DOI:10.14188/j.1671-8844.2024.0519 文章编号:1671-8844(XXXX)XX-0001-09

基于隐式信道特征的全双工IAB网络端到端混合波束成形技术

林思思[1],陈琪美[1],江昊[1],高斌[2],赵明明[1],徐乐[2]

(1. 武汉大学电子信息学院,湖北 武汉 430072; 2. 武汉烽火国际技术有限责任公司,湖北 武汉 430072)

摘要: 全双工(full duplex,FD)集成接入与回程(integrated access and backhaul, IAB)IAB网络需要依赖精确的信道估计抑制自干扰,然而IAB网络中复杂信道的估计会导致较高的导频开销。因此,本文为FD IAB网络提出一种基于隐式信道特征的端到端的混合波束成形框架,其能够减少导频开销并有效消除复杂干扰。首先,本文设计一个Sensing Transformer模块设计空间信道感知向量,IAB节点通过感知向量来主动观测导频信号。该模块利用注意力机制,可高效地处理任意长度的导频序列观测值并提取隐式信道特征。利用所提出的隐式信道特征,进一步设计混合波束成形神经网络(hybrid beamforming neural network, HBFnet)来设计IAB节点的混合波束成形,从而有效地抑制自干扰并补偿信道衰落。仿真结果表明所提出的方案相较传统方案可以在更低的导频开销下达到更高的频谱效率。

关键词: 集成接入与回程网络;混合波束成形;Transformer;深度学习

中图分类号: TU 457 **文献标志码:** A

End-to-End Hybrid Beamforming for Full Duplex Integrated Access and Backhaul Based on Implicit Channel feature

LIN Sisi[1], CHEN Qimei[1], JIANG Hao[1], GAO Bin[2], ZHAO Mingming[1], XU Le[2]

(1. School of Electronic Information, Wuhan University, Wuhan 430072, China;
2. Wuhan Fiberhome International Technology Co., Ltd., Wuhan 430072, China)

Abstract: Full duplex (full duplex, FD) IAB (integrated access and backhaul) networks rely on accurate channel estimation to suppress self-interference (SI). However, the estimation of complex channels often results in high pilot overhead. To address this, this paper proposes an End-to-End hybrid beamforming framework for FD IAB networks based on implicit channel feature, which effectively reduces pilot overhead and mitigates complex interference. Firstly, we design a Sensing Transformer module to generate spatial channel sensing vectors, enabling the IAB node to active observe pilot signals. This module leverages the attention mechanism to efficiently handle pilot observation sequences of arbitrary lengths and extract implicit channel features. Based on the extracted implicit channel features, we further design a Hybrid Beamforming Neural Network (HBFnet) to design the hybrid beamforming of the IAB node, thereby effectively suppressing SI and compensating for

收稿日期: XXXX-XX-XX
作者简介: 林思思(2000-),女,硕士研究生,主要从事无线通信技术研究,E-mail: double0623@163.com。
通信作者: 陈琪美(1989-),女,副教授,硕士生导师,主要从事5G移动通信关键技术研究,E-mail: chenqimei@whu.edu.cn。
基金项目: "政府间国际科技创新合作"重点专项(2020YFE0205800);湖北省重点研发计划项目(2022AAA003)。

本文引用格式: 林思思,陈琪美,江昊,等.基于隐式信道特征的全双工IAB网络端到端混合波束成形技术[J].武汉大学学报(工学版),XXXX,XX(XX):1-9.

Citation: LIN Sisi, CHEN Qimei, JIANG Hao, et al. End-to-End Hybrid Beamforming for Full Duplex Integrated Access and Backhaul Based on Implicit Channel feature[J]. Engineering Journal of Wuhan University, XXXX, XX(XX):1-9.

channel fading. Simulation results demonstrate that the proposed scheme achieves higher spectrum efficiency with lower pilot overhead compared to traditional methods.

Key words: integrated access and backhaul; hybrid beamforming; transformer; deep learning

未来的无线网络正趋向于基站的密集部署以满足未来通信应用的需求[1],在这种情况下,采用传统的有线光纤回程接入基站会导致较高的运营成本,这推动了集成接入与回程系统(integrated access and backhaul, IAB)的出现[2]。在IAB网络中,只有少数基站与通过有线的基础设施接入到核心网,而其他基站依赖无线回程接入。全双工(full duplex, FD)IAB通信使接入和回程链路能够在相同的频谱上同时工作,从而提高了频谱效率,但同时面临严重的自干扰(self interference, SI)问题[3]。在传统方案中,有三种方式实现自干扰消除:射频消除、天线消除和数字消除。近年来,由于低复杂度的混合大规模天线架构的优势,毫米波系统可以采用混合波束成形架构来补偿高频路径损耗,并进一步减轻自干扰[4][5]。然而,现有的混合波束成形方案通常依赖于精确的信道状态信息(channel state information, CSI),但FD IAB系统拥有多种无线信道,传统的信道估计方案会导致大量的导频开销。

为了应对高维信道估计带来的导频开销挑战,许多研究致力于利用深度学习构建信道状态信息,通常可以分为精确信道估计和隐式信道估计。精确信道估计根据历史观测到的导频信号估计精确的CSI[6][7],并用于下一步的波束成形设计,但信道估计的误差会在第二个阶段进行传播从而影响网络的最终性能。隐式信道估计方案则感知空间信道并提取隐式信道特征,直接用其设计波束,避免了对高维信道的精确估计[8]。方案中的作者提出了一种主动感知策略,该框架使用长短期记忆(long short-term memory, LSTM)网络捕捉导频观测序列中的时间相关性,从而提取隐式信道特征,并进一步用于设计波束赋形器[9]。

尽管上述工作为混合波束成形设计奠定了坚实的基础,但传统的信道感知方案无法并行处理历史观测数据,难以保留长时间感知序列的信息,这会降低的信道感知的性能。此外,在FD IAB系统中,低导频开销的混合波束成形算法还未被充分研究,这促使本文为FD IAB系统提出一种基于隐式信道特征的端到端(End-to-End, E2E)混合波束成形框架,该框架可以在更低导频开销的情况下实现更高的频谱效率。主要贡献可归纳如下:

1) 本文为FD IAB系统提出了一种基于隐式信道特征的端到端混合波束成形框架,为了减少高维信道估计的导频开销并有效消除SI,本文将导频训练与波束成形过程结合为一个端到端的神经网络。

2) 本文提出一种基于Sensing Transformer的主动感知模块,用于设计导频观测的感知向量。所提出的模块利用注意力机制从历史导频观测序列中提取隐式信道特征,并能够处理任意长度的输入序列。

3) 仿真结果表明,所提出的方案可在更低的导频开销下实现更高的频谱效率。

1 系统模型与问题方程

本文考虑毫米波FD IAB系统中的下行场景,如图1所示,其中gNB通过有线光线接入到核心网,IAB节点通过无线回程与gNB通信,并通过无线接入链路给用户(user equipment,UE)提供通信服务。网络中三种类型的节点都采用混合波束成形的架构,其中gNB、IAB节点和UE分别拥有N^D、N^I和N^U根天线,并且其射频链路数分别满足$N_{RF}^D \leqslant N^D$、$N_{RF}^I \leqslant N^I$和$N_{RF}^U \leqslant N^U$。

在本工作中,IAB节点采用同一资源块同时进行接收和传输,这会产生较大自干扰。因此,IAB节点采用三节点的自干扰消除:传播域被动抑制、模拟自干扰消除以及数字消除[10]。此外,本文采用混合波束成形设计进一步减轻自干扰。

1.1 信道模型

发射器i到接收器j的毫米波信道记为$\mathbf{H}_{ij}$,信道模型表示为:

$$\mathbf{H}_{ij}=\sqrt{\frac{N_t N_r}{CR_c}}\sum_{c=1}^{C}\sum_{r_c=1}^{R_c}\alpha_{r_c}^{c}\mathbf{a}_r(\theta_{ij}^{c,r_c})\mathbf{a}_t^{*}(\phi_{ij}^{c,r_c}), \quad (1)$$

其中N_t和N_r分别表示发射器和接收器的天线数量,C是簇的数量,R_c是每个簇的射线数量。$\alpha_{r_c}^{c}$是一个复值高斯随机变量,其幅度和相位分别服从瑞利分布和均匀分布。θ_r和ϕ_t分别是到达角和发射角,$\mathbf{a}_r(\theta_r)$和$\mathbf{a}_t(\phi_t)$是对应的接受和发射天线的响应向量。

自干扰信道定义为发射天线阵列与接收天线阵列之间的信道,表示为:

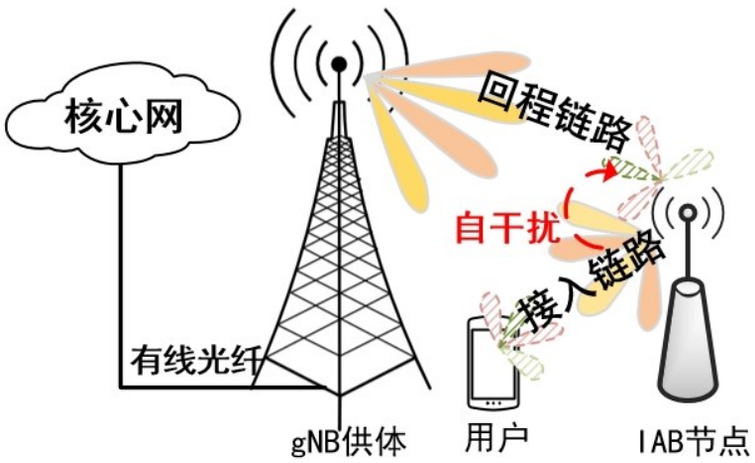


图 1　全双工集成接入与回程网络系统模型

Fig.1　System model of FD IAB network

$$\mathbf{H}_{\mathrm{SI}}=\sqrt{\frac{\kappa}{\kappa+1}}\,\mathbf{H}_{\mathrm{LOS}}+\sqrt{\frac{1}{\kappa+1}}\,\mathbf{H}_{\mathrm{NLOS}},\tag{2}$$

其中κ是瑞利因子，$\mathbf{H}_{\mathrm{LOS}}$是近场信道的视距分量，$\mathbf{H}_{\mathrm{NLOS}}$是反射路径。其中，$\mathbf{H}_{\mathrm{LOS}}$采用球面波传播模型，$\mathbf{H}_{\mathrm{NLOS}}$遵循(1)中定义的信道模型。

1.2　信号模型

为了简化表达，gNB用于发射信号的混合波束成形表示为$\mathbf{F}_{\mathrm{RF}}^{(\mathrm{D})}\mathbf{F}_{\mathrm{BB}}^{(\mathrm{D})}=\mathbf{F}^{(\mathrm{D})}$，IAB节点的混合合并器与混合预编码器分别表示为$\mathbf{W}_{\mathrm{BB}}^{(\mathrm{I})}\mathbf{W}_{\mathrm{RF}}^{(\mathrm{I})}=\mathbf{W}^{(\mathrm{I})}$和$\mathbf{F}_{\mathrm{RF}}^{(\mathrm{I})}\mathbf{F}_{\mathrm{BB}}^{(\mathrm{I})}=\mathbf{F}^{(\mathrm{I})}$，用户用于接受信号的混合合并器表示为$\mathbf{W}_{\mathrm{BB}}^{(U)}\mathbf{W}_{\mathrm{RF}}^{(U)}=\mathbf{W}^{(U)}$。

IAB节点设计合并器在回程链路接受信号，该过程可以表述为：

$$\mathbf{y}_b=\underbrace{\mathbf{W}^{(I)H}\mathbf{H}_B\mathbf{F}^{(D)}s^{(D)}}_{\text{所需信号}}+\underbrace{\xi\mathbf{W}^{(I)H}\mathbf{H}_{SI}\mathbf{F}^{(I)}s^{(I)}}_{\text{自干扰}}+\underbrace{\mathbf{W}^{(I)H}\mathbf{n}}_{\text{噪声}},\tag{4}$$

其中$\mathbf{H}_B$和$\mathbf{H}_{SI}$分别是回程信道与自干扰信道，$s^{(D)}$是gNB发送给IAB节点的信号，$\mathbf{n}$是符合分布$CN(0,\sigma^2)$的噪声，ξ是前文所述的三阶段自干扰消除实现的自干扰消除能力系数。

UE通过接入链路接受来自IAB节点的信号，经过合并器接受的信号可以表示为：

$$\mathbf{y}_a=\underbrace{\mathbf{W}^{(U)H}\mathbf{H}_A\mathbf{F}^{(I)}s^{(I)}}_{\text{所需信号}}+\underbrace{\mathbf{W}^{(U)H}\mathbf{n}}_{\text{噪声}}.\tag{5}$$

其中$\mathbf{H}_A$是接入信道，$s^{(I)}$是IAB节点发送给UE的信号。

1.3　联合导频训练与混合波束成形设计

考虑到gNB和IAB节点的位置保持相对稳定，信道状态变化平稳，本文假定掌握了回程链路的CSI。然而，对于SI链路和接入链路，CSI仍然是未知的。本文提出了一种低导频开销的端到框架，用隐式CSI设计混合波束成形，主要包含两个阶段：导频训练与混合波束成形设计。具体而言，IAB节点通过感知向量接受来自自身发射天线阵列和UE的导频符号，并利用所设计的感知向量进一步设计用于回程链路数据接受的合并器$\mathbf{W}^{(\mathrm{I})}$和接入链路发送数据的前置编码器$\mathbf{F}^{(\mathrm{I})}$，整个过程无需实现对CSI的精确估计。

在导频训练阶段，UE和IAB节点使用相互正交的导频信号，因为IAB节点很容易区分接受到的导频信号。IAB节点接收到的来自其自身发射天线阵列的导频信号可表示为：

$$\tilde{\mathbf{y}}_{\mathrm{si}}=\tilde{\mathbf{W}}_{\mathrm{si}}\mathbf{H}_{\mathrm{SI}}\mathbf{b}_{\mathrm{si}}+\tilde{\mathbf{W}}_{\mathrm{si}}\mathbf{n},\tag{6}$$

其中$\tilde{\mathbf{W}}_{\mathrm{si}}$是IAB节点用于接受导频信号的感知向量，$\mathbf{b}_{\mathrm{si}}$是发射天线阵列发送的导频符号，$\mathbf{n}$是具有$CN(0,\sigma^2)$分布的噪声。相应地，IAB节点接收到的来自UE的导频信号可以表示为：

$$\tilde{\mathbf{y}}_a=\tilde{\mathbf{W}}_a\mathbf{H}_A\mathbf{b}_a+\tilde{\mathbf{W}}_a\mathbf{n},\tag{7}$$

在射频链路受限的系统中，模拟波束赋形器通常通过网络中的相位移器来实现。一般来说$\tilde{\mathbf{W}}$应满足常数模约束，即$|[\tilde{\mathbf{W}}]_{i,j}|=\sqrt{1/N^I}$，$\forall i,j$。

接收到的导频信号中可以提取信道特征，并进一步利用所提取的隐式CSI为IAB节点设计混合波束赋形器，所设计的混合前置编码器$\{\mathbf{F}_{\mathrm{RF}}^{(\mathrm{I})},\mathbf{F}_{\mathrm{BB}}^{(\mathrm{I})}\}$用于回程链路上信号的接受，混合合并器$\{\mathbf{W}_{\mathrm{RF}}^{(\mathrm{I})},\mathbf{W}_{\mathrm{BB}}^{(\mathrm{I})}\}$用于接入链路上信号的发送，上述过程表示为：

$$\{\mathbf{F}_{RF}^{(I)},\mathbf{F}_{\mathrm{BB}}^{(I)},\mathbf{W}_{\mathrm{RF}}^{(I)},\mathbf{W}_{\mathrm{BB}}^{(I)}\}=F(\tilde{\mathbf{y}}_a,\tilde{\mathbf{y}}_{si}),\tag{8}$$

其中$F(\cdot)$表示从接受的导频信号到混合波束成形器的映射函数

1.4　问题方程

接入链路和回程链路上可实现的速率可分别

表示为

$$R_a=\log_2\left(1+\frac{\mathbf{W}^{(U)H}\mathbf{H}_A\mathbf{F}^{(I)}s^{(I)}}{\mathbf{W}^{(U)H}\mathbf{n}}\right), \tag{9}$$

$$R_b=\log_2\left(1+\frac{\mathbf{W}^{(I)H}\mathbf{H}_B\mathbf{F}^{(D)}s^{(D)}}{\xi\mathbf{W}^{(I)H}\mathbf{H}_{SI}\mathbf{F}^{(I)}s^{(I)}+\mathbf{W}^{(I)H}\mathbf{n}}\right), \tag{10}$$

由于IAB需要先从gNB处接收信号再传输给UE,因此UE的瞬时速率由二者共同决定:

$$R_m=\min(R_a,R_b). \tag{11}$$

本文的目标是为IAB节点设混合波束成形器以最大化系统的总速率,目标函数可表示为:

$$\max_{\tilde{\mathbf{W}}_a,\tilde{\mathbf{W}}_{si},F(\cdot)} R_m, \tag{12}$$

$$\{\mathbf{F}_{RF}^{(I)},\mathbf{F}_{\mathrm{BB}}^{(I)},\mathbf{W}_{\mathrm{RF}}^{(I)},\mathbf{W}_{\mathrm{BB}}^{(I)}\}=F(\tilde{\mathbf{y}}_a,\tilde{\mathbf{y}}_{si}), \tag{12a}$$

$$|[\mathbf{F}_{RF}^{(I)}]_{i,j}|=1,\forall i,j, \tag{12b}$$

$$\|\mathbf{F}_{RF}^{(I)}\mathbf{F}_{BB}^{(I)}\|_F^2\leqslant P_t, \tag{12c}$$

$$|[\tilde{\mathbf{W}}]_{i,j}|=\sqrt{1/N^I},\forall i,j, \tag{12d}$$

$$|[\mathbf{W}_{RF}^{(I)}\mathbf{W}_{BB}^{(I)}]_{i,j}|=\sqrt{1/N^I},\forall i,j. \tag{12e}$$

其中(12b)满足了模拟波束赋形器的恒模约束,(12c)满足了IAB节点的功率约束,(12d)与(12e)满足了合并器的硬件约束。解决上述问题的传统方法通常涉及两个步骤,即信道估计和混合波束成形设计,这将不可避免地导致系统性能下降和高导频开销。为了应对这一挑战,如(8)中描述的那样,本文联合导频训练与混合波束成形设计,无需进行信道的精确估计。然而,解决这样一个具有复杂约束和多变量的非凸优化问题面临巨大困难。为此,本文提出了一种E2E混合波束成形框架来解决这一问题,该框架将导频训练与波束成形设计整合成一个E2E神经网络,从而避免了信道估计,并降低了模型训练过程中的导频开销。

2 端到端混合波束成形框架

2.1 端到端学习框架

本部分将介绍FD IAB系统的端到端混合波束成形框架,如图2所示。在导频训练阶段,UE和IAB节点的发射天线阵列同时向IAB节点发射导频符号,IAB节点通过感知向量进行观测。本文所提出的主动感知策略可以帮助IAB节点根据实时环境状态自适应设计感知向量,有助于基站更精确地探测空间信道,并从中提取隐式信道特征。在通信阶段中,HBF网络根据第一阶段提取到的隐式信道信息为IAB节点设计混合波束成形器用于数据通信。最后,对频谱效率取负作为损失函数用于整个E2E神经网络的训练。

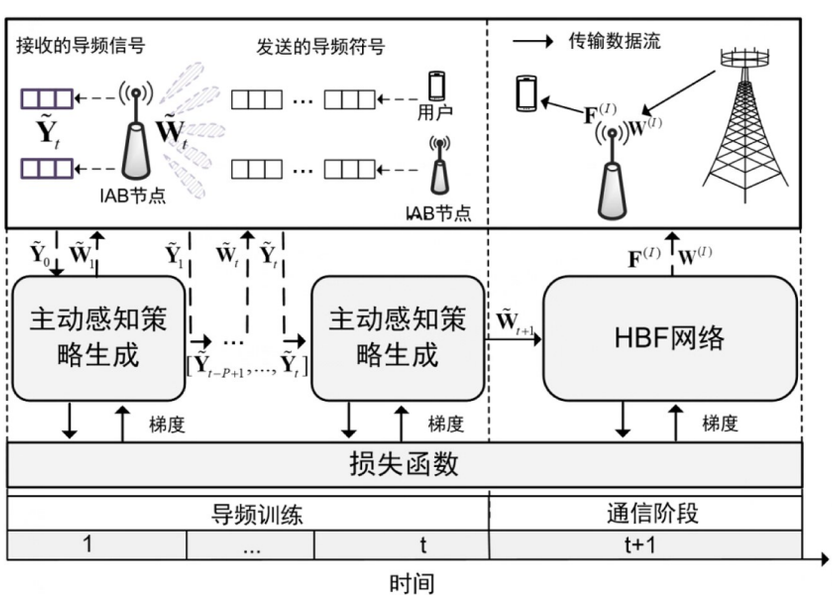


图2 FD IAB系统的端到端混合波束成形框架

Fig.2 E2E hybrid beamforming architecture for FD IAB

2.2 基于Sensing Transformer的导频训练

本节考虑IAB节点在T时间帧内与无线通信网络进行交互并主动感知空间信道。具体而言,IAB节点在每个时隙t=1,…,T根据历史接受到的导频观测值提取隐式信道信息,并用于设计下一时刻的感知向量,该过程可表述为:

$$\tilde{\mathbf{W}}_{t+1}=G_t(\tilde{\mathbf{y}}_{1:t},\tilde{\mathbf{W}}_{1:t}),t=0,\cdots,T-1, \tag{13}$$

其中$G_t(\cdot)$是t时刻的主动感知策略。这是一个连续

感知问题，需要一种能够与环境互动并捕捉历史观测值相关性的方法。传统循环神经网络（recurrent neural networks，RNNs）可以模拟任何开放动态系统[11]，但它仅依赖于前一时刻的信息，难以捕捉到长序列中的相关性。本文引入了Sensing Transformer模块，它可以并行处理任意长度的导频观测数据，并在每个时隙设计主动感知向量$\tilde{\mathbf{W}}_{t+1}$。

注意力（attention）机制是Transformer最重要的组成部分。在长序列中，注意力机制可以通过计算序列中每一对元素之间的相关性来有效捕捉有价值的信息[12]。本文将历史观测到的导频信号$\tilde{\mathbf{Y}}=[\tilde{\mathbf{y}}_{t-P+1},\ldots,\tilde{\mathbf{y}}_t]\in\mathbb{R}^{n\times P}$作为该模块的输入，其中$P$是输入序列的最大长度，$n$是序列中每个元素的特征维度。本文对$\tilde{\mathbf{Y}}$应用三种不同的线性变换，分别得到键矩阵$\mathbf{K}=\mathbf{W}^k\tilde{\mathbf{Y}}$、索引矩阵$\mathbf{Q}=\mathbf{W}^q\tilde{\mathbf{Y}}$与值矩阵$\mathbf{V}=\mathbf{W}^v\tilde{\mathbf{Y}}$，其中$\mathbf{W}^k\in\mathbb{R}^{d\times n}$、$\mathbf{W}^q\in\mathbb{R}^{d\times n}$和$\mathbf{W}^v\in\mathbb{R}^{n\times n}$分别是三种线性转化矩阵，$d$是键矩阵的特征维度。基于$\mathbf{K}$和$\mathbf{Q}$，可以计算得到注意力矩阵：

$$\mathbf{E}=\mathrm{Softmax}\left(\frac{\mathbf{K}^T\mathbf{Q}}{\sqrt{d}}\right). \tag{14}$$

由于乘积$\mathbf{K}^T\mathbf{Q}$随着特征维度d增加，因此本文将乘积结果除以$\sqrt{d}$，$\mathrm{Softmax}(\mathbf{x})=\frac{\exp(x_i)}{\sum\exp(x_i)}$被用于对矩阵的每一列进行归一化处理。

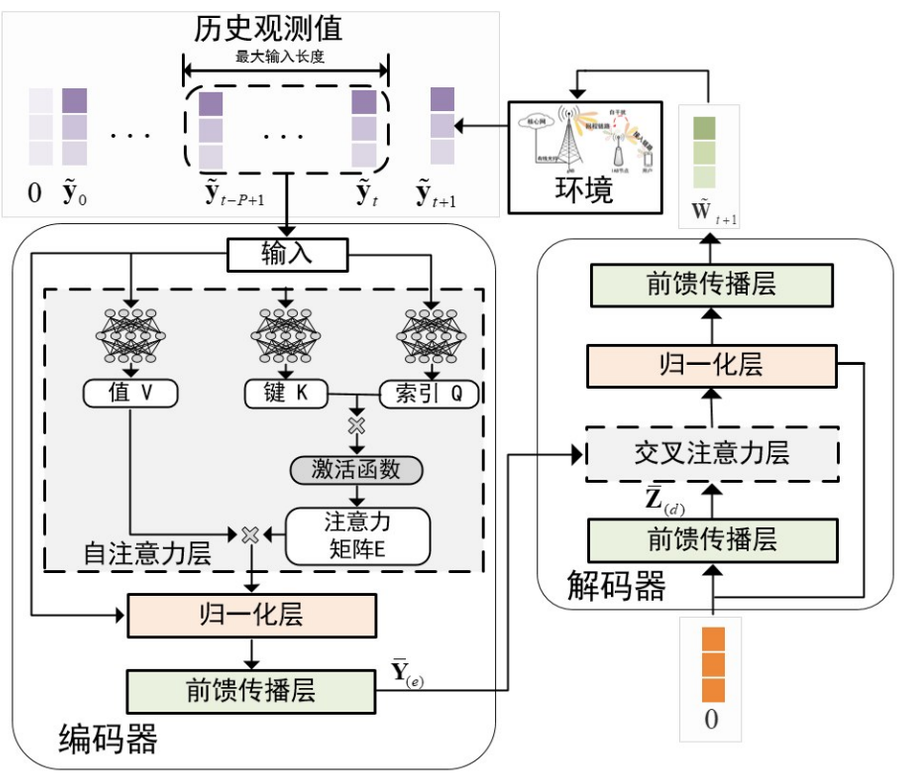


图3 所提出的用于主动感知的Sensing Transformer模块

Fig.3 Proposed Sensing Transformer block for active sensing

如图3所示，所提出的Sensing Transformer模块由一个编码器和一个解码器组成。编码器的任务是提取隐式信道特征，而解码器则负责根据隐式信道特征推断和生成下一时刻的感知向量。需要注意的是，前文介绍的注意力机制可直接应用于编码器的自我注意力模块，并稍作修改后可在解码器的交叉注意力模块上加以推广。

编码器模块采用可变长输入，当感知时间t小于最大输入长度P时，算法将t时刻之间观测到的所有导频信号作为输入；当t大于等于P时，将最近P个时刻的导频信号作为输入。需要额外说明的是，当$t=0$时，一个长度为1，0值填充的序列作为编码器的初始化输入。首先，将自注意力机制应用于输入，根据注意力矩阵E和值矩阵V即可得到自注意力层的输出$\mathbf{V}_{(d)}\mathrm{Softmax}\left(\frac{\mathbf{K}_{(d)}{}^T\mathbf{Q}_{(d)}}{\sqrt{d}}\right)$。此外，算法还加入了残差连接层[13]和归一化层[14]来解决梯度爆炸的问题。最后，采用前馈层来进一步提取每个输入元素的特征，整个过程可以表示为：

$$\bar{\mathbf{Y}}_{(e)}=\mathrm{FCN}(\mathrm{LN}(\tilde{\mathbf{Y}}+\mathbf{V}_{(e)}\mathrm{Softmax}(\frac{\mathbf{K}_{(e)}{}^{T}\mathbf{Q}_{(e)}}{\sqrt{d}}))),\tag{15}$$

其中 $\mathrm{LN}(\mathbf{X})=\frac{\mathbf{X}[i,j]-\mu_j}{\sqrt{\delta_j^2+\varepsilon}}$ 是归一化层，μ_j 和 δ_j^2 是 $\mathbf{X}[:,j]$ 的期望与方差。此外，在分母中添加 ε 项，以分母出现为0值的情况，$\mathrm{FCN}(\mathbf{X})$ 代表双层全连接网络。

解码器的目的是根据编码器提取的特征 $\bar{\mathbf{Y}}_{(e)}$ 设计下一个时刻的感知向量。解码器的初始输入为零值填充。与编码器中的自注意力机制不同，该模块中采用交叉注意力机制。键矩阵 $\mathbf{K}$ 和值矩阵 $\mathbf{V}$ 由编码器提取的特征 $\bar{\mathbf{Y}}(e)$ 变换得到，而索引矩阵 $\mathbf{Q}$ 由隐藏层变量 $\bar{\mathbf{Z}}_{(d)}$ 变换得到。基于交叉注意力机制，下一时刻的感知向量能够自然地与历史观测到的导频信号相关联。类似(15)，解码器的输出可由以下公式计算得到：

$$\tilde{\mathbf{W}}_{t+1}=\mathrm{FCN}(\mathrm{LN}(\bar{\mathbf{Z}}_{(d)}+\mathbf{V}_{(d)}\mathrm{Softmax}(\frac{\mathbf{K}_{(d)}{}^{T}\mathbf{Q}_{(d)}}{\sqrt{d}}))).\tag{16}$$

由于神经网络输出的是实值，因此需要对其进行复值映射最终得到下一时刻的感知向量 $\tilde{\mathbf{W}}_{t+1}:=\tilde{\mathbf{W}}_{t+1}[:N^I]+j*\tilde{\mathbf{W}}_{t+1}[N^I+1:2N^I]$。

2.3 FD IAB网络的混合波束成形设计

Sensing Transformer得到的感知向量包含隐式的信道特征，这对于混合波束成形的设计至关重要。本文在时刻 T 后采用深度神经网络(deep neural networks, DNNs)从感知向量中提取隐式信道信息，并用于设计IAB节点的混合波束成形 $\{\mathbf{F}_{RF}^{(I)},\mathbf{F}_{\mathrm{BB}}^{(I)},\mathbf{W}_{\mathrm{RF}}^{(I)},\mathbf{W}_{\mathrm{BB}}^{(I)}\}$，该过程可表示为：

$$\{\mathbf{F}^{(I)},\mathbf{W}^{(I)}\}=\sigma_R(\mathbf{A}_R\sigma_{R-1}(\ldots\sigma_1(\mathbf{A}_1\tilde{\mathbf{W}}_{T+1}+\mathbf{b}_1)\ldots)+\mathbf{b}_R),\tag{17}$$

其中 $\{\mathbf{A}_r,\mathbf{b}_r\}_{\forall r}$ 是可训练的权重和偏置，$\sigma_r(\cdot)$ 代表第 r 层的激活函数。

最终，通过采用随机梯度下降算法对E2E神经网络进行训练，从而最大化频谱效率。由于神经网络只支持实值计算，而模型的输入信号与输出的波束成形都是复值变量，算法需要对E2E网络的输入与输出做进一步的设计。

网络的主要输入由观测到的导频信号 $\tilde{\mathbf{y}}_t$ 组成，需要对其作实值映射得到网络的最终输入特征，如：$\tilde{\mathbf{y}}_t:=[\Re(\tilde{\mathbf{y}}_t),\Im(\tilde{\mathbf{y}}_t)]^T$。网络输出的感知向量和模拟波束成形需要满足恒模约束，而数字模型成形需要满足功率约束，因此需要对输出采用不同的激活函数。算法采用 $\sigma_L(\mathbf{W})=\frac{\mathbf{W}}{\|\mathbf{W}\|_2}$ 函数来满足恒模约束，$\mathbf{F}_{BB}^{(I)}=\min(P_t,\|\mathbf{F}_{RF}^{(I)}\mathbf{F}_{BB}^{(I)}\|_F)\frac{\mathbf{F}_{BB}^{(I)}}{\|\mathbf{F}_{RF}^{(I)}\mathbf{F}_{BB}^{(I)}\|_F}$ 来施加功率约束。

3 仿真结果

本章将通过仿真结果评估所提出的E2E方案的性能。基站(包括gNB和IAB节点)的天线数设定为4，UE的设定为2，射频链数量为4。空间数据流的数量设定为2，SI信道特征的 κ 设定为5dB，SI消除系数 ξ 为-80dB。对比实验中，本文采用了三种基准方案：

1) 基于精确CSI的混合波束成形：[4]中提出的基于完美CSI的混合波束成形方法，可以视为问题的最优解。

2) 基于OMP信道估计的混合波束成形：[4]中提出的混合波束成形方案，其中信道信息使用的是基于OMP方法估计的CSI。

3) 基于LSTM的E2E方法：E2E混合波束成形方案，其中导频训练阶段用LSTM设计主动感知策略。

本文在TensorFlow[15]平台实现所提出的E2E框架，并采用学习率为 5×10^{-4} 的亚当优化器[16]。在导频训练阶段，最大输入序列长度设置为6，其编码器和解码器均由3层神经网络组成，每层包含8个注意力头。此外，全连接网络的隐藏层大小设置为128。在通信阶段，使用了一个3层的HBF网络，全连接层的大小为 $[1024,1024,2N^I]$。

为了评估所提出方法的收敛性，本文绘制了不同信噪比下的模型的频谱效率曲线，训练样本数量为500，结果如图4所示。由图可知，随着训练轮次的增加，模型可实现的性能逐步提升，大约在2500个训练轮次时收敛至模型的局部最优解，这验证了所提出方案的可行性。

本文在图5中对所提出的E2E方案与基准方案进行了性能对比，绘制出了不同方案在感知时间为8的时候，不同信噪比下可实现的频谱效率。由图可知，基于精确CSI的混合波束成形方案

实现了最佳的性能，值得注意的是，本文提出的基于Transformer主动感知策略的E2E方案表现接近该上界，并由于基于LSTM的方法。可以看出，当感知的时间较短，接收到的导频长度受到限制时，基于传统信道估计的方法难以准确估计CSI，而两种基于学习的E2E方法均优于基于OMP信道

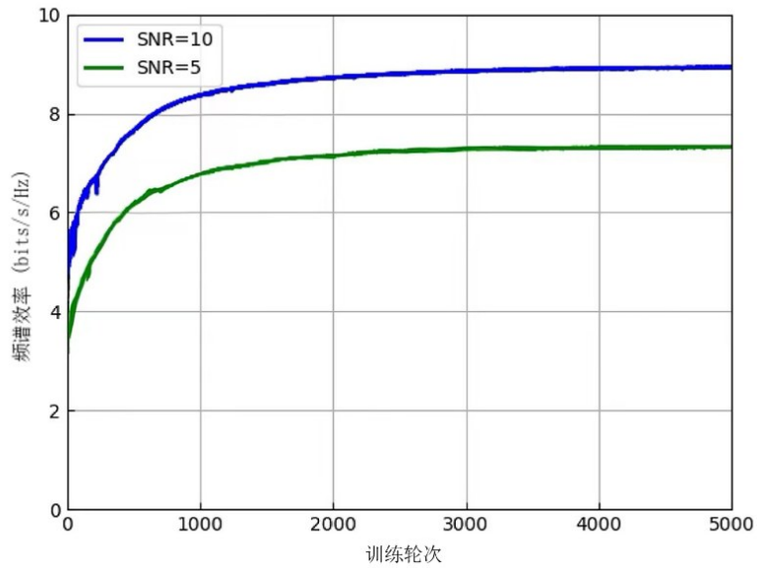


图 4　所提出的方法在不同场景下的收敛性

Fig.4　Convergence of proposed methods with different settings

估计方法。相比之下,所提出的E2E方法从接收的导频信号中提取隐式CSI,并利用其直接设计波束成形,可以实现更高的性能,并降低了信道估计造成的导频开销。

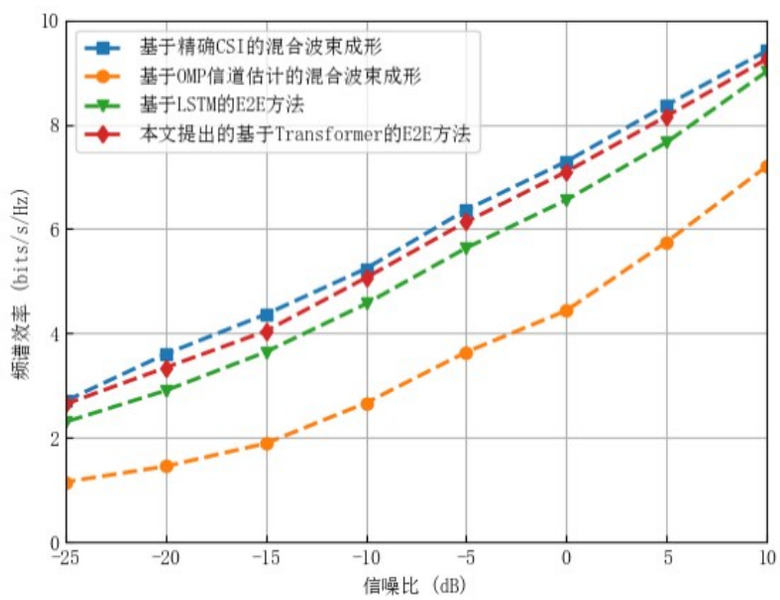


图 5　不同方案在不同信噪比下实现的频谱效率

Fig.5　Spectral Efficiency achieved by different methods versus SNRs

图6绘制了当信噪比为10dB时,不同方法在不同感知时间长度下的性能比较。随着感知时间的增加,E2E方法和传统信道估计方法的性能均有所提升。值得注意的是,即使在较短的感知时间帧下,本文提出的基于Transformer的方法可以表现出比其他方案更高的频谱效率。这证明了所提出的方法在混合波束成形中能够有效减少感知的时间并进一步降低导频开销,同时提高频谱效率。

4　结论

本文提出了一种适用全双工IAB系统的低导频开销的端到端混合波束成形框架。本文将导频训练模块和混合波束成形设计模块统一为两阶段的端到端神经网络,仅利用隐式信道特征设计波束成形,从而避免了对高维显式信道状态信息的依

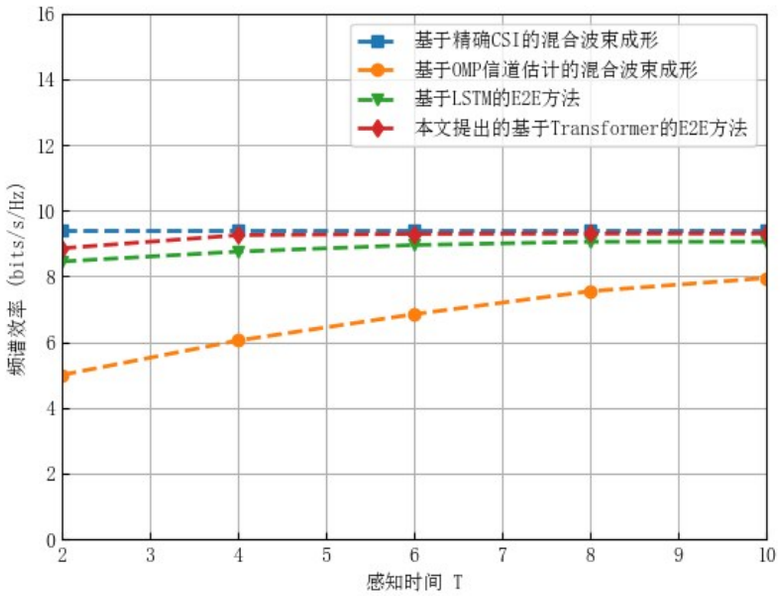


图 6 不同感知时间下的方案性能对比

Fig.6 Performance comparison versus sensing time frame

赖。首先,IAB 节点通过一个 Sensing Transformer 模块动态感知空间信道,该模块能够处理可变长度的导频观测序列,并捕获序列间元素的潜在相关性,从而设计下一时刻的感知向量。基于收集到的感知信号,进一步提出了 HBFnet,用于提取隐式 CSI并设计混合预编码器和合并器,从而有效抑制自干扰并提高频谱效率。仿真结果验证了所提出方案的有效性,能在导频开销受限的情况下表现实现更高的频谱效率。未来将考虑将所提出的端到端混合波束成形方案推广至多基站多用户的场景,增强其可拓展性与可用性。

参考文献:

[1] 赵亚军,郁光辉,徐汉青.6G 移动通信网络:愿景、挑战与关键技术[J].中国科学:信息科学,2019,49(08):963-987.
Zhao Yajun, Yu Guanghui, Xu Hanqing.6G mobile communication network:vision, challenges and key technologies[J]. Science in China:Information Science, 2019, 49(08):963-987.

[2] 毕峰.基于5G无线接入和无线回程一体化的增强技术研究[J].电信科学,2022,38(05):173-178.
Bi Feng. Research on Enhanced Technologies for Integrated 5G Wireless Access and Wireless Backhaul [J]. Telecommunication Science, 2022, 38(05): 173-178.

[3] 雷维嘉,周洋,谢显中,等.MIMO全双工双向安全通信系统的预编码矩阵设计[J].通信学报,2020,41(10):156-171.
Lei Weijia, Zhou Yang, Xie Xianzhong, et al. Precoding Matrix Design for MIMO Full-Duplex Two-Way Secure Communication Systems [J]. Journal of Communications, 2020, 41(10): 156-171.

[4] E. Balti, C. Dick and B. L. Evans, "Low Complexity Hybrid Beamforming for mmWave Full-Duplex Integrated Access and Backhaul," GLOBECOM 2022 - 2022 IEEE Global Communications Conference, Rio de Janeiro, Brazil, 2022, pp. 1606-1611, doi: 10.1109/GLOBECOM48099.2022.10001634.

[5] K. Satyanarayana, M. El-Hajjar, P. -H. Kuo, A. Mourad and L. Hanzo, "Hybrid Beamforming Design for Full-Duplex Millimeter Wave Communication," in IEEE Transactions on Vehicular Technology, vol. 68, no. 2, pp. 1394-1404, Feb. 2019, doi: 10.1109/TVT.2018.2884049.

[6] 汪周飞,袁伟娜.基于深度学习的多载波系统信道估计与检测[J].浙江大学学报(工学版),2020,54(04):732-738.
WANG Zhoufei, YUAN Weina. Deep learning-based channel estimation and detection for multicarrier systems[J]. Journal of Zhejiang University (Engineering Edition),2020,54(04):732-738.

[7] H. Jiang, M. Cui, D. W. K. Ng and L. Dai, "Accurate Channel Prediction Based on Transformer: Making Mobility Negligible," in IEEE Journal on Selected Areas in Communications, vol. 40, no. 9, pp. 2717-2732, Sept. 2022, doi: 10.1109/JSAC.2022.3191334.

[8] Z. Gao et al., "Data-Driven Deep Learning Based

Hybrid Beamforming for Aerial Massive MIMO-OFDM Systems With Implicit CSI," in IEEE Journal on Selected Areas in Communications, vol. 40, no. 10, pp. 2894-2913, Oct. 2022, doi: 10.1109/JSAC.2022.3196064.

[9] F. Sohrabi , T. Jiang , W. Cui and W. Yu , "Active Sensing for Communications by Learning," in IEEE Journal on Selected Areas in Communications, vol. 40, no. 6, pp. 1780-1794, June 2022, doi: 10.1109/JSAC.2022.3155496.

[10] G. Y. Suk , S. -M. Kim, J. Kwak , S. Hur , E. Kim and C . -B. Chae, "Full Duplex Integrated Access and Backhaul for 5G NR: Analyses and Prototype Measurements," in IEEE Wireless Communications, vol. 29, no. 4, pp. 40-46, August 2022, doi: 10.1109/MWC.003.2100099.

[11] Schäfer A M, Zimmermann H G. Recurrent neural networks are universal approximators[C]//Artificial Neural Networks – ICANN 2006: 16th International Conference, Athens, Greece, September 10-14, 2006. Proceedings, Part I 16. Springer Berlin Heidelberg, 2006: 632-640.

[12] Xu D, Ruan C, Korpeoglu E, et al. Self-attention with functional time representation learning[J]. Advances in neural information processing systems, 2019, 32.

[13] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.

[14] Xiong R, Yang Y, He D, et al. On layer normalization in the transformer architecture[C]//International Conference on Machine Learning. PMLR, 2020: 10524-10533.

[15] M. Abadi et al., "TensorFlow: Large-scale machine learning on heterogeneous distributed systems," Mar. 2016. [Online]. Available: https://arxiv. org/abs/1603.04467

[16] D. P. Kingma and J. Ba , "Adam: A method for stochastic optimization," Dec. 2014. [Online]. Available: https://arxiv.org/abs/1412.6980