



专题：智能通信技术

人工智能辅助的信道估计最新研究进展

李坤, 张静, 李潇, 金石

(东南大学移动通信国家重点实验室, 江苏 南京 210096)

摘要: 作为第六代移动通信发展的主流方向, 智能通信正在蓬勃发展中, 且初步展示了其与传统通信方法相比的优势。人工智能辅助的信道估计作为智能通信的重要组成, 在已有的研究成果中展示了其相比传统信道估计算法的优越性, 尤其是基于压缩感知技术、超分辨技术、残差学习等开展信道估计研究均获得了丰硕的成果。针对人工智能辅助的信道估计技术, 结合近来学术界最新研究成果, 分别从基于深度卷积神经网络、基于深度循环神经网络、基于超分辨技术、基于压缩感知技术 4 个维度展示了人工智能辅助的信道估计的全貌。最后, 对比总结了 4 类信道估计方法优劣及其未来研究方向, 展望了信道估计与深度学习结合的广阔前景。

关键词: 人工智能; 信道估计; 深度学习; 压缩感知; 超分辨

中图分类号: TN929

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2020288

An overview of artificial intelligence assisted channel estimation

LI Kun, ZHANG Jing, LI Xiao, JIN Shi

National Mobile Communications Research Laboratory, Southeast University, Nanjing 210096, China

Abstract: As the mainstream of the sixth generation mobile communication development, intelligent communication assisted by artificial intelligence technology is vigorously developing, and has initially demonstrated its advantages over traditional communication methods. As an important component of intelligent communication, artificial intelligence assisted channel estimation shows its superiority over traditional channel estimation algorithms in the existing research results, especially those researches based on compressive sensing technology, super resolution technology, residual learning, etc. Aiming at the channel estimation technology assisted by artificial intelligence, combined with the latest research results in the academic field, the whole picture of the channel estimation technology assisted by artificial intelligence from the four dimensions of deep convolution neural network, deep recurrent neural network, super-resolution technology and compression sensing technology were showed. Finally, the advantages and disadvantages of four kinds of channel estimation methods and their future research directions, and the broad prospect of the combination of channel estimation and deep learning were looked forward.

Key words: artificial intelligence, channel estimation, deep learning, compressive sensing, super resolution

收稿日期: 2020-09-01; 修回日期: 2020-10-10

基金项目: 国家重点研发计划项目 (No.2018YFA0701602); 国家自然科学基金杰出青年科学基金资助项目 (No.61625106); 深圳基础研究基金资助项目 (No.JCYJ20170412104656685)

Foundation Items: The National Key Research and Development Program (No.2018YFA0701602), The National Science Foundation for Distinguished Young Scholars of China (No.61625106), The Shenzhen Basic Research Foundation (No.JCYJ20170412104656685)

1 引言

随着移动通信应用场景不断涌现和扩张,随之而来的是指数增长的无线设备接入和海量的无线数据传输,无线通信面临更大容量、更密网络、更低时延的巨大挑战。因此,5G 移动通信对未来通信系统提出了更高标准,包括 10~100 倍的传输速率提升、5~10 倍的频谱效率提升、毫秒级的端到端时延等。5G 面向增强的移动互联网提供更高体验速率和更大带宽的接入能力,面向物联网场景提供更高连接密度的控制能力,面向车联网、应急通信、工业互联网等垂直行业提供低时延高可靠的信息交互能力。

作为 5G 的核心技术,大规模 MIMO (multiple-input multiple-output, MIMO) 和毫米波通信成为当前研究的热点,高效的、准确的信道估计(channel estimation, CE)为二者赋能,亦是通信系统设计的基础。在实际通信系统中,信道的时频域响应是不断变化的,阴影衰落、频率选择性衰落等会对无线信道产生巨大的负面影响,使得信道随机性增大;而接收机中的信号检测需要准确的信道状态信息(channel state information, CSI),信道估计精确与否将直接决定在接收端是否可以解调出正确的原始信号。根据是否使用导频,可以将信道估计分成 3 类^[1]:非盲信道估计、盲信道估计、半盲信道估计。非盲信道估计利用发送端插入的导频信息进行信道估计,是人们研究的重点,因其往往可以获得更好的估计性能,且计算复杂度较小,但同时带来了传输效率降低、导频污染等问题。经典的信道估计算法有最小二乘(least square, LS)估计、最小均方误差(minimum mean square error, MMSE)估计等,其中前者因其较低的计算复杂度而被广泛应用在实际通信系统当中。与此同时,人工智能(artificial intelligence, AI)技术在自然语言处理、计算机视觉、语音识别、机器翻译等领域获

得了空前的成功,自然也引起了无线通信领域研究者们的关注。研究者们期望将 AI 特别是深度学习技术与无线通信的各个层面相结合,打造面向未来通信系统的智能通信,并将其视为后 5G 时代的主流发展方向。目前,相关的研究主要分布在无线通信的物理层、数据链路层、网络层和应用层等,包括物理层收发机的设计和实现、无线资源管理与调度等。

在物理层无线通信结合 AI 技术的领域已经有大量的研究成果,包括端到端的通信系统^[2]、信道编解码^[3]、CSI 反馈^[4]和 OFDM (orthogonal frequency division multiplexing) 接收机^[5]等,一些成果可以达到甚至超越传统通信算法的性能,展示了 AI 技术在通信领域的巨大潜能,智能通信的研究热潮仍在继续。在智能通信领域中,人工智能辅助的信道估计是重要的组成部分,目前对于诸多具有挑战性的课题已经有了初步的探索成果;研究者们也在不断推动人工智能辅助的信道估计的发展,以期覆盖更多通信场景下的复杂信道环境,将信道估计的高效性、准确性不断提升。

2 与深度学习相关的知识

深度学习^[6]作为近年来 AI 算法迅猛发展的主要推动力,其已经在计算机视觉(computer vision, CV)和自然语言处理(natural language processing, NLP)等学科领域中取得了丰硕的成果。深度学习是人工智能领域的一个分支,通常借助于深度神经网络进行算法实现学习功能,包含监督学习算法和无监督学习算法。常用的监督学习算法,通过构造网络预测结果与真实值之间的损失函数,在训练阶段利用反向传播机制最小化损失函数,从而获得最优的神经网络参数。近年来,基于深度学习的图像超分辨技术及压缩感知技术正蓬勃发展,引起了通信领域研究者的关注并被运用在信道估计上。本节将对上述两种



深度学习技术进行介绍，并分析其在信道估计问题上的适用性。

2.1 图像超分辨

基于卷积神经网络的图像超分辨 (super resolution, SR) 研究, 旨在将输入的低分辨 (low resolution, LR) 图像恢复成高分辨 (high resolution, HR) 图像, 在遥感成像、视频监控、医学影像处理等领域有着广泛应用。超分辨 (SR) 技术如图 1 所示^[7], 输入的 LR 图像, 通常先经过插值预处理, 然后输入神经网络, 输出最后的 HR 图像。超分辨技术根据重建任务的不同分为两种: 单图像超分辨 (single image super-resolution, SISR) 和多图像超分辨 (multi image super-resolution, MISR)。SISR 指从一幅 LR 图像恢复出一幅 HR 图像, MISR 则是从多幅 LR 图像恢复出一幅 HR 图像, 本文仅针对前者进行讨论与分析。




图1 超分辨 (SR) 技术

2014 年 SRCNN (super resolution CNN) 被提出, SRCNN 是一个三层 CNN 结构, 每层分别对应图像特征块的提取与表示、特征的非线性映射和图像重建 3 个环节, 并使用 MSE 作为 LOSS 函数。SRCNN 的结构相对简单, 网络的每一层功能比较直观, 同时也展示了其超越传统超分辨算法的巨大优势。自 SRCNN 被提出后, 基于深度学习的 SISR 算法开始蓬勃发展。其中, VDSR^[8]和 DRCN^[9]向着扩展网络深度的方向探索, 展示了增大网络深度带来的显著增益并解决了梯度弥散的问题; 在此基础上, 基于残差学习的 EDSR^[10]和 SRGAN^[11]等网络均获得超越 SRCNN 的性能表现。

2.2 压缩感知

压缩感知 (compressive sensing, CS)^[12]的核心思想是对于可以稀疏表示的信号, 能够从低于奈奎斯特采样率的采样中重建原始信号。CS 技术为处理信息提供了新的思路, 尤其为欠定系统寻找稀疏问题带来极大便利, 近年来被广泛应用于医学影像、数字信号处理、雷达探测、应用数学等领域。

CS 技术的核心分别是信号的稀疏表达、信号的观测矩阵以及信号的重建算法^[13]。通常, 离散信号如果包含大量的零值或足够小的值、少量的非零值, 则可以称信号为稀疏的。若信号本身不稀疏, 但在变换域上稀疏, 则称信号在这个变换域上是稀疏的。观测矩阵将高维的稀疏信号投影到低维空间, 利用低维信号代替原信号进行传输, 可以极大提升信号传输效率。在信号重建阶段, 将信号重建视为一个优化问题, 从低维信号中恢复出原始的高维稀疏信号。压缩感知 (CS) 技术原理如图 2 所示。




图2 压缩感知 (CS) 技术原理

传统的 CS 重建算法大多采用迭代方式求取最优解, 计算复杂度高、重建速度慢。近年来, 基于深度学习的 CS 重建算法有效提升了重建速度和重建质量, 尤其是在低采样率下的表现令人瞩目。Mousavi 等^[14]使用堆叠的去噪自动编码器 (stacked denoising autoencoder, SDA) 作为非监督的特征学习网络, 提取信号内部的统计相关性以提升重建性能, 并同时极大提升了重建速度。DR²-NET^[15]采用深度残差网络, 融合了全连接的

线性映射网络和多个残差学习模块, 进一步提升了重建质量。ReconNet^[16]基于 CNN 架构, 融合去噪模块, 在极低感知率 (sensing rate) 下获得了超越传统重建算法的性能。

2.3 适用性分析

现有研究成果表明, 基于超分辨、压缩感知等深度学习方法的信道估计相比于传统信道估计, 已经展示出明显优势, 并在国内外研究界引起了热潮。深度学习方法的优势在于, 无须先验的信道统计信息从而避免对信道特性本身进行建模, 降低了神经网络的学习成本。同时, 以数据驱动 (data driven) 为主流的网络设计方法, 简化了神经网络的设计过程, 只需投入样本空间内的足量样本数据, 网络则可以很好完成预设的预测任务。无论是超分辨技术还是压缩感知技术, 运用在进行信道估计问题上时, 多是将待估计的信道信息视为二维 (two dimensional, 2D) 图像信息, 并将图像去噪技术运用在估计出的带噪信道 (noisy channel) 上, 以获得更准确的信道信息。其中, 超分辨技术与基于稀疏导频的信道估计问题可以有效结合, 常见于 OFDM 系统信道估计的研究中。另一方面, 压缩感知技术可以分别从时域、频域和角度域的稀疏性对信道估计问题建模, 在一般 OFDM 系统和毫米波大规模 MIMO 系统中均适用。

3 人工智能辅助的信道估计

人工智能辅助的信道估计, 是指将 AI 技术与 CE 算法相结合, 利用神经网络尤其是深度神经网络的学习能力, 更高效、准确地获取 CSI, 为通信系统赋能。本节面向人工智能辅助的信道估计技术, 从基于深度 CNN、基于深度 RNN、基于 SR 技术、基于 CS 技术 4 个方面展开详细介绍, 展示了近年来国际学术界在该领域的最新研究进展。

3.1 基于深度 CNN 的人工智能辅助信道估计

参考文献 [17] 探究了毫米波大规模

MIMO-OFDM 通信场景下, 空间相关性和频率相关性的联合对信道估计性能的增益。文献首先利用传统信道估计算法进行初始信道估计 (tentatively estimated), 然后将 S 个连续载波上的时延域信道矩阵作为二维图像信息输入深度 CNN 中。在网络前向传播过程中, 时延域的信道矩阵中利用卷积运算可以提取出空间相关性, 同时在 S 个连续载波上的卷积亦能提取频率相关性。由仿真实验结果可以看出, 该文献采用的联合信道估计可以几乎达到理想 MMSE 的估计性能, 并且在信道统计特性发生变化时, 其稳健性也远好于理想 MMSE 估计。此方法证明了联合信道估计可以充分利用多种相关信息, 在初始信道估计的结果上进一步提升信道估计精度; 同时得益于深度神经网络的强大拟合能力, 在实际信道与训练信道不匹配时, 该方法只有微小的性能损失, 优于 MMSE 等传统估计算法的稳健性。参考文献 [18] 提出的 CBDNet 克服了其他人工智能辅助的信道估计方法对 SNR 范围敏感的问题, 将噪声水平估计 (noise level estimation, NLE) 子网与非盲去噪 (non-blind denoising, NBD) 子网相结合, 并使用非对称联合损失函数完成神经网络的训练。该文献受到图像领域盲去噪 (blind denoising) 理念的启发, 将毫米波大规模 MIMO 的信道矩阵视为一个带噪图像, NLE 子网首先估计出噪声图 (noise map) 联合带噪信道图像输入 NBD 子网, NBD 子网估计出噪声矩阵, 最后将带噪信道减去估计的噪声矩阵得到最终的信道估计结果。CBDNet 采用非对称学习的理念进行去噪, 即采用不同的 LOSS 函数去应对不同噪声水平, 这有效降低了网络对于 SNR 的敏感度, 使得网络即使在训练区间之外的 SNR 条件下也具有良好的稳健性。仿真实验证明, CBDNet 相比于 DnCNN 等网络在训练过程中收敛更快, 并且超越了如 AMP、SBL 等基于 CS 的信道估计算法的 NMSE 性能。基于深度 CNN 的人工智能辅助的信道估计研究, 通常将信道矩



阵视为带噪的图像信息，通过 CNN 的卷积效应提取频域和时域上的局部相关性，以提升信道估计精度。同时，去噪也是此研究方向的关键环节，而高效的残差学习往往是研究者们的第一选择。

3.2 基于深度 RNN 的人工智能辅助信道估计

循环神经网络（recurrent neural network, RNN）对序列数据有着强大的处理能力，对数据的时域相关性十分敏感，可以有效地跟踪信道的随时间变化特征，尤其适合在高速移动场景下时变信道的估计。传统的频域信道估计假设导频符号到数据符号间的信道变化是线性的，但这一假设在高速场景下不再成立，从而导致传统频域估计算法性能的明显下降。基于 RNN 的人工智能辅助的信道估计，常使用 LSTM（long short time memory）网络或其变体来综合考虑当前时刻的 CSI 与前后多时刻 CSI 间的相关性，正逐渐被越来越多的研究者们选择作为高速移动场景下的信道估计解决方案。参考文献[19]提出的 SBGRU 估计器探究了无多径干扰的时变瑞利衰落信道估计问题，将 RNN 结构与滑动窗相结合，对于可变长度的传输符号、不同导频开销、变化的信道统计特性均具有良好的稳健性。SBGRU 估计器的基本单元是 GRU（gated recurrent unit），是 LSTM 的一种变体，在多种时序数据处理任务上可以达到与 LSTM 相近的性能，并且训练参数较少、训练过程更快。在无须任何先验的信道统计信息条件下，SBGRU 估计器可以达到接近理想 MMSE 估计器的估计性能。文章探究了 4 种长度滑动窗对估计性能的影响，得出结论是滑动窗长度应当根据信道特性选择，过长的滑动窗会增加网络复杂度而增益十分有限，但未给出滑动窗长度与信道特性间的定量分析。同样地，对于多径干扰场景的研究仍待进一步探索。参考文献[20]提出的 ChanEstNet 使用 CNN 提取信道响应特征矢量、使用 BiLSTM 进行信道估计。网络的输入是将 LS 估计所得的 CSI 图像展开成一维序列形式，首先

通过一维 CNN 提取特征矢量。正向预测时，后一时刻的 CSI 由前一时刻的 CSI 预测得到；反向预测时，前一时刻的 CSI 通过后一时刻 CSI 预测得到。ChanEstNet 可以充分利用前向和后向的导频信息，以进一步地提升信道估计的精度。网络的输出层通过全连接网络将 BiLSTM 每个时序的输出进行维度变换，使得最终的输出维度与输入维度一致，从而完成整个估计流程。通过仿真实验，ChanEstNet 在不增加计算复杂度的前提下，展示了超越传统算法的估计精度和稳健性。

3.3 基于 SR 技术的人工智能辅助信道估计

基于 SR 的人工智能辅助的信道估计是时将频域的信道矩阵视为一个含噪的低分辨率图像，用 SR 技术获得完整的时频信道矩阵——高分辨图像。通常，时频域信道矩阵中，导频处的 CSI 可以通过简单的信道估计算法如 LS 估计获取，这样的结果往往是含噪的。在求取少数导频位置处的 CSI 后，通过插值方法可以获取非导频位置的 CSI，常用的插值算法包括线性插值、高斯插值等。基于深度学习的 SR 技术，可以很好地克服插值算法带来的信道估计精度损失，并进一步提升在整个时频域上的信道估计精度。参考文献[21]研究了基于 MIMO-OFDM 的 Wi-Fi 通信过程中的信道估计问题，并使用 SRCNN 作为传统插值算法的替代，完成从导频处 CSI 到完整 CSI 估计过程。文章采用 COST 2100 信道模型生成神经网络的训练样本，分别使用 LS 估计和 MMSE 估计进行导频处 CSI 估计，并通过线性插值算法将低分辨的输入图像拉伸成高分辨图像然后送入 SRCNN。区别于原 SRCNN 的输入是 RGB 三通道的像素值，本文将通道数扩展为发送天线数乘以接收天线数，输入图像的尺寸为 64×64 ，其中导频占用的时频资源格为 14×14 或者 28×28 。在 SNR 固定为 20 dB 时，基于 SRCNN 的信道估计性能大幅超越了 MMSE/LS 估计加插值算法，展示了 SR 技术在 MIMO-OFDM 信道估计中的广阔前景。参考文献[22]

提出的 ChannelNet 同样采用了前述的 SR 与 CE 的结合理念,并在 SRCNN 的基础上,加入了 DnCNN 网络作为去噪网络,充分利用了残差学习的优势,加速网络的训练过程并进一步提升信道估计精度。输入图像的尺寸为 14×72 ,其中导频占用的时频资源格为 48 个。其中, SRCNN 与 DnCNN 分别进行训练,并在训练后者时固定前者的网络参数。网络在 $\text{SNR}=12 \text{ dB}/22 \text{ dB}$ 下训练得到两组网络参数,在低 SNR 时采用前一组参数进行网络的前向传播,在高 SNR 时采用后一组参数。仿真结果表明,在无须任何先验的信道信息时, ChannelNet 可以获得与理想 MMSE 信道估计相似的性能。参考文献[23]提出的 ReEsNet 则在 ChannelNet 基础上进一步提升估计精度并降低了计算复杂度。与 ChannelNet 采用的插值方式不同, ReEsNet 使用反卷积(transposed convolution)实现 LR 图像的分辨率拉伸,从而可以更好地支持多种导频分配方式。而且,反卷积层在网络的最后,有效降低了网络在中间层的传参负担。另外, ReEsNet 采用端到端的训练方式,并且网络参数比 ChannelNet 减少了约 92%。仿真结果表明, ReEsNet 在使用较少导频资源时,估计性能相比 ChannelNet 有 2~5 dB 的性能提升。

3.4 基于 CS 技术的人工智能辅助信道估计

一种 AI 与 CE 算法的结合方式,是将迭代算法近似替换成深度神经网络,将每一层网络视为原算法的一次或多次迭代过程。这样的结合方式,通常要求迭代算法的结构相对简单,而对于具有较高计算复杂度如包含高维矩阵求逆的算法并不适用。CS 重建常用的 AMP 算法,引起了通信领域研究者的注意,并结合深度神经网络来解决波束域毫米波大规模 MIMO 信道估计问题。参考文献[24]提出的 LDAMP 网络以 D-AMP 算法作为网络设计的基础,将信道估计转换成信号恢复问题。其将信道矩阵视为 2D 图像,结合残差学习理念使用神经网络学习信道估计噪声,然后用含噪信道

矩阵减去学习出的残差噪声,从而得到准确的信达估计结果。LDAMP 网络的每一层包含 DnCNN(denoising CNN)降噪器、散度估计器和关联系数组成,其中, DnCNN 含有 20 个卷积层,深度的网络结构可以很好地处理高斯噪声。这种基于残差的训练方式,不仅有效降低了训练时间,同时增加了深度神经网络的可解释性和模型的有效性。文章的仿真结果表明,以 DnCNN 去噪器为核心的 LDAMP 网络可以超越 D-AMP 算法以及其他基于 CS 的信道估计算法性能。受到参考文献[24]的启发,Wei 等^[25]提出的 LampResNet 结合迭代的 AMP 算法和残差学习来解决波束域毫米波大规模 MIMO 的信道估计问题。LampResNet 包含级联的 LAMP 网络和 ResNet 网络,前者进行初始的信道估计并获得二维信道矩阵作为第二部分的输入,后者将 LAMP 估计的信道矩阵进一步优化并去除噪声。与参考文献[17]不同的是, ResNet 是包含多个串联去噪块的去噪器,每个去噪器包含 3 个卷积层。仿真结果表明, LampResNet 获得了超越 LDAMP 的性能表现,并且有着比后者更低的计算复杂度。另一种基于 CS 重建的人工智能辅助的信道估计算法,是从毫米波大规模 MIMO 信道稀疏性受损的角度出发,利用神经网络选择正确的索引以完成重建。由于受到有限的波束域分辨率影响,信道能量的泄漏会破坏波束域信道稀疏性,以致信道参数中原本应当为 0 的值变成极小的非零值。传统的 OMP 算法和 DGMP 算法等,是逐向量的贪婪选择参数索引,而不能保证全局的最优性。参考文献[26]提出的 DLCS 方法,由级联的波束域信道幅值(channel amplitude)估计网络和信道重建网络组成,前者用于估计信道并预测波束域信道参数主要索引(dominant beamspay channel entry)以完成重建。

3.5 对比与分析

综合第 3.1~第 3.4 节的分析,4 种深度学习方法辅助的信道估计方式对比见表 1。



表 1 不同深度学习方式辅助的信道估计对比

深度学习方法	典型应用场景	特点分析
深度 CNN	毫米波大规模 MIMO 系统	多子网联合、稳健性强、计算复杂度高
深度 RNN	时变信道及高速移动场景	聚焦 CSI 时间相关性、LSTM 网络
SR 技术	OFDM 通信系统	依赖图像去噪算法、稳健性较差
CS 技术	毫米波大规模 MIMO 系统	深层展开理念、复杂的去噪器设计

基于深度 CNN 的人工智能辅助的信道估计，拥有比传统估计算法更强的稳健性，但也面临计算复杂度较高的挑战。良好的稳健性得益于神经网络强大的学习能力，可以在训练数据中获取隐含的信道信息，在特定的训练场景以及一般场景中都可以发挥作用。这些数据，可以是实际通信场景中采集获得的数据，亦可以是通过仿真获得的近似通信系统模型产出的数据。神经网络在被部署使用在新的通信场景中时，利用少量的新场景下的数据进行重训练，进而对网络参数进行微调（finetune），即可完成对新场景的快速适应并发挥神经网络稳健性优势。

不同于基于深度 CNN 的信道估计，基于 SR 技术的研究通常以较小的导频开销获得初始的 CSI 估计，并且将超分辨的一些基本概念融入到网络设计过程中，比如分辨率拉伸、特征间非线性映射等。参考文献[21-23]展示了 SR 技术对于信道估计的有益影响，尤其适合多载波通信系统如 OFDM 通信的信道估计。同时，去噪器使用的深层神经网络往往也会引起计算复杂度的增加，如参考文献[22]使用的 DnCNN 是 ChannelNet 计算复杂度高于 ReEsNet 的主要原因；另外，在信道特性发生变化时，噪声的特征也会改变，致使去噪器的性能受到影响，基于 SR 技术的人工智能辅助的信道估计的稳健性仍需进一步探究。

基于深度 RNN 的人工智能辅助的信道估计研究，多数聚焦于信道的时变特性，利用 RNN 的状态记忆特性可以充分利用 CSI 的时间关联性，

更好地追踪信道的变化过程。目前的研究均基于简单的时变信道模型，需要将研究扩展到更多、更复杂的通信场景中去。

基于 CS 技术的信道估计，无论是将迭代的 CS 重建算法用神经网络替代，或是寻找 CS 重建过程的正确参数索引，均展示了深度学习超越传统算法的性能，在毫米波大规模 MIMO 的信道估计研究中正大放异彩。同时，类似 LDAMP 和 LampResNet 的深层网络结构，降低网络的计算复杂度是第一要务，而提升去噪网络对变化 SNR 尤其是训练 SNR 范围以外的稳健性也需投入更多的研究精力。

综合上述对比分析，人工智能辅助的信道估计研究结合了神经网络本身与通信场景二者的特点，如时变信道的时变相关性决定了 RNN 在该类通信场景中的适用性、稀疏导频结构与低分辨率图像的类比使得超分辨在此类信道估计问题中的有效性。同时，神经网络的稳健性、计算复杂度较高的问题也十分突出，如何提升神经网络对通信场景的快速适应性以及降低神经网络的部署成本，也将是业界必须面临的棘手问题。

目前，新的通信场景不断涌现，深度学习方法也在不断发展更新中，找到二者之间新的匹配模式，也将为人工智能辅助的信道估计注入新的活力。例如，在未来的无线通信研究中，通信频段向太赫兹甚至更高频段的探索过程将会带来更多的挑战，而当下对于毫米波频段的研究将为其提供宝贵的研究经验。于此同时，应当清楚看到诸如计算机视觉、自然语言处理等领域的快速发

展, 将类似 SR 技术、CS 技术等行之有效的深度学习引入无线通信领域中来, 用新的技术来为研究问题提供新的解决思路。

4 未来研究方向

基于 CS 技术的信道估计, 将成为毫米波信道估计发展的主要推动力。由信道估计获取显式 CSI 对于完全发挥毫米波带宽优势和大型天线阵列的增益至关重要。从毫米波信道的稀疏性出发, 将 CS 技术与信道估计相结合, 将复杂的 CS 重建算法分解, 将一次或多次的迭代过程用一层神经网络替代, 并将迭代过程中的关键参数替换成神经网络学习的结果, 这种深层展开 (deep unfolding) 的概念为迭代算法与 AI 技术结合开辟了新的方向。同时, 将相关研究从毫米波频段转至太赫兹频段从而为 6G 移动通信系统研究打下基础, 亦是一个极具挑战性的课题。

基于 SR 技术的信道估计, 为多载波通信系统的信道估计问题带来新的思路。研究者们常将时频域信道矩阵视为一个二维图像, 兼顾时间轴和频率轴上的相关性, 使用简单的 LS 估计获得导频处的 CSI 以组成原始的 LR 图像输入; 同时利用超分辨、图像去噪和残差学习等图像领域的先进技术, 进一步提升信道估计的精度, 以获得完整的 CSI 输出。在此基础上, 研究如何提高降噪效果、降低网络传参负担、降低导频开销、适应多种导频排列方式等, 均有重要的现实意义。

同时, 基于深度神经网络的人工智能辅助的信道估计也在蓬勃发展。如在高速移动场景下, 信道的时变特性可以通过 RNN 的记忆功能进行追踪, 尤其是具有双向性的 BiLSTM 受到了研究者们青睐。未来的相关研究将从提升信道跟踪性能、信道预测技术、抗多径干扰等方面开展, 进一步提升时变信道的估计精度。另一方面, 深度 CNN 抓取空间和频率相关性的联合信道估

计算法, 启发了研究者们向波束域、角度域等多个维度索取更多的信道信息, 并通过级联的神经网络进行传递。解决降低网络的复杂度、融合不同域的信道信息、提升对变化信道特性的稳健性的挑战, 将会为基于 CNN 的信道估计增加活力。

作为智能通信的重要组成, 人工智能辅助的信道估计已经在大量的研究过程中展示了其先进性, 但是其仍面临不可忽视的实际应用难题。首先, 深度神经网络的计算复杂度往往较高, 难以满足实际通信系统中的实时性要求。如何在大带宽、高吞吐量的通信系统中, 设计实现轻量化网络并部署在通讯设备之上, 是从理论研究转换到实际应用的重点课题。同时, 信道估计神经网络对不同 SNR 条件、不同信道特性的稳健性仍需进一步提升。在神经网络的训练阶段, 由于训练样本的有限性, 导致网络只能学习有限样本空间内的信道信息, 而在训练范围之外的 SNR 和信道特性对于网络而言是陌生的、难以处理的。综上, 这些挑战的存在, 为后续研究者们留下了广阔的探索空间。

5 结束语

本文从传统通信过程信道估计问题出发, 引出深度学习方法在该领域的潜在价值, 并以 CS 和 SR 技术为例, 介绍了深度学习在图像领域的具体应用实现并分析了其在信道估计问题上的适用性。然后分别从基于 CS 技术、基于 SR 技术、基于深度 RNN、基于深度 CNN 4 个方面, 以近来学术界的最新研究进展为例详细介绍了人工智能辅助的信道估计的全貌。人工智能辅助的信道估计是智能通信的重要组成, 高效、准确的信道估计结果为整个通信系统赋能。丰富的研究成果证明, AI 技术能够为信道估计研究带来增益, 人工智能辅助的信道估计有着重要的研究价值和巨大发展潜力。



参考文献：

- [1] ZENG Y, NG T. A semi-blind channel estimation method for multiuser multiantenna OFDM systems[J]. *IEEE Transactions on Signal Processing*, 2004, 52(5): 1419-1429.
- [2] DORNER S, CAMMERER S, HOYDIS J, et al. Deep learning based communication over the air[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(1): 132-143.
- [3] HE Y, ZHANG J, WEN C, et al. TurboNet: a model-driven DNN decoder based on max-log-MAP algorithm for turbo code[C]// *IEEE VTS Asia Pacific Wireless Communications Symposium*, Piscataway: IEEE Press, 2019: 1-5.
- [4] WEN C, SHIH W, JIN S. Deep learning for massive MIMO CSI feedback[J]. *IEEE Wireless Communications Letters*, 2018, 7(5): 748-751.
- [5] GAO X, JIN S, WEN C, et al. ComNet: combination of deep learning and expert knowledge in OFDM receivers[J]. *IEEE Communications Letters*, 2018, 22(12): 2627-2630.
- [6] SCHMIDHUBER J. Deep learning in neural networks: an overview[J]. *Neural Networks*, 2015(61): 85-117.
- [7] DING C, LOY C C, HE K, et al. Learning a deep convolutional network for image super-resolution[C]// *Proceedings of ECCV*. Cham: Springer, 2014: 184-199.
- [8] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks[C]// *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Piscataway: IEEE Press, 2016: 1646-1654.
- [9] KIM J, LEE J K, LEE K M. Deeply-recursive convolutional network for image super-resolution[C]// *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2016: 1637-1645.
- [10] LIM B, SON S, KIM H, NAH S, et al. Enhanced deep residual networks for single image super-resolution[C]// *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition Workshops*. Piscataway: IEEE Press 2017: 1132-1140.
- [11] LEDIG C, THEIS L, HUSZAR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]// *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2017: 105-114.
- [12] DONOHO D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306.
- [13] FOUCART S, RAUHUT H. A mathematical introduction to compressive sensing[M]. New York: Springer-Verlag, 2013.
- [14] MOUSAVI A, PATEL A B, BARANIUK R G. A deep learning approach to structured signal recovery[C]// *Proceedings of 53rd Annual Allerton Conference on Communication, Control, and Computing*. Piscataway: IEEE Press, 2015: 1336-1343.
- [15] YAO H T, DAI F, ZHANG D M, et al. DR2-Net: deep residual reconstruction network for image compressive sensing[J]. *Neurocomputing*, 2019, 359: 483-493.
- [16] KULKARNI K, LOHIT S, TURAGA P, et al. ReconNet: non-iterative reconstruction of images from compressively sensed measurements[C]// *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2016: 449-458.
- [17] DONG P, ZHANG H, LI G Y, et al. Deep CNN for wideband mmWave massive mimo channel estimation using frequency correlation[C]// *IEEE International Conference on Acoustics, Speech and Signal Processing*. Piscataway: IEEE Press, 2019: 4529-4533.
- [18] JIN Y, ZHANG J, AI B, et al. Channel estimation for mmWave massive MIMO with convolutional blind denoising network[J]. *IEEE Communications Letters*, 2020, 24(1): 95-98.
- [19] BAI Q, WANG J, ZHANG Y, et al. Deep learning-based channel estimation algorithm over time selective fading channels[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2020, 6(1): 125-134.
- [20] LIAO Y, HUA Y, DAI X, et al. ChanEstNet: a deep learning based channel estimation for high-speed scenarios[C]// *Proceedings of IEEE International Conference on Communications*. Piscataway: IEEE Press, 2019: 1-6.
- [21] SHI Q, LIU Y, ZHANG S, et al. Channel estimation for Wi-Fi prototype systems with super-resolution image recovery[C]// *Proceedings of IEEE International Conference on Communications*. Piscataway: IEEE Press, 2019: 1-6.
- [22] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation[J]. *IEEE Communications Letters*, 2019, 23(4): 652-655.
- [23] LI L, CHEN H, CHANG H, et al. Deep residual learning meets OFDM channel estimation[J]. *IEEE Wireless Communications Letters*, 2020, 9(5): 615-618.
- [24] HE H, WEN C K, JIN S, et al. Deep learning-based channel estimation for beamspace mmWave massive MIMO systems[J]. *IEEE Wireless Communications Letters*, 2018, 7(5): 852-855.
- [25] WEI Y, ZHAO M, ZHAO M, et al. An AMP-based network with deep residual learning for mmWave beamspace channel estimation[J]. *IEEE Wireless Communications Letters*, 2019, 8(4): 1289-1292.
- [26] MA W, QI C, ZHANG Z, et al. Deep learning for compressed sensing based channel estimation in millimeter wave massive MIMO[C]// *Proceedings of International Conference on Wireless Communications and Signal Processing*. Piscataway: IEEE Press, 2019: 1-6.

[作者简介]



李坤（1995—），男，东南大学移动通信国家重点实验室硕士生，主要研究方向为无线通信物理层技术与深度学习结合。



李潇（1982—），女，东南大学移动通信国家重点实验室副教授、硕士生导师，主要研究方向为移动通信理论与关键技术、人工智能在无线通信中的应用等。



张静（1993—），女，东南大学移动通信国家重点实验室博士生，主要研究方向为 5G 移动通信物理层关键技术、机器学习等。



金石（1974—），男，东南大学移动通信国家重点实验室教授、博士生导师，主要研究方向为移动通信理论与关键技术、物联网理论与关键技术以及人工智能在无线通信中的应用等。