arXiv:2301.00981v1 [eess.SP] 3 Jan 2023

基于迁移生成对抗网络（T-GAN）的太赫兹信道建模

胡正东、李元博和韩崇，太赫兹无线通信（TWC）实验室，中国上海交通大学。电子邮件： {huzhengdong, yuanbo.li, chong.han}@sjtu.edu.cn

摘要—**太赫兹（THz）通信被视为第六代移动通信及未来无线系统的一项有前景的技术，可提供超宽带宽，从而实现每秒太比特（Tbps）的数据速率。然而，作为设计太赫兹通信的基础，信道建模与表征对于审视新频谱的潜力至关重要。传统统计信道建模方法依赖物理测量，受限于假设的特定分布和经验参数，存在精度较低的问题。此外，在太赫兹频段获取大量信道测量数据既耗时又昂贵。本文提出一种适用于太赫兹频段的迁移生成对抗网络（T-GAN）建模方法，该方法利用生成对抗网络对复杂分布进行建模的优势，并借助迁移学习将源任务中的知识迁移过来，以便在训练数据有限的情况下提升对目标任务的泛化能力。具体而言，首先，使用由第三代合作伙伴计划（3GPP）标准信道模型生成的仿真数据集对所提出的生成对抗网络进行预训练。此外，通过迁移知识并对预训练的生成对抗网络进行微调，利用少量太赫兹测量数据构建了T-GAN。实验结果表明，所提出的T-GAN方法生成的功率时延谱分布与测量结果吻合良好。此外，与传统3GPP方法相比，T-GAN在信道建模方面表现良好，均方根误差改善了9 dB，且结构相似性指数（SSIM）更高。**

I. 引言

随着互联设备数量呈指数级增长，预计第六代移动通信（6G）将实现万物、随时随地的智能连接 [1],，这要求无线数据速率达到 Tbit/s。为满足这一需求，得益于从数十 GHz 到数百 GHz 的超宽带宽，太赫兹（THz）通信作为第六代移动通信系统的一项关键技术，正日益受到关注 [2]。太赫兹频段有望解决当前无线系统面临的频谱资源稀缺和容量限制问题，并实现人们期待已久的应用，包括无线认知、定位以及感知与通信一体化 [3]。

设计可靠的太赫兹无线系统，一项根本挑战在于开发准确的信道模型，以描述传播现象。由于频率较高，太赫兹频段会出现新的特性，例如频率选择性吸收损耗和粗糙表面散射。鉴于这些新特性，太赫兹信道建模需要能够捕捉这些特性。然而，传统统计信道建模方法存在精度较低的问题，因为它们假设了特定的分布和经验参数。例如，基于几何的随机信道模型（GSCM）假设散射体的位置服从特定的统计分布，例如在发射机和接收机周围的圆形区域内服从均匀分布 [4]。然而，散射体的位置难以用特定的统计分布来描述，因此 GSCM 不适用于太赫兹频段。此外，获取大量用于太赫兹信道建模的信道测量数据既耗时又昂贵。因此，需要一种能够利用有限测量数据对太赫兹频段进行准确信道建模的方法。

近年来，深度学习（DL）在无线通信领域广受欢迎并得到广泛应用，例如信道估计 [5],[6] 和信道状态信息（CSI）反馈 [7]。在各种深度学习方法中，生成对抗网络（GAN）能够在无需任何统计假设的情况下准确建模复杂分布，因此可用于开发信道模型。文献 [8]中的作者训练 GAN，以近似随机信道响应的概率分布函数（PDF）。文献 [9],将 GAN 用于生成与真实信道样本分布相近的合成信道样本。文献 [10] 中的研究人员通过信道输入输出测量，利用 GAN 对信道进行建模。文献 [11],提出了一种用于智能反射面（IRS）辅助通信系统的模型驱动的基于 GAN 的信道建模方法。这些方法在信道建模方面表现良好，并证明了目标信道分布与生成的信道分布具有高度一致性。然而，基于 GAN 的信道建模方法尚未应用于太赫兹频段。此外，面对稀缺的太赫兹信道测量数据集，如何训练 GAN 进行信道建模仍是一项挑战。

本文提出一种基于迁移生成对抗网络（T-GAN）的太赫兹信道建模方法，用于学习太赫兹信道功率时延分布（PDP）的分布。此外，针对太赫兹频段信道测量有限这一挑战，本文在 T-GAN 中引入迁移学习技术，将预训练模型中存储的知识迁移至新模型，从而降低训练所需信道数据集的规模，并提升信道建模性能 [12], [13]。此外，通过实测数据验证了 T-GAN 在信道分布建模方面的性能 [14]。

本文的主要贡献如下。

- 我们提出一种基于 T-GAN 的太赫兹信道建模

方法，该方法设计了一种生成对抗网络，通过在功率时延谱样本数据集上进行训练，来捕捉太赫兹信道功率时延谱的分布。

- 为应对太赫兹信道建模中测量数据有限的挑战，T-GAN 进一步利用迁移学习，将预训练模型中存储的知识迁移至新模型，从而降低对训练数据集规模的要求，并提升生成对抗网络的性能。

其余各节安排如下：第II节详细介绍所提出的基于 T-GAN 的信道建模方法。第III节展示所提出的 T-GAN 方法的性能。论文最后在第IV节作总结。

符号说明： a表示标量。**a** 表示向量。**A** 表示矩阵。$\mathbb{E}\{\cdot\}$ 表示期望。∇ 表示梯度运算。$\|\cdot\|$ 表示 L2范数。$\mathbf{I}_N$ 表示一个 N 维单位矩阵。$\mathcal{N}$ 表示正态分布。

II. 基于迁移生成对抗网络（T-GAN）的信道建模

本节首先将信道建模问题表述为信道分布学习问题。然后，详细介绍 T-GAN 方法中提出的生成对抗网络。最后，介绍 T-GAN。

A. 问题表述

信道冲激响应（CIR）可表示为

$$h(\tau)=\sum_{l=0}^{L-1}\alpha_l e^{j\phi_l}\delta(\tau-\tau_l), \tag{1}$$

其中，τ_l 表示 l^{th} 多径分量（MPC）的时延，L 表示MPC的数量，α_l 表示路径增益，ϕ_l 表示相应MPC的相位。为表征信道，功率时延剖面（PDP）是一项重要特征，它表示功率随时延的扩散情况，具体而言，即多径信道中接收功率与时延的关系。它可由信道冲激响应通过以下方式提取：

$$P(\tau)=|h(\tau)|^2, \tag{2}$$

随后，通过学习功率时延谱（PDPs）的分布来解决信道建模问题，该分布记为 p_r，且难以用解析形式表示。为此，可以通过生成服从分布 p_g的伪造PDP样本来捕获分布 p_r，使生成的PDP分布 p_g 与实际分布 p_r相匹配。

B. 所提出的生成对抗网络

GAN 可用于学习由 p_r表示的功率时延谱分布，其框架如图 1 所示。GAN 由两个子网络组成，即生成器和判别器。生成器旨在生成虚假样本 $G(z)$，以欺骗判别器，其中 z 是噪声样本；它通过将输入噪声分布 $p_z(z)$映射为生成的分布 $p_g=p(G(z))$来实现这一目标。判别器则试图

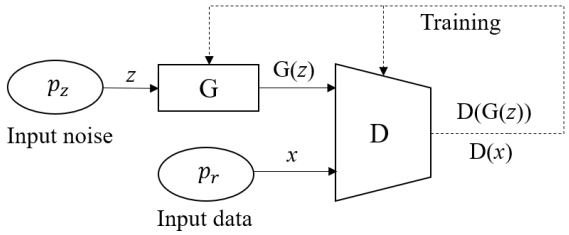

图1. 生成对抗网络框架。

区分来自 p_r 的真实样本 x 与来自 p_g的虚假样本$G(z)$，判别器的输出 $D(x)$ 和$D(G(z))$可视为样本为真实样本的概率。这两个网络以对抗方式进行训练，可将其视为双人零和极小极大博弈。具体而言，训练目标可表示为

$$\min_G\max_D \mathbb{E}_{\boldsymbol{x}\sim p_r}[\log D(\boldsymbol{x})]+\mathbb{E}_{\boldsymbol{z}\sim p_z}[\log(1-D(G(\boldsymbol{z})))], \tag{3}$$

其中，生成器旨在最小化生成样本被判别器判定为伪造样本的概率（$1-D(G(z))$），而判别器则旨在最大化该概率。因此，在训练过程中，生成器和判别器以相反的目标相互竞争。通过对抗训练，可以达到纳什均衡，此时生成器和判别器无法仅通过改变自身网络来改进各自的目标。此外，当 $p_g=p_r$时，训练目标的全局最优解可在均衡状态下实现。然而，使用式（3）中的目标函数进行训练并不稳定，因为训练目标关于生成器参数 [15]可能不连续。因此，采用改进版的生成对抗网络，即带梯度惩罚的Wasserstein生成对抗网络（WGAN-GP） [15] 。修改后的目标函数表示为

$$\begin{aligned}\min_G\max_D \mathbb{E}_{\boldsymbol{x}\sim p_r}[D(\boldsymbol{x})]+&\mathbb{E}_{\boldsymbol{z}\sim p_z}[(1-D(G(\boldsymbol{z})))]\\&+\lambda\mathbb{E}_{\tilde{\boldsymbol{x}}}[(\|\nabla_{\tilde{\boldsymbol{x}}}D(\tilde{\boldsymbol{x}})\|-1)^2)],\end{aligned} \tag{4}$$

其中，最后一项是梯度惩罚项，用于施加利普希茨约束，使GAN网络的梯度不超过某个最大值；符号 $\tilde{\boldsymbol{x}}$ 表示在点 $\boldsymbol{x}$ 和点 G之间均匀采样的点（$\boldsymbol{z}$）。此外，参数 λ 为惩罚系数。

介绍 GAN 的框架后，本文提出的 GAN 网络的详细架构如下所述。生成器 G 和判别器 D 的结构如图 2 所示，其中括号内的数字表示维度。生成器的输入是一个维度为 $n_z=100$的噪声向量 z，该向量从概率密度函数 $\mathcal{N}(0,\sigma^2\mathbf{I}_{n_z})$中采样得到。生成器由五个全连接层组成，各层的神经元数量依次为 128、128、128、128 和 401。值得注意的是，输出层的大小等于 PDP 的大小。

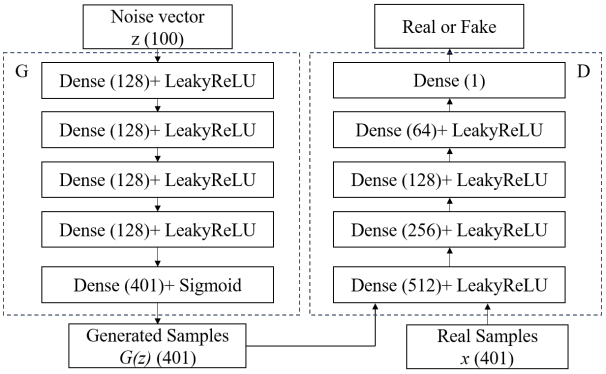

图 2. 生成器和判别器的结构。

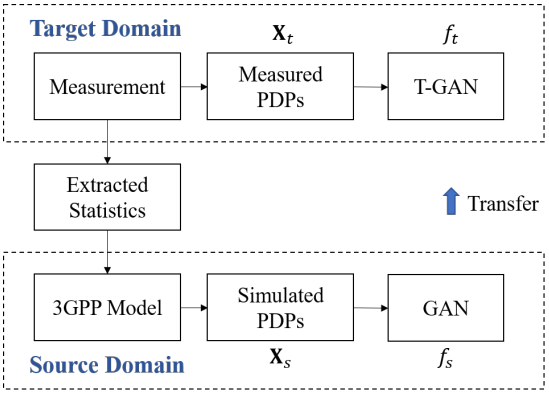

图 3. T-GAN 框架。

前四个全连接层的激活函数为 LeakyReLU 函数，该函数可以加快收敛并避免梯度消失问题。LeakyReLU 函数的公式表示为

$$f(x) = \begin{cases} x, & \text{if } x \geq 0 \\ \alpha x, & \text{if } x < 0 \end{cases}, \tag{5}$$

其中，α 是神经元 x 的值为负时的斜率系数。除 LeakyReLU 函数外，最后一层还使用 Sigmoid 函数，将输出映射到 [0, 1]的范围内。Sigmoid 函数定义为

$$f(x) = \frac{1}{1+e^{-x}}. \tag{6}$$

输入噪声向量经过生成器中的全连接层和激活函数后，被转换为生成样本。随后，生成样本与真实样本一起输入判别器。

判别器旨在区分生成样本和真实样本。判别器中五个全连接层的神经元数量分别为 512、256、128、64 和 1。前四层选用前文介绍的 LeakyReLU 函数作为激活函数。输出层采用线性激活函数，这是由式 (4) 中介绍的 WGAN-GP 目标函数决定的。

C. 所提出的 T-GAN

所提出的 T-GAN 框架如图 3 所示，其中迁移学习在测量数据与 3GPP TR 38.901 模型之间进行 [16]。测量功率时延谱是指从小规模测量数据中提取的功率时延谱，而仿真功率时延剖面则是指由 3GPP 模型仿真的功率时延剖面，该模型采用从测量数据中提取的统计特性实现。随后，分别使用仿真功率时延剖面和测量功率时延谱训练具有相同网络结构的所提出的 GAN 和 T-GAN，以捕获功率时延谱的分布。由于测量功率时延谱的规模对于 T-GAN 的训练而言相当小，可能导致难以收敛或出现过拟合问题，因此采用迁移学习来解决这些问题。

为正式描述迁移学习，领域 $\mathcal{D}$ 由特征空间 $\mathcal{X}$ 和定义在$\mathbf{X}$上的边缘概率分布 $\mathcal{P}(\mathbf{X})$组成$\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \cdots, \mathbf{x}_N\} \in \mathcal{X}$，其中 N 是$\mathbf{X}$中特征向量的数量。如图 3 所示，目标领域 $\mathcal{D}_t$ 和源领域 $\mathcal{D}_s$ 分别定义在测量数据和 3GPP 模型上。这两个领域的特征空间均由功率时延谱构成，其边缘概率分布分别定义在测量功率时延谱$\mathbf{X_t}$ 和仿真功率时延谱$\mathbf{X_s}$上。

此外，给定一个领域 $\mathcal{D}(\mathcal{X}, P(\mathbf{X}))$，一个由 $\mathcal{T}$ 表示的任务由标签空间 $\mathcal{L}$ 和预测函数 $f(\cdot)$ 定义，并且该预测函数通过样本对 $(\mathbf{x}_n, l_n)$ 进行学习，其中 $\mathbf{x}_n \in \mathbf{X}$ 且 $l_n \in \mathcal{L}$。在目标领域 $\mathcal{D}_t$ 和源领域 $\mathcal{D}_s$ 中，任务相同，均用于捕获功率时延谱的分布；标签空间为 $\mathcal{L} = \{0, 1\}$，表示 PDP 样本是由所提出的 GAN 生成，还是来自训练数据集。T-GAN 和 GAN 分别作为预测函数 f_t 和 f_s。随后，迁移学习旨在利用源领域 $\mathcal{D}_s$ 中的 $\mathcal{T}_s$ 知识，在目标领域 $\mathcal{D}_t$ 中学习函数 f_t，即将经过仿真功率时延剖面训练的 GAN 中所存储的知识迁移到经过实测功率时延剖面训练的 T-GAN 中。

迁移学习采用了 [13] 微调方法。T-GAN 以经过仿真功率时延剖面训练的 GAN 的权重进行初始化，然后使用小规模的实测功率时延剖面对其进行微调。值得注意的是，GAN 中的生成器和判别器都会被迁移；与仅迁移生成器或判别器 [13] 相比，这能够在生成高质量样本和实现快速收敛方面取得更好的性能。

通过迁移学习，T-GAN 的性能可得到大幅提升。具体而言，所提出的、基于仿真功率时延剖面训练的生成对抗网络能够捕获 3GPP 方法提取的信道统计特性，并将其进一步迁移至 T-GAN。此外，T-GAN 还能直接从测量数据中学习 3GPP 方法未能捕获的功率时延谱特征，从而进一步提升 T-GAN 对功率时延谱分布的建模性能。

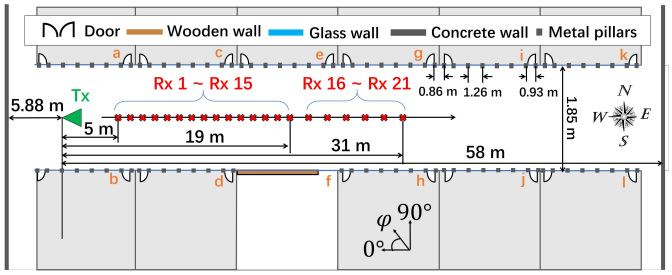

图4. 室内走廊场景中的测量布局 [14]。

III. 实验与性能评估

本节将详细介绍实验设置。此外，我们通过将生成的功率时延谱分布与测量结果进行比较，评估 T-GAN 的性能。

A. 数据集与设置

数据集采集自 [14]中的测量活动，该活动在306–321 GHz频段的室内走廊场景中进行，最大时延为400 ns，如图4所示。利用测量数据，可以提取功率时延谱，以表征21个接收点处的信道。由于采样频率间隔较小，为2.5 MHz，实测功率时延剖面很长，包含6001个采样点，导致训练生成对抗网络需要耗费大量计算资源和时间。为解决这一问题，我们仅使用314至315 GHz频带内的实测信道传递函数，据此可将功率时延谱缩短至401个采样点。

21个实测信道的功率时延谱构成测量数据集。除测量数据集外，还可以利用从测量中提取的统计特性，通过3GPP模型生成仿真功率时延剖面数据集，其中包含10000个信道。与测量数据集相比，仿真数据集的数据规模更大，并嵌入了信道统计特性。此外，通过最小-最大归一化方法，将两个数据集中的功率时延谱归一化到 [0, 1] 范围内。

GAN 网络的训练过程详细说明如下。首先，利用多元正态分布生成大小为 100 的输入噪声向量 z，使其能够转换为所需的分布。(4) 式中的梯度惩罚参数 λ 设为 10，该设置在训练过程中效果良好。此外，生成器网络采用随机梯度下降（SGD）优化器，判别器网络采用自适应矩估计（Adam）优化器。另外，两个优化器的学习率均设为 0.0002，以稳定训练过程。

所有实验均在一台配备 AMD Ryzen Threadripper 3990X @ 2.19 GHz 和四块 Nvidia GeForce RTX3090 Ti 图形处理器的 PC 上进行。此外，GAN 网络的训练在 PyTorch 框架中完成。

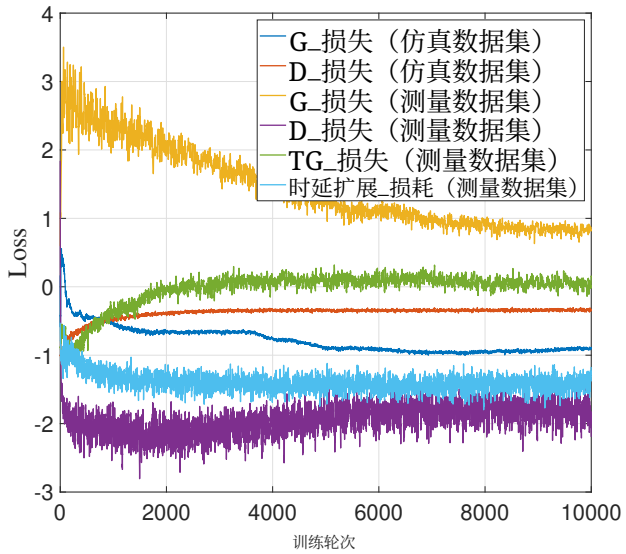

图 5. GAN 网络中生成器和判别器的损失。

B. 收敛

首先在仿真数据集上训练所提出的生成对抗网络，然后通过迁移学习在测量数据集上对其进行微调，以构建 T-GAN。所提出的生成对抗网络和 T-GAN 的训练轮次均设为 10000。一个训练轮次定义为完整遍历训练数据集的一次训练周期，在此期间，生成器和判别器各迭代训练一次。为展示迁移学习的优势，还在不使用迁移学习的情况下，直接在测量数据集上训练生成对抗网络，以作比较。图5展示了生成器损失（记为 G loss）和判别器损失（记为 D loss），其中 TG loss 和 TD loss 分别对应 T-GAN 的生成器损失和判别器损失。对于仿真数据集，显然生成器和判别器最终达到均衡。对于测量数据集，除少量波动外，T-GAN 的损失与仿真数据集上的损失接近。这些波动是由测量数据集规模较小所致。相比之下，不使用迁移学习的生成对抗网络训练过程并不稳定。判别器损失波动较大，且与仿真数据集上的损失相比，G loss 和 D loss 的绝对值都相当大。这一比较展示了迁移学习在生成对抗网络训练中的优势：借助迁移学习，T-GAN 能够在训练数据集较小的情况下收敛。此外，T-GAN 仅需 4000 个训练轮次即可收敛，而在仿真数据集上训练的生成对抗网络则需要 6000 个训练轮次。T-GAN 在测量数据集上的训练时间也很短，仅为 114 秒，而在仿真数据集上训练生成对抗网络则需要 7 小时。由此可见，迁移学习技术能够利用预训练模型中的知识，提高 T-GAN 的收敛速度并降低训练开销。

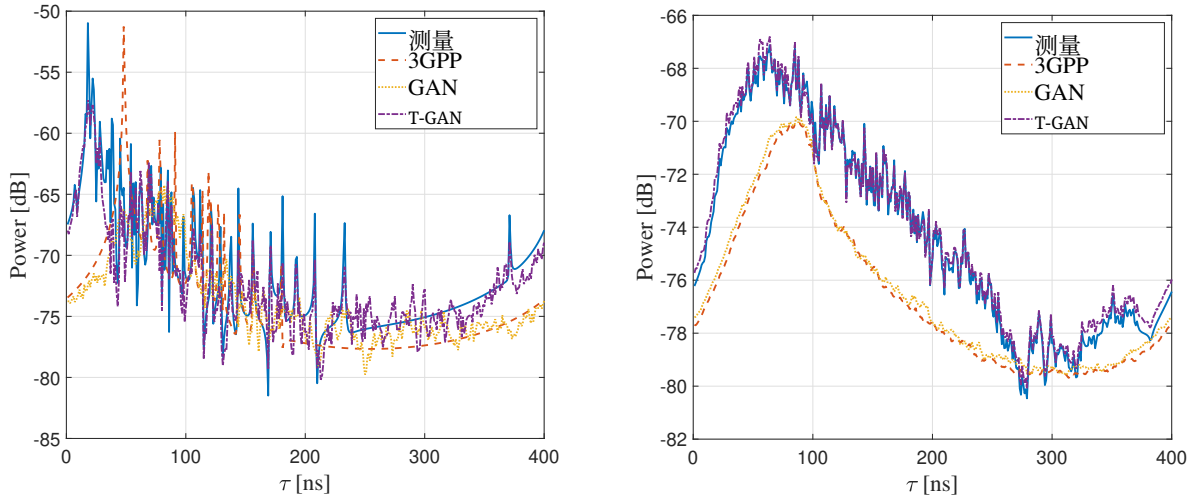

(a) PDP 样本。 (b) 平均 PDP。

图 6. 测量数据、3GPP、所提出的生成对抗网络和 T-GAN 生成的功率时延谱图。

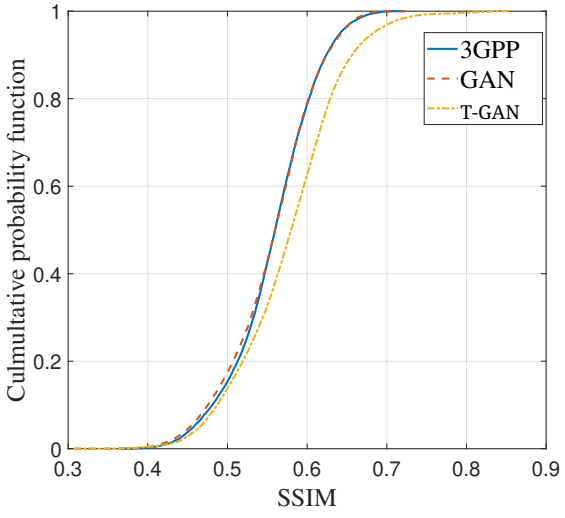

Fig. 7. 3GPP、所提出的生成对抗网络和 T- 的功率时延剖面结构相似性指数 GAN.

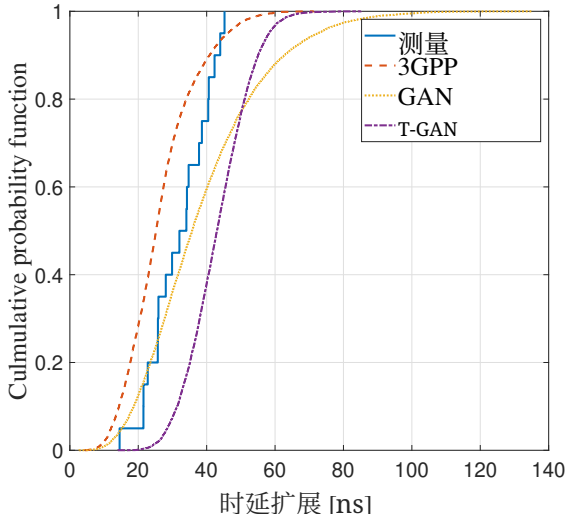

图8. 3GPP、所提出的生成对抗网络和 T -GAN 的时延扩展。

C. 功率时延剖面

实验中，对测量、3GPP方法、所提出的生成对抗网络和 T-GAN 得到的功率时延剖面样本进行了比较，如图 6(a) 所示。显然，这些功率时延谱彼此相似，证明所提出的生成对抗网络和 T-GAN 能够学习功率时延谱的特征。此外可以观察到，测量得到的功率时延剖面比 3GPP方法得到的更为复杂，其时域中存在更多峰值和波动。这表明 3GPP 无法充分捕捉功率时延剖面中蕴含的信道效应。比较所提出的生成对抗网络和 T-GAN 生成的功率时延谱可知，T-GAN 生成的功率时延剖面接近测量结果，而所提出的生成对抗网络生成的功率时延剖面则与 3GPP 方法相似。这是合理的，因为 T-GAN 能够捕捉测量数据中的功率时延剖面特征通过迁移学习，而所提出的生成对抗网络只能学习 3GPP方法仿真功率时延剖面的特征。

此外，这些方法得到的平均功率时延谱绘制于图 6(b)中。显然，T-GAN 与测量结果吻合良好，而 3GPP 和生成对抗网络与测量结果存在较大偏差。偏差可通过均方根误差（RMSE）进行衡量，其计算公式如下：

$$\mathrm{RMSE} = \sqrt{\frac{1}{N_\tau}\sum(P_m(i\Delta\tau) - P_g(i\Delta\tau))^2}, \qquad (7)$$

其中， N_τ 表示PDP中的采样点数量， i为PDPs的时间采样点索引， N_τ 表示采样点数量， $\Delta\tau$ 为采样间隔。此外， P_m（$i\Delta\tau$）和 P_g（$i\Delta\tau$）分别表示

测量得到的PDPs和生成的PDPs中i^{th} 采样点处的平均功率。3GPP、所提出的GAN和T-GAN的均方根误差分别为4.29 dB、4.12 dB和-4.82 dB。与其他方法相比，T-GAN的均方根误差性能提升了约9 dB，这表明T-GAN在PDP平均功率建模方面优于其他方法。这归功于GAN在建模复杂分布方面的强大能力，以及迁移学习能够更好地利用小规模测量数据集的优势。

此外，为了定量衡量相似性，我们引入了结构相似性指数（SSIM），该指标广泛用于评估图像的质量和相似性。SSIM 的取值范围为 0 到 1，图像间的相似性越高，SSIM 值越大。我们将 3GPP方法、所提出的生成对抗网络和 T-GAN 生成的功率时延谱与测量结果进行了比较。这些方法的 SSIM 累积分布函数如图 7 所示。可以看出，与其他方法相比，所提出的 T-GAN 能够取得更高的 SSIM 值。T-GAN 的 SSIM 值中有超过 40% 高于 0.6，而 3GPP 方法和所提出的生成对抗网络仅有 20% 高于 0.6。这进一步表明，T-GAN 在对功率时延谱进行建模方面性能更优。

D. 时延扩展

时延扩展表征时域中多径分量的功率扩散，可通过功率时延谱的二阶中心矩计算，具体如下：

$$\begin{aligned}\bar{\tau} &= \frac{\sum_{i=0}^{N_\tau} i\Delta\tau P(i\Delta\tau)\Delta\tau}{\sum_{i=0}^{N_\tau} P(i\Delta\tau)\Delta\tau},\\ \tau_{rms} &= \sqrt{\frac{\sum_{i=0}^{N_\tau}(i\Delta\tau-\bar{\tau})^2 P(i\Delta\tau)\Delta\tau}{\sum_{i=0}^{N_\tau} P(i\Delta\tau)\Delta\tau}},\end{aligned} \tag{8}$$

其中，$\bar{\tau}$ 表示按功率加权的平均时延，τ_{rms} 表示均方根（RMS）时延扩展，$P(i\Delta\tau)$表示PDP中 i^{th} 个采样点处的功率。

随后，图8展示了测量结果、3GPP、所提出的GAN和T-GAN的时延扩展累积分布函数（CDF）曲线。可以观察到，3GPP、所提出的GAN和T-GAN的时延扩展累积分布函数与测量结果吻合良好。

IV. 结论

本文提出了一种基于 T-GAN 的太赫兹信道建模方法，该方法利用所设计的生成对抗网络捕获太赫兹信道功率时延谱的分布。此外，T-GAN 采用迁移学习，通过将预训练生成对抗网络在仿真数据集上存储的知识迁移到仅使用有限测量数据训练的目标 T-GAN 中，降低了对训练数据集规模的要求，并提升了生成对抗网络的性能。最后，我们通过测量验证了 T-GAN 的性能。T-GAN 能够生成与测量结果吻合良好的功率时延谱。与传统方法相比，T-GAN 在功率时延谱分布建模方面表现更佳，均方根误差降低了 9 dB 均方根误差有所改善，结构相似性指数更高。T-GAN 的结构相似性指数值中，超过 40% 高于 0.6；相比之下，3GPP 和所提出的生成对抗网络仅有 20% 高于 0.6。

参考文献

[1] I. F. Akyildiz、C. Han、Z. Hu、S. Nie 和 J. M. Jornet，《太赫兹频段通信：重访一个老问题并探讨未来十年的研究方向（特邀论文）》，*IEEE*通信汇刊，第70卷，第6期，4250–4285页，2022年。[2] Z. Chen 等，《面向2030年及以后的太赫兹无线通信：前沿尖端》，*IEEE*通信杂志，第59卷，第11期，66–72页，2021年。[3] C. Han、Y. Wu、Z. Chen、Y. Chen 和 G. Wang，《太赫兹集成感知与通信：太赫兹感知与通信一体化的物理层视角》，*arXiv*预印本：*2209.03145*，2022年。[4] P. Petrus、J. Reed 和 T. Rappaport，《面向移动环境的基于几何的统计宏蜂窝信道模型》，*IEEE*通信汇刊，第50卷，第3期，495–502页，2002年。[5] Y. Chen、L. Yan 和 C. Han，《太赫兹超大规模MIMO信道的球面波与平面波混合建模及深度卷积神经网络辅助估计》，*IEEE*通信汇刊，第69卷，第10期，7063–7076页，2021年。[6] Y. Chen、L. Yan、C. Han 和 M. Tao，《太赫兹超大规模MIMO系统的毫度级到达方向估计与跟踪》，*IEEE*无线通信汇刊，第21卷，883，2022年2月，第869页起。[7] T. Wang、C.-K. Wen、S. Jin 和 G. Y. Li，《面向时变大规模MIMO信道的基于深度学习的CSI反馈方法》，*IEEE*无线通信快报，第8卷，第2期，416–419页，2019年。[8] T. J. O'Shea、T. Roy 和 N. West，《逼近虚无：利用变分生成对抗网络从观测中学习随机信道模型》，载于计算、网络与通信国际会议论文集，2019年，681–686页。[9] H. Xiao、W. Tian、W. Liu 和 J. Shen，《ChannelGan：基于深度学习的信道建模与生成》，*IEEE*无线通信快报，第11卷，第3期，650–654页，2022年。[10] T. Orekondy、A. Behboodi 和 J. B. Soriaga，《MIMO-GAN：生成式MIMO信道建模》，载于*IEEE*国际通信会议论文集，2022年，5322–5328页。[11] Y. Wei、M.-M. Zhao 和 M.-J. Zhao，《信道分布学习：面向IRS辅助无线通信的模型驱动生成对抗网络信道建模》，*IEEE*通信汇刊，第70卷，4497，2022年7月，第4482页起。[12] N. V. Huynh 和 G. Y. Li，《无线网络中的信号检测迁移学习》，*IEEE*无线通信快报，1–1页，2022年。[13] Y. Wang、C. Wu、L. Herranz、J. van de Weijer、A. Gonzalez-Garcia 和 B. Raducanu，《迁移生成对抗网络：利用有限数据生成图像》，载于欧洲计算机视觉国际会议，2018年。[14] Y. Li、Y. Wang、Y. Chen、Z. Yu 和 C. Han，《300吉赫兹室内走廊场景中的信道测量与分析》，载于*IEEE*国际通信会议论文集，2022年，2888–2893页。[15] I. Gulrajani、F. Ahmed、M. Arjovsky、V. Dumoulin 和 A. Courville，《改进Wasserstein生成对抗网络的训练》，载于神经信息处理系统国际会议论文集，2017年，5769–5779页。[16] *0.5*至*100 GHz*频段信道模型研究（第*15*版），文件TR 38.901，3GPP，2018年。