2024年9月

文章编号: 2095-4980(2024)09-1014-07

基于自编码器的动态协作中继系统

吴 楠,王悦然,王旭东

(大连海事大学 信息科学技术学院, 辽宁 大连 116026)

摘 要:鉴于大多数现有端到端自编码器(AE)仅适用于点对点的通信场景,提出一种基于AE 的动态协作通信系统,将基于深度学习的AE扩展到多点通信系统。构建了3个神经网络子系统, 分别用于学习发送端、中继节点和接收端的最佳编码、传输和解码,通过三者的联合训练达到多 点通信系统的最佳传输性能。其中,发送端和接收端使用一维卷积层进行信号特征的提取及学习, 中继节点通过引入密集层和一维卷积层,支持放大转发(AF)和解码转发(DF)两种经典的中继协作 方式。仿真实验表明,在加性高斯白噪声以及瑞利衰落信道条件下,提出的模型采用两种不同的 协作方式,其误码性能均优于单一点到点通信系统,验证了系统方案的可行性和有效性。此外, 该系统支持动态的节点拓扑结构,在无需额外训练的条件下,本系统支持中继节点数量实时变化。 关键词:自编码器:动态中继:卷积神经网络

中国分类号: TN929.5
文献标志码: A
doi: 10.11805/TKYDA2022242

Dynamic cooperative relay system based on autoencoder

WU Nan, WANG Yueran, WANG Xudong

(School of Information Science and Technology, Dalian Maritime University, Dalian Liaoning 116026, China)

Abstract: Considering that most existing end-to-end Autoencoders(AE) are only suitable for pointto-point communication scenarios, this paper proposes a dynamic collaborative communication system based on AE, extending the AE based on deep learning to multi-point communication systems. Three neural network subsystems are constructed, each for learning the optimal encoding, transmission, and decoding at the transmitter, relay node, and receiver, respectively, with joint training of the three to achieve the best transmission performance of the multi-point communication system. Among them, the transmitter and receiver use one-dimensional convolutional layers for signal feature extraction and learning, while the relay node supports two classic relay cooperation methods, Amplify-and-Forward (AF) and Decode-and-Forward(DF), by introducing dense layers and one-dimensional convolutional layers. Simulation experiments show that under the conditions of additive white Gaussian noise and Rayleigh fading channels, the proposed model, using two different cooperation methods, has better error performance than a single point-to-point communication system, verifying the feasibility and effectiveness of the system scheme. In addition, the system supports dynamic node topologies, and without the need for additional training, this system supports real-time changes in the number of relay nodes.

Keywords: autoencoder; dynamic relay; Convolutional Neural Networks

通信的本质是利用发射机和接收机,把来自信源的信息可靠地传送到目的地。近年来,随着人工智能 (Artificial Intelligence, AI)技术的飞速发展,特别是深度学习(Deep Learning, DL)的持续突破,基于DL的通信系 统设计成为了关键研究问题。目前,学者们已在通信系统中成功引入了一些经典DL框架,并在调制识别¹¹、信 道估计^[2-4]、信道译码^[5-6]等问题上进行了深入研究。近几年来,基于端到端学习的传输系统成为通信领域提出的 一种新的设计理念,其内核是用深度神经网络(Deep Neural Networks, DNNs)学习发送信号的最佳表征形式和接 收信号的最佳译码算法。由于利用自编码器(AE)框架^[7]可以端到端地学习点对点通信系统的收发机,因而AE成 为了一个极有前途的解决方案^[8]。文献[9]提出了利用卷积神经网络(CNNs)实现AE的方法,但网络在高信噪比条 件下出现了明显的地板效应。为改进其泛化性, 文献[10]提出了一种改进的 CNN 端到端自编码器系统(CNN-AE), 对参数重新进行了设计, 优化了网络性能。

与点对点网络相比,使用中继节点的协作网络更为复杂^[11],它的基本原理是利用其他通信节点实现中继传输,提升通信的有效性和可靠性。如,在无线网络中,协作分集有利于提高信道空间分集^[12]。传统的协作分集 技术通过多个中继节点发送与源节点相同的信息给目的节点,可提高系统的误码率(Bit Error Rate, BER)性能。 协作通信是对抗衰落,提高系统传输能力、系统误码性能的有效手段,成为目前通信领域的一个重要研究方向。

放大转发(AF)和解码转发(DF)协议是两种被广泛使用的传统中继算法。AF协议中,中继节点根据功率限制 直接将接收到的信号放大,并将放大后的信号转发到目的节点。DF协议中,中继节点先对接收到的信号进行解 码,再对解码后的信号进行重新编码后,将其传输到接收机。传统的中继协作方式具有其局限性:AF协议的主 要缺点是中继节点在放大信号功率的同时也会将噪声放大,不利于接收端解调信号。DF协议的主要缺点是中继 节点解码产生的错误会引起错误传播,降低接收端的有效信噪比(Signal-to-Noise Ratio, SNR)。基于上述局限 性,学者们开始尝试设计基于神经网络(Neural Networks, NNs)的中继协作通信系统,试图利用 NNs设计出更高 效、准确的训练协作通信系统。文献[11]中提出了一种基于 DNN 的中继辅助协作通信,并针对经典三节点协作 系统,设计了一种基于 NNs 的收发模型。结果证明了提出模型的 BER 性能可媲美传统 AF和 DF中最先进方法的 性能。文献[13]将 AE 用于 AF中继方案,根据有无信道状态信息(Channel State Information, CSI)知识,设计了 AF 的方式。然而上述几个文献仅利用 DL 实现了对中继协作系统的构建,未考虑设计多中继协作提高通信系统可靠 性以及动态中继协作的鲁棒性;并且,对于多中继通信系统,传统研究多局限于利用算法优化通信系统的中继 选择。如,文献[14]通过设计动态规划算法监视中继当前的状态,优化节点所选中继的数量;文献[15-16]为避免 系统资源过度使用,提出了基于全局 CSI 最优中继选择方案。但目前并未有学者立足于神经网络研究和解决中继 数量的动态变化对于通信系统整体的影响。

基于上述问题,本文设计了一种以多个一维卷积层(Conv1D)为基础的自编码器中继动态协作系统,实现信号 调制、放大/解码转发、解调等功能。通过训练网络模型,该系统可在整个 SNR 范围内,利用不同的中继协议正 常工作,其误码性能在中继数量大于1时优于点对点 CNN-AE 通信系统。通过对加性高斯白噪声(AWGN)和瑞利 (Rayleigh)衰落信道下的系统性能进行仿真分析,验证了系统的有效性和可靠性。

1 系统模型

一个典型的中继协作系统包含发射机、中继节点和接收机。图1、图2分别为采用AF、DF中继方式的系统 图。相比于传统的通信系统,本文使用基于DL的AE端到端的学习整个通信过程中发射机、中继节点和接收机 的信号表征、传输及解码方案。考虑长距离通信的实际模型,信息传输可分为2个阶段:第1阶段为广播阶段, 由发送端将包含比特信息的符号经过信道广播给中继节点;第2阶段为协作阶段,中继节点接收到编码的信息 后,根据AF或DF协议对接收到的信号进行处理,然后转发到接收端,借此帮助信源传输信号。最后,接收端 试图恢复收到的受到噪声污染的信息,使其与信源信息尽可能地接近。

1.1 AE 模型

设中继节点的个数为 N_r ,且系统以 $M=2^k$ 进制符号进行调制。为保证各中继收发的数据相互独立,发送端将输入的比特信息按照每kN比特分组转换为独热编码(one-hot)向量S。如图1所示,发射机包含2个Conv1D层,实现信源对信息S的特征提取。Conv1D层可同时处理整个符号序列S,即可以同时处理 $kN \times L$ 比特信息,其中L为每帧符号数(块长度)。发送端第1个Conv1D层由128个滤波器构成,用于将one-hot向量从 2^{kN} 维空间映射到128维空间。此映射可从高维空间中提取信源信息的更多潜在特征,为不同的信道环境寻找最佳的传输码元映射方法;同时有利于接收端尽可能地恢复相应的信息。然后,通过另一层Conv1D层将高维空间特征映射为2个实数表示的复信号,完成对信源信息的信号调制。每次符号发送过程等效为占用n个I/Q复数子信道,系统的编码速率为R=k/n。发射机的功率归一化层将符号从128维空间压缩成 $2nN_r$ 维,并对发送信号进行能量约束,得到发送信号X。

无线信道中,传输信号主要受高斯白噪声的加性干扰以及信道的乘性干扰。将有固定方差的加性高斯白噪 声添加到信号中,对于平坦衰落信道,发送的信号*X*需在到达接收端前与信道的冲击响应进行卷积。系统的信 道建模为:

$$Y = HX + N, Y \in \mathbb{C}^{N_r \times n}$$



图2 DF中继系统框图

在AF协议下,中继节点对收到的数据不进行任何的解调或解码操作,仅将其放大。本文采用4层全连接密 集(Dense)层构建AF中继节点,如图1所示,在每个Dense层后添加批处理归一化(Batch Normalization, BN)层, 消除因 Dense 层隐藏节点的减少而产生的协方差偏移。在DF协议下,中继节点对收到的数据先进行解码,尽可 能将源节点与中继节点之间的噪声影响剔除,之后重新编码,如图2所示。AF节点和DF节点的AE结构分别如 表1~2所示。

表1 AF 中继节点结构

表2 DF中继节点结构

Table1 AF relay node structure				Table2 DF relay node structure		
layer	activation function	output dimensions		layer	activation function	output dimensions
Dense+BN	linear	$L \times 128$		Conv1D	Elu	$L \times 128$
Dense+BN	Elu	$L \times 64$		Conv1D	Softmax	$L \times 2^{kN_r}$
Dense+BN	Elu	$L \times 32$		Conv1D	Elu	$L \times 128$
Dense+BN	Softmax	$L \times 2nN_r$	_	Conv1D	linear	$L \times 2nN_r$

接收端的任务是根据所学习的信号特征,将接收信号的2^{kv},种情况进行分类。接收机采用2层Conv1D进行信号解码,第1层Conv1D包含128个滤波器,用于将接收到的信号2^{kv},解压缩到128维;第2层Conv1D将接收到的信号恢复到2^{kv},维。在两层间进行逐级特征提取,恢复被信道畸变影响的信号。通过比特位之间的联系在高维空间中寻找二进制消息序列S的映射关系,估计出原始one-hot向量。同时,假设CSI在接收机已知,与接收信号 Y 一并传递给接收机,为接收端提供完美的信道状态信息,使最终估计得到的信号 Ŝ 尽可能地接近信源信息 S。本文提出的动态协作中继通信系统发射机和接收机的详细结构参数如表3 所示。设定神经网络的层数时,需考虑到,虽然Conv1D 层数可以提高系统网络的提取信号潜在信息和分类能力,但随着网络层数的增加,网络的梯度会消失或网络训练变得很困难。仿真试验表明,发送端和接收端模块采用2层Conv1D可以充分保障网络的学习性能,并达到最优的传输可靠性。

1.2 模型的训练

图1和图2系统的训练数据是将随机生成的二进制数据按照比特映射的方式编码为one-hot向量,因此可将系统传输数据的训练过程视为一种多分类问题。将one-hot向量作为训练数据和标签数据,对于二者的不同概率分布情况,交叉熵损失(Cross Entropy Loss, CEL)函数是最好的一种评价方法,其表达式为:

$$L_{\rm CE} = -\frac{1}{N_{\rm sam}} \sum_{i=1}^{N_{\rm sam}} \sum_{j=1}^{N_{\rm c}} y_{ij} \log \hat{y}_{ij}$$
(2)

式中:y和 \hat{y} 分别为训练数据以及标签数据; N_{sam} 和 N_{c} 分别为分类数和样本数。

由于发送端与接收端的 NNs 代替了编码器的调制与 编码功能以及解码器的信号解调功能,从 DL 的角度 看,其维度大小相当于使用的滤波器个数。若滤波器 个数太少,则没有充分的高维空间去获得信号的潜在 特征,系统的训练效果很差;若滤波器个数太多,会 使训练时间延长,系统难以收敛。考虑到实验数据的 调制阶数,本文将发送端和信号解调模块的滤波器个 数设置为128,如表3 所示。

考虑到要增加系统网络的非线性,赋予系统实现分 类软判决的能力,并使系统在恰当的时候实现线性映 射,选取 Elu、Softmax 和 Linear 函数作为发送端编码模

表3 动态协作中继通信系统结构发射机和接收机的结构 Table3 The transmitter and receiver structures of the dynamic collaborative relay communication system

	layer	activation function	output dimensions
	one-hot input	none	$L \times 2^{kN_r}$
	Conv1D	Elu	$L \times 128$
transmitter	Conv1D	linear	$L \times 2nN_{\rm r}$
	power norm layer	none	$L \times 2nN_{\rm r}$
	Conv1D	Elu	$L \times 128$
receiver	Conv1D	Softmax	$L \times 2^{kN_r}$

块、中继及接收端信号解调模块的激活函数。同时选用Adam优化器,因其能够从梯度均值及梯度平方两个角度 自适应地调节对梯度下降步长的计算,保障了神经网络的收敛,避免了精确度的波动。学习率设定为0.001,当 损失函数结果不再下降时,学习率降为原值的1/10。

AE 模型的训练过程中,固定的训练信噪比的选取也极为重要,它是影响系统性能的重要因素之一。系统接收端需要在决策边界收集足够多的统计样本,学习已被噪声污染的信号特征。若信噪比取值过小,则有用信号将被噪声淹没,网络无法提取信号特征,只能学习到噪声特征;若信噪比设置过大,则接收机只能学习到完美的信号特征,样本中只有少部分分布在决策边缘附近,系统无法训练出最佳的译码性能,任何小的噪声干扰都可能影响接收机的正确分类。因此需选取适合的训练信噪比,保证网络能够在决策边界有足够的训练样本,展现出系统的最佳性能。

本文的数据样本集为随机生成的二进制比特序列,考虑到网络训练效率,设定训练集样本数为12800,每条 样本包含L个符号,每个符号含有kN,比特信息。测试集包含64000条数据,批处理量设定为64。

1.3 模型复杂度

使用 NNs 构建 3 个通信子系统,在终端设备上运行 CNN 与 Dense 层,兼顾其存储和运算能力,因此需对系统进行建模复杂度分析,包括了模型的计算量分析(时间/计算复杂度)以及模型参数量分析(空间复杂度)。

在计算模型的时间复杂度时,最常用的一种度量方法是考虑模型浮点运算的次数(Floating Point Operations Per Second, FLOPS),即模型理论计算量。这是一种间接的测量方法,可用来估算计算速度和时延等。单个 CNN 的时间复杂度为: $O(M^2K^2C_{in}C_{out})$,其中, M为卷积核输出特征图的边长; K为每个卷积核的边长; C_{in} 为每 个卷积核的输入通道数,即上一层的输出通道数; C_{out} 为本卷积层的卷积核个数,即输出通道数。每个 CNN 中, 数据都以三维形式存在,可将其视为由多个二维数据矩阵叠加在一起,将其中的每一个二维数据矩阵称为一个

特征图。输出特征图的尺寸由输入向量矩阵尺寸X、 卷积核尺寸K、padding(p)、stride(s)这4个参数决定: $M = (X - K + 2 \times p)/(s + 1)$ 。因此, CNN 的整体时间复杂 度为: $O\left(\sum_{l=1}^{p} M_l^2 K_l^2 C_{l-1} C_l\right)$ 。其中, D为系统中 CNN 的 层数,即网络的深度; l为第l个 CNN; C_l 为第l层 CNN 的输出通道数 C_{out} ; C_{l-1} 为第l层 CNN 的输入通 道数 C_{in} 。由此可见, CNN 整体时间复杂度是所有 CNN 的时间复杂度的累加。本文中,发射机、接收机 以及 DF 中继系统均由 Conv1D构建,具体的时间复杂 度计算所需参数如表4所示。

AF 中继节点使用 Dense 层构建,其 FLOPs 计算式 为: $O\left(\sum_{l=1}^{p} (2I_l - 1)O_l\right)$,其中, I_l 为第 l 层的输入层维 度; O_l 为第 l 层的输出层维度。AF 中继节点的输入、 输出数据维度已由表 1 给出。

模型的参数数目由其空间复杂度所决定。由于受 维度诅咒的约束,模型中的参数越多,所需的数据量 就越大。模型中包含的参数,不仅决定了模型的规 模,还会影响到模型学习时所占的内存大小。CNN的 空间复杂度严格来讲由两部分组成:总参数量和各层 输出特征图。总参数量是模型所有带参数的层的权重 参数总量,即模型体积;各层输出特征图是模型在实 时运行过程中每层所计算出的输出特征图大小。CNN

的空间复杂度为: $O\left(\sum_{l=1}^{D} K_l^2 C_{l-1} C_l + \sum_{l=1}^{D} M^2 C_l\right)$ 。由表达

表4	动态协作中继通信系统结构发射机和接收机及
	DF中继节点时间复杂度计算参数

Table4 The transmitter and receiver structures of the dynamic collaborative relay communication system and their time complexity calculation parameters

	parameter	size
	kernel size K	1×1
	input vector matrix size X_1	$L \times 2^{kN_r}$
	input vector matrix size X_2	$L \times 128$
tuonomitton	number of channel C_0	2^{kN_r}
transmitter	number of channel C_1	128
	number of channel C_2	$2nN_r$
	padding	1
	stride	1
	kernel size K	1×1
	input vector matrix size X_1	$L \times 128$
	input vector matrix size X_2	$L \times 2^{kN_r}$
	input vector matrix size X_3	$L \times 128$
	input vector matrix size X_4	$L \times 2nN_r$
DE rolou	number of channel C_0	$2nN_r$
Diffelay	number of channel C_1	128
	number of channel C_2	2^{kN_r}
	number of channel C_3	128
	number of channel C_4	$2nN_r$
	padding	1
	stride	1
	kernel size K	1×1
	input vector matrix size X_1	$L \times 2^{kN_r}$
	input vector matrix size X_2	$L \times 128$
receiver	number of channel C_0	2^{kN_r}
receiver	number of channel C_1	128
	number of channel C_2	$2nN_r$
	padding	1
	stride	1

式可知, 总参数量只与卷积核尺寸K、通道数C和层数D有关; 特征图的输出尺寸是其空间尺寸 M^2 和通道数C的连乘。具体参数由表4给出。

Dense 层的参数量是其参数权重和偏置大小的总和,因此其空间复杂度为: $O\left(\sum_{l=1}^{p} T_{i}^{(0)} T_{o}^{(l)} + T_{o}^{(l)}\right)$ 。其中, $T_{i}^{(0)}$ 为第l层的输入向量长度; $T_{o}^{(l)}$ 为第l层的输出向量长度。AF中继节点的输入、输出数据维度由表1给出。

由时间、空间复杂度计算公式及表1、表4中的参数即可计算出对应模型的时间、空间复杂度,其数值与参数取值相关。分析可知,Dense 层的权重参数量远大于 CNN。因此,若需减少网络参数,应主要关注 Dense 层;进行计算优化时,重点放在 CNN。值得注意的是,本文构建的3个 NNs 子系统分别处于整个通信网络的不同节点上,其系统开销应分别计算,并不是积累效果。

2 性能分析

通过仿真实验验证本文提出的基于 AE 的中继动态协作系统性能的可靠性以及动态协作的鲁棒性,系统基于 TensorFlow 后端的 Keras 框架实现。为更有效地进行性能比较,实验中,固定 Rayleigh 信道训练信噪比为12 dB, AWGN 信道训练信噪比为5 dB,中继信道的信噪比为20 dB。设定通信系统 k=2,每个符号含有2 bit 信息; n=2, 信息通过2个信道时隙发送;通信速率 R=1。

2.1 Rayleigh 信道不同通信协作方式及中继个数条件下性能分析

如图 3 所示,以文献[10]中的 CNN-AE"点对点"通信系统作为系统基准,与本文设计的动态中继系统 (CNN-AE-AF, CNN-AE-DF)的性能相比较。当中继数为1时,采用中继的系统 BER 性能差于点对点系统,这是 因为中继节点引入了噪声和误码。随着中继节点数量的提升,num_relay=2、4时,中继系统带来的分集增益开 始体现,因而 BER 性能优于点对点 CNN-AE 系统。同时,可以观察到,采用 AF 的中继系统性能稍优于采用 DF 的系统,说明 DF 方式硬解码的错误传播现象比较严重,而 AF 方式的转发信号可以与接收机一起进行软判决。 此外,在高信噪比区域,所有中继系统均表现出"错误地板"现象。这是因为中继系统引入的噪声和硬解码限制了接收机恢复信号的能力。不难看出,无论是AF还是DF方式,均给系统引入了分集增益,因而优于相对应的点对点系统。

2.2 动态多中继协作性能分析

以中继个数 num_relay=2 的协作通信系统为基准,验证 本文提出的系统在中继数量突然变化时的泛化能力和鲁棒 性。如图 4 所示,在 AWGN 信道下,num_relay=2 的系统提 高了接收机的信噪比,体现出比"点对点"无中继系统更好 的 BER 性能。更重要的是,当被训练好的系统中继数量突然 减少为 dynamic_relay=1 时,CNN-AE-AF和 CNN-AE-DF系 统具有良好的泛化能力,信号的传输并不会因此崩溃,仍能 达到与被训练完美的 num_relay=1 系统同样的误码性能。需 要注意的是,在AWGN 信道条件下,中继节点个数动态减少 为原 1/2 时,相当于接收信号功率减少到原先的一半,因此





BER与num_relay=2系统相差了3dB。另一方面,当被训练好的系统中继数量突然变为dynamic_relay=3时,系统的误码性能也因为接收信号功率增加而相应提升,如图4所示。此外,需指出的是,在整个过程中,CNN-AE-AF和CNN-AE-DF系统无需进行额外的训练,只保持num_relay=2系统的训练结果进行编码和译码。

类似地,图5演示了CNN-AE-AF和CNN-AE-DF系统在Rayleigh信道环境下动态支持中继节点数量的变化 情况。尽管该系统被训练成适应固定的num_relay=2个中继,但中继系统对动态协作有很强的泛化能力,对中继 数的突然变化有稳健的BER性能表现。具体地说,在Rayleigh信道下,当中继突然变为dynamic_relay=1时,其 表现出的性能相当于减少了一条空间分集路径,性能等同于单中继节点系统。当dynamic_relay=3时,系统BER 性能得到了相应的提高。



Fig.4 BER performance analysis of CNN-AE-AF and CNN-AE-DF systems under AWGN channel 图4 AWGN信道下, CNN-AE-AF和CNN-AE-DF系统 的BER性能分析



Fig.5 BER performance analysis of CNN-AE-AF and CNN-AE-DF systems under Rayleigh channel 图 5 Rayleigh 信道下, CNN-AE-AF 和 CNN-AE-DF 系统 的 BER 性能分析

3 结论

本文提出了与通信专业领域知识相结合的基于 CNN-AE 的动态中继协作通信系统。采用 Conv1D 进行信号特征学习与译码,并将能量约束及信道模型添加到自编码器的通信系统中。AF 中继节点使用 Dense 层构建,DF 中继节点采用一维卷积层构建。相比于点对点系统,本文设计的 CNN-AE-AF 和 CNN-AE-DF 系统提供了协作分集增益、抗衰落,提高了系统的传输能力和误码性能。

此外,本文所提出的系统模型可在不同信道条件及不同协作方式下表现出良好的误码性能,并对于中继数 量的动态变化具有极强的泛化能力和鲁棒性,考虑其物理意义,此系统具有较大的应用价值。

参考文献:

[1] 吴楠,谷万博,王旭东. 基于深度 LSTM 辅助卷积网络的新型自动调制分类[J]. 太赫兹科学与电子信息学报, 2021,19(2): 235-

243. (WU Nan,GU Wanbo,WANG Xudong. A novel efficient automatic modulation classification algorithm using deep LSTM aided convolutional networks[J]. Journal of Terahertz Science and Electronic Information Technology, 2021,19(2):235–243.) doi:10.11805/TKYDA2020034.

- [2] HE Hengtao, WEN Chaokai, JIN Shi, et al. Deep learning-based channel estimation for beamspace mmwave massive MIMO systems[J]. IEEE Wireless Communications Letters, 2018,7(5):852-855. doi:10.1109/LWC.2018.2832128.
- [3] NEUMANN D, WIESE T, UTSCHICK W. Learning the MMSE channel estimator[J]. IEEE Transactions on Signal Processing, 2018,66(11):2905-2917. doi:10.1109/TSP.2018.2799164.
- [4] HUANG Hongji, YANG Jie, HUANG Hao, et al. Deep learning for super-resolution channel estimation and DOA estimation based massive MIMO system[J]. IEEE Transactions on Vehicular Technology, 2018, 67(9): 8549-8560. doi: 10.1109/TVT. 2018. 2851783.
- [5] JIANG Yihan, KANNAN S, KIM H, et al. DEEPTURBO: deep turbo decoder[C]// 2019 IEEE the 20th International Workshop on Signal Processing Advances in Wireless Communications(SPAWC). Cannes: IEEE, 2019: 1-5. doi: 10.1109/SPAWC. 2019. 8815400.
- [6] MU Tianjie, CHEN Xiaohui, CHEN Li, et al. An end-to-end block autoencoder for physical layer based on neural networks[EB/OL]. (2019-06-15)[2021-01-15]. https://arxiv.org/abs/1906.06563.
- [7] O'SHEA T, HOYDIS J. An introduction to deep learning for the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2017,3(4):563-575. doi:10.1109/TCCN.2017.2758370.
- [8] YE Hao,LI G Y,JUANG B H F,et al. Channel agnostic end-to-end learning based communication systems with conditional GAN[C]// 2018 IEEE Globecom Workshops(GC Wkshps). Abu Dhabi:IEEE, 2018:1–5. doi:10.1109/GLOCOMW.2018.8644250.
- [9] ZHU Banghua, WANG Jintao, HE Longzhuang, et al. Joint transceiver optimization for wireless communication PHY using neural network[J]. IEEE Journal on Selected Areas in Communications, 2019,37(6):1364-1373. doi:10.1109/JSAC.2019.2904361.
- [10] 王旭东,林彬,张凯尧,等. 一种改进的 CNN 端到端自编码器通信系统[J]. 电讯技术, 2020,60(2):147-152. (WANG Xudong, LIN Bin, ZHANG Kaiyao, et al. An improved CNN end-to-end learning based autoencoder communication system[J]. Telecommunication Engineering, 2020,60(2):147-152.) doi:10.3969/j.issn.1001-893x.2020.02.004.
- [11] LU Yuxin, CHENG Peng, CHEN Zhuo, et al. Deep autoencoder learning for Relay-Assisted cooperative communication systems[J]. IEEE Transactions on Communications, 2020,68(9):5471-5488. doi:10.1109/TCOMM.2020.2998538.
- [12] AHLSWEDE R, CAI Ning, LI S Y R, et al. Network information flow[J]. IEEE Transactions on Information Theory, 2000, 46(4): 1204-1216. doi:10.1109/18.850663.
- [13] GUPTA A, SELLATHURAI M. End-to-end learning-based framework for amplify-and-forward relay networks[J]. IEEE Access, 2021(9):81660-81677. doi:10.1109/ACCESS.2021.3085901.
- [14] MUKHOPADHYAY R, NEOGY S, CHATTOPADHYAY S. Dynamic relay selection using a greedy cluster strategy[C]// 2020 IEEE International Conference on Advanced Networks and Telecommunications Systems(ANTS). New Delhi: IEEE, 2020: 1-4. doi:10.1109/ANTS50601.2020.9342757.
- [15] BLETSAS A,SHIN H,WIN M Z. Cooperative communications with outage-optimal opportunistic relaying[J]. IEEE Transactions on Wireless Communications, 2007,6(9):3450-3460. doi:10.1109/TWC.2007.06020050.
- [16] MICHALOPOULOS D S, KARAGIANNIDIS G K. Performance analysis of single relay selection in Rayleigh fading[J]. IEEE Transactions on Wireless Communications, 2008,7(10):3718-3724. doi:10.1109/T-WC.2008.070492.

作者简介:

吴 楠(1979-),男,博士,副教授,主要研究方向 为现代移动无线通信系统、基于深度学习的无线通信系 统、可见光通信系统等.email:wu.nan@dlmu.edu.cn. **王悦然**(1998-),女,在读硕士研究生,主要研究方向为深度学习在无线通信中的应用.

王旭东(1967-),男,博士,教授,主要研究方向为 MIMO、无线通信、空间调制、可见光无线通信及定位 技术.