适用于 OTFS 调制系统的基于未训练神经网络的贝叶斯检测器

Hao Chang*、Alva Kosasih*、Wibowo Hardjawana*、Xinwei Qu* 和 Branka Vucetic*
*悉尼大学物联网与电信卓越中心，澳大利亚悉尼。
{hao.chang,alva.kosasih,wibowo.hardjawana,xinwei.qu,branka.vucetic}@sydney.edu.au

arXiv:2305.04414v1 [eess.SP] 8 May 2023

摘要——近年来，面向高移动性通信场景的正交时频空间（OTFS）符号检测器设计受到广泛关注。目前最先进的 OTFS 检测器主要分为两类：迭代检测器和基于训练的深度神经网络（DNN）检测器。许多实用的迭代检测器依赖最小均方误差（MMSE）去噪器来获得初始符号估计。然而，其计算复杂度会随检测符号数量的增加而呈指数级增长。基于训练的 DNN 检测器通常依赖大量计算资源以及训练阶段合成数据集的保真度，而这两者的代价都很高。本文提出一种基于深度图像先验（DIP）和解码器架构的未训练 DNN，称为 D-DIP，用以替代迭代检测器中的 MMSE去噪器。DIP 是一种无需训练的 DNN，这一特性使其适用于 OTFS检测器设计。随后，我们提出将 D-DIP 去噪器与贝叶斯并行干扰消除（BPIC）检测器结合，以执行迭代符号检测，并将其称为 D-DIP-BPIC。仿真结果表明，所提出的 D-DIP-BPIC检测器的符号错误率（SER）性能比实用的最先进检测器高出 0.5 dB，同时保持较低的计算复杂度。

索引词——OTFS、符号检测、深度图像先验、贝叶斯并行干扰消除、移动蜂窝网络。

I. 引言

未来的移动通信系统将支持各种高移动性场景（例如无人驾驶飞行器和自动驾驶汽车），并满足严格的移动性要求 [1]。然而，由于大量高速移动反射体会造成严重的载波间干扰（ICI），当前的正交频分复用（OFDM） [2] 并不适用于这些场景。提出正交时频空间（OTFS）调制 [1]，正是为了解决这一问题，因为它能够在符号估计过程中跟踪ICI。目前的文献中已研究了多种OTFS符号检测器 [3]–[10]。

已提出多种适用于 OTFS 系统的迭代检测器，例如消息传递（MP） [3], 近似消息传递（AMP） [4], 采用最小均方误差（MMSE）去噪器的贝叶斯并行干扰抵消（BPIC） [5], 酉近似消息传递（UAMP）[6], 以及期望传播（EP） [7] 检测器。与传统 MMSE 检测器相比，这些检测器显著提升了符号错误率（SER）性能[8]。遗憾的是，当移动反射体数量较多时 MP 和 AMP 会因载波间干扰（ICI）较强而导致性能下降 [5]。UAMP 检测器在执行 AMP 之前，通过利用 OTFS 信道的结构进行奇异值分解（SVD），从而解决这一问题。我们提出的迭代 MMSE-BPIC 检测器 [5]在可靠性和复杂度方面也达到了与 UAMP 检测器相近的性能。我们结合 MMSE 去噪器、贝叶斯概念和并行干扰抵消（PIC），执行迭代符号检测。遗憾的是，与 EP OTFS 检测器相比，其性能仍然欠佳 [7]。EP 利用贝叶斯概念和多元高斯分布，根据观测到的接收信号，迭代估计后验检测符号的均值和方差。EP 检测器的优越性能是以执行迭代矩阵求逆运算所需的高计算复杂度为代价的。

除了这些迭代检测器，基于深度神经网络（DNN）的方法也广泛应用于符号检测器设计。这些方法可分为两类：1）基于训练的DNN；2）未训练DNN。基于训练的 DNN需要使用大型数据集训练符号检测器，然后才能进行部署。近年来，基于训练的DNN方法包括文献 [9] 中基于二维卷积神经网络（CNN）的OTFS检测器，以及我们最近提出的BPICNet OTFS检测器 [10] ；后者整合了 MMSE去噪器、BPIC和DNN，并利用DNN训练经过修改的BPIC参数。基于训练的DNN方法有两项主要缺点：1）依赖充足的计算资源，导致训练阶段 [11]需要消耗大量能源或产生大量二氧化碳排放，且成本高昂；2）由于获取真实数据集 [12]的成本高昂，在真实环境中使用人工生成的合成训练数据，其保真度难以保证。例如，高保真度的训练数据集意味着必须预先知道移动反射体所有可能速度对应的分布函数，而这是不可能做到的。

第二类未训练DNN无需训练数据集。文献 [13]提出的深度图像先验（DIP）作为一种未训练DNN方法，已广泛应用于图像复原。原始DIP采用的编码器-解码器架构在图像复原任务中表现出色，但其可训练参数多达数百万，导致时延较高，因此仍无法用于要求接近实时处理的 OTFS检测器

时间。近期，文献 [14] 的作者表明，在应用于磁共振成像（MRI）时，仅解码器DIP的性能与编码器-解码器DIP架构相近。仅解码器DIP的复杂度显著低于原始编码器-解码器DIP，因此更有望用于实时OTFS检测器。迄今为止，尚无研究针对基于未训练DNN的OTFS检测器展开。

本文提出将未训练DNN与BPIC结合，用于执行迭代符号检测。具体而言，我们采用仅含解码器的架构实现DIP，称为D-DIP，并将其用作去噪器，为BPIC检测器提供初始符号估计。此处选择BPIC是为了降低OTFS接收机的计算复杂度。我们首先介绍由发射机、信道和接收机构成的单输入单输出（SISO）OTFS系统模型。随后回顾 [5], [15] 中采用MMSE去噪器获取初始符号估计的MMSE-BPIC检测器。我们不采用MMSE，而是提出一种高性能D-DIP去噪器，用于计算输入BPIC的初始符号估计。接着，我们详细介绍所提出的D-DIP，并将其计算复杂度和性能与其他方案进行比较。仿真结果表明，与文献中的其他实用方案相比，其符号错误率（SER）平均性能优势约为0.5 dB。

本文的主要贡献是首次提出将仅解码器DIP去噪器与BPIC OTFS检测器相结合。所提出的去噪器 1）为BPIC检测器提供更好的初始符号估计；2）其计算复杂度低于MMSE去噪器。因此，与其他方案相比，所提出的方案在计算复杂度大幅降低的情况下，实现了最接近期望传播方案的SER性能（复杂度约为期望传播方案的十五分之一）。

符号说明： a、a 和 A 分别表示标量、向量和矩阵。$\mathbb{C}^{M\times N}$ 表示 $M\times N$ 维复矩阵的集合。我们用 I_N、F_N 和 $\mathrm{F}_N^{\mathbf{H}}$分别表示 N维单位矩阵、 N点离散傅里叶变换（DFT）矩阵和 N点逆离散傅里叶变换（IDFT）矩阵。$(\cdot)^T$ 表示转置运算。我们将矩阵 A 按列向量化记作 $\mathrm{a}=\mathrm{vec(A)}$，而 $\mathrm{A}=\mathrm{vec}^{-1}\mathrm{(a)}$ 表示将向量元素折叠回矩阵。克罗内克积记作 $\otimes$。$\lfloor\frac{a}{b}\rfloor$ 表示向下取整运算，$[\cdot]_M$ 表示模M 运算。向量 x 的欧几里得距离记作 $\|\mathrm{x}\|$。我们用 $\mathcal{N}(\mathrm{x}:\ \boldsymbol{\mu},\boldsymbol{\Sigma})$表示向量 x 的多元高斯分布，其中 $\boldsymbol{\mu}$ 为均值，$\boldsymbol{\Sigma}$ 为协方差矩阵。

II. OTFS系统模型

我们考虑一个 OTFS 系统，如图1所示。下面将介绍 OTFS 发射机、信道和接收机的具体细节。

A. OTFS发射机

在发射机端，MN 个来自大小为 $Q\mathbb{A}=\{a_1,\cdots,a_Q\}$ 的调制字母表的信息符号 $\mathrm{X_{DD}}\in\mathbb{C}^{M\times N}$ 被分配到延迟-多普勒（DD）域中的 $M\times N$ 网格上，其中 M 和 N 分别表示所用的子载波数和时隙数。如图 1 所示，DD 域符号通过逆辛有限傅里叶变换（ISFFT） [1]转换到时频（TF）域。这里，TF 域离散为由 N 个网格构成的 M，网格间隔分别为 Δf（Hz）和 $T_s=1/\Delta f$（秒）。因此，采样时间为 T_s/M。TF 域样本 $\mathrm{X_{TF}}\in\mathbb{C}^{M\times N}$构成一个 OTFS 帧，其占用带宽为 $M\Delta f$、持续时间为 NT_s，表示为

$$\mathbf{X}_{\mathrm{TF}}=\mathbf{F}_M\mathbf{X}_{\mathrm{DD}}\mathbf{F}_N^{\mathbf{H}},\tag{1}$$

其中，$\mathrm{F}_M\in\mathbb{C}^{M\times M}$ 和 $\mathrm{F}_N^{\mathbf{H}}\in\mathbb{C}^{N\times N}$ 分别为 M点离散傅里叶变换矩阵和 N点逆离散傅里叶变换矩阵，它们的第（p, q）个元素分别为（$\frac{1}{\sqrt{M}}e^{-j2\pi pq/M}$）$_{p,\ q=0,\ \cdots,\ M-1}$和（$\frac{1}{\sqrt{N}}e^{j2\pi pq/N}$）$_{p,\ q=0,\ \cdots,\ N-1}$。$\mathrm{X_{TF}}$的第（$m$, n）个元素 $X_{\mathrm{TF}}[m,n]$可写为

$$X_{\mathrm{TF}}[m,n]=\frac{1}{\sqrt{MN}}\sum_{k=0}^{N-1}\sum_{l=0}^{M-1}X_{\mathrm{DD}}[k,l]e^{j2\pi(\frac{nk}{N}-\frac{ml}{M})},\tag{2}$$

其中，$X_{\mathrm{DD}}[k,l]$ 表示 $\mathrm{X_{DD}}$ 的第（k, l）个元素，其中 $k=0$、$\cdots$、$M-1$、$l=0$、$\cdots$、$N-1$。随后，应用（离散）海森堡变换 [1] ，并利用式（1）和克罗内克积规则[1],生成时域发射信号，其向量形式可写为

$$\mathbf{s}=\mathrm{vec}(\mathbf{G}_{\mathrm{tx}}\mathbf{F}_M^{\mathbf{H}}\mathbf{X}_{\mathrm{TF}})=(\mathbf{F}_N^{\mathbf{H}}\otimes\mathbf{G}_{\mathrm{tx}})\mathbf{x}_{\mathrm{DD}},\tag{3}$$

其中，$\mathrm{G_{tx}}$ 是脉冲成形波形，我们考虑持续时间为 T_s的矩形波形，因此$\mathrm{G_{tx}}=\mathrm{I}_M$ [16]，$\mathrm{x_{DD}}=\mathrm{vec(X_{DD})}$，且 $\mathrm{x_{DD}}=[x_{\mathrm{DD}}(0)\ \cdots,x_{\mathrm{DD}}(MN-1)]^T$。$\mathrm{s}\in\mathbb{C}^{MN\times 1}$是发射信号的向量形式，$\mathrm{s}=[s(0)\ \cdots,s(n)\ \cdots,s(MN-1)]^T$, $n=0,\cdots,MN-1$，且$s(n)$可写为

$$s(n)=\frac{1}{\sqrt{N}}\sum_{k=0}^{N-1}e^{j2\pi\lfloor\frac{n}{M}\rfloor k/N}x_{\mathrm{DD}}([n]_M+kM).\tag{4}$$

我们在每个 OTFS帧的起始处插入循环前缀（CP），循环前缀的长度与最大时延索引 l_{max}相同。因此，添加循环前缀后的持续时间为$NT_s+N_{\mathrm{cp}}\frac{T_s}{M}$，其中 $N_{\mathrm{cp}}=l_{max}$。添加循环前缀后，$\mathrm{s}=[s(MN-N_{\mathrm{cp}}+1)\ s(MN-N_{\mathrm{cp}}+2)\ \cdots,s(MN-1)\ s(0)\ \cdots,s(n)\ \cdots,s(MN-1)]^T$，并通过时变信道传输s。

B. OTFS 无线信道

OTFS 无线信道是一种时变多径信道，由延迟-多普勒

[1]矩阵乘法通常通过结合克罗内克积进行向量化来表示。也就是说，vec(ABC) = ($C^T\otimes A$)vec(B)

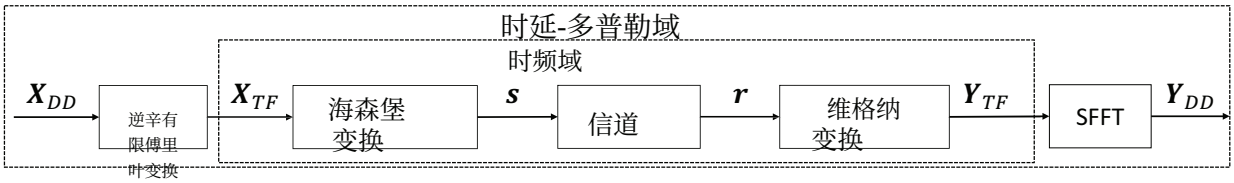

图1：OTFS调制方案的系统模型

域，

$$h(\tau, v) = \sum_{i=1}^{P} h_i \delta(\tau - \tau_i)\delta(v - v_i) \tag{5}$$

其中，$\delta(\cdot)$为狄拉克δ函数，$h_i \sim \mathcal{N}(0, 1/P)$表示第 i条路径的增益，P是路径总数。每条路径表示移动反射体/发射机与接收机之间的一条信道，具有不同的时延（τ_i）和/或多普勒（v_i）特性。时延和多普勒频移分别表示为 $\tau_i = l_i\frac{T_s}{M}$和$v_i = k_i\frac{\triangle f}{N}$。载波间干扰取决于信道的时延和多普勒，如 [16]所示。这里，对于每条路径，随机选取的整数 $l_i \in [0, l_{max}]$ 和 $k_i \in [-k_{max}, k_{max}]$ 分别表示时延和多普勒频移的索引，其中 l_{max} 和k_{max} 分别是所有信道路径中最大时延和最大多普勒频移的索引。请注意，每条路径的 l_i 和 k_i 组合均不相同。对于我们的无线信道，假设 $l_{max} \leq M-1$和 $k_{max} \leq \lfloor \frac{N}{2} \rfloor$，这意味着最大信道时延和多普勒频移分别小于 T_s秒和 Δf 赫兹。

C. OTFS接收机

在接收端，时域接收信号 $r(t)$ 表示为 [1]

$$r(t) = \int\int h(\tau, v)s(t-\tau)e^{j2\pi v(t-\tau)}d\tau dv + w(t), \tag{6}$$

其中，$s(t)$ 是时域接收信号 s，而 $h(\tau, v)$ 是式 (5) 中所示的延迟-多普勒域信道。随后，在 处对接收信号 $r\ t \qquad t = \frac{n}{M\Delta f} \qquad n = 0 \cdots MN-$ ( ) 进行采样，其中 1 ，，。去除循环前缀后，由式 (5) 和 (6) 得到离散接收信号 ( )，写作

$$r(n) = \sum_{i=1}^{P} h_i e^{j2\pi\frac{k_i(n-l_i)}{MN}} s([n-l_i]_{MN}) + w(n), \tag{7}$$

接着，将式 (7) 写成向量形式：

$$\mathbf{r} = \mathbf{H}\mathbf{s} + \mathbf{w}, \tag{8}$$

其中，w 是复数独立同分布 (i.i.d.) 白高斯噪声，服从 $\mathcal{N}(0, \sigma_c^2\mathrm{I})$，$\sigma_c^2$是噪声的方差。$\mathrm{H} = \sum_{i=1}^{P} h_i \mathrm{I}_{MN}(l_i)\mathbf{\Delta}(k_i)$，$\mathrm{I}_{MN}(l_i)$ 表示将单位矩阵的列循环左移 l_i 次后得到的矩阵。$\mathbf{\Delta}$ 是多普勒频移对角矩阵，$\mathbf{\Delta}(k_i)$ =diag $\left[e^{j2\pi k_i}{}_{(0)MN}, e^{j2\pi k_i}{}_{(1)MN}, \cdots, e^{j2\pi k_i}{}_{\frac{(MN-1}{MN}}\right])$，而 diag(·) 表示对一个向量执行对角化操作。注意，the 矩阵 $\mathrm{I}_{MN}(l_i)$ 和 $\mathbf{\Delta}(k_i)$ 分别对式（5）中的时延和多普勒频移进行建模。如图1所示，时频域接收信号 Y $_{\mathrm{TF}} \in \mathbb{C}^{M\times N}$ 通过应用维格纳变换 [16], 得到，表示为:

$$\mathbf{Y}_{\mathrm{TF}} = \mathbf{F}_M \mathbf{G}_{\mathrm{rx}} \mathbf{R}, \tag{9}$$

其中，R =vec^{-1}(r)，G_{rx} 是接收机中持续时间为 T_s 的矩形波形，且 $\mathrm{G}_{\mathrm{rx}} = \mathrm{I}_M$。然后，利用辛有限傅里叶变换 (SFFT) 得到延迟-多普勒域接收信号 $\mathrm{Y}_{\mathrm{DD}} \in \mathbb{C}^{M\times N}$，即

$$\mathbf{Y}_{\mathrm{DD}} = \mathbf{F}_M^{\mathbf{H}} \mathbf{Y}_{\mathrm{TF}} \mathbf{F}_N = \mathbf{F}_M^{\mathbf{H}} \mathbf{F}_M \mathbf{G}_{\mathrm{rx}} \mathbf{R} \mathbf{F}_N = \mathbf{G}_{\mathrm{rx}} \mathbf{R} \mathbf{F}_N. \tag{10}$$

根据克罗内克积的向量化规则，可将式 (10) 重写为

$$\mathbf{y}_{\mathrm{DD}} = \mathrm{vec}(\mathbf{Y}_{\mathrm{DD}}) = \mathrm{vec}(\mathbf{G}_{\mathrm{rx}} \mathbf{R} \mathbf{F}_N) = (\mathbf{F}_N \otimes \mathbf{G}_{\mathrm{rx}})\mathbf{r}. \tag{11}$$

将 (3) 代入 (8) 和 (11)，得到

$$\mathbf{y}_{\mathrm{DD}} = \mathbf{H}_{\mathrm{DD}} \mathbf{x}_{\mathrm{DD}} + \tilde{\mathbf{w}}, \tag{12}$$

其中，$\mathrm{H}_{\mathrm{DD}} = (\mathrm{F}_N \otimes \mathrm{G}_{\mathrm{rx}})\mathrm{H}(\mathrm{F}_N^{\mathbf{H}} \otimes \mathrm{G}_{\mathrm{tx}})$ 和 ˜w $= (\mathrm{F}_N \otimes \mathrm{G}_{\mathrm{rx}})$w 分别表示延迟-多普勒域中的等效信道和噪声。这里，˜w 是独立同分布的高斯噪声，因为 $\mathrm{F}_N \otimes \mathrm{G}_{\mathrm{rx}}$ 是酉正交矩阵 [1], [16]。为方便起见，我们将式 (12) 中的复值模型转换为实值模型。相应地，$\begin{bmatrix} \Re & \\ \Im & \end{bmatrix}_{\mathrm{DD}} = [\Re(\mathrm{x}_{\mathrm{DD}}) \ \Im(\mathrm{x}_{\mathrm{DD}})]^T_{\Re}$. y $= \Im[\Re(\mathrm{y}$) $\Im($ y)$]^T$，n $= [\Re($ ˜w) $\Im($ ˜w)$]^T$，H (H) (H) (H) (H)，( ) 和 ( ) 分别为实部和虚部。因此，n 的方差为 $\sigma^2 = \sigma_c^2/2$，x、y、n 是大小为 $2MN$ 的向量，$\mathrm{H}_{\mathrm{eff}}$ 是大小为 $2MN \times 2MN$ 的矩阵。于是，我们可以将式 (12) 重写为

$$\mathbf{y} = \mathbf{H}_{\mathrm{eff}} \mathbf{x} + \mathbf{n}. \tag{13}$$

我们假设检测器端已知 $\mathrm{H}_{\mathrm{eff}}$。为简化符号表示，我们省略式（13）中 $\mathrm{H}_{\mathrm{eff}}$ 的下标，并在后续各节中将其记为 H。系统的信噪比（SNR）定义为 SNR $= 10\log_{10}(\frac{1}{\sigma_c^2})$dB。

III. MMSE-BPIC 检测器

本节简要介绍近期在 [15] 中提出的采用 MMSE 去噪器的 BPIC检测器。BPIC检测器的结构如图 2 所示。它由四个模块组成：去噪器、贝叶斯符号观测（BSO）、贝叶斯符号估计（BSE）和判决统计量合并（DSC）。

在去噪器模块中，如图 2 所示，首次 BPIC迭代 [15]时采用最小均方误差方案来获得初始符号估计 $\hat{\mathbf{x}}^{(0)}$。MMSE去噪器可表示为

$$\hat{\mathbf{x}}^{(0)} = \left(\mathbf{H}^T\mathbf{H} + \sigma^2\mathbf{I}\right)^{-1}\mathbf{H}^T\mathbf{y}. \tag{14}$$

在 BSO模块中，使用基于匹配滤波器的 PIC方案检测发送符号，如下所示

$$\mu_q^{(t)} = \hat{x}_q^{(t-1)} + \frac{\mathbf{h}_q^T\left(\mathbf{y} - \mathbf{H}\hat{\mathbf{x}}^{(t-1)}\right)}{\|\mathbf{h}_q\|^2}, \tag{15}$$

其中，$\mu_q^{(t)}$是第 q个符号 x_q在第 t 次迭代中的软估计，$\mathbf{h}_q$ 是矩阵 $\mathbf{H}$ 的第 q 列。$\hat{\mathbf{x}} = [x_1^{(t-1)} \cdots x_q^{(t-1)} \cdots x_{2MN}^{(t-1)}]^T$ 是估计符号的向量。第 q个符号估计的方差 $\Sigma_q^{(t)}$由 [15] 推导如下

$$\Sigma_q^{(t)} = \frac{1}{(\mathbf{h}_q^T\mathbf{h}_q)^2}\left(\sum_{\substack{j=1\\ j\neq q}}^{MN}(\mathbf{h}_q^T\mathbf{h}_q)^2 v_j^{(t-1)} + (\mathbf{h}_q^T\mathbf{h}_q)\sigma^2\right), \tag{16}$$

其中，$v_j^{(t-1)}$ 是符号估计方差向量中的第 j个元素，$\mathbf{v}^{(t-1)}$ 表示第 $t-1$ 次迭代中的方差，且 $\mathbf{v}^{(t-1)} = [v_1^{(t-1)}, \cdots, v_q^{(t-1)}, \cdots, v_{2MN}^{(t-1)}]^T$；由于开始时我们没有关于方差的先验知识，因此设 $\mathbf{v}^{(0)} = 0$。然后，将估计符号 $\boldsymbol{\mu}^{(t)} = [\mu_1^{(t)}, \cdots, \mu_q^{(t)}, \cdots, \mu_{2MN}^{(t)}]^T$和方差 $\boldsymbol{\Sigma}^{(t)} = [\Sigma_1^{(t)}, \cdots, \Sigma_q^{(t)}, \cdots, \Sigma_{2MN}^{(t)}]^T$传递给 BSE模块，如图 2 所示

在 BSE 模块中，我们计算贝叶斯符号估计，以及从 BSO 模块获得的第 q 个符号的方差，表示为

$$\hat{x}_q^{(t)} = \mathbb{E}\left[x_q\middle|\mu_q^{(t)}, \Sigma_q^{(t)}\right] = \sum_{a\in\Omega} a\hat{p}^{(t)}(x_q = a|\mathbf{y}) \tag{17}$$

$$v_q^{(t)} = \mathbb{E}\left[\left|x_q - \mathbb{E}\left[x_q\middle|\mu_q^{(t)}, \Sigma_q^{(t)}\right]\right|^2\right], \tag{18}$$

其中，$\hat{p}^{(t)}(x_q|\mathbf{y}) = \mathcal{N}(x_q; \mu_q^{(t)}, \Sigma_q^{(t)})$ 由 BSO 模块获得，并经过归一化，使得$\sum_{a\in\Omega}\hat{p}^{(t)}(x_q = a|\mathbf{y}) = 1$。随后，BSE 模块的输出 $\hat{x}_q^{(t)}$和 $v_q^{(t)}$ 被发送至后续的 DSC 模块。

DSC 模块对连续两次迭代中的符号估计进行线性组合，如下所示

$$\hat{x}_q^{(t)} = \left(1 - \rho_q^{(t)}\right)\hat{x}_q^{(t-1)} + \rho_q^{(t)}\hat{x}_q^{(t)} \tag{19}$$

$$v_q^{(t)} = \left(1 - \rho_q^{(t)}\right)v_q^{(t-1)} + \rho_q^{(t)}v_q^{(t)}. \tag{20}$$

加权系数通过最大化信干噪比方差来确定，表示为

$$\rho_q^{(t)} = \frac{e_q^{(t-1)}}{e_q^{(t)} + e_q^{(t-1)}}, \tag{21}$$

其中，$e_q^{(t)}$定义为

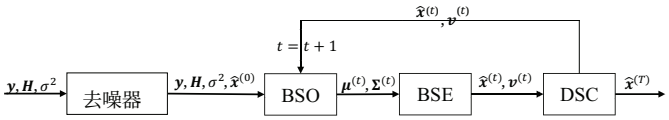

图2：BPIC检测器架构

使用 MRC滤波器计算出的第 q 个符号估计的瞬时平方误差，

$$e_q^{(t)} = \left\|\frac{\mathbf{h}_q^T}{\|\mathbf{h}_q\|^2}\left(\mathbf{y} - \mathbf{H}\hat{\mathbf{x}}^{(t)}\right)\right\|^2. \tag{22}$$

加权符号估计$\hat{\mathbf{x}}^{(t)}$ 及其方差$\mathbf{v}^{(t)}$随后返回BSO模块，以继续迭代。经过 T 次迭代后，将$\hat{\mathbf{x}}^{(T)}$ 作为符号估计向量。

IV. 用于符号估计的D-DIP去噪器

本节提出D-DIP，以提升BPIC检测器的初始符号估计性能；D-DIP的完整迭代过程如图3所示。

D-DIP中使用的深度神经网络被归类为由 $L = 5$ 个全连接层组成的全连接解码器深度神经网络。这些层可分为一个输入层、一个输出层和三个隐藏层，其神经元数量分别为p1 = 4、p2 = 8、p3 = 16、p4 = 32、p5 = $2MN$。我们从正态分布 $\mathcal{N}(0, 1)$中抽取一个大小为4x1的随机向量$\mathbf{z}_0$，作为深度神经网络第一层（即输入层）的输入。在D-DIP迭代过程中，$\mathbf{z}_0$保持不变。

第 i $\mathbf{x}^{(i)}_{\mathrm{D-DIP}}$ 次迭代时的DNN输出通过将 $\mathbf{z}_0$ 输入5层后得到，如下所示

$$\mathbf{x}^{(i)}_{\mathrm{D-DIP}} = cf_L^{(i)}(f_{L-1}^{(i)}(\cdots f_2^{(i)}(\mathbf{z}_0))), \tag{23}$$

其中，c 是用于控制DNN输出范围的常数，$f_l^{(i)}$ 是第 l 层在第 i次迭代时的输出，

$$f_l^{(i)} = \mathrm{Tanh}(\mathbf{W}_l^{(i)}f_{l-1}^{(i)} + \mathbf{b}_l^{(i)}), l = 2, \ldots, L \tag{24}$$

其中，$\mathbf{z}_0, \mathbf{W}_l^{(i)}$ 表示第 l 层与第 $l-1$ 层之间在第 i次迭代时的权重矩阵。$\mathbf{b}_l^{(i)}$ 是第l 层在第 i次迭代时的偏置向量。开始时，$\mathbf{W}_l^{(0)}$ 和$\mathbf{b}_l^{(0)}$ 的每个元素均按照范围为 $(\frac{-1}{\sqrt{p_l}}, \frac{1}{\sqrt{p_l}})$ 的均匀分布随机初始化，[17], 其中，p_l 表示第 l层中的神经元数量。双曲正切函数是每层之后使用的激活函数。

之后，我们在 [18] 中采用一种停止方案来控制 D-DIP 的迭代过程，以避免 DIP 的参数化特性导致过拟合问题。该停止方案基于计算深度神经网络输出的方差，表示为

$$\varsigma^{(i)} = \frac{1}{W}\sum_{j=i-W}^{i}\|\mathbf{x}^{(j)}_{\mathrm{D-DIP}} - \frac{1}{W}\sum_{j'=i-W}^{i}\mathbf{x}^{(j')}_{\mathrm{D-DIP}}\|^2, i \geq W, \tag{25}$$

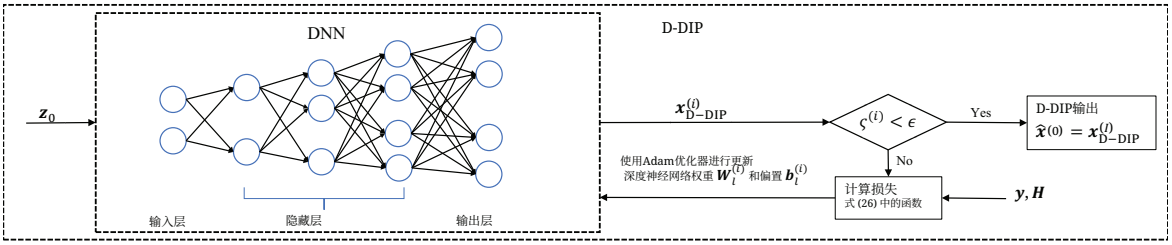

图 3：D-DIP结构

其中，$\varsigma^{(i)}$ 是迭代次数为 i时的方差值。当 $i < W$时，不进行方差计算。 W 是根据实验确定的一个常数，应小于 D-DIP 收敛所需的迭代次数。如图 3 所示，我们将 $\varsigma^{(i)}$ 与阈值 ϵ进行比较。如果 $\varsigma^{(i)} < \epsilon$，D-DIP 的迭代过程将停止，随后将 D-DIP 的输出 $\mathbf{x}^{(I)}_{\text{D-DIP}}$传递给 BPIC，作为初始符号估计，即 $\hat{\mathbf{x}}^{(0)} = \mathbf{x}^{(I)}_{\text{D-DIP}}$，其中 I 是最后一次 D-DIP 迭代的编号。否则，使用均方误差（MSE）计算损失，如下所示

$$\mathcal{L}^{(i)} = \frac{1}{2MN}\|\mathbf{H}\mathbf{x}^{(i)}_{\text{D-DIP}} - \mathbf{y}\|^2. \tag{26}$$

由权重 $\mathbf{W}_l^{(i)}$ 和偏置 $\mathbf{b}_l^{(i)}$ 组成的深度神经网络参数，随后使用 Adam优化器 [19] 和式 (26) 中计算出的损失进行优化。然后，如图 3 所示，重复这一过程。

V. 复杂度分析

本节分析所提出的 D-DIP-BPIC检测器的计算复杂度。对于 D-DIP 的复杂度，全连接层的计算复杂度为矩阵向量乘法，代价为 $\mathcal{O}(M^2N^2I)$，其中 I 表示 D-DIP 所需的迭代次数。不同检测算法的计算复杂度如表 I 所示，其中 T 表示 BPIC、UAMP、EP 和 BPICNet 检测器所需的迭代次数。例如，对于 $M = 12$、$N = 7$、$T = 10$、$I = 50$，D-DIP-BPIC 的复杂度比 MMSE-BPIC、UAMP 和 BPICNet 低约 1.5 倍。D-DIP-BPIC 的复杂度比 EP 低约 15 倍。因此，与上述高性能检测器相比，我们提出的检测器具有最低的复杂度。

需要注意的是，BPICNet由于训练要求而具有额外的复杂度。BPICNet使用一个大型数据集进行部署前训练。例如，$b = 5.12 \times 10^6$在 [10]中使用。

图4展示了I 的累积分布函数（CDF）（即满足停止方案（25）所需的D-DIP迭代次数），对应于 $M = 12$、24、36、48、$N = 7$ l_{max} =$M - 1$、$k_{max} = 3$、$SNR = 15dB$。图中显示，D-DIP收敛所需的迭代次数 I对OTFS帧大小（即 M 和 N）并不敏感，这是一个显著优势。

检测器	复杂度阶（训练）	复杂度阶（部署）
MMSE-BPIC [5]	不需要	$\mathcal{O}(M^3N^3 + M^2N^2T)$
UAMP [20]	不需要	$\mathcal{O}(M^3N^3 + M^2N^2T)$
期望传播 [7]	不需要。	$\mathcal{O}(M^3N^3T)$
BPICNet [10]	$\mathcal{O}(b(M^3N^3 + MN + M^2N^2T))$	$\mathcal{O}(M^3N^3 + MN + M^2N^2T)$
D-DIP-BPIC	不需要	$\mathcal{O}(M^2N^2I + M^2N^2T)$

表 I：计算复杂度比较

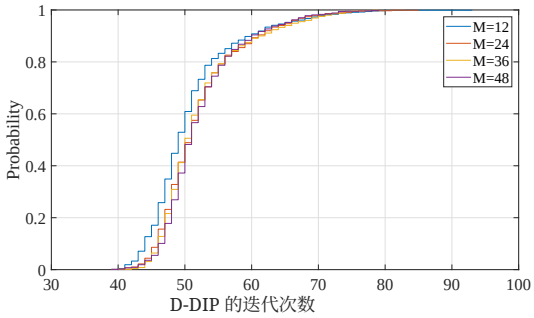

图4：I的累积分布函数

VI. 数值结果

本节通过将所提检测器的SER性能与MMSE-BPIC [5], UAMP [20],EP [7] 和BPICNet [10]的SER性能进行比较，评估该检测器的性能。这里我们改用 [20] 中的UAMP，因为 [6] 中提出的UAMP不适用于我们的系统模型，如[5]所示。仿真中，我们设置 $N = 7$、$l_{max} = M - 1$、$\Delta f = 15$ kHz。载波频率设为 $f_c = 10$ GHz。仿真采用4-QAM调制，并设置 $c = 1/\sqrt{2}$，该值对应于星座的归一化功率，用于归一化DNN输出。所有仿真中，DNN均采用第四节所述的相同DNN参数（例如层数及每层的神经元数量）。我们使用Adam优化器，以0.01的学习率优化DNN参数。(25)中的停止准则参数 W 设为30，阈值 ϵ 设为0.001。BPIC、UAMP、EP和BPICNet的迭代次数设为 $T = 10$，以确保收敛。对于BPICNet的训练设置，我们采用 [10],中的相同设置，其中训练过程中使用 $M = 12$、$N = 7$、$l_{max} = 11$、$k_{max} = 3$ 和500个训练轮次；每个训练轮次中，40个批次

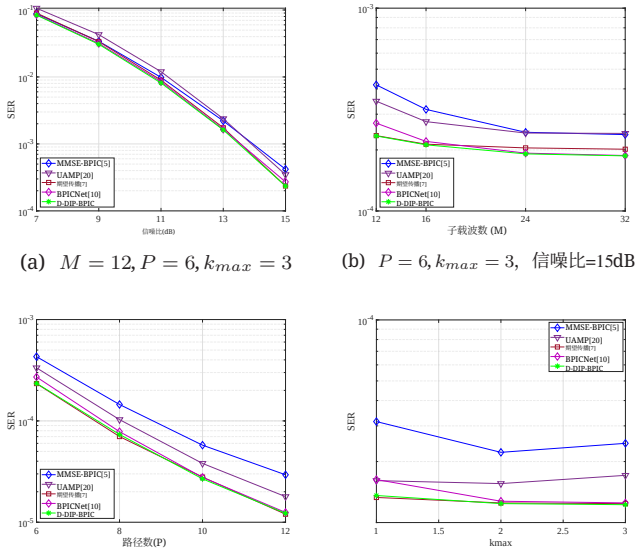

(a) $M = 12, P = 6, k_{max} = 3$ (b) $P = 6, k_{max} = 3$，信噪比=15dB

(c) $M = 12, k_{max} = 3$, 信噪比=15dB (d) $M = 12, P = 12$，信噪比=15dB

图5：符号错误率性能

每个批次生成256个样本。 $P \in \{6, \ldots, 12\}$ 随机选取，信噪比值在一定范围内均匀分布，更多详情见 [10]。

图 5(a) 表明，所提出的 D-DIP-BPIC 检测器相比 MMSE-BPIC 和 UAMP 获得了约 0.5 dB 的性能增益。事实上，其符号错误率性能与 BPICNet 和期望传播非常接近。图 5(b) 评估了所提出的 D-DIP-BPIC 检测器的可扩展性。随着 OTFS 帧大小（即子载波数）的增加，D-DIP-BPIC 仍优于 MMSE-BPIC 和 UAMP，且性能接近 BPICNet 和期望传播。图 5(c) 显示，随着路径数（例如，移动反射体）的增加，D-DIP-BPIC 检测器仍能达到接近 BPICNet 和期望传播的性能，并优于其他方法。如图 5(d) 所示，与 $k_{max} = 2$,3 相比，在 $k_{max} = 1$ 情况下，BPICNet 检测器的性能显然有所下降，这是因为训练数据的保真度受到影响，而我们的 D-DIP-BPIC 仍保有其优势。

VII. 结论

我们提出了一种基于未经训练的神经网络的 OTFS 检测器，与当前最先进的 OTFS 检测器相比，该检测器能够实现优异的性能。仿真结果表明，与 MMSE-BPIC 相比，所提出的 D-DIP-BPIC 检测器在符号错误率（SER）性能方面提升了 0.5 dB，并且在复杂度显著降低的情况下，实现了接近期望传播（EP）的 SER 性能。

参考文献

[1] R. Hadani、S. Rakib、M. Tsatsanis、A. Monk、A. J. Goldsmith、A. F. Molisch 和 R. Calderbank，《正交时频空调制》，载于 IEEE无线通信与网络会议（WCNC）论文集，美国，2017年3月，第1–6页。

[2] T. Jiang、H. H. Chen、H. C. Wu 和 Y. Yi，《频率色散信道中车对车通信系统的信道建模与载波间干扰分析》，Mob. Netw. Appl.，第15卷，第1期，第4–12页，2010年5月。[3] P. Raviteja、K. T. Phan、Y. Hong 和 E. Viterbo，《正交时频空调制的干扰消除与迭代检测》，IEEE Trans. Wirel. Commun.，第17卷，第10期，第6501–6515页，2018年8月。[4] M. Khumalo、W. T. Shi 和 C. K. Wen，《大规模MIMO系统中近似消息传递（AMP）算法的定点实现》，Digit. Commun. Netw.，第2卷，第4期，第218–224页，2016年9月。[5] X. Qu、A. Kosasih、W. Hardjawana、V. Onasis 和 B. Vucetic，《用于正交时频空调制系统的基于贝叶斯的符号检测器》，载于 IEEE Int. Symb. Pers. Indoor Mob. Radio Commun.（PIMRC）论文集，芬兰，2021年9月。[6] Z. Yuan、F. Liu、W. Yuan、Q. Guo、Z. Wang 和 J. Yuan，《采用酉近似消息传递的正交时频空调制迭代检测》，IEEE Trans. Wireless Commun.，第21卷，第2期，第714–725页，2022年。[7] F. Long、K. Niu 和 J. Lin，《基于期望传播的低复杂度OTFS块均衡器》，IEEE Wireless Commun. Lett.，第11卷，第2期，第376–380页，2022年2月。[8] P. Singh、A. Gupta、H. B. Mishra 和 R. Budhiraja，《具有不完美信道状态信息的MIMO-OTFS系统低复杂度ZF/MMSE接收器》。

[9] [ ] 2010 04057 在线。获取地址：https://arxiv.org/abs/。Y. K. Enku、B. Bai、F. Wan、C. U. Guyo、I. N. Tiba、C. Zhang 和 S. Li，《基于二维卷积神经网络的OTFS系统信号检测》，IEEE Wireless Commun. Lett.，第10卷，第11期，第2514–2518页，2021年。[10] A. Kosasih、X. Qu、W. Hardjawana、C. Yue 和 B. Vucetic，《正交时频空调制的贝叶斯神经网络检测器》，IEEE Wireless Commun. Lett.，第11卷，2574，2022年12，2570期，第–页。[11] E. Strubell、A. Ganesh 和 A. McCallum，《自然语言处理中深度学习的能耗与政策考量》，载于计算语言学协会年会（ACL），2019年7月，第3645–3650页。[12] A. Linden，《合成数据是人工智能的未来吗？》，gartner.com。https://www.gartner.com/en/newsroom/press-releases/2022-06-22-is-synthetic-data-the-future-of-ai（访问日期：2023年1月8日）。[13] V. Lempitsky、A. Vedaldi 和 D. Ulyanov，《深度图像先验》，载于 IEEE/CVF计算机视觉与模式识别会议论文集，美国，2018年6月，第9446–9454页。[14] M. Z. Darestani 和 R. Heckel，《使用未训练神经网络加速MRI》，IEEE Trans. Comput. Imag.，第7卷，第724–733页，2021年。[15] A. Kosasih、V. Miloslavskaya、W. Hardjawana、C. She、C. K. Wen 和 B. Vucetic，《具有改进复杂度-可靠性权衡的贝叶斯接收器：大规模MIMO系统应用》，IEEE Trans. Commun.，第69卷，第9期，第6251–6266页，2021年9月。[16] P. Raviteja、Y. Hong、E. Viterbo 和 E. Biglieri，《用于降低循环前缀的OTFS实用脉冲成形波形》，IEEE Trans. Vehic. Technol.，第68卷，第1期，第957–961页，2019年1月。[17] K. He、X. Zhang、S. Ren 和 J. Sun，《深入探究整流器：在ImageNet分类中超越人类水平表现》，载于 IEEE Int. Conf. Comput. Vis.（ICCV）论文集，智利，2015年12月，第1026–1034页。[18] H. Wang、T. Li、Z. Zhuang、T. Chen、H. Liang 和 J. Sun，《深度图像先验的早停》，2021年。 [在线]。获取地址：https://arxiv. org/abs/ 2112 06074 。D. P. Kingma 和 J. Ba，《Adam：一种随机优化方法》[19]，载于国际学习表征会议（ICLR）论文集，美国，2015年，第1–15页。[20] Z. Yuan、Q. Guo 和 M. Luo，《采用酉变换的近似消息传递：鲁棒双线性恢复》，IEEE Trans. Signal Process.，第69卷，第617–630页，2021年。