

面向6G的生成对抗网络研究进展综述

孟婵媛¹, 熊轲^{1,2}, 高博^{1,2}, 张煜³, 樊平毅⁴

(1. 北京交通大学计算机与信息技术学院, 北京 100044;

2. 北京交通大学高速铁路网络管理教育部工程研究中心, 北京 100044;

3. 国网能源研究院有限公司, 北京 102209; 4. 清华大学电子工程系, 北京 100084)

摘要: 人工智能 (AI, artificial intelligence) 与通信技术的深度融合是 6G 网络的典型特征。一方面, AI 为 6G 网络发展注入了新动力, 能够有效利用网络运行产生的历史数据, 使网络具备自维护、自优化的功能, 加速了网络智能化进程。另一方面, 6G 网络丰富的场景和大规模的物联网设备入网应用为 AI 提供了广阔的应用渠道和海量的训练数据, 使 AI 能够更好地训练和部署, 充分发挥 AI 的内在优势, 为用户提供更加优质的智能服务。尽管如此, 在一些实际应用中, 受复杂环境的影响, 存在数据样本收集困难、收集成本高和样本普适性不足等问题, 难以充分发挥 AI 的性能优势。为此, 学术界和工业界将生成对抗网络 (GAN, generative adversarial network) 引入无线网络的设计中, 利用 GAN 强大的特征学习和特征表达能力产生大量模拟实际的生成样本, 实现无线数据库的扩充, 从而有效提升面向无线网络的 AI 模型的泛化能力。由于其优秀的性能表现, 以 GAN 为代表的生成式模型在无线网络领域受到越来越多的关注, 并迅速发展成为 6G 网络新的研究热点。首先, 综述了 GAN 的原理及其改进衍生模型, 对各种衍生模型的框架及优缺点进行了分析归纳; 然后, 综述了这些模型在无线网络领域的研究及应用现状; 最后, 面向 6G 网络的需求展望了 GAN 在 6G 网络中的研究趋势, 为未来的研究提供了一些有价值的探索。

关键词: 生成对抗网络; 无线网络; 信道估计; 物理层安全; 无线感知; 零和博弈

中图分类号: TN92

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2024.00369

Survey on the research progress of generative adversarial networks for 6G

MENG Chanyuan¹, XIONG Ke^{1,2}, GAO Bo^{1,2}, ZHANG Yu³, FAN Pingyi⁴

1. School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044, China

2. Engineering Research Center of Network Management Technology for High Speed Railway of Ministry of Education,

Beijing Jiaotong University, Beijing 100044, China

3. State Grid Energy Research Institute Co., Ltd., Beijing 102209, China

4. Department of Electronic Engineering, Tsinghua University, Beijing 100084, China

Abstract: The deep integration of artificial intelligence (AI) and communication technology is the typical feature of the 6G network. On the one hand, AI injects new vitality into the development of the 6G network, which can effectively use the data generated by the historical operation of the network. It enables the network to be self-maintained and self-optimized, and accelerates the process of network intelligence. On the other hand, the rich scenarios and IoT devices of the 6G network provide a large number of application fields and massive data for AI. These can enable the better deployment

收稿日期: 2023-03-14; 修回日期: 2023-09-20

通信作者: 熊轲, kxiong@bjtu.edu.cn

基金项目: 国家自然科学基金项目 (No. 62071033); 中央高校基本科研业务费资助项目 (No. 2022JBGP003)

Foundation Items: The National Natural Science Foundation of China (No. 62071033), The Fundamental Research Funds for the Central Universities (No. 2022JBGP003)

of AI, fully demonstrate the performance advantages of AI, and provide high-quality services for users. However, in practice, it is difficult to give full play to the performance advantages of AI due to the difficulty of sample collection, high cost of the collection, and lack of universality which caused by the complexity of the environment. Therefore, academia and industry introduce generative adversarial network (GAN) into the design of wireless networks. The powerful feature learning and feature expression ability of GAN can generate a large number of generated samples, which realizes the expansion of the wireless database. The introduction of GAN can effectively improve the generalization ability of AI models for wireless networks. Owing to the excellent performance of GAN, the generative model represented by GAN has attracted increased attention in the field of wireless networks, and rapidly became the new research hotspot of 6G networks. Firstly, the principle of GAN and its different versions of improved derived models were summarized. Then, the framework, advantages and disadvantages of each model were analyzed. Secondly, the research and application status of these models in wireless networks were reviewed. Finally, the research trends of GAN were proposed for the 6G network requirements, which provided some valuable exploration for future research.

Key words: generative adversarial network, wireless network, channel estimation, physical layer security, wireless sensing, zero-sum game

0 引言

随着6G^[1]万物互联时代的来临,一方面,具备一定通信、存储和计算能力的智能终端和网元节点数目剧增;另一方面,在网络运行过程中,各类网络节点源源不断地产生海量数据。海量数据蕴含丰富的知识,充分挖掘并利用这些知识,不断提升网络学习能力,可加快驱动网络朝智能化方向发展。近年来,数据驱动的6G网络智能化发展引起了学术界的广泛关注^[2]。

对于挖掘分析海量网络数据,有多种有效工具可以选择。传统基于统计分析^[3]的数据处理方法依靠人工经验抽取样本特征,利用统计学方法对样本特征进行分析,得到没有层次结构的单层特征,属于“浅层学习(SL, shallow learning)”,如支持向量机(SVM, support vector machine)^[4]、多层感知机(MLP, multi-layer perceptron)^[5]、逻辑回归(LR, logistic regression)^[6]等。浅层学习模型容易理解、训练速度快、参数少,在处理小样本数据集上具有优势,但在处理海量数据时局限性较大^[7]。一方面,在有限计算单元情况下,使用浅层学习表示复杂函数能力有限且建模准确性难以保证,使其在处理复杂分类问题时泛化性受到约束。另一方面,当输入数据具有高维特征空间时,浅层学习需要指数级规模数量的计算单元,同时需要利用训练样本对计算单元中的参数值进行调整,计算复杂度较高^[8]。为解决上述问题,学术界将深度学习(DL, deep learning)^[9]引入网络数据分析领域。深度学习通过

搭建神经网络隐藏层形成深层非线性网络结构,对原始输入进行逐层特征变换,将样本在原空间的特征表示变换到新的特征空间,学习得到层次化的特征表示,从而更有利于分类或特征的可视化。利用深度学习从海量数据中提取有用信息特征进行分析,可智能感知网络意图、扩展业务种类、提升网络性能,加速实现6G愿景。有监督深度学习^[10-12]是深度学习的重要分支,通过训练神经网络得到优良模型,为各种具体的无线场景提供了一种有效利用和分析网络数据的工具。为保障有监督深度学习方法的性能,需要准确标记大量网络数据。在实际应用中,人工标记大量数据标签负担重、耗时长、成本高。例如,在基于Wi-Fi的室内定位场景中,室内定位性能依赖于数据库的规模以及精确程度,每一个数据都需要实验人员将接收设备放在对应位置进行测量并标记,因而构建一个精确的大规模有标签数据库须消耗巨大的时间与人力资源^[13]。在一些特殊应用场景中,采集有效样本集比较困难。例如,将有监督学习应用于网络安全防护,对窃听、假冒攻击等恶意攻击进行识别。然而,在收集训练数据集时,某些攻击类型出现的频率很低,导致收集齐备的攻击数据集难度较高^[14]。另外,在有监督学习中,大多数基于数据驱动的深度学习模型泛化性和鲁棒性较差,若网络结构或拓扑发生变化,可能导致网络训练模型准确性大幅度降低^[15]。

与有监督深度学习不同,无监督深度学习^[16]更符合智能化推广,不需要标签或人工注释的监督信

息，从数据集中学习潜在的结构和规律，如数据之间的相似性、差异性、分布的特征与结构等^[17-26]。无监督深度学习主要包含聚类、降维、异常检测、关联规则学习以及生成模型等算法。其中，生成模型通过学习数据的分布特征，生成目标数据集。生成对抗网络（GAN, generative adversarial network）^[27]作为最具代表性的生成模型，已在计算机视觉（CV, computational vision）^[28]、机器学习（ML, machine learning）^[29]、自动语音识别（ASR, automatic speech recognition）^[30]等多个领域发挥了重要作用。由于GAN具备强大的样本学习和生成能力，学术界已开始将GAN应用于无线网络，通过对抗训练，生成与真实无线数据样本分布相同的生成样本，在减免收集有标签样本成本的同时，丰富了无线数据样本多样性。另外，GAN中的鉴别网络能够有效识别与真实样本分布不同的样本，在物理层安全领域有不俗的表现，已经成为颇具研究价值的研究方向。

综上所述，大量的研究工作表明，基于GAN的无线网络相关研究越来越多地受到学术界关注，并且发展出了多个细分方向。为了给后续研究者提供较为系统且有价值的参考，本文首先综述了GAN及其不同版本的改进衍生模型的原理，对每种衍生模型的框架以及优缺点进行了分析归纳，然后综述了这些模型在无线网络领域的研究及应用现状，最后面向6G网络的需求展望了GAN在无线领域的研究趋势和值得关注的研究点，为未来的研究提供了一些有价值的参考。

1 GAN的介绍

本节首先阐述GAN的模型结构、工作机制及其训练过程，在此基础上同其他生成模型进行对比，并对其优缺点进行分析和概括。

1.1 GAN的模型结构

GAN是依据博弈论中的二人零和博弈理论提

出的一种无监督深度学习框架，参与博弈的双方在竞争中一方的收益会导致另一方的损失，双方不存在合作的关系。GAN架构如图1所示，由生成网络（ G , generative network）、判别网络（ D , discriminative network）和对抗训练（adversarial training）3个部分组成。 G 的输入是一个随机变量 z ，其输出为从某一分布中采样得到的生成样本 $G(z)$ 。生成网络的目标是通过不断学习掌握真实样本的数据分布特性，从随机变量中生成与真实样本分布相同的生成样本。 D 的输入由真实样本和生成样本两部分组成，其输出为一个概率值，用于刻画输入来自于真实样本的概率，并将结果反馈给生成网络帮助其更有效地训练。判别网络的目标是通过迭代训练准确地判别输入是否为真实样本。对抗训练是基于博弈框架训练两个网络模型，训练过程是一个二元极大极小（minimax）的对抗过程，目标为最小最大化生成样本分布与真实样本分布之间的差异，即KL散度（Kullback-Leibler divergence）。因此，目标函数定义为

$$\min_G \max_D V(G, D) = E_{x \sim p_{\text{data}}} [\ln D(x)] + E_{z \sim p_z} [\ln(1 - D(G(z)))] \quad (1)$$

其中， $V(G, D)$ 为二分类交叉熵函数。生成网络根据判别网络的反馈来计算参数的梯度；判别网络根据真实样本和生成样本的标签计算其参数的梯度。梯度信息反向传播利用链式法则将损失函数的梯度从网络输出层传递到网络的输入层，从而更新网络参数。设真实样本的数据分布为 p_{data} ，在理想情况下，通过迭代训练，两个网络逐渐优化改进，最终达到一种稳定状态，即纳什均衡（Nash equilibrium）状态。通过对全局信息进行采样和学习，在网络完成训练时，能够生成和实际数据服从相同分布的生成样本。

1.2 GAN与其他生成模型对比及其优缺点

1.2.1 GAN与其他生成模型对比

除GAN以外，常用的生成模型还包括变分自




图1 GAN架构

编码器 (VAE, variational autoencoder)^[31]、自回归模型 (autoregressive model)^[32]、生成式矩匹配网络 (GMMN, generative moment matching network)^[33]和生成地形图 (GTM, generative topographic map)^[34]。GAN与其他生成模型对比见表1。

1.2.2 GAN的优点

首先, 相对于一些传统的生成模型, 如VAE等, GAN模型设计较为简单, 不需要预先设计复杂的函数模型^[27]。GAN通过反向传播来更新训练两个神经网络的参数, 不依赖马尔可夫链的推断过程 (如隐马尔可夫模型 (HMM, hidden Markov model)), 也不依赖近似推理 (如变分推断), 没有复杂的变分下界, 能够适当降低训练难度, 提高训练效率。此外, 模型设计自由度较高, 神经网络结构能够集成各种损失函数, 可以根据具体任务的需求, 选择不同的损失函数。

其次, GAN生成过程较为自由, 样本多样^[45]。GAN采用的神经网络结构不限制生成样本的维数, 从而拓宽了生成样本的范围。另外, 生成样本的过程不是对真实数据或平均值进行处理, 而是通过学习真实数据分布来生成样本, 能够增加样本多样性。

再者, GAN不需要先验知识, 具有较好的拟合能力^[46]。通过持续的训练与交互, GAN可以学习数据的内在规律, 在理论上可以拟合任何分布, 具有无限的建模能力。

1.2.3 GAN的缺点

目前, GAN虽然已经有效解决了生成模型的

许多问题并为其他AI方法带来了灵感, 但其仍然存在以下局限性。

首先, GAN模型较难确保两个对抗性网络的平衡性和同步性^[47]。理论上, 训练GAN需要最终达到纳什均衡状态。然而, 由于生成网络与判别网络具有不同的优化目标和参数空间, 在学习速度上存在一定的差异, 这可能导致两个网络之间的学习失衡, 使训练过程更加困难。

其次, GAN模型可解释性较差^[48]。神经网络的参数在网络学习过程中自主选择, GAN最终只能学到一个端到端的、具有黑盒特性的数据分布函数。由于无法解释每个参数所代表的物理含义, 在优化过程中难以给出明确且有针对性的优化方案。

再者, GAN易出现模式崩溃问题^[49]。生成网络的参数优化依赖判别网络提供的梯度信息。如果判别网络无法提供丰富的梯度信息, 即无法准确指导生成网络的学习, 生成网络可能无法学到真实数据分布, 生成的样本与真实样本之间的差异较大。

为解决GAN在训练过程中存在的问题, 研究者针对网络结构和损失函数进行改进得到了许多基于GAN的衍生模型。第2节将详细介绍一些代表性的衍生模型。

2 基于GAN的衍生模型

2.1 针对GAN结构改进的衍生模型

针对GAN结构进行改进的常见衍生模型包括: 条件生成对抗网络 (CGAN, conditional genera-

表1 GAN与其他生成模型对比

生成模型	机制	相似点	差异点
VAE [35-37]	VAE由编码器和解码器组成, 结合自编码器和概率图模型的思想, 旨在通过学习潜在变量的概率分布来实现数据的生成和重构	通过学习训练数据的潜在分布生成样本	VAE使用编码器-解码器架构, 并采用变分推理进行训练; GAN采用生成-判别网络对抗学习框架。VAE目标是最大化数据的边际似然; GAN目标为生成能欺骗判别网络的样本
自回归模型 [38-39]	自回归模型(如PixelCNN和WaveNet)通过条件概率分布逐步生成数据序列, 输出依赖于历史时间步的输出	通过对输入进行调整生成多样化数据样本	自回归模型显式地建模数据的联合概率分布; GAN通过对抗学习的方式从隐含的数据分布中进行采样生成样本。自回归模型的输出依赖历史输出; GAN的输出不依赖历史输出
GMMN [40-42]	GMMN旨在学习生成符合给定条件的矩阵数据。通过将随机噪声映射到高维特征空间中, 然后通过反卷积等操作将特征重构为矩阵形式	通过学习数据分布的特征生成样本	GMMN使用最大均匀度作为训练目标和损失函数; GAN使用生成网络和判别网络进行对抗训练。GMMN没有显式的判别网络; GAN中有显式的判别网络
GTM [43-44]	GTM通过最大似然估计或贝叶斯推断等方法学习节点和潜在变量之间的关系。将输入数据映射到已学习的拓扑地图上的节点, 实现数据的降维和可视化	涉及潜在空间的概念, 表示数据的潜在结构	GTM是基于概率建模的模型, 它将数据映射到拓扑结构上, 每个节点代表潜在的数据生成源; GAN通过博弈性训练生成样本。GTM主要应用于数据建模、数据可视化、模式发现等任务, 能够帮助理解数据的结构和分布; GAN主要应用于计算机视觉、无线网络、风格迁移等领域

tive adversarial network)、深度卷积生成对抗网络(DCGAN, deep convolutional generative adversarial network)、信息最大化生成对抗网络(Info-GAN, information maximizing generative adversarial network)、半监督生成对抗网络(SGAN, semi-supervised generative adversarial network)、辅助分类器生成对抗网络(AC-GAN, auxiliary classifier generative adversarial network)。

2.1.1 CGAN

由于GAN对生成网络 G 没有任何约束,在生成数据时易导致生成过程过于自由、模型训练易崩塌等问题。为了解决上述问题,CGAN^[50]通过将生成任务所需的信息编码为辅助标签信息(即条件变量 y),对生成样本进行约束增强,使得生成过程更具控制性和可预测性。通过在条件变量中引入不同的条件,生成网络能够生成具有不同属性及特征的样本。CGAN架构如图2所示, G 和 D 均利用条件变量实施训练,其目标函数为

$$\min_G \max_D V_c(G, D) = E_{x \sim p_{\text{data}}} [\ln D(x|y)] + E_{z \sim p_z} [\ln(1 - D(G(z|y)))] \quad (2)$$

将 y 作为附加信息输入 G 和 D 中进行训练,能够有效缓解GAN生成过程过于自由的问题,使网络朝着既定的方向生成样本。与此同时,CGAN的生成能力依赖于条件变量的质量和准确性。若条件变量输入不准确或有噪声,可能会生成不符合期望的样本。因此,对于CGAN的应用,需要确保提供

准确且有意义的条件变量。

2.1.2 DCGAN

MLP作为GAN中两个网络的架构,存在空间信息建模能力不足、易受梯度问题影响以及不适用于处理大规模样本等问题^[51]。为了解决上述问题,针对样本生成任务,采用卷积神经网络(CNN, convolutional neural network)能够更好地捕捉空间信息和局部相关性^[52]。DCGAN架构如图3所示,DCGAN^[53]将CNN与GAN结合,继承了两者的优势。具体来说,由于传统的池化(pooling)操作会忽略很多细节信息,DCGAN用卷积层替代池化层。这种结构能够保证信息的完整性,生成样本更加完整和清晰。其次,为了将低维噪声向量转化为高维特征图,DCGAN引入转置卷积层,增加了生成样本的维度。另外,DCGAN堆叠多个卷积层和转置卷积层形成层级结构,能够学习到样本的多层次抽象表示。同时,DCGAN采用不同的激活函数,有助于避免梯度消失的问题。尽管DCGAN可以生成较高质量的生成样本,但通过简单方式控制生成样本的特定属性仍具有一定的挑战,需要进行复杂的网络设计才能生成特定属性的样本。

2.1.3 Info-GAN

为增强GAN的输入 z 与输出样本语义特征之间对应关系的可解释性,Info-GAN架构如图4所示,Info-GAN^[54]将生成网络的输入 z 分解为一组与特定属性相关的结构化隐层变量 $c(c_1, c_2, \dots, c_L)$ 和不可压缩、无法解释的非结构化噪声 z' 。通过调整隐层变

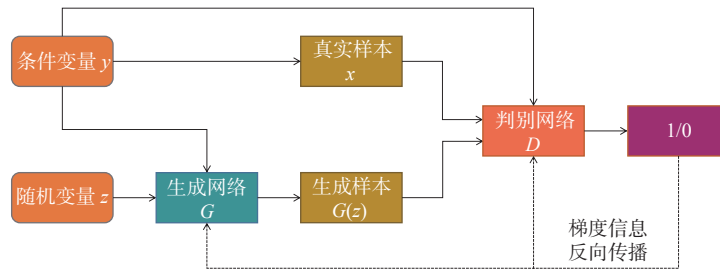


图2 CGAN架构




图3 DCGAN架构




图4 Info-GAN架构

量部分（如维度），可以在生成过程中控制生成样本的特定属性。同时，Info-GAN通过调整噪声 z' 部分，提供了更大的样本空间。生成网络的输出表示为 $G(z',c)$ ，其中 c 在不同的问题中代表不同的意义，如高斯分布的值或信息变量。Info-GAN的目标是学习到一些有意义的隐层变量 c ，其目标函数定义为

$$\min_G \max_D V_{\text{info}}(G, D) = V(G, D) - \lambda I(c; G(z', c)) \quad (3)$$

相较于GAN的目标函数，Info-GAN的目标函数多了一项约束 $\lambda I(c; G(z', c))$ ，表示 c 与 $G(z', c)$ 的互信息，即该值越大， c 与 $G(z', c)$ 两者越相关。

2.1.4 SGAN

SGAN^[55]将GAN拓展到半监督学习。SGAN架构如图5所示，在训练时，判别网络的输入由3个部分组成：生成样本 $G(z)$ 、无标签样本 x 和标签样本 (x, y) 。判别网络输出 $N + 1$ 个输出单元，分别对

应 $(\text{class}_1, \text{class}_2, \text{class}_N, \text{fake})$ 。判别网络旨在判别输入样本，并且利用标签样本集对无标签样本进行分类。判别网络重建的标签信息在一定程度上给生成网络提供了更多的信息用于更新网络。

2.1.5 AC-GAN

AC-GAN^[56]通过引入辅助分类器，使得网络能够对样本进行有效判别和分类。AC-GAN架构如图6所示，生成网络的输入由随机变量 z 和对应的类别标签 $C \sim P_c$ 两部分组成，网络输出为 $G(c, z)$ 。判别网络对样本进行判别并输出其属于某一类别标签的概率值。AC-GAN联合优化生成网络、判别网络和辅助分类器，能够提高生成样本的多样性和分类准确性。其目标函数由判别正确样本源的对数似然函数 L_s 和判别正确类别的对数似然函数 L_c 两部分构成，表示为

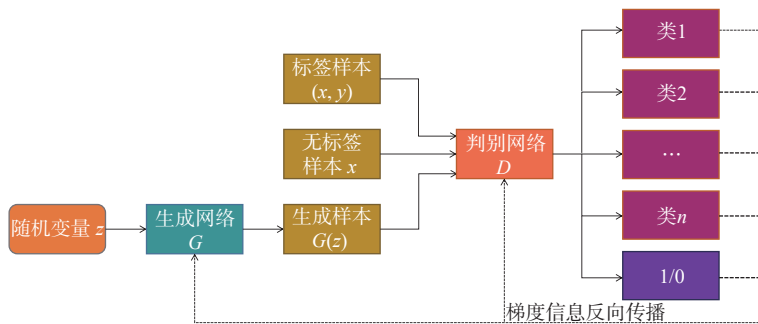


图5 SGAN架构

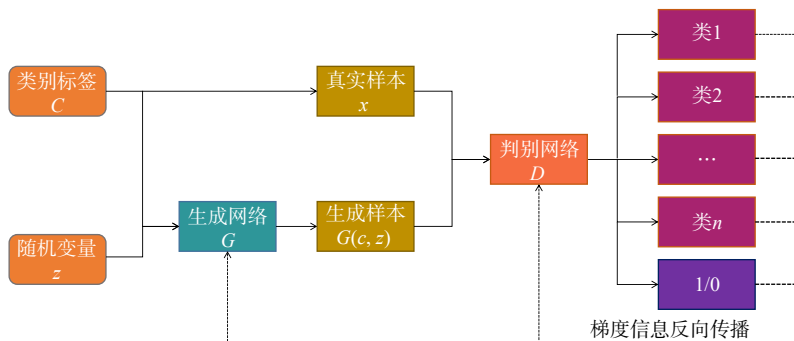


图6 AC-GAN架构

$$L_S = E \left[\log P(S = \text{real} | X_{\text{real}}) \right] + E \left[\log P(S = \text{fake} | X_{\text{fake}}) \right] \quad (4)$$

$$L_C = E \left[\log P(C = c | X_{\text{real}}) \right] + E \left[\log P(C = c | X_{\text{fake}}) \right] \quad (5)$$

判别网络的训练目标为最大化 $L_S + L_C$ ，生成网络的训练目标为最大化 $L_C - L_S$ 。AC-GAN 常用于生成带有类别标签的样本，例如，生成特定类别的图像或进行有监督学习任务。

2.2 针对GAN损失函数改进的衍生模型

针对GAN损失函数进行改进的常见衍生模型包括：Wasserstein生成对抗网络（WGAN, Wasserstein GAN）、带梯度惩罚的Wasserstein生成对抗网络（WGAN-GP, Wasserstein GAN with gradient penalty）、基于事件重要性度量的生成对抗网络（MIM-GAN, message importance measure-based GAN）。

2.2.1 WGAN

为解决GAN训练过程中存在的梯度消失等问题，WGAN^[57]引入Wasserstein距离度量生成样本与真实样本之间的差异。Wasserstein距离是一种连续的距离度量，具有较好的可微性，有助于更稳定的训练^[57]。另外，为保证判别网络满足Lipschitz连续性条件，WGAN采用权重剪裁技术限制判别网络的权重固定在合理范围内，确保Wasserstein距离的有效计算。WGAN的目标函数定义为

$$\min_G \max_D V_w(G, D) = \sup_{\|D\|_L \leq 1} \left\{ E_{x \sim p_{\text{data}}} [D(x)] - E_{z \sim p_z} [D(G(z))] \right\} \quad (6)$$

其中， $\|D\|_L \leq 1$ 表示1-Lipschitz约束条件。

2.2.2 WGAN-GP

虽然WGAN引入权重剪裁等技术来满足Wasserstein距离的计算要求，但权重剪裁易导致训练不稳定和模式崩溃。为解决该问题，WGAN-GP^[58]引入梯度惩罚来替代权重剪裁，确保判别网络满足Lipschitz连续性条件。其损失函数定义为

$$L = \underbrace{E_{\hat{x} \sim P_z} [D(\hat{x})] - E_{x \sim P_{\text{data}}} [D(x)]}_{\text{原始损失函数}} + \underbrace{\lambda E_{\hat{x} \sim P_z} \left[\left(\left\| \nabla_{\hat{x}} D(\hat{x}) \right\|_2 - 1 \right)^2 \right]}_{\text{梯度惩罚项}} \quad (7)$$

其中， λ 为梯度惩罚参数，用于调节梯度惩罚力度。梯度惩罚能够显著提高训练速度，解决了WGAN

梯度二值化问题与梯度消失或爆炸等问题^[58]。

2.2.3 MIM-GAN

GAN的性能与优化目标函数的设计密切相关，不同的目标函数在学习样本分布效率上存在差异。GAN一般采用基于对数函数的KL散度来描述生成样本分布拟合真实分布的程度，由于KL散度不满足对称性，GAN数据训练和生成的性能受限，易造成模式崩塌等问题，即生成样本多样性不足^[59]。基于指数函数的MI散度（message identification divergence）度量概率分布之间的信息距离，定义为 $D_{\text{MI}}(P // Q, \varpi) = D_{\varpi}(P // Q) = \log \sum_{i=1}^n p_i e^{(\varpi p_i / q_i)} - \varpi$ ，其中， P 和 Q 是两种概率分布， ϖ 是可调节的参数。基于指数函数的MI散度对异常值的检测效果优于KL散度^[60]。因此，MIM-GAN^[59]中利用指数型目标函数代替原始的对数形式的目标函数，其目标函数定义为

$$\max_G \min_D V_{\text{MIM}}(G, D) = E_{x \sim p_{\text{data}}} \left[\exp(1 - D(x)) \right] + E_{z \sim p_z} \left[\exp(D(G(z))) \right] \quad (8)$$

3 GAN及衍生模型在无线领域的应用

本节将介绍GAN及其衍生模型在信道估计、物理层安全和无线感知等应用中采用不同GAN模型所带来的影响及其作用。现有研究在不同场景下针对不同目标采用的GAN模型见表2。

3.1 GAN在信道估计中的研究

6G网络中，为追求更高的频谱效率并支持海量设备接入，收发端会部署超大规模天线阵列。超大规模天线阵列的高效传输取决于对6G信道模型的准确刻画。传统的信道建模方法需要根据大量实测数据统计信道特征，利用电磁波传播理论分析无线传播模型，具有复杂度高、场景局限性大等缺点。

利用GAN提取信道特征可有效降低复杂度并刻画实时传输场景，且不需要任何先验知识，可直接通过原始信道信息学习到信道分布^[61-67]及信道转移概率^[68]，生成与真实信道分布相同的样本。基于GAN的信道函数学习框架如图7所示。目前，现有大部分研究通常采用离线训练CGAN^[69-75]、WGAN^[76-77]、基于梯度惩罚的条件WGAN（CWGAN-GP, conditional WGAN-GP）^[78]、DCGAN^[79]、变分生成对抗网络（VGAN, variational generative adversarial network）^[80]等模型获得最优的生成模型，用于在线生

表 2 现有研究在不同场景下针对不同目标采用的 GAN 模型

现有研究	GAN 及其衍生模型									研究内容				
	GAN	针对 GAN 结构改进的衍生模型					针对 GAN 损失函数改进的衍生模型			其他	信道估计	物理层安全	无线感知	
		CGAN	DCGAN	Info-GAN	SGAN	AC-GAN	WGAN	WGAN-GP	MIM-GAN				手势识别	室内定位
[61-68]	√	-	-	-	-	-	-	-	-	-	√	-	-	-
[69-75]	-	√	-	-	-	-	-	-	-	-	√	-	-	-
[76-77]	-	-	-	-	-	-	√	-	-	-	√	-	-	-
[78]	-	-	-	-	-	-	-	-	-	√	√	-	-	-
[79]	-	-	√	-	-	-	-	-	-	-	√	-	-	-
[80]	-	-	-	-	-	-	-	-	-	√	√	-	-	-
[81-84]	√	-	-	-	-	-	-	-	-	-	-	√	-	-
[85-86]	-	-	-	-	-	-	-	√	-	-	-	√	-	-
[87]	-	√	-	-	-	-	-	-	-	-	-	√	-	-
[88]	-	-	√	-	-	-	-	-	-	-	-	√	-	-
[89]	-	-	-	-	-	-	-	-	-	√	-	√	-	-
[90]	-	-	-	√	-	-	-	-	-	-	-	√	-	-
[91]	-	-	-	-	-	-	-	-	-	-	√	-	√	-
[92]	-	-	-	-	-	-	-	-	√	-	-	√	-	-
[93]	-	√	-	-	-	-	-	-	-	-	-	-	√	-
[94-95]	-	-	-	-	-	-	-	-	-	√	-	-	√	-
[96-97]	√	-	-	-	-	-	-	-	-	-	-	-	-	√
[98]	-	-	-	-	√	-	-	-	-	-	-	-	-	√
[99]	-	√	-	-	-	-	-	-	-	-	-	-	-	√
[100]	-	-	-	-	-	-	-	-	-	√	-	-	-	√
[101]	-	-	√	-	-	-	-	-	-	-	-	-	-	√
[102]	-	-	-	-	-	-	-	-	-	-	-	-	-	√

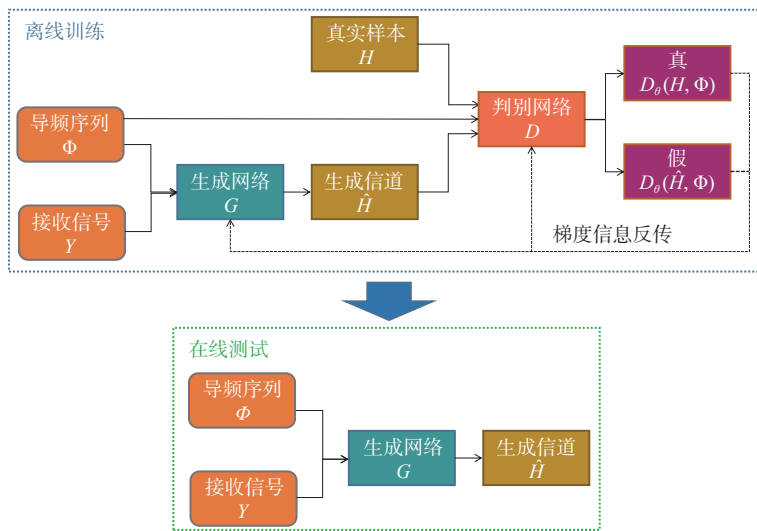


图 7 基于 GAN 的信道函数学习框架

成信道样本。文献[69-75]利用 CGAN 学习环境和信道矩阵之间的映射关系，将来自发射机的编码信号、接收信号以及用于估计信道的导频信息作为条件信息，对模型进行约束。CGAN 在不同数据集上均生成了质量较好的样本，已经成为性能比较的基准模型。文献[76-77]利用 WGAN 来刻画信道分布，

通过修改网络结构及截断网络参数保证重构的信道限制在一定范围内，解决了 GAN 训练不稳定的问题。为了提高模型的学习能力并保证估计的准确性，CWGAN-GP^[78]集成 CGAN 与 WGAN-GP 两者的优势，将训练序列和相应的接收序列作为条件信息，并利用 Wasserstein 距离衡量生成样本分布与真

实分布之间的差异。文献[79]将DCGAN应用在高载波频率选择信道中进行信道估计，多层CNN结构保证网络可学习到样本的多层次抽象表示。为了准确捕获随机行为，文献[80]提出的VGAN利用变分网络特性准确地捕获随机行为，通过修改体系结构和损失函数，提升了训练的稳定性。然而，其估计的分布方差在较高振幅的情况下存在一定的误差。

3.2 GAN在物理层安全中的研究

由于无线链路的开放性，无线网络中的设备易遭受各种恶意攻击，设备之间需要进行身份认证。传统基于密钥协议的身份认证方式在物联网场景中不仅容易被破解，还增加了额外的通信开销^[103]。近年来，基于无线设备硬件特性的射频指纹识别技术凭借其唯一性和不易复制等特性引起学术界和工业界的广泛关注，常用于设备的双向身份识别，增强物联网接入的安全性。然而，攻击事件发生的随机性和偶然性导致收集大规模攻击数据集挑战性极大。为解决上述问题，通常采用GAN进行攻击数据库的扩充并训练判别网络实现设备身份识别，增强接入安全性。基于GAN的物理层安全学习框架如图8所示。具体而言，在训练阶段利用生成网络学习发射机特有特征（如I/Q不平衡、固有波形等），判别网络通过博弈提高鉴别非法发射机的准确性。在部署阶段，利用判别网络识别非法发射机^[81-84]，并将学习到的特征作为指纹来对合法发射机进行分类^[81]。文献[85-86]利用由多个WGAN-GP

构成的判别网络检测恶意发射机并对可信发射机进行分类。文献[87]利用CGAN学习发射机的发射信号特征。为了解决正负样本数据量不平衡造成的训练效果差等问题，DCGAN^[88]直接从原始数据中提取特征，生成足量样本来平衡数据集。另外，文献[26]通过DAGAN对样本进行修改来增加样本数据量。为了实现上述功能，相比原始GAN模型，DAGAN作出如下改变：首先，对网络输入信号进行解调和重调并进行功率归一化处理；其次，对网络的目标函数进行优化设计。Distributed GAN^[89]在每个节点分布式部署GAN进行训练，在不依赖任何集中控制器的情况下检测异常行为。文献[90]中Info-GAN以一个结构化多模态潜在向量的形式与无线传播信道的先验统计特征进行结合，能够提高GAN生成样本的质量。文献[91]提出的Triple GAN在原始GAN的基础上增加了一个用于计算生成数据和标签数据交叉熵的分类器和一个特征提取子网络，形成一个四重结构的框架，有助于提高分类性能。Triple GAN能够在保证准确率的前提下提高网络的收敛速度。文献[92]利用MIM-GAN进行异常检测，在不同数据集上均取得了较优的效果。

3.3 GAN在无线感知中的研究

6G网络可通过分析无线信号实现目标检测、识别、定位等感知功能^[104]。利用GAN生成大量样本，实现样本库扩充，有助于加强对环境信息的分析，提高模型泛化能力，进一步提升6G无线感知的性能。

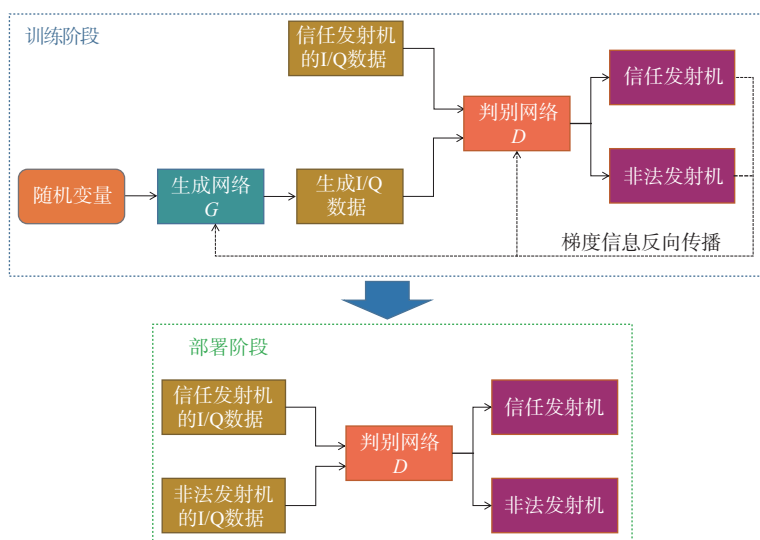


图8 基于GAN的物理层安全学习框架

3.3.1 GAN在基于无设备的手势识别中的应用

随着无线网络的发展，无线信号不仅用于通信，还可依据信号特征来识别人类手势。基于无线信号的手势识别凭借易部署、高隐私性等优势，得到了研究人员的广泛研究。在构建手势数据库时，利用GAN进行数据库扩充，在降低收集样本成本的同时，增强了样本多样性。基于GAN的手势识别学习框架如图9所示。在训练阶段，通过迭代训练GAN，得到最优的生成网络参数，用于在生成阶段生成手势样本。

文献[93]将标签信息作为额外条件，利用CGAN生成大量样本扩充数据库，以降低样本集过小导致的过拟合风险。文献[94]指出，单场景生成对抗网络(SS-GAN, single scenario generative adversarial network)和场景迁移生成对抗网络(ST-GAN, scenario transferring generative adversarial network)利用当前场景中的真实样本和其他可用场景学到的额外知识能够提高算法的鲁棒性，可解决场景发生变化引起的模型性能下降问题。文献[95]提出的可变形深度卷积生成对抗网络(De-DCGAN, deformable deep convolutional generative adversarial network)使用缩放的指数线性单元作为激活层，保证了网络能自标准化。此外，所有卷积层均使用可变形的卷积核。De-DCGAN不仅能够提高不同手势组合的正确识别率，而且可以缩短测试时间。

3.3.2 GAN在基于Wi-Fi的室内定位中的应用

近年来，由于Wi-Fi网络部署广泛且无线信道信息具备独特性，学术界展开了大量有关基于指纹的室内定位研究，其中指纹数据库构建至关重要。利用GAN学习有限数据库样本分布并生成信号数据样本，用于增加数据库集的规模并更新指纹数据库，从而提高识别精度^[96-97]。基于GAN的室内定位学习框架如图10所示。在训练阶段，训练GAN学习真实指纹样本的特征，将训练好的生成网络在数据集加强阶段生成指纹数据。

对于一些收集标签数据较难的场景，SGAN^[98]可利用收集到的数据(有标签和无标签)生成样本数据辅助位置预测，能够减少对昂贵标记数据的依赖。文献[99]将两种具有不同先验知识的草图作为CGAN的条件，生成从低到高分辨率的数据。振幅-特征深度卷积生成对抗网络^[100](AF-DCGAN, amplitude-feature deep convolutional generative adversarial network)将每个参考点收集到的信道状态信息(CSI, channel state information)制作成振幅特征图。AF-DCGAN通过学习每个参考点的CSI振幅特征图，生成相似的样本数据进行数据增强。AF-DCGAN能够加速训练阶段的收敛性并增加CSI振幅特征图的多样性。与AF-DCGAN用于增强所有参考点的数据量不同，DCGAN^[101-102]可用于减少需要收集的参考点。为实现上述目标，将参考点的CSI转换为CSI振幅图像并输入DCGAN中进行训

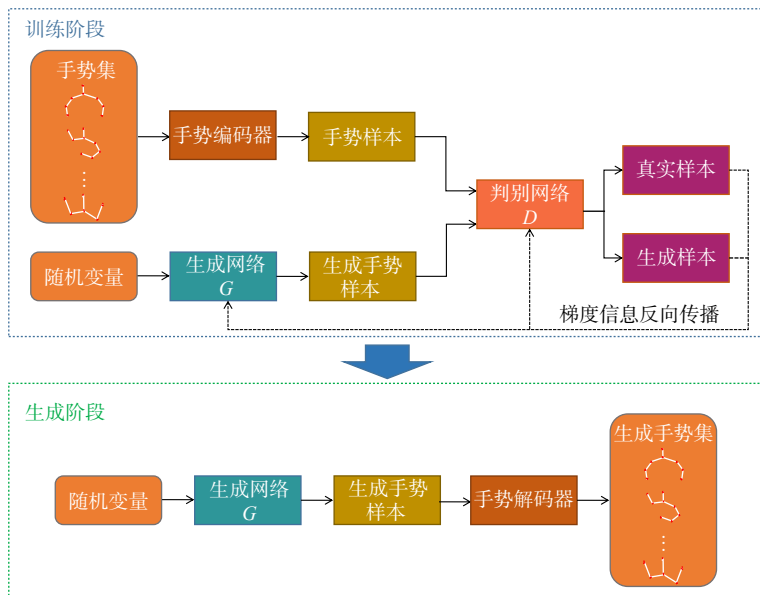


图9 基于GAN的手势识别学习框架

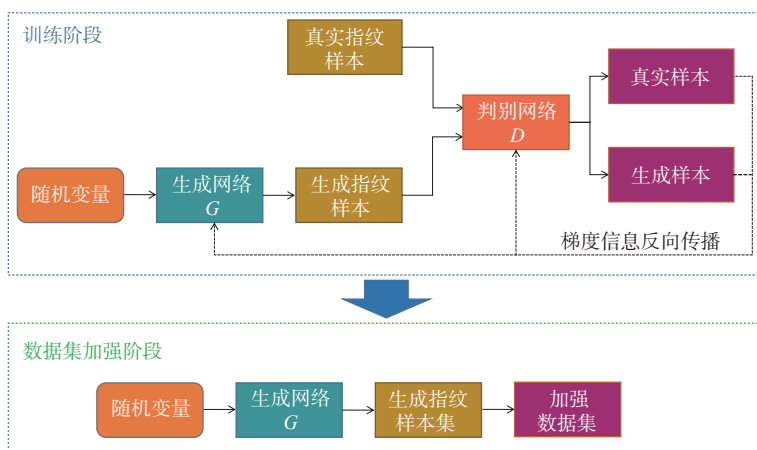


图10 基于GAN的室内定位学习框架

练。在训练后的DCGAN的潜在空间对每个参考点之间进行插值，合成密集指纹图，从而降低构建基于指纹的室内定位中离线数据库的成本。

4 挑战与展望

综上所述，GAN在无线网络的多个领域已受到广泛关注并取得了一些代表性的研究进展和成果。尽管如此，GAN在面向6G的研究和应用中，仍有诸多理论和技术问题亟待研究和完善。

1) 如何构建面向无线环境的可解释性强的GAN模型

GAN虽然在现有的训练模式下已取得了一些优势，但是制约其发展和应用最突出的问题是模型的可解释性。若想要突破性能瓶颈，需要把无线网络的一些物理属性融入GAN模型构造和训练中，从而赋予其优化过程一定的物理含义，使GAN具备较好的可解释性。因此，在未来面向6G的研究中，为了GAN能够在无线网络的场景中落地应用并充分发挥共性的优势，必须研究可解释性强的GAN。

2) 如何构建面向无线应用的具有良好稳定性和收敛性的GAN架构和损失函数

6G环境复杂、组网形式多样，对实时性和智能响应要求高，进而对GAN在训练时间、稳定性和收敛性等方面也提出了更高要求，因此需要在生成网络和判别网络的架构、改良损失函数、提升模型训练稳定性及避免模式崩溃等方面进行优化设计。另外，GAN生成样本的质量和多样性优劣程度主要取决于神经网络的拟合能力，而神经网络的拟合能力与网络的架构设计有直接关系。遗憾的

是，目前尚未有相关的理论对环境与神经网络结构的适配性及神经网络架构的改变对生成结果的影响进行明确的解释和有效的评价。因此，结合实际问题进行全面的理论分析并持续改进GAN，是将其应用在6G各种新场景必须要做的研究工作。

3) 如何将先进信息理论与GAN模型进行融合优化

6G网络是一个多目标、多技术融合的复杂体。只有将多种先进技术深度融合，才能实现多技术融合带来的“一加一大于二”的效果。目前，已有研究将GAN与其他学科方向的最新研究成果，如神经科学、认知科学、信息论等进行结合，综合继承各模型的优点完成样本生成任务，目的是在提升GAN算法性能的基础上满足无线新业务场景的新需求。然而，GAN在与其他技术融合过程中会面临多目标间存在折中关系的挑战。只有弄清这些机理，方能使GAN与不同算法和资源深度融合，达到较好的系统设计效果。

4) 如何有效评估面向无线领域的GAN的性能

目前，对GAN的评估仍以定性评价和一些传统指标（如启发式分数（IS, inception score）、模式分数（MS, mode score）等）为主。在实际情况下，大多需要结合不同的场景和所解决的问题选择一个较为合理的评价指标，尽管这些评价指标在一些任务上有效，但是难以综合地对模型以及生成样本质量进行评估，缺乏确定统一、适用范围广的标准。因此，如何综合科学地评估GAN及各种衍生模型的准确性、稳定性、可解释性、复杂度，及其在不同6G场景下生成样本的真实性、多样性是亟须解决的问题。

5) 如何构建能够处理无线场景离散量的 GAN 算法

目前, 相较于传统样本扩充方法, GAN 已经能够在 6G 的信道估计、物理层安全和无线感知等领域生成更加准确的样本, 但在一些 6G 场景中, 优化变量中存在离散型变量, 如边缘计算中的二进制卸载变量、多载波分配变量。GAN 在处理离散数据时, 由于判别网络不能很好地将梯度更新信息传递到生成网络中, 因此处理离散变量场景时, 产生样本质量较差。探索通过改变 GAN 结构, 使 GAN 能够有效处理离散变量, 是将 GAN 部署在更多 6G 应用场景值得研究的问题。

6) 如何实现更深层次融合 GAN 与 6G 框架

针对 6G 具体应用场景和需求, 设计并优化适用于该场景的 GAN 架构, 从而实现 GAN 与 6G 框架的深层次融合, 提供更强大、智能且高效的网络服务与应用。例如, 在边缘计算场景下, 可设计一种结合生成模型和推断模型的网络架构, 以实现在边缘设备上进行实时的生成和推断任务^[105]。同时, GAN 可以结合强化学习和自适应算法, 动态地调整 GAN 模型的参数和网络结构, 进行智能的资源分配和调度, 优化网络性能。此外, 探索 GAN 与其他 6G 关键技术的联合优化和协同学习, 从而实现更灵活、高效和个性化的网络服务^[106]。例如, 将 GAN 与网络切片以及联邦学习等技术相结合, 实现对数据的有效隐私保护, 同时保持较好的模型性能。

5 结束语

近年来, 基于 GAN 的衍生模型不断涌现。作为有效的生成式深度学习框架, GAN 及其衍生模型通过对抗训练学习样本分布, 能够有效生成与真实无线数据分布相同的样本, 在减免收集成本的同时, 丰富了无线数据样本多样性。基于此背景, 本文首先阐述了 GAN 及其改进衍生模型的原理、框架和优缺点。进一步, 对 GAN 模型在无线网络领域的研究及应用现状、研究趋势和值得关注的研究点进行较为全面的阐述。总之, GAN 在无线网络领域具有可观的发展和前景, 对推动 6G 发展具有重要意义。

参考文献:

- [1] ALWIS C D, KALLA A, PHAM Q V, et al. Survey on 6G frontiers: trends, applications, requirements, technologies and future research[J]. IEEE Open Journal of the Communications Society, 2021, 2: 836-886.
- [2] 张彤, 任奕璟, 闫实, 等. 人工智能驱动的 6G 网络: 智慧内生[J]. 电信科学, 2020, 36(9): 14-22.
ZHANG T, REN Y J, YAN S, et al. Artificial intelligence driven 6G networks: endogenous intelligence[J]. Telecommunications Science, 2020, 36(9): 14-22.
- [3] 张学工. 关于统计学习理论与支持向量机[J]. 自动化学报, 2000, 26(1): 32-42.
ZHANG X G. Introduction to statistical learning theory and support vector machines[J]. Acta Automatica Sinica, 2000, 26(1): 32-42.
- [4] VERT J P, TSUDA K, SCHÖLKOPF B. A primer on Kernel Methods[J]. Kernel Methods in Computational Biology, 2012: 35-70.
- [5] ALSMADI M K, OMAR K B, NOAH S A, et al. Performance comparison of multi-layer perceptron (back propagation, delta rule and perceptron) algorithms in neural networks[C]//Proceedings of 2009 IEEE International Advance Computing Conference. Piscataway: IEEE Press, 2009: 296-299.
- [6] DONG Y D, GUO H P, ZHI W M, et al. Class imbalance oriented logistic regression[C]//Proceedings of 2014 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery. Piscataway: IEEE Press, 2014: 187-192.
- [7] 程学旗, 靳小龙, 王元卓, 等. 大数据系统和分析技术综述[J]. 软件学报, 2014, 25(9): 1889-1908.
CHENG X Q, JIN X L, WANG Y Z, et al. Survey on big data system and analytic technology[J]. Journal of Software, 2014, 25(9): 1889-1908.
- [8] BENGIO Y. Learning deep architectures for AI[J]. Foundations and Trends® in Machine Learning, 2009, 2(1): 1-127.
- [9] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep learning[M]. Cambridge, Massachusetts: The MIT Press, 2016.
- [10] LIU J C, DENG R C, ZHOU S, et al. Seeing the unobservable: channel learning for wireless communication networks[C]//Proceedings of 2015 IEEE Global Communications Conference (GLOBECOM). Piscataway: IEEE Press, 2016: 1-6.
- [11] LI J L, ZHANG Q, XIN X J, et al. Deep learning-based massive MIMO CSI feedback[C]//Proceedings of 2019 18th International Conference on Optical Communications and Networks (ICOON). Piscataway: IEEE Press, 2019: 1-3.
- [12] KUMARESAN S P, TAN C K, NG Y H. Efficient user clustering using a low-complexity artificial neural network (ANN) for 5G NOMA systems[J]. IEEE Access, 2020, 8: 179307-179316.
- [13] 徐潇潇, 谢林柏, 彭力. 基于 WiFi 信号强度特征的室内定位系统设计[J]. 计算机工程, 2015, 41(4): 87-91.
XU X X, XIE L B, PENG L. Design of indoor positioning system based on WiFi signal intensity characteristic[J]. Computer Engineering, 2015, 41(4): 87-91.
- [14] SOMMER R, PAXSON V. Outside the closed world: on using machine learning for network intrusion detection[C]//Proceedings of

- 2010 IEEE Symposium on Security and Privacy. Piscataway: IEEE Press, 2010: 305-316.
- [15] KIM H. Design and optimization for 5G wireless communications[M]. John Wiley & Sons, 2020.
- [16] 殷瑞刚, 魏帅, 李晗, 等. 深度学习中的无监督学习方法综述[J]. 计算机系统应用, 2016, 25(8): 1-7.
- YIN R G, WEI S, LI H, et al. Introduction of unsupervised learning methods in deep learning[J]. Computer Systems & Applications, 2016, 25(8): 1-7.
- [17] ZHENG H N, XIONG K, SUN M Y, et al. Age-energy efficiency in WPCNs: a deep reinforcement learning approach[C]//Proceedings of IEEE INFOCOM 2022 - IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPs). Piscataway: IEEE Press, 2022: 1-2.
- [18] LU Y P, ZHANG C T, CHEN D E, et al. Handover enhancement in high-speed railway 5G networks: a LSTM-based prediction method[C]//Proceedings of 2022 13th International Conference on Computing Communication and Networking Technologies (ICCCNT). Piscataway: IEEE Press, 2022: 1-6.
- [19] REKKAS V P, SOTIROUDIS S, SARIGIANNIDIS P, et al. Unsupervised machine learning in 6G networks-state-of-the-art and future trends[C]//Proceedings of 2021 10th International Conference on Modern Circuits and Systems Technologies (MOCASST). Piscataway: IEEE Press, 2021: 1-4.
- [20] ZHANG R C, XIONG K, LU Y, et al. Joint coordinated beamforming and power splitting ratio optimization in MU-MISO SWIPT-enabled HetNets: a multi-agent DDQN-based approach[J]. IEEE Journal on Selected Areas in Communications, 2022, 40(2): 677-693.
- [21] ZHANG X, LUAN N, LU Y P, et al. AoI-based joint user scheduling and transmit power optimization in high-speed railway mobile networks[C]//Proceedings of 2022 13th International Conference on Computing Communication and Networking Technologies (ICCCNT). Piscataway: IEEE Press, 2022: 1-6.
- [22] ZHANG R C, XIONG K, TIAN X C, et al. Inverse reinforcement learning meets power allocation in multi-user cellular networks[C]//Proceedings of IEEE INFOCOM 2022 - IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPs). Piscataway: IEEE Press, 2022: 1-2.
- [23] LIU L S, XIONG K, CAO J, et al. Average AoI minimization in UAV-assisted data collection with RF wireless power transfer: a deep reinforcement learning scheme[J]. IEEE Internet of Things Journal, 2022, 9(7): 5216-5228.
- [24] ZHANG R C, XIONG K, GUO W, et al. Q-learning-based adaptive power control in wireless RF energy harvesting heterogeneous networks[J]. IEEE Systems Journal, 2021, 15(2): 1861-1872.
- [25] ZHANG R C, XIONG K, LU Y, et al. Energy efficiency maximization in RIS-assisted SWIPT networks with RSMA: a PPO-based approach[J]. IEEE Journal on Selected Areas in Communications, 2023, 41(5): 1413-1430.
- [26] MERCHANT K, NOUSAIN B. Securing IoT RF fingerprinting systems with generative adversarial networks[C]//Proceedings of MILCOM 2019-2019 IEEE Military Communications Conference (MILCOM). Piscataway: IEEE Press, 2020: 584-589.
- [27] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [28] CAO Y J, JIA L L, CHEN Y X, et al. Recent advances of generative adversarial networks in computer vision[J]. IEEE Access, 2018, 7: 14985-15006.
- [29] MENG D L, WU B Y, LIU N H, et al. Semi-supervised deep learning seismic impedance inversion using generative adversarial networks[C]//Proceedings of IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE Press, 2021: 1393-1396.
- [30] DONAHUE C, LI B, PRABHAVALKAR R. Exploring speech enhancement with generative adversarial networks for robust speech recognition[C]//Proceedings of 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE Press, 2018: 5024-5028.
- [31] LOPEZ R, REGIER J, JORDAN M I, et al. Information constraints on auto-encoding variational bayes[J]. Advances in neural information processing systems, 2018.
- [32] BOX G E P, JENKINS G M, REINSEL G C, et al. Time series analysis: forecasting and control[M]. John Wiley & Sons, 2015.
- [33] LI Y, SWERSKY K, ZEMEL R. Generative moment matching networks[C]//International Conference on Machine Learning. PMLR, 2015: 1718-1727.
- [34] BISHOP C M, SVENSÉN M, WILLIAMS C K I. GTM: the generative topographic mapping[J]. Neural Computation, 1998, 10(1): 215-234.
- [35] BAUR M, FESL B, KOLLER M, et al. Variational autoencoder leveraged MMSE channel estimation[J]. arXiv Preprint, 2022: arXiv: 2205.05345.
- [36] LI Q, XIANG Z, REN P, et al. Variational autoencoder based receiver for orthogonal time frequency space modulation[J]. Digital Signal Processing, 2021(117): 103170.
- [37] ZHAO T, LI F. Variational-autoencoder signal detection for MIMO-OFDM-IM[J]. Digital Signal Processing, 2021(118): 103230.
- [38] YUAN J D, NGO H Q, MATTHAIIOU M. Machine learning-based channel estimation in massive MIMO with channel aging[C]//Proceedings of 2019 IEEE 20th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). Piscataway: IEEE Press, 2019: 1-5.
- [39] YUAN J D, NGO H Q, MATTHAIIOU M. Machine learning-based channel prediction in massive MIMO with channel aging[J]. IEEE Transactions on Wireless Communications, 2020, 19(5): 2960-2973.
- [40] LI C L, CHANG W C, CHENG Y, et al. MMD GAN: towards deeper understanding of moment matching network[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM Press, 2017: 2200-2210.

- [41] PARK S W, KWON J. Sphere generative adversarial network based on geometric moment matching[C]//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2020: 4287-4296.
- [42] GAO H C, HUANG H. Joint generative moment-matching network for learning structural latent code[C]//Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. California: International Joint Conferences on Artificial Intelligence Organization, 2018.
- [43] BISHOP C M, SVENSÉN M, WILLIAMS C K I. Developments of the generative topographic mapping[J]. *Neurocomputing*, 1998, 21(1/2/3): 203-224.
- [44] KIREEVA N, BASKIN I I, GASPAR H A, et al. Generative topographic mapping (GTM): universal tool for data visualization, structure-activity modeling and dataset comparison[J]. *Molecular Informatics*, 2012, 31(3/4): 301-312.
- [45] KARRAS T, AILA, LAINE S, et al. Progressive growing of GANs for improved quality, stability, and variation[J]. *arXiv Preprint*, 2017: arXiv: 1710.10196.
- [46] ARORA S, GE R, LIANG Y, et al. Generalization and equilibrium in generative adversarial nets (GANs) [C]// International Conference on Machine Learning. PMLR, 2017: 224-232.
- [47] SALIMANS T, GOODFELLOW I, ZAREMBA W, et al. Improved techniques for training GANs[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. New York: ACM Press, 2016: 2234-2242.
- [48] BAU D, ZHU J, STROBELT H, et al. GAN dissection: visualizing and understanding generative adversarial networks[J]. *arXiv Preprint*, 2018: arXiv: 1811.10597.
- [49] ARORA S, ZHANG Y. Do GANs actually learn the distribution? an empirical study[J]. *arXiv Preprint*, 2017: arXiv: 1706.08224.
- [50] MIRZA M, OSINDERO S. Conditional generative adversarial nets[J]. *arXiv Preprint*, 2014: arXiv: 1411.1784.
- [51] 付兴兵, 刘光远. 粒子群多层感知器在地震预报中的应用研究[J]. *湖南工程学院学报(自然科学版)*, 2007, 17(1): 23-26.
- FU X B, LIU G Y. Research on application of earthquake prediction using neural networks based on particle swarm optimization[J]. *Journal of Hunan Institute of Engineering (Natural Science Edition)*, 2007, 17(1): 23-26.
- [52] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. *计算机学报*, 2017, 40(6): 1229-1251.
- ZHOU F Y, JIN L P, DONG J. Review of convolutional neural network[J]. *Chinese Journal of Computers*, 2017, 40(6): 1229-1251.
- [53] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks[J]. *arXiv Preprint*, 2015: arXiv: 1511.06434.
- [54] CHEN X, DUAN Y, HOUTHOOFT R, et al. InfoGAN: interpretable representation learning by information maximizing generative adversarial nets[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. New York: ACM Press, 2016: 2180-2188.
- [55] HUANG X, LI Y X, POURSAEED O, et al. Stacked generative adversarial networks[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2017: 1866-1875.
- [56] ODENA A, OLAH C, SHLENS J. Conditional image synthesis with auxiliary classifier GANs[C]//Proceedings of the 34th International Conference on Machine Learning - Volume 70. New York: ACM Press, 2017: 2642-2651.
- [57] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein Gan[J]. *arXiv Preprint*, 2017: arXiv: 1701.07875.
- [58] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM Press, 2017: 5769-5779.
- [59] SHE R, FAN P Y, LIU X Y, et al. Interpretable generative adversarial networks with exponential function[J]. *IEEE Transactions on Signal Processing*, 2021(69): 3854-3867.
- [60] SHE R, LIU S Y, FAN P Y. Amplifying inter-message distance: on information divergence measures in big data[J]. *IEEE Access*, 2017, 5: 24105-24119.
- [61] O'SHEA T J, ROY T, WEST N, et al. Physical layer communications system design over-the-air using adversarial networks[C]//Proceedings of 2018 26th European Signal Processing Conference (EUSIPCO). Piscataway: IEEE Press, 2018: 529-532.
- [62] ZHANG D Y, ZHAO J H, YANG L H, et al. Generative adversarial network-based channel estimation in high-speed mobile scenarios[C]//Proceedings of 2021 13th International Conference on Wireless Communications and Signal Processing (WCSP). Piscataway: IEEE Press, 2021: 1-5.
- [63] WEI Y, ZHAO M M, ZHAO M J. Channel distribution learning: model-driven GAN-based channel modeling for IRS-aided wireless communication[C]//Proceedings of IEEE Transactions on Communications. Piscataway: IEEE Press, 2022: 4482-4497.
- [64] YANG Y, LI Y, ZHANG W X, et al. Generative-adversarial-network-based wireless channel modeling: challenges and opportunities[J]. *IEEE Communications Magazine*, 2019, 57(3): 22-27.
- [65] CHEN W B, WANG D S, WANG D D, et al. Generative adversarial network-based channel modeling for free-space optical communication[C]//Proceedings of 26th Optoelectronics and Communications Conference. Washington, D.C.: Optica Publishing Group, 2021: 1-3.
- [66] ZHAO S Q, FANG Y, QIU L. Deep learning-based channel estimation with SRGAN in OFDM Systems[C]//Proceedings of 2021 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2021: 1-6.
- [67] ZHANG Y H, ZHANG Z Y, ZHANG Y X, et al. Blind denoiser-based beamspace channel estimation with GAN in millimeter-wave systems[C]//Proceedings of 2021 IEEE 94th Vehicular Technology Conference (VTC2021-Fall). Piscataway: IEEE Press, 2021: 1-5.

- [68] SUN L, WANG Y W, SWINDLEHURST A L, et al. Generative-adversarial-network enabled signal detection for communication systems with unknown channel models[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(1): 47-60.
- [69] LI X F, ALKHATEEB A, TEPEDELENLIOĞLU C. Generative adversarial estimation of channel covariance in vehicular millimeter wave systems[C]//*Proceedings of 2018 52nd Asilomar Conference on Signals, Systems, and Computers*. Piscataway: IEEE Press, 2019: 1572-1576.
- [70] YE H, LI G Y, JUANG B H F, et al. Channel agnostic end-to-end learning based communication systems with conditional GAN[C]//*Proceedings of 2018 IEEE Globecom Workshops (GC Wkshps)*. Piscataway: IEEE Press, 2019: 1-5.
- [71] YANG H, NIU Z K, XIAO S L, et al. Fast and accurate optical fiber channel modeling using generative adversarial network[J]. *Journal of Lightwave Technology*, 2021, 39(5): 1322-1333.
- [72] ZHANG Q Q, FERDOWSI A, SAAD W, et al. Distributed conditional generative adversarial networks (GANs) for data-driven millimeter wave communications in UAV networks[J]. *IEEE Transactions on Wireless Communications*, 2022, 21(3): 1438-1452.
- [73] DONG Y D, WANG H X, YAO Y D. Channel estimation for one-bit multiuser massive MIMO using conditional GAN[J]. *IEEE Communications Letters*, 2021, 25(3): 854-858.
- [74] BANERJEE B, ELLIOTT R C, KRZYMIENIŃ W A, et al. Downlink channel estimation for FDD massive MIMO using conditional generative adversarial networks[J]. *IEEE Transactions on Wireless Communications*, 2023, 22(1): 122-137.
- [75] YE M, ZHANG H, WANG J B. Channel estimation for intelligent reflecting surface aided wireless communications using conditional GAN[J]. *IEEE Communications Letters*, 2022, 26(10): 2340-2344.
- [76] BALEVI E, DOSHI A, JALAL A, et al. High dimensional channel estimation using deep generative networks[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(1): 18-30.
- [77] DOSHI A, BALEVI E, ANDREWS J G. Compressed representation of high dimensional channels using deep generative networks[C]//*Proceedings of 2020 IEEE 21st International Workshop on Signal Processing Advances in Wireless Communications (SPAWC)*. Piscataway: IEEE Press, 2020: 1-5.
- [78] HU T Y, HUANG Y, ZHU Q M, et al. Channel estimation enhancement with generative adversarial networks[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2021, 7(1): 145-156.
- [79] BALEVI E, ANDREWS J G. Wideband channel estimation with a generative adversarial network[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(5): 3049-3060.
- [80] O'SHEA T J, ROY T, WEST N. Approximating the void: learning stochastic channel models from observation with variational generative adversarial networks[C]//*Proceedings of 2019 International Conference on Computing, Networking and Communications (ICNC)*. Piscataway: IEEE Press, 2019: 681-686.
- [81] ROY D, MUKHERJEE T, CHATTERJEE M, et al. RFAL: adversarial learning for RF transmitter identification and classification[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2020, 6(2): 783-801.
- [82] USAMA M, ASIM M, LATIF S, et al. Generative adversarial networks for launching and thwarting adversarial attacks on network intrusion detection systems[C]//*Proceedings of 2019 15th International Wireless Communications & Mobile Computing Conference (IWCMC)*. Piscataway: IEEE Press, 2019: 78-83.
- [83] SHI Y, DAVASLIOĞLU K, SAGDUYU Y E. Generative adversarial network in the air: deep adversarial learning for wireless signal spoofing[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2021, 7(1): 294-303.
- [84] BANAEIZADEH F, BARBEAU M, GARCIA-ALFARO J, et al. Pilot contamination attack detection in 5G massive MIMO systems using generative adversarial networks[C]//*Proceedings of 2021 IEEE International Mediterranean Conference on Communications and Networking (MeditCom)*. Piscataway: IEEE Press, 2021: 479-484.
- [85] HAN H, CUI L, LI W, et al. Radio frequency fingerprint based wireless transmitter identification against malicious attacker: an adversarial learning approach[C]//*Proceedings of 2020 International Conference on Wireless Communications and Signal Processing (WCSP)*. Piscataway: IEEE Press, 2020: 310-315.
- [86] HAN H, WANG X M, GU F L, et al. Better late than never: GAN-enhanced dynamic anti-jamming spectrum access with incomplete sensing information[J]. *IEEE Wireless Communications Letters*, 2021, 10(8): 1800-1804.
- [87] ERPEK T, SAGDUYU Y E, SHI Y. Deep learning for launching and mitigating wireless jamming attacks[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2019, 5(1): 2-14.
- [88] YANG J, LI T, LIANG G, et al. A simple recurrent unit model based intrusion detection system with DCGAN[J]. *IEEE Access*, 2019, 7: 83286-83296.
- [89] FERDOWSI A, SAAD W. Generative adversarial networks for distributed intrusion detection in the internet of things[C]//*Proceedings of 2019 IEEE Global Communications Conference (GLOBECOM)*. Piscataway: IEEE Press, 2020: 1-6.
- [90] GONG J L, XU X D, LEI Y K. Unsupervised specific emitter identification method using radio-frequency fingerprint embedded InfoGAN[J]. *IEEE Transactions on Information Forensics and Security*, 2020(15): 2898-2913.
- [91] GONG J L, XU X D, QIN Y F, et al. A generative adversarial network based framework for specific emitter characterization and identification[C]//*Proceedings of 2019 11th International Conference on Wireless Communications and Signal Processing (WCSP)*. Piscataway: IEEE Press, 2019: 1-6.
- [92] SHE R, FAN P Y. From MIM-based GAN to anomaly detection: event probability influence on generative adversarial networks[J]. *IEEE Internet of Things Journal*, 2022, 9(19): 18589-18606.

- [93] HAN Z J, GUO L C, LU Z M, et al. Deep adaptation networks based gesture recognition using commodity WiFi[C]//Proceedings of 2020 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2020: 1-7.
- [94] WANG J, ZHANG L, WANG C C, et al. Device-free human gesture recognition with generative adversarial networks[J]. IEEE Internet of Things Journal, 2020, 7(8): 7678-7688.
- [95] ZHANG J J, SHI Z G. Deformable deep convolutional generative adversarial network in microwave based hand gesture recognition system[C]//Proceedings of 2017 9th International Conference on Wireless Communications and Signal Processing (WCSP). Piscataway: IEEE Press, 2017: 1-6.
- [96] NABATI M, NAVIDAN H, SHAHBAZIAN R, et al. Using synthetic data to enhance the accuracy of fingerprint-based localization: a deep learning approach[J]. IEEE Sensors Letters, 2020, 4(4): 1-4.
- [97] TRAN D H, CHUNG B, JANG Y M. GAN-based data augmentation for UWB NLOS identification using machine learning[C]//Proceedings of 2022 International Conference on Artificial Intelligence in Information and Communication (ICAIC). Piscataway: IEEE Press, 2022: 417-420.
- [98] NJIMA W, CHAFII M, SHUBAIR R M. GAN based data augmentation for indoor localization using labeled and unlabeled data[C]//Proceedings of 2021 International Balkan Conference on Communications and Networking (BalkanCom). Piscataway: IEEE Press, 2021: 36-39.
- [99] CHEN L F, ZHANG S T, TAN H B, et al. Progressive RSS data augments with conditional adversarial networks[J]. IEEE Access, 2020, 8: 26975-26983.
- [100] LI Q Y, QU H, LIU Z, et al. AF-DCGAN: amplitude feature deep convolutional GAN for fingerprint construction in indoor localization systems[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2021, 5(3): 468-480.
- [101] LIM C, PAK J. Cost reduction in fingerprint-based indoor localization using generative adversarial network[C]//Proceedings of 2021 International Conference on Information and Communication Technology Convergence (ICTC). Piscataway: IEEE Press, 2021: 1024-1026.
- [102] LI Q Y, QU H, LIU Z, et al. Wavelet transform DC-GAN for diversity promoted fingerprint construction in indoor localization[C]//Proceedings of 2018 IEEE Globecom Workshops (GC Wkshps). Piscataway: IEEE Press, 2019: 1-7.
- [103] FERRAG M A, MAGLARAS L A, JANICKE H, et al. Authentication protocols for Internet of things: a comprehensive survey [J]. Security and Communication Networks, 2017: 1-41.
- [104] 栾宁, 熊轲, 张煜, 等. 6G: 典型应用、关键技术与面临挑战[J]. 物联网学报, 2022, 6(1): 29-43.
- LUAN N, XIONG K, ZHANG Y, et al. 6G: typical applications,

key technologies and challenges[J]. Chinese Journal on Internet of Things, 2022, 6(1): 29-43.

- [105] 张彦, 卢云龙. 数字孪生边缘网络[J]. 中兴通讯技术, 2023.
- ZHANG Y, LU Y L. Digital twin edge networks[J]. ZTE Technology Journal, 2023.
- [106] BEI Y, XIN L, SHENGNAN L, et al. Intelligent 6G wireless network with multi-dimensional information perception[EB]. 2023.

[作者简介]



孟婵媛(1998-), 女, 北京交通大学计算机与信息技术学院博士生, 主要研究方向为资源优化、机器学习、6G网络等。



熊轲(1981-), 男, 博士, 北京交通大学计算机与信息技术学院教授、副院长, 主要研究方向为人工智能、6G网络、无线大数据分析处理、AI赋能的移动网络优化设计等。



高博(1984-), 男, 博士, 北京交通大学计算机与信息技术学院副教授, 主要研究方向为无线网络、移动计算、机器学习等。



张煜(1983-), 男, 博士, 国网能源研究院有限公司高级研究员, 主要研究方向为边缘计算、无线协作网络和能源互联网等。



樊平毅(1965-), 男, 博士, 清华大学电子工程系教授、博士生导师, 主要研究方向为网络信息论、无线通信、大数据理论、分布式机器学习等。