyclic spectra to reduce the computational complexity, which are then taken to build the data set. Moreover, a CNN based modulation classifier with low computational complexity is proposed. Simulation results show that the proposed intelligent modulation recognition algorithm can achieve higher classification accuracy with lower computational complexity.

Keywords: intelligent modulation recognition; Convolutional Neural Network; two-dimensional cyclic spectrum images; deep learning

调制信号识别技术已广泛用于电子对抗、无线电监听和频谱管理等领域^[1], 以实现不同调制类型的分类。已有的调制识别算法可分为两类: 基于似然的调制识别算法^[2]和基于特征的调制识别算法^[1]。基于似然的调制识别算法通过确定概率密度函数, 并应用假设检验来识别调制类型; 基于特征的调制识别算法则需从信号中提取出有区分度的特征, 再利用分类器识别不同信号的特征, 从而实现不同调制类型的分类。目前常用的特征包括信号的瞬时特征^[3]、高阶累积量^[4]和循环谱(Cyclic Spectrum, CS)^[5]等, 常用的分类器包括支持向量机^[6]、决策树^[7]和人工神经网络^[8]等。尽管基于似然的调制识别算法比基于特征的调制识别算法具有更高的分类精确度, 但需要已知先验信息, 使其难以在实际系统中应用。而基于特征的调制识别算法不需要获取先验信息, 因此实用性更高。为进一步提升基于特征的调制识别性能, 借助于深度学习的特征提取能力, 学者们将其用于调制识别领域。文献[8]采用了一种将同相正交(In-phase and Quadrature, IQ)信号作为输入的卷积神经网络(CNN), 对 11 种调制方式进行了识别, 但分类精确度较低。文献[9]提出了一种基于长短期记忆(Long Short-Term Memory, LSTM)网络的自动调制分类模型, 该模型利用了调制信号的幅值和相位信息实现调制识别, 但

收稿日期: 2021-03-24; 修回日期: 2021-05-10

基金项目: 西藏自治区科技计划项目-重点研发与转化计划资助项目(XZ201901-GB-16); 广东省自然科学基金资助项目(2020A1515010703)

*通信作者: 张琳 email:isszl@mail.sysu.edu.cn

该 LSTM 网络训练阶段的计算复杂度很高。文献[10]提出了一种利用多特征融合技术和 CNN 的自动调制分类方法, 但该方法的分类精确度较低。

针对当前调制识别算法分类精确度较低、计算复杂度较高的问题, 本文提出一种基于 CNN 与 RGB 循环谱图的调制识别算法。首先, 计算调制的三维循环谱, 并沿着 Z 轴归一化三维循环谱, 再获取三维循环谱在 XY 平面中的 RGB 图像, 实现将三维循环谱转换为 RGB 循环谱图。然后, 将 RGB 循环谱图特征作为网络的输入, 训练 CNN 对其进行调制类型分类。在实际部署使用阶段, 将 RGB 循环谱图特征输入到已训练好的 CNN, 便可得到网络预测的信号调制类型。

1 问题描述及无线电信号数据集

在通信系统中, 接收信号可以表示为:

$$r(t) = x(t) * h(t) + n(t) \quad (1)$$

式中: $x(t)$ 为无噪声的接收信号的复基带包络; $h(t)$ 为信道的脉冲响应; $n(t)$ 为均值为 0 的复加性高斯白噪声。

调制识别可归结为 N 类别分类问题, 本文设计一种分类器, 以评估概率 $P(x(t) \in N_i | g(r(t)))$, 其中 $g(\cdot)$ 是 $r(t)$ 的一个变换函数, 其目的是提取出 $r(t)$ 中的有用特征, N_i 是指第 i 个类别。此外, 本文采用公开的无线电信号数据集 RadioML2016.10a^[11] 作为数据集, 用于评估本文设计的变换函数 $g(\cdot)$ 和 CNN 分类器的性能。该数据集生成的 IQ 信号的生成遵循式(1), 表 1 列出了数据集的详细参数。

表 1 RadioML2016.10a 数据集的参数

Table1 RadioML2016.10a parameters

modulations	samples per symbol	sample length	sampling frequency	signal dimension per sample	SNR range	number of training samples	number of testing samples
AM-SSB,AM-DSB,WBFM,BPSK,CPFSK,GFSK,PAM4,QPSK,8PSK,16QAM,64QAM	8	128	1 MHz	2×128	[-20 dB,18 dB]	110 000 vectors	110 000 vectors

2 基于卷积神经网络与循环谱图的调制识别算法

由于循环谱估计方法能够识别调制信号特征且对噪声不敏感, 具有较好的鲁棒性, 因此本文将利用循环谱构建用于 CNN 训练和在线实施的数据集。首先, 计算数据集各类 IQ 信号的三维循环谱, 为了降低计算复杂度, 沿 Z 轴对信号的三维循环谱进行归一化处理, 获取三维循环谱在 XY 平面中的 RGB 图像, 将三维循环谱转换为 RGB 循环谱图。为进一步降低复杂度, 从 RGB 循环谱图中选择一部分作为基于 CNN 分类器的输入, 对信号的调制类型进行识别。上述将 IQ 信号转换为部分 RGB 循环谱图的过程就是特征提取的过程, 将其用变换函数 $g(\cdot)$ 来表示。算法的实现具体如下所述。

2.1 部分 RGB 循环谱图的获取

信号的循环平稳特性^[12]可以通过信号的三维循环谱来表征。

信号 $x(t)$ 的循环谱可表示为

$$S_x^\alpha(f) = \int_{-\infty}^{\infty} R_x^\alpha(\tau) e^{-j2\pi f\tau} d\tau \quad (2)$$

式中: $R_x^\alpha(\tau)$ 为信号的循环自相关函数, 可表示为 $R_x^\alpha(\tau) = \lim_{T_0 \rightarrow \infty} \frac{1}{T_0} \int_{-T_0/2}^{T_0/2} x(t)x^*(t-\tau) e^{-j2\pi\alpha t} dt$ ^[12]; α 为循环频率; f 为

信号频率。因为调制信号与加性高斯白噪声以及平稳干扰之间没有谱相关性, 即使在低信噪比下, 信号的循环谱也能够体现出不同调制技术的特点。此外, 循环谱还包含着与定时参数相关的相位和频率信息^[13]。因此, 本文利用信号的循环谱特征来实现调制识别。

为了降低复杂度和方便 CNN 的处理, 还需要将三维循环谱转换为 RGB 循环谱图。首先, 将三维循环谱在 Z 轴上归一化到 0~1 的范围内。然后, 获取归一化后的三维循环谱在 XY 平面中的 RGB 图像, 便可以实现将三维循环谱转换为 RGB 循环谱图。图 1 为当信噪比(Signal-to-Noise Ratio, SNR)为 18 dB 时, 使用 BPSK、QPSK 和 8PSK 调制信号生成的 RGB 循环谱图。

为了进一步降低复杂度, 需要从 RGB 循环谱图中选择部分图像作为 CNN 的输入, 该部分大小是原图像的一半。图 2 展示了当 SNR 为 18 dB 时, 从 BPSK 调制信号的 RGB 循环谱图中选出部分图像的过程, 白色矩形圈出的部分即被选择的部分。被选择的部分图像的像素为 60×60。




Fig.1 RGB cyclic spectrum images generated for BPSK, QPSK and 8PSK modulated signals at $R_{SN}=18$ dB
图 1 $R_{SN}=18$ dB 时 BPSK、QPSK 和 8PSK 调制信号生成的 RGB 循环谱图




Fig.2 Process of selecting part of the image from the RGB cyclic spectrum image of BPSK modulated signal
图 2 从 BPSK 调制信号的 RGB 循环谱图中选出部分图像的过程

2.2 基于卷积神经网络的调制分类器

传统的 CNN 结构包括卷积层、池化层和全连接层^[14]。其中，卷积层将输入特征图和一个可训练的卷积核进行卷积计算，可得到输出的特征图。卷积层是三种层中最重要的，既能够深层次地挖掘输入数据中的信息，又能够减少网络可训练参数的数量，从而减小网络过拟合的概率。卷积层的卷积操作运算为：

$$y_j = \sum_{i \in M_j} x_i * k_{ij} + b_j \quad (3)$$

式中： y_j 为输出特征图的第 j 个通道； x_i 为输入特征图的第 i 个通道； k 为卷积核； b 为偏置值； k_{ij} 是用于计算 y_j 的通道集合。池化层是通过池化函数对提取的特征进行过滤，可以降低数据维度，去除冗余信息，保留更重要的特征。均值池化是常见的池化操作，用于计算图像某个区域中的均值并将其作为该区域池化后的值。全连接层是将所有特征图连接到一起作为其输入，再对输入的特征进行加权求和。实际实现中，在卷积层和全连接层中可以加一个能把多维输入一维化的压平层，以提高计算性能。

图 3 为本文提出的基于 CNN 的调制分类器的网络结构图。设计了具有 11 层结构的 CNN 架构，各层具体参数信息如下：

- 1) 第一层为输入层，在该层输入 60×60 像素的 RGB 循环谱图；
- 2) 第二层为批标准化(Batch Normalization, BN)层，BN 是一种用于降低训练难度的特征归一化方法^[15]；
- 3) 第三层为二维卷积层，选择 40 个 4×2 的卷积核矩阵对输入的特征图进行卷积操作，进行卷积操作后还需经过整流线性单元(Rectified Linear Unit, ReLU)激活函数处理，其表达式为 $f_R(x) = \max(x, 0)$ ， x 为 ReLU 函数的输入；
- 4) 第四层为均值池化层，该层采样窗口设置为 2×2 ；
- 5) 第五层是二维卷积层，选择 8 个 4×2 的卷积核矩阵对输入的特征图进行卷积操作，在卷积操作后也需经过 ReLU 函数处理；
- 6) 第六层为均值池化层，该层采样窗口设置为 2×2 ；
- 7) 第七层为二维卷积层，选择 6 个 4×2 的卷积核矩阵对输入的特征图进行卷积操作，在卷积操作后也需经过 ReLU 函数处理；
- 8) 第八层为均值池化层，该层采样窗口设置为 2×2 ；
- 9) 第九层为压平层；
- 10) 第十层为全连接层，其神经元个数为 35，在加权求和操作后也需经过 ReLU 函数处理；
- 11) 第十一层为输出层，也是全连接层，其神经元个数取决于调制方式的类数。本文所用数据集的调制类别数目为 11，因此神经元数目为 11；此外，在进行加权求和操作后，需经过 softmax 函数处理，其表达式为 $y_j = e^{x_j} / \sum_{i=1}^{N_{class}} e^{x_i}$ ，其中， N_{class} 为类数， x 和 y 分别为 softmax 函数的输入和输出， i 和 j 为输出层神经元的索引， y_j 可视为属于第 j 类的输入对应的预测概率。

2.3 卷积神经网络的训练与测试

本文提出的调制识别算法的实施过程包括训练阶段和测试阶段。在训练前，先将数据集分为训练集和测试集，训练集和测试集数量比例设置为 1:1，再将训练集和测试集中的 IQ 信号转换为部分 RGB 循环谱图。

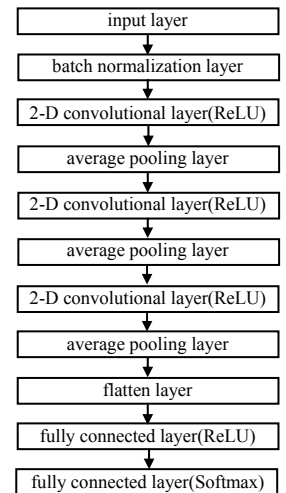


Fig.3 Structure of the CNN-based modulation classifier
图 3 基于 CNN 的调制分类器的网络结构

在训练阶段, 将训练集对应的 RGB 循环谱图输入到 CNN 中, 采用反向传播算法对 CNN 的参数进行调整。CNN 的损失函数是分类交叉熵函数, 其表达式为 $L = -\sum_{j=1}^{N_{\text{class}}} t_j \log(y_j)$, 其中, y_j 为 softmax 函数的输出, t_j 是属于第 j 类的输入对应的真实概率。

在训练结束后, 将 CNN 的权重参数和偏置参数保存。在测试阶段或实际部署阶段, 将收集到的接收 IQ 信号对应的部分 RGB 循环谱图输入到训练好的 CNN 中, 可实时提取并识别 IQ 信号的调制类型。

2.4 超参数的设置和实现细节

在训练阶段需要选择超参数。采用批大小为 1 024 的随机梯度下降算法。此外, 使用 Adam 优化器^[15]。在训练时, 逐步降低学习率, 前 50 个训练周期学习率为 0.1, 50 个周期后学习率为 0.01, 最后 50 个周期学习率为 0.001。在 Tensorflow^[16]框架下, 使用 Python 实现了基于 CNN 的调制分类器, 训练过程使用了 Nvidia GeForce GTX 1080 GPU。

3 仿真分析

本节将基于所设计的深度神经网络和变换函数, 评估调制识别性能, 并将其与同类算法的识别精确度进行比较。因本文所提算法基于 CNN 和循环谱, 故将其简称为 CNN-CS(CNN-Cyclic Spectrum)。

3.1 识别性能分析与比较

将 CNN-CS 与文献[8]、文献[9]中两种同样基于深度学习的调制识别算法进行比较, 结果如图 4 所示。将文献[8]提出的算法称为 CNN-IQ, 将文献[9]提出的算法简称为 LSTM-AP。从图 4 可以看出, 与 CNN-IQ 和 LSTM-AP 相比, 本文算法在 $R_{\text{SN}} > 0$ dB 时, 具有更高的识别精确度; 当 $R_{\text{SN}} < -4$ dB 时, 本文算法与 CNN-IQ 和 LSTM-AP 的分类精确度差别不大。因此, 本文算法的识别性能优于 CNN-IQ 和 LSTM-AP。本文算法识别精确度更高的原因在于: a) 不同调制方法的循环谱图特征不同; b) 所提出的神经网络架构中, 卷积层增强了提取并学习循环谱图中的特征的能力。

进一步, 为更好地对比所提算法、CNN-IQ 和 LSTM-AP 的性能, 本文对其在 $R_{\text{SN}} = 18$ dB 时的混淆矩阵进行分析。如图 5 所示, 混淆矩阵的每一列表示算法预测的调制类型, 每一行表示真实的调制类型。由图 5 可以看出, 与 CNN-IQ 和 LSTM-AP 相比, CNN-CS 的混淆矩阵有更清晰的对角线, 这意味着当 $R_{\text{SN}} = 18$ dB 时, 该算法的分类精确度优于 CNN-IQ 和 LSTM-AP。




Fig.4 Classification accuracy comparison of different algorithms
图 4 不同算法分类精确度对比图




Fig.5 Confusion matrices of different algorithms at $R_{\text{SN}} = 18$ dB
图 5 $R_{\text{SN}} = 18$ dB 时不同算法的混淆矩阵

3.2 计算复杂度比较与分析

表 2 对比了本文算法、CNN-IQ 和 LSTM-AP 的计算复杂度。由表 2 可知，CNN-CS 的训练时间比 LSTM-AP 短，但比 CNN-IQ 长。考虑到一般情况下信道的变化并不剧烈，只有当信道有相当大的变化时再重新进行训练。因此，本文更关注能够反映实际部署阶段复杂度的预测时间指标。由表 2 可知，CNN-CS 的预测时间比 LSTM-AP 略长，比 CNN-IQ 短得多。

表 2 三种调制识别算法的计算复杂度

Table 2 Computational complexity of three modulation recognition algorithms			
	CNN-IQ ^[8]	LSTM-AP ^[9]	CNN-CS
number of trainable parameters	2830 k	330 k	9 k
training time/s	480	4 371	1 120
prediction time/(μ s/sample)	364	37	100

综合识别精确度和计算复杂度的分析与比较，可以得出，与同类智能调制识别算法相比，本文提出的算法可以在较低的计算复杂度下获得更高的识别精确度。

4 结论

本文提出了一种基于卷积神经网络和循环谱图的调制识别算法，以循环谱二维图作为用于深度学习以识别调制类型的数据集，并设计了深度神经网络结构。本文设计方案中，首先训练卷积神经网络，对网络参数进行配置和优化，随后在实施阶段，利用训练好的 CNN，从调制信号的 RGB 循环谱图中自动学习有用的特征并识别调制类型。仿真结果表明，该系统能有效地对 RadioML2016.10a 数据集中的 11 种调制类型进行分类，分类精确度较高，同时又具有较低的计算复杂度。未来的研究方向包括如何在极低信噪比下，进一步提高智能调制识别性能。

参考文献：

- [1] DOBRE O A, ABDI A, BAR-NESS Y, et al. Survey of automatic modulation classification techniques: classical approaches and new trends[J]. IET Communications, 2007, 1(2): 137-156.
- [2] HAMEED F, DOBRE O A, POPESCU D C. On the likelihood-based approach to modulation classification[J]. IEEE Transactions on Wireless Communications, 2009, 8(12): 5884-5892.
- [3] 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(347): 25-30. (LI Pei, WANG Longlong, TAO Liwei, et al. Automatic recognition and realization of digital modulation signal based on instantaneous features and BP neural network[J]. Communications Technology, 2020, 53(347): 25-30.)
- [4] 张利, 李青. 基于高阶累积量的调制识别算法的研究[J]. 信息工程大学学报, 2017, 18(4): 403-408. (ZHANG Li, LI Qing. Research on modulation recognition algorithm based on higher-order cumulant[J]. Journal of Information Engineering University, 2017, 18(4): 403-408.)
- [5] 赵雄文, 郭春霞, 李景春. 基于高阶累积量和循环谱的信号调制方式混合识别算法[J]. 电子与信息学报, 2016, 38(3): 674-680. (ZHAO Xiongwen, GUO Chunxia, LI Jingchun. Mixed recognition algorithm for signal modulation schemes by high-order cumulants and cyclic spectrum[J]. Journal of Electronics & Information Technology, 2016, 38(3): 674-680.)
- [6] 陈佳林, 熊刚. 一种基于新型特征与支持向量机的调制识别方法[J]. 通信技术, 2018, 51(4): 763-767. (CHEN Jialin, XIONG Gang. A modulation recognition method based on new feature and SVM[J]. Communications Technology, 2018, 51(4): 763-767.)
- [7] 孙闽红, 赵太飞, 郭勇, 等. 基于决策树的调制信号自动识别算法及其 DSP 实现[J]. 桂林工学院学报, 2005, 25(1): 115-118. (SUN Minhong, ZHAO Taifei, GUO Yong, et al. Realization of automatic recognition of modulated signal by DSP based on decision tree[J]. Journal of Guilin Institute of Technology, 2005, 25(1): 115-118.)
- [8] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]// International Conference on Engineering Applications of Neural Networks. Aberdeen, UK: [s.n.], 2016: 213-226.
- [9] RAJENDRAN S, MEERT W, GIUSTINIANO D, et al. Distributed deep learning models for wireless signal classification with low-cost spectrum sensors[J]. IEEE Transactions on Cognitive Communications and Networking, 2018, 4(3): 433-445.
- [10] WU H, LI Y, ZHOU L, et al. Convolutional neural network and multi-feature fusion for automatic modulation classification[J]. Electronics Letters, 2019, 55(16): 895-897.
- [11] O'SHEA T J, WEST N. Radio machine learning dataset generation with GNU radio[C]// Proceedings of the 6th GNU Radio Conference. Boulder, CO, USA: [s.n.], 2016.

- [12] ROBERTS R S,BROWN W A,LOOMIS H H. Computationally efficient algorithms for cyclic spectral analysis[J]. IEEE Signal Processing Magazine, 1991,8(2):38–49.
- [13] FEHSKE A,GAEDDERT J D,REED J H. A new approach to signal classification using spectral correlation and neural networks[C]// IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks. Baltimore,MD, USA:IEEE, 2005:144–150.
- [14] 张佳琳,柏思佳,刘爽. 基于卷积神经网络的旅游推荐模型设计[J]. 太赫兹科学与电子信息学报, 2020,18(6):1128–1132. (ZHANG Jialin,BAI Sijia,LIU Shuang. Design of travel recommendation model based on convolutional neural network[J]. Journal of Terahertz Science and Electronic Information Technology, 2020,18(6):1128–1132.)
- [15] 冯宇旭,李裕梅. 深度学习优化器方法及学习率衰减方式综述[J]. 数据挖掘, 2018,8(4):186–200. (FENG Yuxu,LI Yumei. An overview of deep learning optimization methods and learning rate attenuation methods[J]. Hans Journal of Data Mining, 2018,8(4):186–200.)
- [16] ZENG Zixian,GONG Qingge,ZHANG Jun. CNN model design of gesture recognition based on tensorflow framework[C]// 2019 IEEE Information Technology,Networking,Electronic and Automation Control Conference. Chengdu,China:IEEE, 2019:1062–1067.

作者简介:

林心桐(1995–), 女, 在读硕士研究生, 主要研究方向为基于深度学习的智能通信与定位.
email:825590525@qq.com.

张琳(1976–), 女, 博士, 副教授, 主要研究方向为智能通信、信号处理、无线可见光通信等.

吴志强(1973–), 男, 博士, 教授, 主要方向为信号处理技术等.

姜军(1980–), 男, 硕士, 副教授, 主要方向为信号处理技术等.

(上接第 616 页)

- [25] IEEE Standards Association. IEEE 802.15.4-2011-IEEE standard for local and metropolitan area networks-part 15.4: Low-Rate Wireless Personal Area Networks(LR-WPANs)[S]. 2011.
- [26] IEEE Standards Association. IEEE 802.15.1-2002-IEEE Standard for telecommunications and information exchange between systems—LAN/MAN—specific requirements—part 15:wireless Medium Access Control(MAC) and Physical Layer (PHY) specifications for Wireless Personal Area Networks(WPANs)[S]. 2002.
- [27] 3GPP TS 51.010-1 V5.3.0. 3rd generation partnership project. Technical specification group GSM/EDGE radio access network digital cellular telecommunications system(phase 2+);Mobile Station(MS) conformance specification; part 1: conformance specification(Release 5)[S]. 2003.
- [28] ETSI TS 125 101 V3.1.0. Universal Mobile Telecommunications System(UMTS);UE radio transmission and reception (FDD)(3G TS 25.101 version 3.1.0 release 1999)[S]. 2000.
- [29] Std-T A. ETSI TS 136 101 V9.4.0. LTE;Evolved Universal Terrestrial Radio Access(E-UTRA);User Equipment(UE) radio transmission and reception(3GPP TS 36.101 version 9.4.0 release 9)[S]. 2010.

作者简介:

俞佳宝(1992–), 男, 浙江省绍兴市人, 博士, 专职研究员, 主要研究方向为物理层安全、射频指纹.email: yujiabao@seu.edu.cn.

李古月(1989–), 女, 江苏省淮安市人, 博士, 副教授, 主要研究方向为物理层安全、无线通信安全.email:guyuelee@seu.edu.cn.

胡爱群(1964–), 男, 江苏省如皋市人, 博士, 教授, 主要研究方向为无线网络安全、无线通信安全.email:aqhu@seu.edu.cn.