

## 基于轻量并行去噪网络的OTFS信道估计算法

熊俊<sup>1</sup>, 韩雪晴<sup>1</sup>, 刘潇然<sup>1</sup>, 张晖<sup>2</sup>, 赵海涛<sup>1</sup>, 魏急波<sup>1</sup>

(1. 国防科技大学电子科学学院, 湖南 长沙 410073; 2. 南京邮电大学物联网学院, 江苏 南京 210023)

**摘要:** 正交时频空 (OTFS, orthogonal time frequency space) 作为 6G 关键候选技术之一, 能够有效对抗双选择性衰落信道的影响。然而, OTFS 系统的信道估计一直是学术界研究的重点和难点。近年来, 有研究提出了基于深度学习的 OTFS 信道估计方案, 其运用人工智能技术快速捕捉信道变化, 但也存在网络规模大、难以满足移动终端轻量化需求的问题。为此, 以提高计算效率、降低设备功耗为目标, 提出一种基于轻量并行去噪网络的 OTFS 信道估计算法。该算法结合图像去噪和数据驱动思想, 在保留深度学习算法强大的泛化能力的基础上, 通过优化网络结构和降低导频功率, 降低了移动端的算力成本, 为高速移动场景下终端通信的轻量化提供了新的解决方案。所提算法的参数规模仅为现有基于图像去噪的卷积神经网络 (DnCNN, denoising convolutional neural network) 的 15%, 大幅降低了网络参数规模和计算复杂度。仿真结果表明, 凭借独特的并行结构设计, 所提算法弥补了轻量化设计带来的估计性能损失。在五径快时变信道下, 所提算法相较于 DnCNN 实现了 4 dB 的性能增益。

**关键词:** OTFS; 信道估计; 深度学习; 去噪网络; 轻量化

**中图分类号:** TN929.05

**文献标志码:** A

**doi:** 10.11959/j.issn.2096-3750.2025.00502

## Lightweight parallel denoising network-based OTFS channel estimation algorithm

XIONG Jun<sup>1</sup>, HAN Xueqing<sup>1</sup>, LIU Xiaoran<sup>1</sup>, ZHANG Hui<sup>2</sup>, ZHAO Haitao<sup>1</sup>, WEI Jibo<sup>1</sup>

1. College of Electronic Science and Technology, National University of Defense Technology, Changsha 410073, China

2. School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

**Abstract:** Orthogonal time frequency space (OTFS) as one of the key candidate technologies for 6G, is recognized for its ability to effectively combat the effects of doubly-selective fading channels. However, channel estimation in OTFS systems has remained a major focus and challenge in academic research. In recent years, deep learning-based OTFS channel estimation schemes were proposed, which utilized artificial intelligence techniques to rapidly capture channel variations. Nevertheless, these existing algorithms were generally characterized by large network scales, making it difficult to meet the lightweight requirements of mobile terminals. To address this issue, an OTFS channel estimation algorithm based on a lightweight parallel denoising network was proposed with the aim of improving computational efficiency and reducing device power consumption. By integrating image denoising and data-driven concepts, the algorithm retained the strong generalization capability of deep learning methods while reducing the computational cost on mobile devices through optimized network architecture and reduced pilot power, thereby providing a new solution for lightweight terminal communication in high-mobility scenarios. The parameter quantity of the proposed algorithm was only 15% of that of the existing denoising convolutional neural network (DnCNN), significantly reducing both the network parameter scale and computa-

收稿日期: 2025-04-16; 修回日期: 2025-06-23

通信作者: 韩雪晴, han2809@qq.com

基金项目: 国家自然科学基金资助项目 (No. U2441226, No. 62371462); 湖南省自然科学基金资助项目 (No. 2025JJ20067); 湖南省科技创新项目 (No. 2022RC1093)

**Foundation Items:** The National Natural Science Foundation of China (No. U2441226, No. 62371462), Natural Science Foundation of Hunan Province (No. 2025JJ20067), The Science and Technology Innovation Program of Hunan Province (No. 2022RC1093)

tional complexity. Simulation results demonstrated that, thanks to its unique parallel structure design, the proposed algorithm compensated for the estimation performance loss caused by lightweight design. Under a five-path fast time-varying channel, a performance gain of 4 dB was achieved compared to DnCNN.

**Key words:** OTFS, channel estimation, deep learning, denoising network, lightweight

## 0 引言

随着第六代移动通信（6G, the 6th generation mobile communication）技术的快速发展，正交时频空（OTFS, orthogonal time frequency space）调制作为6G潜在的关键技术之一，通过在时延多普勒（DD, delay-Doppler）域进行资源映射，并利用该域信道的稀疏性和稳定性，能够实现更高的数据传输可靠性。与传统的正交频分复用（OFDM, orthogonal frequency-division multiplexing）技术相比，OTFS调制在处理高移动性及复杂环境下的信道时，表现出更强的抗多普勒频移能力<sup>[1]</sup>。

信道估计作为通信接收机的关键处理模块，其估计精度直接决定了OTFS调制系统的接收性能<sup>[2-4]</sup>。常见的OTFS信道估计算法有基于阈值的信道估计算法和基于压缩感知的信道估计算法等<sup>[5-12]</sup>。文献[5]提出了一种基于保护带的单导频信道估计算法，该算法在导频符号的周围设置空白保护区，通过在接收端设置一个阈值筛选出接收信号的导频位置，从而获取信道参数，最后构建出信道冲激响应矩阵。在复高斯白噪声干扰强烈或信道衰落明显的情况下，该算法将会遭遇路径检测遗漏与信道衰落增益估计误差偏大的问题。文献[7]设计了一种数据与导频叠加方案，实现了快时变衰落信道下信道估计性能的提升。然而，上述方案难以扩展到更高移动速度的OTFS信道，究其原因是它们难以应对大多普勒频移影响下的导频与数据间干扰。除了文献[5]提出的基于阈值的信道估计算法外，基于压缩感知的信道估计算法则利用OTFS信道的稀疏性，通过少量的采样数据就能够准确地估计出信道状态信息，同样被广泛运用到OTFS调制系统中。其中最具代表性的算法有正交匹配追踪（OMP, orthogonal matching pursuit）信道估计算法<sup>[11]</sup>和稀疏度自适应匹配追踪（SAMP, sparsity adaptive matching pursuit）信道估计算法<sup>[12]</sup>，均实现了在较低导频开销下的高精度信道估计。

上述方法虽得到了一定的应用，但也存在着一

些局限性。首先，这些方法高度依赖于理想化信道模型假设，如线性时变信道模型，而实际复杂环境变化易导致模型失配问题，进而降低估计精度；其次，这些方法通常需要将信道统计特性作为先验信息，如OMP算法需要已知信道多径数目，但动态场景中这些信道统计参数通常难以实时获取。一旦信道发生动态变化，将可能出现信道跟踪滞后问题，导致系统误码率上升。

近年来，在高速移动场景下的OTFS信道估计算法中，基于深度学习的算法展现出了更优的性能。这类算法不受某种特定的信道模型约束，在应用于不同的信道环境时，无须对算法本身进行复杂的数学重构或调整，仅需重新训练网络模型即可适应新的信道特性。这降低了算法对特定数学表达形式或先验统计信息的依赖，极大地拓宽了信道估计算法的应用范围<sup>[13-19]</sup>。文献[20]利用一个简单的卷积网络对接收信号进行去噪，提升了OTFS信道估计性能。进一步，文献[21]首先利用压缩感知算法对稀疏信道矩阵进行重构，随后借助残差网络（ResNet）实现从粗估计值到理想估计值的非线性映射。ResNet中的残差结构有效抑制了网络过拟合现象。为进一步降低参数量和运算量，文献[22]引入分组卷积，在增加网络深度的同时削减网络参数量，提高了算法的运行效率。文献[23]则将自注意力机制的代表Transformer结构运用到OTFS信道估计中，构建了一个调制-解调结构。与已有的卷积网络结构相比，Transformer结构获得了明显的性能提升。然而，Transformer结构沿用了更适用于序列处理的全连接结构，但存在参数量过大和运行速度慢的问题。为解决分数多普勒系统下路径难以识别的问题，文献[24]设计了一种能够直接提取信道参数的神经网络，有效改善了分数多普勒系统的通信质量。然而，该方法适用场景较为单一，难以应用到传播路径数目较多的通信场景中。

对上述基于深度学习的OTFS信道估计算法的总结可发现，现有方法所采用的网络结构普遍参数量较大，难以满足移动终端对模型轻量化的需

求。尤其值得注意的是，这些基于深度学习的信道估计算法在执行阶段不仅需要高精度的数值运算，还需要处理大量实时数据，因此对计算资源的需求极高。然而，现实中手机、笔记本电脑等移动设备的内置处理器和内存等硬件资源相对有限。在面对高速移动场景下复杂的OTFS信道估计任务时，现有基于深度学习的算法容易出现运行时间过长、设备过载甚至过热等问题，不仅影响用户体验，还可能对硬件设备造成潜在损害。为此，本文以提高计算效率、降低设备功耗为目标，提出一种轻量化的深度学习信道估计算法。本文的主要贡献如下。

1) 设计了一种轻量化并行去噪网络结构，通过将传统串行网络结构重构为多尺度并行模块(MSPB, multi-scale parallel blocks)，实现了跨时延-多普勒维度的特征融合。

2) 提出了一种面向轻量化并行去噪网络的OTFS信道估计算法。该算法结合图像去噪和数据驱动的思想，在保持深度学习算法强大泛化能力的同时，通过降低导频功率减少移动端资源开销，为

高速移动场景下的OTFS轻量化信道估计提供了新的解决方案。

3) 仿真比较了所提基于轻量化并行去噪网络的信道估计算法与传统基于卷积神经网络结构的信道估计、基于阈值的信道估计和基于OMP的信道估计算法。凭借独特的并行结构设计，所提轻量并行去噪网络弥补了轻量化设计带来的估计性能损失，其网络参数规模仅为现有基于图像去噪的卷积神经网络(DnCNN, denoising convolutional neural network)的15%，大幅降低了运算复杂度。与其他信道估计算法相比，所提轻量并行去噪网络的信道估计算法借助其强大的特征学习和对复杂信道特性的理解，展现出更优的估计性能和泛化能力。

### 1 系统模型

OTFS数据帧结构如图1所示。在OTFS系统中，发送端将比特流调制为DD域符号，使其排布在帧结构的特定位置上。DD域符号经过逆辛有限傅里叶变换(ISFFT, inverse symplectic finite fourier

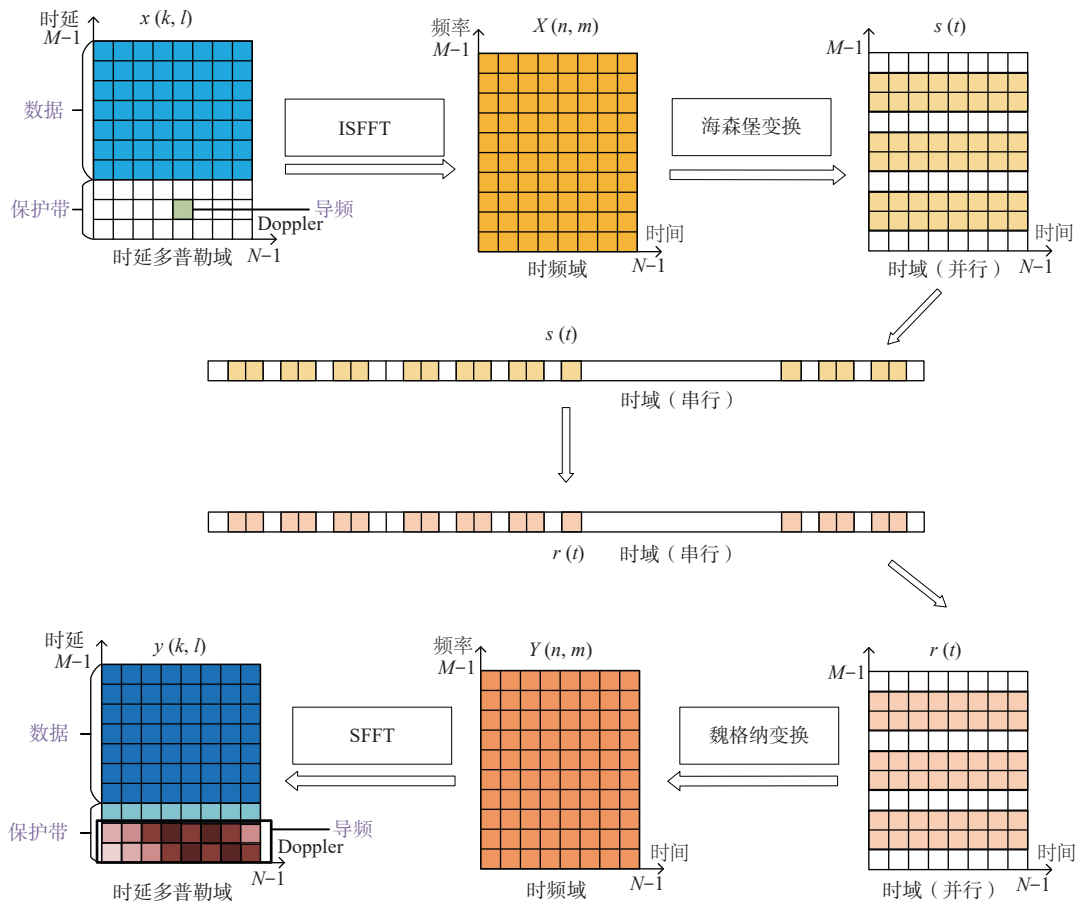


图1 OTFS数据帧结构

transform) 转变为时频域符号, 再经过海森堡变换得到并行的时域信号, 将并行时域符号进行串并转换后得到发送信号。接收端对接收到的串行时域信号进行串并转换、采样和魏格纳变换, 最后经过有限傅里叶变换 (SFFT, symplectic finite fourier transform) 得到 DD 域接收符号。

OTFS 信号将时频域上的  $N \times M$  个采样单元映射到 DD 域, DD 域上每个单元的分辨率为  $\tau_0 \times \nu_0$ , 其中  $\tau_0 = 1/B$ ,  $\nu_0 = 1/T_r$ 。  $T_r = NT$  为 OTFS 的帧持续时间,  $B = M\Delta f$  为 OTFS 数据帧的频带宽度,  $\Delta f$  为子载波间隔,  $T$  为 OTFS 符号持续时间。

在 OTFS 系统中, 信道估计和信号检测是影响其性能的关键模块。在信道估计部分, 先利用基于阈值的传统信道估计算法获取初始的信道估计参数, 即信道的粗估计值<sup>[5]</sup>。

OTFS 信号的调制过程如下: 首先, 发送端将比特流映射为数据符号, 并将符号排布在图 1 中 DD 域信号  $x(k, l)$  的数据区域。此外, 空白保护区位于帧结构的底端, 用于隔离数据对导频符号的干扰和信道估计。发送符号  $x(k, l)$  取值为:

$$x(k, l) = \begin{cases} x_{\text{pilot}}, & k = k_{\text{pilot}}, l = l_{\text{pilot}} \\ x_{\text{data}}, & k = k_{\text{data}}, l = l_{\text{data}} \\ 0, & \text{其他} \end{cases} \quad (1)$$

其中,  $x_{\text{pilot}}$  和  $x_{\text{data}}$  分别代表导频符号和数据符号,  $k_{\text{pilot}}$  和  $l_{\text{pilot}}$  表示导频点位置对应的坐标参数,  $k_{\text{data}}$  和  $l_{\text{data}}$  表示数据点位置对应的坐标参数。如图 1 所示, 导频符号在时延域上的两侧均设置了保护间隔。导频与数据之间的保护间隔能够防止导频与受到时延影响的数据符号混叠。

发送符号  $x(k, l)$  经过 ISFFT 得到时频域发送符号  $X(n, m)$ , 其中, ISFFT 的定义为:

$$X(n, m) = \frac{1}{\sqrt{NM}} \sum_{k=0}^{N-1} \sum_{l=0}^{M-1} x(k, l) e^{j2\pi(\frac{nk}{N} - \frac{ml}{M})} \quad (2)$$

将  $X(n, m)$  进行海森堡变换, 得到并行的时域信号, 其中  $g_{\text{tx}}$  为信号发送脉冲波形:

$$s(t) = \sum_{m=0}^{N-1} \sum_{n=0}^{M-1} X(n, m) e^{j2\pi m \Delta f (t - nT)} g_{\text{tx}}(t - nT) \quad (3)$$

随后对  $s(t)$  进行串并转换, 生成发送信号。信号在传输过程中经历了多条路径的绕射、反射与折射, 形成了相位、幅度各有差异的多个信号分量。在传输过程中, 信号还叠加了复高斯白噪声。综合以上过程, 可以将时域接收信号表示为:

$$r(t) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} h(\tau, \nu) s(t - \tau) e^{j2\pi\nu(t - \tau)} d\tau d\nu + w(t) \quad (4)$$

其中,  $w(t)$  为传输过程中叠加的复高斯白噪声。假设信道有  $P$  条路径, 第  $i$  条路径对应的信道衰落增益、延迟和多普勒频移分别为  $h_i$ 、 $\tau_i$  和  $\nu_i$ , 则理想状态下的 DD 域信道冲激响应可以表示为:

$$h(\tau, \nu) = \sum_{i=0}^{P-1} h_i \delta(\tau - \tau_i) \delta(\nu - \nu_i) \quad (5)$$

在接收端对信号进行解调, 将串行接收信号转换为并行时域信号  $r(t)$ , 随后经过采样与魏格纳变换, 得到时频域接收符号:

$$Y(n, m) = \int g_{\text{rx}}^*(t' - t) r(t') e^{-j2\pi f(t' - t)} dt' \Big|_{t = nT, f = m\Delta f} \quad (6)$$

其中,  $g_{\text{rx}}$  为接收脉冲波形。通过 SFFT 将时频域接收符号转换到 DD 域上, 得到 DD 域接收符号:

$$y(k, l) = \frac{1}{\sqrt{NM}} \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} Y(n, m) e^{-j2\pi(\frac{nk}{N} - \frac{ml}{M})} \quad (7)$$

接收端截取  $y(k, l)$  的第  $k_{\text{pilot}}$  行到第  $M-1$  行符号用于信道估计, 该区域内的接收符号可以表示为:

$$y(k, l) = b(k - k_i, l - l_i) \hat{h}(k - k_i, l - l_i) x_i + w(k, l) \quad (8)$$

其中,  $b(k - k_i, l - l_i)$  表示该符号对应的位置存在一条时延参数为  $l_i \tau_i$ , 多普勒参数为  $k_i \nu_i$  的传输路径。若  $b(k - k_i, l - l_i)$  值为 0, 则表明该路径不存在, 接收采样点  $y(k, l)$  仅包含复高斯白噪声。

为了更好地区分仅包含噪声的采样点与路径对应的采样点, 使用一个阈值对保护带中的数据进行筛选, 一般取门限  $\zeta = 3\sigma$ , 其中  $\sigma$  为噪声的标准差。如果保护带内接收符号的幅值达到了复高斯白噪声标准差的 3 倍及以上, 那么可以认定该符号为延展后的导频, 而非复高斯白噪声或其他干扰。若接收信号的幅值  $|y(k, l)| > \zeta$ , 则认为存在该采样点对应多普勒时延参数的路径, 该点对应的  $b(k, l)$  值为 1; 反之则认为不存在对应的路径,  $b(k, l) = 0$ , 此时的  $|y(k, l)|$  仅包含复高斯白噪声幅值。根据筛选出的采样点数量、位置和幅度, 可以得到多径数目及各条路径分别对应的时延  $\tau_i$ 、多普勒频移  $\nu_i$  和信道衰落增益  $h_i$ , 进而构建出完整的 DD 域信道矩阵。

该算法运算简单、易于实现, 但如文献[20-22]所述, 上述基于阈值的 OTFS 信道估计算法在复杂通信场景下, 接收端难以辨别真正的传输路径, 容易引发虚警, 造成参数的估计错误。同时, 该算法

未对信号传输中引入的噪声分量进行滤除，降低了信道估计精度。

为了实现OTFS信道的快速估计，有研究提出了基于深度学习的信道估计方案，然而这些方案普遍网络结构庞大、计算复杂度高。例如，文献[20, 24-25]中提出的卷积神经网络（CNN, convolutional neural network）结构，文献[21]采用的ResNet结构。通过对比可以发现，即便是结构相对简洁的ResNet，其参数量也超过了50 000个，给资源受限的移动设备带来了巨大的计算负担和存储压力。

因此，如何在大幅度损失算法性能的同时，有效缩减网络规模，成了当前亟待解决的问题。为解决这一问题，需要算法在网络架构上进行创新，探索更为紧凑、高效的模型结构。为此，本文提出一种适用于移动终端的轻量并行去噪网络的OTFS信道估计算法。该算法在降低信道估计导频功耗的同时，最大程度地压缩深度学习网络的规模，为未来低功耗、轻量化智能通信技术的实现开辟了新思路。

## 2 基于轻量并行去噪网络的OTFS信道估计方法

### 2.1 现有去噪网络结构

文献[24-25]基于图像去噪思维，将OTFS信道估计问题转化为一个图像去噪问题。其主要是将前述基于阈值的信道估计结果作为初始估计输入，进而借助DnCNN学习噪声数据和干净数据之间的映射关系，实现对噪声图像的提取。DnCNN能够处理具有未知噪声水平的高斯去噪问题，并且可以扩展到其他一般的图像去噪任务的处理中，如单图像超分辨率和JPEG图像去块等<sup>[26-29]</sup>。

原始DnCNN网络结构如图2所示。其参数设置为：首个卷积层作为特征提取模块，设置为 $3 \times 3 \times 64$ ；SerialBlock中的卷积层设置为 $3 \times 3 \times 32$ ；最后的重构模块将卷积核尺寸设置为 $3 \times 3 \times 2^{[24]}$ 。

然而，由文献[24-25]可知，原始DnCNN并非直接输出抑制干扰后的信道矩阵，而是输出噪声观测和潜在干净图像之间的差异。由于高斯白噪声在任意两个不同时刻上的随机变量之间统计独立，意味着在这种噪声的处理过程中，一个采样点的值不会影响其他采样点的值，使得高斯白噪声在信号处理中表现出独特的统计特性，这也在一定程度上限

制了信道估计性能。并且，原始DnCNN网络为了追求高性能，采用了大量的特征图，导致网络规模庞大，对算力资源和存储空间均提出了较高的要求。

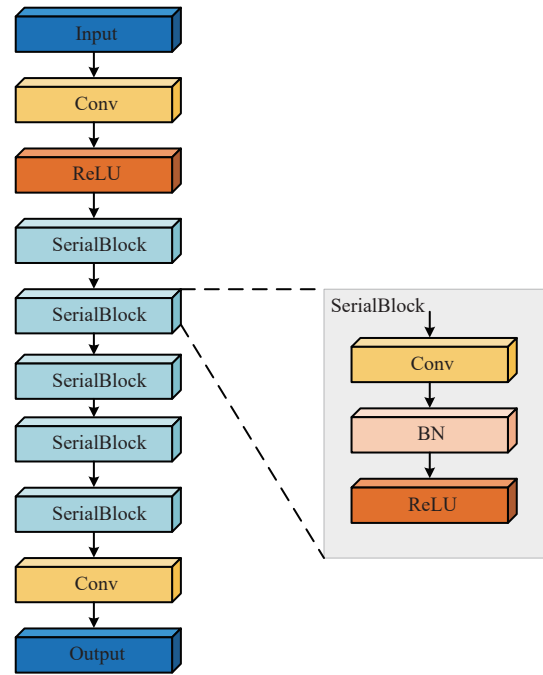


图2 原始DnCNN网络结构

本文同样将基于阈值的信道估计结果作为粗略估计值，结合DD域信道响应特征，对原始的DnCNN结构进行针对性的调整与优化，旨在使网络结构更加契合DD域信道的复杂特性，从而对信道矩阵进行精准地拟合。

### 2.2 轻量并行去噪网络结构设计

本文结合OTFS信号体制特点，对现有去噪网络结构进行了精简优化，设计了一个轻量化去噪网络SimpDnCNN。该网络主要从以下三个方面实现轻量化设计。

1) 减少特征图数量：将首个特征提取卷积层的特征图数量从原先的64缩减至16，后续卷积层特征图数量由32减少至8。这一调整显著降低了网络参数总量和计算复杂度，有效减少了模型的内存占用和运行时的资源消耗，为算法在移动便携设备上的部署和应用提供了可能。

2) 引入残差连接：将网络输出从残差图像改为原始图像，并将特征提取层的输出图像与重构层的输入图像相加，构成深层残差连接结构。残差结构有助于网络更好地构建信道矩阵估计值与真实值之

间的映射，使 **SimpDnCNN** 能够通过网络层参数的细微调整让输出图像最大限度地接近信道矩阵真实值<sup>[21]</sup>。同时，由于残差连接的存在，**SimpDnCNN** 在训练过程中更容易找到最优解，这也有助于降低训练难度，提高模型的泛化能力。

3) 采用多尺度卷积核：**OTFS** 体制通常遭遇多普勒串扰，即采样单元之间的一种相互串扰。与高斯白噪声在各采样单元上表现出的独立性不同，各采样单元之间的相关性使得多普勒串扰难以进行数学表征。传统的、相对单一化的网络结构往往难以对其进行准确且有效的表征。鉴于这一问题，本文在原有 **DnCNN** 结构基础上引入多尺度卷积层，以捕捉多普勒串扰的时空相关性，适应其复杂模式<sup>[9]</sup>。多尺度卷积核的核心思想是通过不同大小的卷积核捕捉不同尺度的特征。在多普勒串扰问题中，串扰信号通常包含多个频率成分，且不同频率成分的分布可能具有不同的空间尺度。具体而言，采用  $1 \times 1$ 、 $3 \times 3$  和  $5 \times 5$  三种不同尺寸卷积核的混合配置。其中， $1 \times 1$  卷积核主要用于通道间的信息融合和降维，虽然不直接捕捉空间特征，但可以通过调整通道权重来增强对特定频率成分响应； $3 \times 3$  卷积核适合捕捉局部空间特征，对于多普勒串扰中高频成分（如快速变化的相位或频率）具有较高敏感性； $5 \times 5$  卷积核则能够提取更大范围的空间特征，适合处理低频成分（如缓慢变化的相位或频率）或更广泛的串扰模式。综上，应用不同尺度的卷积核可以分别捕捉多普勒串扰信号中的高频和低频成分，从而实现更全面的特征提取，并提高对多普勒串扰的建模能力。

具体而言，改进后的 **SimpDnCNN** 摒弃了传统 **DnCNN** 中  $3 \times 3$  卷积核单一尺寸的配置，转而采用了一种包含  $1 \times 1$ 、 $3 \times 3$  和  $5 \times 5$  3 种不同尺寸卷积核的混合配置。这种多尺度的卷积核配置帮助网络有效捕捉从局部细微特征到全局宽泛特征的多层次信息，使网络的数学模型与实际的物理干扰模型更为贴近，显著提升了网络对复杂干扰模式的拟合能力。

此外，如图 2 所示，**DnCNN** 采用的是一种串行结构设计，其在卷积层数量的设置上存在着一系列问题。当卷积层数量设置较少时，网络结构过于浅显，模型对复杂数据的拟合能力不足；反之，若为了增强拟合能力盲目增加卷积层的数量，则会引

入过拟合的风险。同时，在反向传播过程中更容易出现梯度爆炸。这两种情况均会影响网络的稳定性和性能表现。

针对这一难题，本文在前述轻量化设计的 **SimpDnCNN** 基础上，将原有的串行网络结构重构为 **MSPB**，进而设计了一种全新的信道估计网络 **SimpParaDnCNN**。在卷积核参数的设置上，该方法缩减了网络深度，由原先的  $2n$  个串行模块缩减为  $n$  个并行模块。**SimpParaDnCNN** 结构如图 3 所示。




图 3 SimParaDnCNN 结构

在 **SimpParaDnCNN** 结构中，网络不再单一地依赖增加卷积层的深度来增强特征提取能力，而是将相同卷积层串联的工作模式转变为不同卷积层并联的工作模式。并行模式允许网络同时捕捉并处理不同尺度的特征信息，并通过通道拼接操作，对两个并行卷积层输出的多维特征进行有效整合，保留了更为丰富和全面的特征表示。最后，通道拼接后的结果送入到批标准化（**BN**, batch normalization）层进行归一化处理。这样的结构，不仅有助于加速网络收敛速度，还能进一步稳定训练过程，缓解因数据分布偏移导致的训练不稳定问题。通过一系列的结构优化，本文所提的并行网络架构能够在显著削减网络深度的同时保持良好的拟合效果，有效避免了梯度爆炸和过拟合现象的发生，极大地降低了网络训练的难度。

从网络规模的角度来看，相较于现有研究中所采用的神经网络模型，**SimpParaDnCNN** 大幅减少

了网络参数量。SimpParaDnCNN的设计并非简单的参数削减，而是基于对预测目标的深刻理解。正如后续仿真结果所示，尽管网络规模有所缩减，但SimpParaDnCNN并未在性能上做出过多的妥协。相反，它凭借独特的网络结构和高效的特征提取机制，展现出了强大的特征学习能力。这种能力使得SimpParaDnCNN能够在高速移动场景下有效地捕捉并解析信道的关键特征，为后续的信道估计提供准确的信息基础。

CNN、DnCNN、ResNet和SimpParaDnCNN网络参数规模对比见表1。由表1数据可知，本文所提并行去噪网络结构在参数规模上实现了显著的缩减，其参数量仅为现有DnCNN结构的15%，体现出SimpParaDnCNN并行多尺度卷积架构的精简程度。

表1 网络参数规模对比

网络	参数量
CNN <sup>[20]</sup>	65 900
DnCNN <sup>[24-25]</sup>	94 900
ResNet <sup>[21,27]</sup>	56 600
SimpParaDnCNN	14 400

下面对信道矩阵在网络中的拟合过程进行了计算复杂度分析<sup>[30]</sup>。相同的网络输入经过SimpParaDnCNN需要共计1 828 716 544次浮点运算，经过CNN<sup>[20]</sup>需要共计2 986 344 448次浮点运算，经过DnCNN<sup>[24-25]</sup>需要共计5 888 802 816次浮点运算，ResNet<sup>[21,27]</sup>需要共计14 797 504 512次浮点运算。对比可知，SimpParaDnCNN能够显著降低信道矩阵在网络内的运算复杂度，为移动端节省可观的算力成本。

### 2.3 本文算法

本文所提OTFS信道估计算法主要为线下训练与线上估计相结合的模式。值得一提的是，为进一步降低功耗，本文所提算法对导频功率进行了优化设计。具体而言，本文参考了文献[24]中的两种导频功率与数据符号功率比值设置（导频功率与数据符号功率之比分别为14 dB和23 dB，即导频功率相比数据符号功率分别高14 dB和23 dB）。在离线阶段和在线阶段分别设置了不同的导频功率。离线训练过程中，为了充分提取信道的特征并构建准确的模型，采用了23 dB的高功率导频符号，确保了模型能够学习到信道特性，为后续的在线估计打下

基础。在线估计过程中，考虑到移动设备有限的电量储备，为了减小功耗、延长设备的使用时间，所提算法降低了导频符号的功率，参考文献[24]的对照方案，采用了14 dB的低功率导频进行信道估计。虽然牺牲了部分估计精度，但通过前述网络结构设计，本文所提信道估计算法能够弥补这部分损失，且仍然保持了较高的信道估计精度。

算法步骤如算法1所示。

**算法1** 基于轻量并行去噪网络的OTFS信道估计算法

#### 离线训练阶段：

1) 在多径信道场景下生成训练数据，将基于高功率导频阈值估计算法的结果作为训练输入，理想的DD域信道响应估计矩阵作为输出，并将所有数据划分为训练集和验证集2部分；

2) 对所提的轻量并行去噪网络进行训练，得到训练好的网络模型。

#### 在线估计阶段：

1) 用基于低功率导频的阈值估计法进行初步估计，比较保护带内接收符号的幅度 $|y(k, l)|$ 与阈值 $\varsigma = 3\sigma$ 的大小。幅度超过阈值则认定该位置存在路径，记录路径存在位置对应的坐标 $k_i$ 和 $l_i$ ；

2) 计算各路径对应的多普勒频移 $v_i$ 、时延 $\tau_i$ 和信道衰落增益 $h_i$ ，重构DD域信道矩阵 $\hat{H}_{DD}$ ；

3) 将2)中得到的估计结果 $\hat{H}_{DD}$ 作为网络输入，对粗估计矩阵进行去噪，网络输出 $\hat{H}_{DD}$ 作为信道估计的结果；

4) 用拟合后的信道矩阵 $\hat{H}_{DD}$ 对接收信号进行信号检测，重构发送信号 $\hat{x}(k, l)$ 。

## 3 仿真测试

### 3.1 仿真参数设置

本文在配备了第三代英特尔至强双路可扩展处理器、NVIDIA GTX3090 GPU的服务器上利用MATLAB2024a对所提网络进行了训练。

仿真实验的具体参数设置见表2。其中详尽列出了本次仿真所采用的参数，包括时延域采样点数、多普勒域采样点数、载波频率、子载波间隔以及导频功率与数据符号功率之比等。

在训练数据的获取阶段，本文在信噪比（SNR, signal-to-noise ratio）范围0~20 dB的通信场景下收集了信道矩阵，使模型适用于不同质量的信号接收

场景。为了进一步增强训练数据的多样性，本文在收集训练数据时随机生成了信道参数，确保训练集涵盖了多种可能的信道特性。在此过程中，设定路径数目为5，最大移动速度为500 km/h，以涵盖高速移动场景下的信道变化。

表2 仿真参数

参数名	参数值
时延域采样点数	64
多普勒域采样点数	8
载波频率	3 GHz
子载波间隔	15 kHz
导频功率与数据符号功率之比	14 dB, 23 dB
调制方式	QPSK
蒙特卡洛仿真次数	5 000
最大时延	4 $\mu$ s
最大移动速度	500 km/h
信道模型	瑞利信道
路径数	3, 5, 10
信道衰落增益	-20~0 dB
信噪比	0~20 dB

本文采用五径的衰落信道模型，通过代码仿真生成了5 000组粗估计信道矩阵与对应的真实信道矩阵<sup>[31]</sup>。两组结果分别作为网络训练的输入和输出，既保证了模型的充分训练，又避免了过拟合的风险。在数据集的规划使用上，将整个数据集按照9:1的比例划分为训练集和验证集，确保模型在训练过程中能够得到有效的验证和调优。在训练信道估计网络时，选择 $L_2$ 损失函数作为优化目标。

$$\text{Loss} = L_2 = \frac{1}{M} \sum_{m=1}^M \left\| \mathbf{H}_{\text{DD}} - \hat{\mathbf{H}}_{\text{DD}} \right\|^2 \quad (9)$$

$L_2$ 损失函数能够有效衡量预测值与真实值之间的差异，使网络通过梯度下降算法引导模型参数向最小化该差异的方向迭代，确保训练过程的稳定性和收敛性<sup>[30]</sup>。

### 3.2 仿真结果分析

为了深入揭示低功率导频与高功率导频在信道估计精度上的差异，本文将导频功率与数据符号功率之比为23 dB的传统基于阈值的信道估计算法作为高功率导频的参照，并将其标定为“23 dB”；将导频功率与数据符号功率之比为14 dB的基于阈值的信道估计算法作为低功率导频的参照，标定为“14 dB”。

为了验证SimpParaDnCNN在OTFS信道估计任务中的有效性，本文设计了两组对照算法，作为

消融实验。第一组对照算法采用了文献[24]中的基于原始DnCNN架构的估计算法，该算法在14 dB导频的设定下实施，并被标定为“DnCNN+14dB”；第二组对照算法则采用了SimpDnCNN，同样在14dB导频条件下进行估计，标定为“SDn+14dB”。SimpParaDnCNN在14 dB导频设定下标定为“SPDn+14dB”。上述3种基于深度学习的信道估计方案均是以基于阈值的信道估计结果作为粗估计。同时，为了与传统方法进行比较，本文还仿真了文献[11]所提的基于OMP的信道估计算法在相同的14 dB导频设置，标定为“OMP+14dB”。

五径信道下不同算法的归一化均方误差(NMSE, normalized mean square error)曲线如图4所示。其中信噪比在0~20 dB变化，收发端最大相对移动速度为500 km/h。低信噪比条件下，“14dB”、“DnCNN+14dB”、“SPDn+14dB”和“SDn+14dB”表现出了相近的估计精度趋势，且这几种算法的估计精度均没有23 dB导频的估计精度高。其原因是低信噪比场景下，复高斯白噪声对系统影响较大，而系统难以根据阈值判别接收信号中的低功率导频采样点和仅包含干扰的采样点，使信道估计结果不准确。




图4 五径信道下不同算法的归一化均方误差曲线

由图4可知，在五径信道下，当信噪比达到约1.5 dB后，“OMP+14dB”的信道多径时延扩展导致的维度灾难和多普勒频偏破坏稀疏基的相干性，使其估计误差高于基于阈值的信道估计算法。深度学习网络虽然能提取到部分干扰特征，但在处理粗估计结果较差的信道矩阵时仍表现出了局限性。在信噪比为8 dB的条件下，“DnCNN+14dB”与“SPDn+14dB”均展现出了与“23dB”相近的

估计精度。随着信噪比条件的逐步改善，采用“23dB”进入了误差平台，其估计精度不再随信噪比的增加而提高。相比之下，深度学习算法的估计精度仍然保持着缓慢但稳定的上升趋势，显示出更好的适应性和潜力。尤为值得一提的是，在高信噪比条件下，“SPDn+14dB”相比“DnCNN+14dB”，仍具有近4 dB的性能增益。

三径信道下不同算法的归一化均方误差曲线如图5所示，其中收发端最大相对移动速度为500 km/h。与离线训练中的五径信道相比，三径信道的多普勒串扰相对较小，但干扰形式发生了变化。网络需要准确地拟合干扰的数学表达，才能实现估计精度的提升。从图5可以看出，“OMP+14dB”在信噪比低于5 dB时有着略低于“23dB”的估计精度，随着信噪比的提升，其估计精度逐渐超过了两种基于阈值的信道估计算法（“DnCNN+14dB”与“SPDn+14dB”）。与基于阈值的信道估计算法相比，OMP需要将信道路径数作为先验条件，在实际应用场景中，其实用性较弱。此外，从图5中可见，3种基于深度学习的算法均具有一定的泛化能力，特别是“SPDn+14dB”与“DnCNN+14dB”实现了较高的估计精度。相比其他算法，“SPDn+14dB”仍具有更好的信道估计性能，可见其并行处理架构的特征提取优势。




图5 三径信道下不同算法的归一化均方误差曲线

本实验将五径信道下训练的网络应用到十径信道，收发端最大相对移动速度仍设置为500 km/h，以考察所提算法的泛化性能。在十径信道这一复杂传播环境中，信号经历多条路径的反射、散射与折射，导致多个多普勒串扰分量在时延多普勒域叠

加，使得信道响应矩阵更加难以预测。传统的基于阈值的2种信道估计算法在面对复杂的多普勒串扰时，性能受到限制，过早地进入误差平台。相比之下，3种基于深度学习的信道估计算法凭借其强大的特征学习能力和对复杂信道特性的深刻理解，展现出显著的泛化性能。这3种算法随着信噪比的逐渐增大，其估计精度呈现出稳步提升的趋势。十径信道下不同算法的归一化均方误差曲线如图6所示。




图6 十径信道下不同算法的归一化均方误差曲线

综上所述，在多种信道估计算法的对比评估中，“SPDn+14dB”信道估计算法展现出了最优的估计性能。这主要是因为SimpParaDnCNN中的MSPB不仅优化了计算流程，还赋予了网络强大的特征提取能力。通过并行处理不同路径的信号特征，该网络能够更有效地从接收信号中分离出有用的信道信息，同时抑制噪声和干扰成分，在复杂信道场景下实现更高精度的信道估计。

为进一步评估信道估计性能，在信道估计之后对OTFS信号进行数据检测。本文使用文献[32]提出的适用于含有空白保护带帧结构的迭代检测算法。该算法能够较好处理OTFS检测中的干扰问题。五径信道下不同算法的误码率（BER, bit error rate）曲线如图7所示，其中信噪比在0~20 dB，收发端最大相对移动速度为500 km/h。为了量化检测过程对通信系统BER的影响，本文还引入了一条信号检测误码率的参考基准线“Ideal”，其假定已知理想的信道状态信息。从图7可以看出，在信噪比超过8 dB时，“SPDn+14dB”的BER表现最优，“DnCNN+14dB”算法次优，“23dB”略优于“14dB”和“SDn+14dB”。在信噪比达到15 dB以后，检测

算法“Ideal”的BER下降到0点，此时所提算法“SPDn+14dB”仍然表现为性能最优。

为验证所提算法的泛化能力，设置信噪比为 10 dB，收发端最大相对运动速度扩展到 1 000 km/h，不同路径数下不同算法的误码率曲线如图 8 所示。从图 8 中可见，几种信道估计算法的 BER 受复杂环境的影响，整体呈上升趋势。由于“Ideal”的检测结果是由后验概率推理得到，其误码率几乎不受路径数变化的影响。




图 7 五径信道下不同算法的误码率曲线




图 8 不同路径数下不同算法的误码率曲线

从其他 5 种信道估计算法对应的 BER 曲线可以看出，“SDn+14dB”对应的 SimpDnCNN 算法仅优于“14dB”导频的信道估计算法，与“23dB”导频的估计算法相比，其 BER 略高。这一结果表明，“SDn+14dB”能在一定程度上减少复高斯白噪声带来的影响，但受结构和参数量的限制，该网络的拟合能力有限，因此对信道估计精度的提升效果不是太明显。同时，“DnCNN+14dB”和“SPDn+14dB”

对应的原始 DnCNN 网络和本文所提 SimpParaDnCNN 网络辅助的信道估计算法在 BER 上表现较为优秀。这是由于 DnCNN 结构能够构建复杂的映射关系，因此对多普勒串扰和复高斯白噪声的提取能力较强，展现出优于阈值估计算法的估计精度。此外，“SPDn+14dB”的 BER 略低于原始 DnCNN 估计算法。由此可见，所提轻量并行网络 SimpParaDnCNN 引入多变的卷积核尺寸，网络的特征提取能力得到了增强，因此该算法的 BER 较低。

#### 4 结束语

本文聚焦于高速移动场景下的 OTFS 信道估计问题，由于该场景下信号传输的复杂性和移动设备的资源限制，因此设计轻量化的 OTFS 信道估计算法成为关键。现有基于深度学习的 OTFS 信道估计算法网络规模普遍过大，导频功率过高，对移动终端的硬件提出了较高的要求。为此，本文提出了一种基于轻量并行去噪网络的 OTFS 信道估计算法 SimpParaDnCNN，旨在实现复杂通信场景下信道估计算法的轻量化设计。所提算法将原始卷积神经网络的单一化卷积核尺寸配置重构为多尺度卷积核的混合配置，从而提升网络的拟合能力，且参数量仅为现有卷积神经网络结构的 15%，大幅降低了网络参数规模。该算法在降低了移动端算力成本的同时，保持了较高的信道估计精度。未来工作将进一步探索该算法在实际通信系统中的应用和性能优化。

#### 参考文献:


- [1] BOHLIN E, CAPPELLETTI F. Editorial: policy for 5G and 6G[J]. Telecommunications Policy, 2024, 48(2): 102721.
- [2] 邢旺, 唐晓刚, 周一青, 等. 面向 OTFS 的时延-多普勒域信道估计方法综述[J]. 通信学报, 2022, 43(12): 188-201.  
XING W, TANG X G, ZHOU Y Q, et al. Survey of channel estimation method in delay-Doppler domain for OTFS[J]. Journal on Communications, 2022, 43(12): 188-201.
- [3] 钱志鸿, 肖琳, 王雪. 面向未来移动网络密集连接的关键技术综述[J]. 通信学报, 2021, 42(4): 22-43.  
QIAN Z H, XIAO L, WANG X. Review on strategic technology of dense connection for the future mobile network[J]. Journal on Communications, 2021, 42(4): 22-43.
- [4] HU J C, BAI Z Q, YANG J K, et al. DNN and LS based channel estimation in OTFS system[C]//Proceedings of the 2023 IEEE 23rd International Conference on Communication Technology

- (ICCT). Piscataway: IEEE Press, 2024: 106-110.
- [5] RAVITEJA P, PHAN K T, HONG Y. Embedded pilot-aided channel estimation for OTFS in delay-Doppler channels[J]. IEEE Transactions on Vehicular Technology, 2019, 68(5): 4906-4917.
- [6] ZHAO H, KANG Z Q, WANG H. A novel channel estimation scheme for OTFS[C]//Proceedings of the 2020 IEEE 20th International Conference on Communication Technology (ICCT). Piscataway: IEEE Press, 2020: 12-16.
- [7] YUAN W J, LI S Y, WEI Z Q, et al. Data-aided channel estimation for OTFS systems with a superimposed pilot and data transmission scheme[J]. IEEE Wireless Communications Letters, 2021, 10(9): 1954-1958.
- [8] MISHRA H B, SINGH P, PRASAD A K, et al. OTFS channel estimation and data detection designs with superimposed pilots[J]. IEEE Transactions on Wireless Communications, 2022, 21(4): 2258-2274.
- [9] 蒲旭敏, 邓凯元, 陈前斌. 超大规模MIMO-OTFS系统上行辅助的下行信道估计方法[J]. 物联网学报, 2023, 7(4): 28-38.  
PU X M, DENG K Y, CHEN Q B. Uplink assisted downlink channel estimation method of extra-large scale MIMO-OTFS system[J]. Chinese Journal on Internet of Things, 2023, 7(4): 28-38.
- [10] 李一兵, 汤云鹤, 简鑫, 等. 面对高速移动场景的OTFS系统导频设计方法[J]. 电子与信息学报, 2025, 47(2): 490-497.  
LI Y B, TANG Y H, JIAN X, et al. Pilot design method for OTFS system in high-speed mobile scenarios[J]. Journal of Electronics & Information Technology, 2025, 47(2): 490-497.
- [11] SHEN W Q, DAI L L, AN J P, et al. Channel estimation for orthogonal time frequency space (OTFS) massive MIMO[J]. IEEE Transactions on Signal Processing, 2019, 67(16): 4204-4217.
- [12] LI X F, SHAN C Z, MA Y K, et al. A variable step-size backtracking SAMP channel estimation method for OTFS system[C]//Proceedings of the GLOBECOM 2023 - 2023 IEEE Global Communications Conference. Piscataway: IEEE Press, 2024: 2838-2842.
- [13] PENG Q, LI J B, SHI H. Deep learning based channel estimation for OFDM systems with doubly selective channel[J]. IEEE Communications Letters, 2022, 26(9): 2067-2071.
- [14] SIRIWANITPONG A, BOONSRI MUANG P, MORI K, et al. A deep learning-based channel estimation for high-speed train environments[C]//Proceedings of the 2022 19th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON). Piscataway: IEEE Press, 2022: 1-4.
- [15] GIZZINI A K, CHAFII M. RNN based channel estimation in doubly selective environments[J]. IEEE Transactions on Machine Learning in Communications and Networking, 2024, 2: 1-18.
- [16] 杨丽花, 聂倩, 呼博, 等. 联合BP神经网络与基扩展模型的信道预测算法[J]. 北京邮电大学学报, 2023, 46(3): 13-18.  
YANG L H, NIE Q, HU B, et al. Channel prediction method joint BP neural network with basis expansion model[J]. Journal of Beijing University of Posts and Telecommunications, 2023, 46(3): 13-18.
- [17] LUAN D X, THOMPSON J S. Channelformer: attention based neural solution for wireless channel estimation and effective online training[J]. IEEE Transactions on Wireless Communications, 2023, 22(10): 6562-6577.
- [18] 梅锴, 赵海涛, 刘潇然, 等. 高效的基于数据与模型的信道估计算法[J]. 通信学报, 2022, 43(1): 59-70.  
MEI K, ZHAO H T, LIU X R, et al. Efficient model-and-data based channel estimation algorithm[J]. Journal on Communications, 2022, 43(1): 59-70.
- [19] BAI X D, PENG Q. An online deep learning based channel estimation method for mmWave massive MIMO systems[C]//Proceedings of the 2023 IEEE 97th Vehicular Technology Conference (VTC2023-Spring). Piscataway: IEEE Press, 2023: 1-5.
- [20] ZHANG X Q, HUANG H J, TAN L, et al. Enhanced channel estimation for OTFS-assisted ISAC in vehicular networks: a deep learning approach[C]//Proceedings of the 2023 21st International Symposium on Modeling and Optimization in Mobile, Ad Hoc, and Wireless Networks (WiOpt). Piscataway: IEEE Press, 2023: 703-707.
- [21] GONG Y, LI Q Y, MENG F K, et al. Data-driven deep learning for OTFS detection[J]. China Communications, 2023, 20(1): 88-101.
- [22] WANG B, YUAN Z, ZHENG S L, et al. Data-driven intelligent receiver for OTFS communication in Internet of vehicles[J]. IEEE Transactions on Vehicular Technology, 2024, 73(5): 6968-6979.
- [23] SUN T, LV J B, ZHOU T. A transformer-based channel estimation method for OTFS systems[J]. Entropy, 2023, 25(10): 1423.
- [24] GUO L, GU P, ZOU J, et al. DNN-based fractional Doppler channel estimation for OTFS modulation[J]. IEEE Transactions on Vehicular Technology, 2023, 72(11): 15062-15067.
- [25] ZHANG K, ZUO W M, CHEN Y J, et al. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142-3155.
- [26] ZHANG K, ZUO W M, ZHANG L. FFDNet: toward a fast and flexible solution for CNN-based image denoising[J]. IEEE Transactions on Image Processing, 2018, 27(9): 4608-4622.
- [27] YANG J S, FANG Y, DAI L, et al. Residual network-based channel estimation for the protograph LDPC-coded OFDM systems[J]. IEEE Communications Letters, 2023, 27(10): 2568-2572.
- [28] ZHANG Y L, LI K P, LI K, et al. Image super-resolution using very deep residual channel attention networks[C]//Computer Vision - ECCV 2018. Cham: Springer, 2018: 294-310.
- [29] ANWAR S, BARNES N. Real image denoising with feature attention[C]//Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE Press, 2020: 3155-3164.
- [30] SUTANTO A R, KANG D K. A novel diminish smooth L1 loss model with generative adversarial network[C]//Intelligent Human Computer Interaction. Cham: Springer, 2021: 361-368.
- [31] RAVITEJA P, PHAN K T, JIN Q Y, et al. Low-complexity iterative detection for orthogonal time frequency space modulation[C]//Proceedings of the 2018 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2018: 1-6.

[作者简介]




熊俊(1987-), 男, 国防科技大学电子科学学院副教授、硕士生导师, 主要研究方向为协同通信、无人集群通信和智能无线通信。



张晖(1982-), 男, 南京邮电大学教授、博士生导师, 主要研究方向为未来网络与资源分配、边缘智能、智能终端与人工智能。



韩雪晴(2000-), 女, 国防科技大学电子科学学院硕士生, 主要研究方向为信道估计和信道均衡。



赵海涛(1981-), 男, 博士, 国防科技大学电子科学学院教授、博士生导师, 主要研究方向为认知无线网络、自组织网络、协同通信。



刘潇然(1992-), 男, 博士, 国防科技大学电子科学学院讲师, 主要研究方向为无线通信信号处理、多载波波形设计和智能通信技术。



魏急波(1967-), 男, 国防科技大学电子科学学院教授、博士生导师, 主要研究方向为软件无线电、认知无线电、智能无线通信。