

# 基于半监督生成对抗网络的通信信号调制识别算法

秦博伟<sup>1</sup>, 蒋磊<sup>1</sup>, 郑万泽<sup>2</sup>, 许华<sup>1</sup>

(1. 空军工程大学信息与导航学院, 西安, 710077; 2. 空军工程大学科研学术处, 西安, 710051)

**摘要** 针对小样本条件下通信信号识别混淆的问题,提出了一种基于半监督生成式对抗网络的调制识别算法。首先结合半监督学习思想利用少量标签数据和大量未标签数据训练网络;其次在输出层添加辅助分类器进行结果判定,针对性设计了目标函数和损失函数,以满足网络生成虚假数据和实现信号分类的目的;最后使用不同的激活函数并用反卷积和Dropout代替池化操作,有效降低了算法复杂度并加快网络收敛速度。仿真实验表明:该算法适应性强、计算量小,较传统算法识别准确率提升了6%~13%,有效实现了小样本条件下的调制样式识别。

**关键词** 调制识别;生成式对抗网络;卷积神经网络;半监督学习;小样本

**DOI** 10.3969/j.issn.1009-3516.2021.05.012

**中图分类号** TN975 **文献标志码** A **文章编号** 1009-3516(2021)05-0075-07

## A Communication Signal Modulation Recognition Algorithm Based on Semi-Supervised Generative Adversarial Networks

QIN Bowei<sup>1</sup>, JIANG Lei<sup>1</sup>, ZHENG Wanze<sup>2</sup>, XU Hua<sup>1</sup>

(1. Information and Navigation College, Air Force Engineering University, Xi'an 710077, China;

2. Department of Academic Research, Air Force Engineering University, Xi'an 710051, China)

**Abstract** In view of the confusion problem of few shot learning in communication signal recognition, a communication signal recognition algorithm is proposed based on semi-supervised generative adversarial network in this paper. Firstly, this algorithm utilizes a small amount of labeled samples and a large amount of unlabeled samples for training the network with the idea of semi-supervised learning. Secondly, an auxiliary classifier in the output layer is added to determine the result and a new loss function and objective optimization are designed to meet the purpose of generating fake data and realizing signal classification. Finally, in order to reduce the complexity of the algorithm and accelerate the convergence speed of the algorithm effectively, different activation functions are chosen by the network and the de-convolution and Dropout are used to replace the pooling layer. The experimental results show that this algorithm is adaptable and computationally, the recognition accuracy is improved by 6%~13% compared with the traditional algorithm, effectively realizing the modulation pattern recognition in few shot learning.

**Key words** modulation classification; generative adversarial networks; convolution neural networks; semi-supervised learning; few shot learning

**收稿日期:** 2021-04-07

**作者简介:** 秦博伟(1998—),男,安徽宿州人,硕士生,研究方向:通信信号处理、机器学习、模式识别等。E-mail:1033471857@qq.com

**引用格式:** 秦博伟,蒋磊,郑万泽,等.基于半监督生成对抗网络的通信信号调制识别算法[J].空军工程大学学报(自然科学版),2021,22(5):75-81. QIN Bowei, JIANG Lei, ZHENG Wanze, et al. A Communication Signal Modulation Recognition Algorithm Based on Semi-Supervised Generative Adversarial Networks[J]. Journal of Air Force Engineering University (Natural Science Edition), 2021, 22(5): 75-81.

通信信号的调制样式识别是从信号检测到信息获取的一个重要过程,其目的是在调制信息未知的情况下对通信信号的调制参数进行估计分析得出信号的调制样式,从而为最终解调信号获取信息提供理论依据。传统通信信号调制样式识别通常采用基于特征工程的方法,根据专家的经验构造信号特征并建立特征工程。传统方法主要针对特定调制样式,准确率和识别精度高,但是要以大量的先验信息作为基础,需要人工设定判决门限或固定特征参数,实际应用中受环境的不确定因素影响<sup>[1-5]</sup>。因此寻求一种准确、适应性强的调制分类识别算法迫在眉睫。

随着深度学习算法在图像和自然语言处理等方面展现出优异性能,使得神经网络提取特征的能力被逐渐发掘出来<sup>[6-7]</sup>。基于深度学习的网络模型不需要预先人工设计信号特征,可直接利用网络学习信号特征,建立端到端的信号分类模型<sup>[8]</sup>,具有代表性的网络模型有卷积神经网络(convolution neural network, CNN)和循环神经网络。CNN 具有局部区域感知、权值共享以及空间下采样等特点。T. J. O'Shea 等人<sup>[9]</sup>首次将浅层 CNN 应用到无线电信号的特征提取中,并利用 Softmax 激活函数实现信号调制样式的分类;Jeong 等人首先将原始中频信号通过短时傅里叶变换为二维的时频域信号,利用图像处理的方法,使用 CNN 完成了 7 种信号的调制识别<sup>[10]</sup>。Peng Shengliang 等人<sup>[11]</sup>则将解调后的信号数据转化为星座图格式,将著名的神经网络模型 Alex-Net 和 Google-Net 应用到调制识别领域。Zeng Yuan 等人<sup>[12]</sup>将无线电信号变换为高光谱图片,利用 CNN 直接提取图像特征,在相同信噪比条件下相比较决策树分类网络识别准确率提升 5%。基于深度学习的网络模型利用监督学习,依托大量带标签数据训练网络,取得了很好的效果,但实际应用中往往难以获得大量的标签数据。

针对小样本学习<sup>[13]</sup>问题,目前普遍采用的是基于数据增强的算法和元学习算法。数据增强算法从特征和属性方面通过学习数据的分布生成新样本<sup>[14]</sup>和构造人工特征<sup>[15]</sup>来实现样本扩充;元学习算法<sup>[16]</sup>通过学习模型最优化时的初始条件、参数、网络权值和梯度更新等,迁移到其他任务上的相应权值网络以实现在小样本条件下新任务的快速学习。这两种方法都需要一个泛化性较强的初始网络来实现对新任务的快速适应学习,在实际应用中需要相同分布域的数据来训练这个初始网络。

近年来生成式对抗网络<sup>[17]</sup>(generative adversarial networks, GAN)在图像处理、数据生成、信号

分类识别等领域体现出明显的优势,GAN 直接利用网络去学习不同分布域的数据,生成与之相似度较高的虚假数据,一定程度上解决了网络训练所需标签数据量不足的问题,并且它独特地使用对抗训练机制对 2 个神经网络进行训练,利用随机梯度下降实现优化,避免了反复应用马尔科夫链,从而提高了网络训练效率。BuKe 等人<sup>[18]</sup>借鉴 GAN 的思想,提出一种基于对抗迁移的通信信号调制识别算法,该算法利用大量标签数据生成可靠性较高的虚假数据供网络进行训练,在低信噪比下信号识别准确率较参数迁移方法提升 4%~6%。

基于深度学习的网络模型训练所需标签数据较多、识别准确率不高,针对上述问题,本文设计并提出一种基于半监督生成式对抗网络(semi-supervised auxiliary classifier GAN, SACGAN)的调制识别算法。

## 1 SACGAN 模型设计

### 1.1 生成式对抗网络

GAN 最早由 Goodfellow 在 2014 年提出,它的基本框架包含两个相互对抗的网络:生成器  $G$  和判别器  $D$ ,  $G$  尽量模拟数据真实分布,而  $D$  则是为了准确区分真实数据和虚假数据。受博弈论中二元零和博弈的启发,GAN 采用对抗训练方法。首先将噪声作为数据输入,通过  $G$  模拟真实数据并生成虚假数据,其次将生成的虚假数据和真实数据一起送入  $D$  进行判决,最后输出的结果反馈到  $G$  和  $D$  用于训练,通过这种反馈迭代训练过程,最终  $G$  生成的虚假数据不再被  $D$  所识别,网络训练停止,输出结果。

原始 GAN 中  $G$  和  $D$  的网络结构均为 BP 神经网络,Goodfellow 等<sup>[19]</sup>从博弈论的角度阐释了 GAN 的思想,即达到纳什均衡点的条件为  $G$  最小化真实数据与生成数据的差异, $D$  最大化真实数据与生成数据的差异。 $G$  和  $D$  的对抗训练最终会达到一个纳什均衡点。这里的差异通常是指 Jensen-Shannon 散度或者 Kullback-Leibler 散度<sup>[20]</sup>。

### 1.2 SACGAN 模型设计

为适应通信信号调制识别的应用场合,本文提出的基于 SACGAN 的算法对原始 GAN 结构进行了修改。SACGAN 模型使用不同的激活函数使网络可以更好地进行梯度计算;用反卷积代替池化操作,最大限度地保留数据的初始信息量;网络还根据输入输出的对应关系设计了新的目标函数,满足生成虚假数据、实现信号调制样式识别的目的。

图 1 为本文算法的网络结构,  $G$  和  $D$  的网络结构均为 CNN,  $G$  的输入为噪声、输出为带有指定标签类别的虚假数据,  $D$  的输入为真实数据和虚假数据, 输出为两个判别结果, 一个结果为生成数据的真假性, 另一个结果为所有数据的类别属性, 将数据的类别信息与标签样本进行对比分析, 结果反馈到网络中进行参数调整和损失函数计算。




图 1 SACGAN 模型

### 1.3 网络结构参数设定

图 2 所示为  $G$  和  $D$  的具体网络结构参数, 由于本文设定的小样本条件, 网络层数的深度堆叠会直接造成网络训练过拟合, 参照文献[21]对网络层数的选择标准, 本文通过大量实验证明  $G$  网络采用 3 层 CNN,  $D$  网络采用 4 层 CNN, 隐藏层激活函数选用 ReLU 函数时网络性能最好。

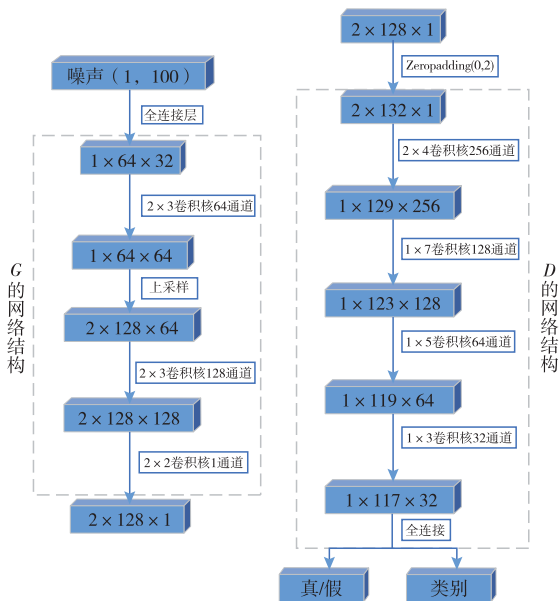


图 2  $G$  和  $D$  的网络模型参数

以单个数据为例, 生成器的输入为  $1 \times 100$  的服从  $(0, 1)$  高斯分布的噪声, 经过卷积和上采样操作, 输出  $2 \times 128 \times 1$  的虚假数据; 判别器的输入为  $2 \times 128 \times 1$  的真实数据, 添加零填充层和卷积操作, 最终输出数据的真/假结果和类别属性。

本文所提的 SACGAN 模型结构不同于其他的 GAN。首先为了扩大感受野,  $D$  网络添加零填充层; 其次为了更好地实现网络的分层分块提取信号的局部特征, 减少网络参数并有效降低算法复杂度,

$D$  网络选取  $2 \times 4, 1 \times 7, 1 \times 5, 1 \times 3$  的步幅为 1 卷积核,  $G$  网络选取  $2 \times 2, 2 \times 3$  的步幅为 1 卷积核; 最后, 为了保留数据的原始信息, 避免因池化操作带来的数据关键信息丢失, 用反卷积和 Dropout 操作代替池化层。

## 2 SACGAN 算法

基于 SACGAN 的算法训练过程主要分为无标签数据训练和有标签数据训练。无标签数据训练阶段,  $G$  网络需要利用噪声生成与真实数据相似度较高的虚假数据, 用  $D$  网络输出层的辅助分类器来判断虚假数据的相似度。有标签数据训练阶段,  $D$  网络需要学习真实数据的标签信息, 用类别分类器判断真实数据的类别。训练过程中通过  $D$  输出的结果分别对  $G$  和  $D$  进行梯度下降训练。下面给出算法的具体训练步骤。

表 1 SACGAN 算法具体步骤

基于 SACGAN 网络的调制识别算法	
输入:	噪声、真实的数据集。
输出:	生成数据的真假概率、分成各个类别概率。
1. 初始化	
2. 设置 Adam, epoch, Dropout	
1) 生成 $m$ 个 $n$ 维的噪声向量 $\{z^1, z^2, \dots, z^m\}$ 。	$m, n$ 取决于真实数据的维度。
2) 将 $m$ 个噪声样本通过 $G$ 生成 $m$ 个无标签虚假样本 $\{(x^1), (x^2), \dots, (x^m)\}$ 。	
3) 将步骤 2) 中 $m$ 个无标签虚假样本和 $m$ 个无标签真实样本 $\{(x^1)', (x^2)', \dots, (x^m)'\}$ 一起送入 $D$ 中执行梯度下降进行训练。	
4) 生成 $m$ 个 $n$ 维的噪声向量 $\{(z^1)', (z^2)', \dots, (z^m)'\}$ 。	$m, n$ 取决于真实数据的维度。
5) 将噪声和标签一一对应并通过 $G$ 生成 $m$ 个虚假样本 $\{(x^1, y^1), (x^2, y^2), \dots, (x^m, y^m)\}$ 。	
6) 将步骤 5) 中 $m$ 个虚假样本和 $m$ 个真实样本 $\{(x^1, y^1)', (x^2, y^2)', \dots, (x^m, y^m)'\}$ 一起送入 $D$ 中执行梯度下降进行训练。	
7) 根据 $D$ 的输出结果设置网络终止条件。	
3. 输出分类结果	

SACGAN 算法模型中  $G$  和  $D$  可以映射为任意的可微函数,  $G$  生成样本  $X_{fake} = G(c, s)$ , 每一类生成样本  $c \sim p_c$ ,  $D$  的输出为两部分: 正确信号源概率分布  $P(S/X)$  和正确信号标签概率分布  $P(C/X)$ ,  $D$  的输出层激活函数分别使用 Sigmoid 和 Softmax。Sigmoid 函数输出一个范围在  $0 \sim 1$  之间的数, 越接近于 0 代表生成的数据越假, 越接近于 1 代表生成

的数据越真。Softmax 函数输出  $k$  维向量  $\mathbf{l} = \{l_1, l_2, \dots, l_k\}$ , 转化成概率表示为  $\mathbf{p} = \{p_1, p_2, \dots, p_k\}$ 。

$$p_j = \frac{e^{l_j}}{\sum_{i=1}^{k+1} e^{l_i}} \quad j = \{1, 2, \dots, k\} \quad (1)$$

式(2)为  $D$  的输出的具体表达式。

$$\begin{aligned} P(S | X) &= P_1 + P_2 \\ P(C | X) &= P_3 + P_4 \\ P_1 &= P(S = \text{fake} | X_{\text{fake}}) \\ P_2 &= P(S = \text{real} | X_{\text{real}}) \\ P_3 &= P(C = \text{real} | X_{\text{real}}) \\ P_4 &= P(C = \text{fake} | X_{\text{fake}}) \end{aligned} \quad (2)$$

SACGAN 的目标函数包括两部分: 正确来源的对数似然函数  $L_s$  和正确类别的对数自然函数  $L_c$ 。

$$\begin{aligned} L_s &= E[\log D'(P_1)] + E[\log D'(G'(P_2))] \\ L_c &= E[\log D'(P_3)] + E[\log D'(G'(P_4))] \end{aligned} \quad (3)$$

式中:  $E$  为求期望;  $G'$  和  $D'$  分别表示  $G$  与  $D$  映射的可微函数;  $D$  的目标函数为最大化  $L_c + L_s$ ;  $G$  的目标函数为最大化  $L_c - L_s$ 。

### 3 实验与结果分析

#### 3.1 仿真平台与数据集

本文的模型训练均使用 python 的 Keras 环境, 配置为 Nvidia GTX 1650 GPU, 借助 Tensorflow 后端进行训练, 数据集采用的是 Deepsig 公开调制识别数据集<sup>[9]</sup>RML 2016. 10b, 表 2 为本文采用的信号集信息。

表 2 调制信号数据集

调制样式	8PSK, AM-DSB, BPSK, GFSK, CPFSK, PAM, QAM16, QAM64, QPSK
样本维度	(2, 128)
样本数量	97 200
信噪比/dB	-4~18(每 2 dB 一个间隔)

#### 3.2 网络初始化

根据 3 通道原则, 将数据维度由 (2, 128) 调整为 (2, 128, 1), 因为数据集信号已经进行归一化, 所以直接利用服从 (0, 1) 高斯分布噪声进行拟合数据, 训练轮数设成 80 个 epoch。训练时采用提前终止迭代算法, 确保网络收敛到验证集损失值最低点。

#### 3.3 实验结果

##### 3.3.1 实验 1: 网络参数初始值设定

为了验证本文设计的网络参数最优性和相比较于其他优化算法是否具有优势, 本文首先对比不同优化器下的算法识别性能, 实验结果见图 3。




图 3 不同优化算法对比结果

实验结果表明, 基于 Adam 优化器相较于其他优化器算法在低信噪比下收敛速度较快, 高信噪比下稳定性更好, 因此本文选用 Adam 优化算法。当改变 Adam 的学习率时, 不管怎么设置其他网络参数, 网络损失值始终保持不变, 因此 Adam 学习率设置为默认数值 0.000 2。在基于 Adam 优化器算法的前提下, 本文还通过大量对比实验得出 Adam 第一衰减率、Batch-size、Dropout 不同取值时的网络性能, 部分实验结果如表 3 所示。

表 3 不同参数下的网络性能比较

Batch-size	第一衰减率	Dropout	分类准确率/%
32	0.4	0.2	0.909
64	0.5	0.05	0.951
128	0.6	0.15	0.943
256	0.5	0.3	0.932
512	0.7	0.15	0.845

根据对结果可以看出, Batch-size 设置为 64, Dropout 设置为 0.05, 第一衰减率设置为 0.5 时, 网络的性能最好, 将此状态下的各项数值设置为网络参数的初始值。

##### 3.3.2 实验 2: 调制信号分类结果

根据实验 1 的网络参数初始值设定, 将数据集切分后输入到网络中进行训练, 为了验证小样本条件下的网络性能, 分别对 (-4~18 dB) 信噪比下的每种信号随机选取 900, 2 700, 5 400, 8 100, 10 800, 21 600, 43 200, 86 400 个标签样本, 将选取后的所有样本按照 8:1:1 的比例分为训练集、验证集和测试集实验, 实验步骤按照表 1 进行,  $m$  为标签样本数量,  $n$  取 100。

训练过程中先训练  $D$ , 从图 4 可以看到  $D$  的损失在 5 epoch 以前下降很快, 之后下降较为缓慢;  $D$  的验证集选取样本较少, 损失函数曲线有波动但整体呈下降趋势。  $D$  训练结束以后固定  $D$  的参数训练  $G$ , 从图 5 中可以看出  $G$  的损失曲线整体表现平稳, 说明每一次  $G$  的训练较为稳定。

从图 6 中可以看出在 SNR=0 dB 以上的信号分类准确率可以达到 95.1%。

图 7~9 为网络测试后的混淆矩阵图。




图 4 D 的损失函数曲线




图 5 D 的损失函数曲线

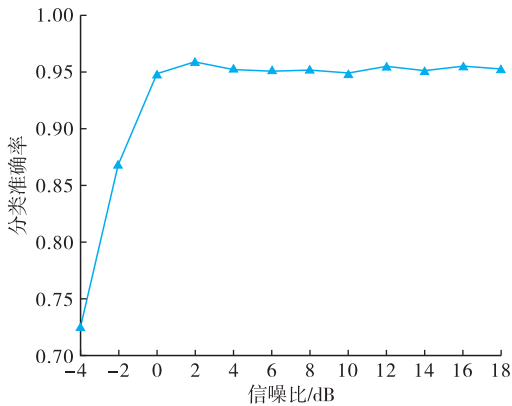


图 6 分类准确率曲线




图 7 SNR=0 dB 的混淆矩阵

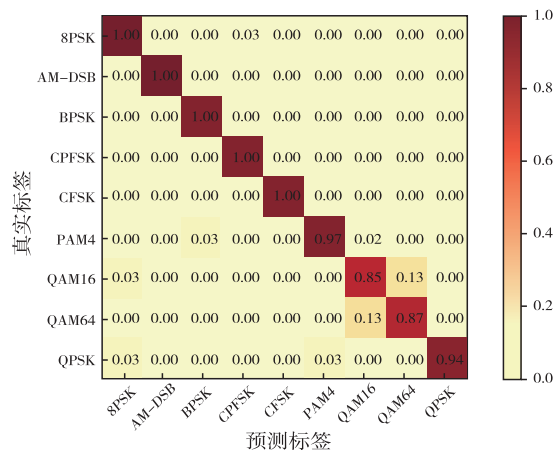


图 8 SNR=10 dB 的混淆矩阵

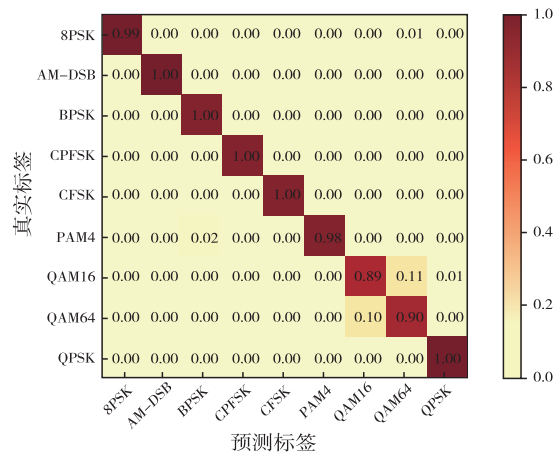


图 9 SNR=18 dB 的混淆矩阵

为了测试网络所需要的最少标签样本量,表 4 给出了具体的对比结果。

表 4 标签样本量对网络的影响

有标签样本/个	无标签样本/个	分类准确率/%
900	97 200	0.951
2 700	97 200	0.951
5 400	97 200	0.948
8 100	97 200	0.953
10 800	97 200	0.952
21 600	97 200	0.954
43 200	97 200	0.954
86 400	97 200	0.954

可以看到当无标签样本数量保持不变,增加有标签样本的数量时,识别准确率的提升并没有那么明显,并且增大标签数据量会显著增加网络的训练时间,因此本文算法收敛的标签样本数量在 900 左右。

### 3.3.3 实验 3:对比实验

将本文所提算法的网络结构分别替换为参考文献[18]提出的 ATLA 算法,参考文献[19]设计的 BP 神经网络和参考文献[22]设计的 VTCNN 和 CLDNN,将 5 种网络的特征提取能力进行对比。在

本文设定的小样本条件下,选取5种网络收敛后的最佳模型结果,分类准确率曲线对比如图10所示,网络参数对比如表5所示,其中运行时间代表每一个epoch的训练时间。




图 10 分类准确率曲线对比

表 5 网络性能对比

网络	网络参数	运行时间/s	分类准确率/%
BP 神经网络	466857	43	0.704
VTCNN	2658426	68	0.823
CLDNN	5516348	82	0.796
ATLA	3752456	69	0.826
SACGAN	D:320202 G:268993	57	0.951

在本文设定的小样本条件下,BP神经网络的参数最少,时间最短,分类准确率相对较低;VTCNN、ATLA和CLDNN3种网络的网络参数较多、算法复杂度相对较高;SACGAN的网络参数显著减少,时间复杂度有所降低,准确率明显提升,模型性能相比较其他4种网络有较好提升。在SNR=0dB以下网络性能提升6%、SNR=10dB以上网络性能提升13%。

综合上述实验结果,对比常规算法采用的标签样本数量,SACGAN算法采用的标签样本数量显著降低,验证了算法在小样本条件下的有效性。

## 5 结语

针对小样本条件下通信信号识别混淆问题,本文提出一种基于SACGAN的调制识别算法,该算法不需要人工设计特征,网络模型添加辅助分类器作为结果判定,并结合半监督学习思想,有效利用少量标签数据和大量未标签数据,通过两个基础网络间的交替对抗训练,更好地学习不同分布域的信号特征。该算法网络结构简单易实现,所用参数和标签样本量明显减少。仿真实验结果表明,在相同样本量条件下较其他深度学习模型效果更优,针对9种调制信号在SNR=0dB以上分类准确率可以达

到95.1%,有效解决了小样本条件下网络难以训练的问题。后续工作将在本文算法基础上,添加级联网络来进一步提升网络特征提取能力,使网络可以更好地区分相近信号。

## 参考文献

- [1] KHARBECH S, DAYOUB I, ZWINGELSTEIN-COLLIN M, et al. On Classifiers for Blind Feature-Based Automatic Modulation Classification over MIMO Channels[J]. IET Communications, 2016, 10(7): 790-795.
- [2] ZHE X, YONG G. Method to Reduce the Signal-to-Noise Ratio Required for Modulation Recognition Based on Logarithmic Properties [J]. IET Communications, 2018, 12(11):1360-1366.
- [3] 戴安群. 基于非合作通信的盲均衡研究[D]. 西安:电子科技大学, 2019.
- [4] 李正权, 林媛, 李梦雅, 等. 基于判别式受限玻尔兹曼机的数字调制识别方法[J]. 通信学报, 2021, 42(2): 81-91.
- [5] XU J L, WEI S, ZHOU M. Likelihood-Ratio Approaches to Automatic Modulation Classification[J]. IEEE Transactions on Systems Man and Cybernetics Part C (Applications and Reviews), 2011, 41(4):455-469.
- [6] LIU Y, SIMEONE O, HAIMOVICH A M, et al. Modulation Classification via Gibbs Sampling Based on a Latent Dirichlet Bayesian Network[J]. IEEE Signal Processing Letters, 2014, 21(9):1135-1139.
- [7] CHEN G, TAO D, MAYBANK S J, et al. Multi-Modal Curriculum Learning for Semi-Supervised Image Classification[J]. IEEE Transactions on Image Processing, 2016, 25(7):3249-3260.
- [8] KHARBECH S, DAYOUB I, ZWINGELSTEIN-COLLIN M, et al. Blind Digital Modulation Identification for Time-Selective MIMO Channels[J]. IEEE Wireless Communications Letters, 2014, 3(4):373-376.
- [9] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional Radio Modulation Recognition Networks [J]. Communications in Computer and Information Science, 2016, 629: 213-226.
- [10] ZHANG Z, WANG C, GAN C, et al. Automatic Modulation Classification Using Convolutional Neural Network with Features Fusion of SPWVD and BJD [J]. IEEE Transactions on Signal & Information Processing over Networks, 2019, 5(3):469-478.
- [11] PENG S, JIANG H, WANG H, et al. Modulation Classification Based on Signal Constellation Diagrams and Deep Learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 30(3): 718-727.

- [12] ZENG Y, ZHANG M, HAN F, et al. Spectrum Analysis and Convolutional Neural Network for Automatic Modulation Recognition [J]. IEEE Wireless Communications Letters, 2019, 8(3):929-932.
- [13] SUNG F, YANG Y, ZHANG L, et al. Learning to Compare: Relation Network for Few-Shot Learning [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018:1199-1208.
- [14] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching Networks for One Shot Learning[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. [S. l.]: ACM, 2016: 3637-3645.
- [15] DIXIT M, KWITT R, NIETHAMMER M, et al. AGA: Attribute Guided Augmentation [C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2017: 7455-7463.
- [16] SANTORO A, BARTUNOV S, BOTVINICK M, et al. One-Shot Learning with Memory-Augmented Neural Networks[C]//Proceedings of the 33rd International Conference on Machine Learning. [S. l.]: ACM, 2016:1842-1850.
- [17] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Nets[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems. [S. l.]: ACM, 2014: 2672-2680.
- [18] BU K, HE Y, JING X, et al. Adversarial Transfer Learning for Deep Learning Based Automatic Modulation Classification [J]. IEEE Signal Processing Letters, 2020, 27:880-884.
- [19] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Networks [J]. Advances in Neural Information Processing Systems, 2014, 3:2672-2680.
- [20] BISHOP C M. Pattern Recognition and Machine Learning (Information Science and Statistics) [M]. Berlin, Heidelberg: Springer-Verlag, 2006.
- [21] O'SHEA T J, HOYDIS J. An Introduction to Deep Learning for the Physical Layer[J]. IEEE Transactions on Cognitive Communications & Networking, 2017, 3(4):563-575.
- [22] O'SHEA T J, ROY T, CLANCY T C. Over-the-Air Deep Learning Based Radio Signal Classification[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1):168-179.

(编辑:徐楠楠)

## (上接第 66 页)

- [13] 吴德伟, 郇能建, 戚君宜. 基于认知理论的 UCAV 智能导航研究新进展[J]. 空军工程大学学报(自然科学版), 2011, 12(4):52-57.
- [14] YAO Y Q, XU X S, ZHU C C, et al. A Hybrid Fusion Algorithm for GPS/INS Integration during GPS Outages[J]. Measurement, 2017, 103:42-51.
- [15] ASLINEZHAD M, MALEKIJAVAN A, ABBASI P. ANN-Assisted Robust GPS/INS Information Fusion to Bridge GPS Outage[J]. EURASIP Journal on Wireless Communications and Networking, 2020, 129:1-9.
- [16] ZHOU Y, WAN J, LI Z, et al. GPS/INS Integrated Navigation with BP Neural Network and Kalman Filter [C]//2017 IEEE International Conference on Robotics and Biomimetics (ROBIO). [S. l.]: IEEE, 2017.
- [17] 鲍泳林, 李皓, 袁鸣, 等. 基于神经网络的 INS/GPS 组合导航误差补偿研究[J]. 弹箭与制导学报, 2019, 39(2):55-59.
- [18] 陈光武, 程鉴皓, 杨菊花, 等. 基于改进神经网络增强自适应 UKF 的组合导航系统[J]. 电子与信息学报, 2019, 41(7):1766-1773.
- [19] 白相文, 杨建华, 杨志强. 神经网络辅助的组合导航算法研究[J]. 导航定位学报, 2020, 8(1):93-98.
- [20] 冯建鑫. SINS/GPS 组合导航系统算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2008.

(编辑:徐楠楠)