



研究与开发

NOMA系统中基于深度学习的压缩感知脉冲噪声抑制方法

胡进, 李有明

(宁波大学信息科学与工程学院, 浙江 宁波 315211)

摘要: 随着物联网技术的广泛应用, 非正交多址接入 (non-orthogonal multiple access, NOMA) 技术作为一种高效的多址接入技术, 由于能满足大规模连接需求并能提升频谱效率而受到关注。然而, 脉冲噪声作为一种广泛存在的干扰因素, 会严重影响NOMA系统的性能。为此, 提出了一种基于深度学习的压缩感知脉冲噪声抑制方法, 基于NOMA系统中脉冲噪声的时域稀疏性, 通过数据驱动方式, 利用深度学习网络来估计脉冲噪声。具体来说, 首先使用线性映射网络代替压缩感知算法, 求伪逆获取脉冲噪声的初始解, 然后将初始解输入压缩感知重构 WaveNet (compressed sensing reconstruction WaveNet, CSR-WaveNet), 通过网络学习脉冲噪声的稀疏特征, 以实现脉冲噪声的精确估计。仿真结果表明, 相较现有技术, 新算法实现了更低的误码率。

关键词: 深度学习; 压缩感知; 脉冲噪声; 非正交多址

中图分类号: TP913

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025191

Deep learning-based compressed sensing impulsive noise suppression in NOMA systems

HU Jin, LI Youming

Faculty of Information Science and Engineering, Ningbo University, Ningbo 315211, China

Abstract: With the widespread application of Internet of things technology, non-orthogonal multiple access (NOMA) has been recognized as an efficient multiple access technique, offering significant advantages in large-scale connectivity and spectral efficiency. However, impulsive noise, a common source of interference, has been found to severely degrade the performance of NOMA systems. To address this issue, a deep learning-based compressed sensing method was proposed for impulsive noise suppression. By exploiting the temporal sparsity of impulsive noise in NOMA sys-

收稿日期: 2025-01-23; 修回日期: 2025-04-27

通信作者: 李有明, liyouming@nbu.edu.cn

基金项目: 国家重点研发计划项目 (No.2023YFC2809400); 国家自然科学基金资助项目 (No.61571250); 浙江省自然科学基金资助项目 (No.LY22F010018)

Foundation Items: The National Key Research and Development Program (No.2023YFC2809400), The National Natural Science Foundation of China (No.61571250), The Zhejiang Natural Science Foundation (No.LY22F010018)



tems, a data-driven approach was employed, with the network being used to estimate the impulsive noise. Firstly, a linear mapping network was used to replace the compressed sensing algorithm in computing the pseudoinverse, providing an initial estimate of the impulsive noise. This estimate was then fed into a compressed sensing reconstruction WaveNet (CSR-WaveNet), which could learn the sparse characteristics of the impulsive noise for more accurate noise estimation. Simulation results show that, compared to existing methods, the proposed approach can achieve lower bit error rates.

Key words: deep learning, compressed sensing, impulsive noise, non-orthogonal multiple access

0 引言

随着物联网技术应用的不断扩展,为解决海量设备接入所需的连接性、可靠性和时延要求问题,非正交多址接入(non-orthogonal multiple access, NOMA)作为一种有效的接入技术被引入。由于NOMA能实现未来无线网络的两个核心优势:支持大规模连接和提高频谱效率^[1],因此,其成为物联网和未来无线网络系统中的主要候选方案^[2]。然而,多项研究表明,NOMA系统在各种室内环境^[3]、制造工厂、工业设备和高压环境^[4]中都会受到脉冲噪声的干扰,这种非高斯脉冲噪声的存在,会导致基于加性白高斯噪声(additive white Gaussian noise, AWGN)假设设计的通信系统性能急剧下降。此外,NOMA系统中的功率域复用和连续干扰消除(successive interference cancellation, SIC)技术会使此类系统对脉冲噪声干扰特别敏感^[5-6]。

传统的脉冲噪声抑制方法通常在接收端通过检测信号中的高峰值幅度来识别脉冲噪声,并对检测到的噪声峰值执行限幅或消隐操作,或将这两者结合起来(即组合限幅消隐方法^[7])。这种处理方式虽然能够减轻高幅度干扰对接收信号的影响,但当信道条件发生变化时,阈值容易受其影响,从而导致模型失配。传统方法中脉冲噪声检测阈值的任何变化都会导致信号检测的接收机阈值模糊,从而降低通信系统的性能。

基于脉冲噪声在时域的稀疏特性^[8-10],一些基于压缩感知的脉冲噪声抑制方法^[11-13]应运而

生,该类方法通过信号中空子载波的信息来构建压缩感知模型,将脉冲噪声估计问题转换为稀疏信号估计问题。由于最小化 l_0 范数非常困难,研究人员提出了基于 l_1 范数优化的基追踪(basis pursuit, BP)算法来估计脉冲噪声^[14]。然而, l_1 范数的计算成本仍然很高^[15]。文献[16]提出了一种光滑 l_0 范数算法,该算法求解的是 l_0 范数的近似解,虽然该算法拥有较低的计算复杂度,但是脉冲噪声估计的性能未得到显著改善。文献[17]提出了一种基于高斯广义近似消息传递(Gaussian generalized approximate message passing, GGAMP)的脉冲噪声抑制方法,该方法采用稀疏贝叶斯学习(sparse Bayesian learning, SBL)框架进行脉冲噪声估计,并将GGAMP引入期望最大(expectation maximization, EM)算法中。虽然该算法的计算复杂度较低,但是GGAMP算法仅能利用单测量向量的信息,难以准确估计脉冲噪声。

为解决上述问题,本文提出了一种基于压缩感知重构WaveNet(compressed sensing reconstruction WaveNet, CSR-WaveNet)的方法,对NOMA系统中的脉冲噪声进行估计。该方法通过引入神经网络,将压缩感知技术和神经网络相结合,以获得更好的脉冲噪声估计性能。具体来说,首先使用线性映射网络代替压缩感知算法求伪逆,从而获取脉冲噪声的初始解,然后将初始解输入CSR-WaveNet,通过网络学习脉冲噪声的稀疏特征,将接收信号的空子载波的部分映射为脉冲噪声,以实现脉冲噪声的精确估计。相较于传统的压缩感知脉冲噪声抑制方法,CSR-

WaveNet 可以实时对脉冲噪声进行估计。相较于现有的深度学习脉冲噪声抑制方法, CSR-WaveNet 通过扩张卷积使得该模型能够覆盖更广泛的输入范围, 更有效地捕捉脉冲噪声的长期时间依赖性, 从而更精确地估计脉冲噪声。为了量化所提出的基于 CSR-WaveNet 的去噪方法的效果, 本文采用误码率 (bit error ratio, BER) 和均方误差 (mean-square error, MSE) 作为主要的性能评估指标, 并在基于 NOMA 的通信系统框架下, 将其与文献中已有的方法进行了比较。

1 系统模型

假设下行 NOMA 系统由一个基站和 M 个用户组成。NOMA 系统的一个符号由 N 个子载波组成, 其中, N_P 为空子载波数, N_D 为数据子载波数。因此, 基带发射的频域信号由式 (1) 给出:

$$\mathbf{x} = \sum_{i=1}^M \sqrt{P_i} \mathbf{s}_i \quad (1)$$

其中, 信号按功率大小排序后, $P_i = a_i E_t$ 为第 i 个排序用户的功率, E_t 为基站的发射功率, a_i 为功率分配系数, $\sum_{i=1}^M a_i = 1$, 且 $a_1 > a_2 > \dots > a_m$, $\mathbf{s}_i$ 为 NOMA 调制符号, 其表达式为:

$$s_i(k) = \frac{1}{N} \sum_{n=0}^{N-1} b_n \exp\left(j \frac{2\pi nk}{N}\right) \quad (2)$$

其中, k 为符号索引, j 为虚数单位, b_n 为映射数据。

基站端将信号叠加之后通过傅里叶逆变换转换为时域信号, 表示为:

$$\mathbf{x}_t = \mathbf{F}^* \mathbf{x} \quad (3)$$

其中, $\mathbf{F}$ 表示归一化傅里叶变换矩阵, $\mathbf{F}^*$ 表示 $\mathbf{F}$ 的厄米特变换。

在接收端, 对于不同用户的时域信号, 可以表示为:

$$\mathbf{r} = \mathbf{H}\mathbf{x}_t + \mathbf{n} \quad (4)$$

其中, $\mathbf{H}$ 表示信道循环卷积矩阵, $\mathbf{n} = \mathbf{n}^w + \mathbf{n}^l$ 表示

总噪声, $\mathbf{n}^w$ 为 AWGN, $\mathbf{n}^l$ 为时域脉冲噪声。

经离散傅里叶变换, 时域信号转化为频域信号, 具体过程如下所示:

$$\mathbf{Y} = \mathbf{F}\mathbf{r} = \mathbf{F}\mathbf{H}\mathbf{F}^* \mathbf{x} + \mathbf{F}\mathbf{n} = \mathbf{F}\mathbf{H}\mathbf{F}^* \mathbf{x} + \mathbf{F}\mathbf{n}^l + \mathbf{F}\mathbf{n}^w = \mathbf{A}\mathbf{x} + \mathbf{F}\mathbf{n}^l + \mathbf{W} \quad (5)$$

其中, $\mathbf{A}$ 表示对角矩阵, 其对角线上的元素为信道的频域响应, $\mathbf{W} = \mathbf{F}\mathbf{n}^w$ 表示频域的背景噪声。

使用 $(\cdot)_P$ 和 $(\cdot)_D$ 分别表示空子载波和数据子载波的索引, 根据式 (5), 接收端的数据子载波中的信号可以表示为:

$$\mathbf{Y}_D = (\mathbf{A}\mathbf{x})_D + \mathbf{F}_D \mathbf{n}^l + \mathbf{W}_D \quad (6)$$

空子载波中的信号可以表示为:

$$\mathbf{Y}_P = (\mathbf{A}\mathbf{x})_P + \mathbf{F}_P \mathbf{n}^l + \mathbf{W}_P \quad (7)$$

由于空子载波中没有数据, 即 $(\mathbf{A}\mathbf{x})_P = 0$, 因此, 接收信号中空子载波中的信号可以表示为:

$$\mathbf{Y}_P = \mathbf{F}_P \mathbf{n}^l + \mathbf{W}_P \quad (8)$$

式 (8) 被视为一组关于未知参数的线性观测。由于空子载波矩阵是一个欠定矩阵, 传统的压缩感知脉冲噪声抑制方法通常通过迭代求解, 这样的方法无法实现脉冲噪声的实时估计。因此, 下一节的主要目标是从式 (8) 中估计出脉冲噪声, 以实现脉冲噪声的实时抑制。

2 基于 CSR-WaveNet 的脉冲噪声抑制

本文所提出的 CSR-WaveNet 方法的脉冲噪声抑制流程如图 1 所示, 其中正交振幅调制 (quadrature amplitude modulation, QAM) 是一种调制方式, 它通过在正交的载波上同时调制信号的幅度和相位, 实现更高的数据传输效率。CSR-WaveNet 方法通过端到端的学习方式, 利用 CSR-WaveNet 对空子载波中的信号进行脉冲噪声的稀疏表示, 从而得到脉冲噪声的估计值。具体而言, 首先将 N_P 维的空子载波信号 $\mathbf{Y}_P$, 经过全连层网络映射到 N 维的脉冲噪声初始解, 然后经过 CSR-WaveNet 学习脉冲噪声的稀疏特征, 将脉冲噪声初始解映射为精确的脉冲噪声估计值。




图1 CSR-WaveNet方法的脉冲噪声抑制流程

在脉冲噪声的估计过程中,考虑脉冲噪声的特性,CSR-WaveNet的设计尤为重要。脉冲噪声通常具有高幅度、短时突发的特点,通常表现为非平稳且难以预测的干扰信号。由于其稀疏性,脉冲噪声在大多数时间呈现低幅度,仅在短时间内突发。基于上述脉冲噪声的特性,本文提出的CSR-WaveNet模型通过学习脉冲噪声的时域特性,提高了噪声估计的精度。此外,为了提升网络学习的性能,本文对WaveNet进行了改进,与常规的WaveNet不同,本文使用的CSR-WaveNet去除了因果卷积层,从而降低了网络训练的时间复杂度。

本文设计的CSR-WaveNet首先将空子载波中的信号输入全连层线性映射网络,以获得脉冲噪声的初始解,具体表示如下。

$$Y_t = WY_p + b \quad (9)$$

其中, W 为全连层的权重矩阵, b 为全连层的偏置向量。

接着,CSR-WaveNet通过扩张卷积在卷积核中引入间隔,使模型能够在不增加参数数量的情况下显著扩大感受野。感受野的扩大意味着模型能够覆盖更长的时间序列范围,更好地捕捉序列中的长时依赖性,从而实现对脉冲噪声更精确的建模。扩张卷积步骤如图2所示。

由扩张卷积的步骤可知,扩张卷积的计算式可以表示为:

$$Y_t * w_t = \sum_{o=0}^{k_s-1} Y_{t-d} w_o \quad (10)$$

其中, Y_t 表示输入信号, $*$ 表示扩张卷积运算, w_t 表示卷积核, k_s 为卷积核的大小, o 为卷积核序号, d 表示扩张因子。




图2 扩张卷积步骤

为了加快收敛速度，避免梯度消失问题，CSR-WaveNet采用残差学习框架，其残差模块的结构如图3所示。

门控激活单元的具体表达式如下所示：

$$z = \tanh(W_{f,k} * Y_t) \odot S(W_{g,k} * Y_t) \quad (11)$$

其中， $\odot$ 表示哈达玛积， $S(\cdot)$ 表示sigmoid激活函数， $\tanh(\cdot)$ 表示tanh激活函数， $W_{f,k}$ 和 $W_{g,k}$ 分别表示第 k 层网络中滤波器 f 和门控 g 对应的扩张卷积核。门控激活单元能够使网络更有效地保留输入信息，其门控机制允许网络选择性地更新或保持输入部分的特征，进而更精确地捕获脉冲噪声的稀疏特征。

CSR-WaveNet整体架构如图4所示。CSR-WaveNet通过堆叠多个残差模块，利用深层网络结构来逐步提取脉冲噪声的稀疏特征。每个残差模块采用扩张卷积操作，以扩大感受野，并在保留参数效率的同时，捕捉信号中的长时依赖性。通过这种方式，模型能够在更大范围内识别脉冲噪声的时域特征，并且在每一层中细化噪声估计的精度。

在CSR-WaveNet的优化过程中，为了提高脉冲噪声的估计精度，网络通过最小化回归损失来学习NOMA信号中的脉冲噪声。所采用的损失函数为MSE，这是一种常见的回归任务损失函数，用于衡量模型预测值与真实值之间的差异，具体




图3 残差模块的结构




图4 CSR-WaveNet整体架构



表示如下。

$$L(\boldsymbol{\Omega}) = \frac{1}{s} \sum_{l=1}^s \left\| \bar{\mathbf{n}}_l^T - F\left((\bar{\mathbf{Y}}_P)_l, \boldsymbol{\Omega}\right) \right\|_2^2 \quad (12)$$

其中, s 为样本数, $\bar{\mathbf{n}}_l^T$ 为相应的脉冲噪声, $(\bar{\mathbf{Y}}_P)_l$ 表示接收信号中空子载波的信号, $F(\cdot)$ 表示 CSR-WaveNet 的映射过程, $\boldsymbol{\Omega}$ 为映射矩阵。由此可以得到脉冲噪声的精确解为:

$$\hat{\mathbf{n}}_l^T = F\left((\bar{\mathbf{Y}}_P)_l, \boldsymbol{\Omega}\right) \quad (13)$$

最后, 在接收端中减去估计的脉冲噪声, 即可完成脉冲噪声的抑制。

3 仿真结果与分析

本节通过仿真分析比较本文提出的脉冲噪声抑制方法与其他方法的性能, 其中, CSR-WaveNet 为本文所提方法, BP 为基追踪方法^[14], SL0 为光滑 l_0 范数方法^[16], GGAMP 为高斯广义近似消息传递方法^[17]。仿真使用下行两用户 NOMA 系统, NOMA 系统的具体仿真参数见表 1。

表 1 NOMA 系统的具体仿真参数

相关参数	仿真设置
调制方式	4-QAM
子载波总数/个	256
空子载波数/个	100
数据子载波数/个	156
用户 1 功率分配系数	0.9
用户 2 功率分配系数	0.1

本文的仿真环境是 Python 3.8, 使用 TensorFlow 库实现神经网络, 使用的数据集为 120 000, 其中训练集为 100 000 个样本, 验证集和测试集均为 10 000 个样本, 训练阶段的学习率设置为 0.000 1, 批量大小设置为 128, 使用 Adam 优化器进行训练。CSR-WaveNet 的具体参数见表 2。

表 2 CSR-WaveNet 的具体参数

网络层数	网络设置	参数设置
第一层	全连层	大小为 512
第二层	残差模块	滤波器个数为 16 卷积核大小为 1×3 扩张卷积大小为 12
第三层	残差模块	滤波器个数为 32 卷积核大小为 1×3 扩张卷积大小为 8
第四层	残差模块	滤波器个数为 64 卷积核大小为 1×3 扩张卷积大小为 4
第五层	残差模块	滤波器个数为 128 卷积核大小为 1×3 扩张卷积大小为 1
第六层	一维卷积层	卷积核大小为 1×7

不同脉冲噪声抑制方法的 MSE 对比如图 5 所示。由图 5 可知, 不同方法的 MSE 都随信噪比 (signal-to-noise ratio, SNR) 增加而下降。在所有脉冲噪声抑制方法中, CSR-WaveNet 方法在整个 SNR 范围内显著优于其他方法, 进一步验证了本文方法在脉冲噪声估计方面的有效性, 特别是在 $\text{MSE} = 10^{-1}$ 时, 本文方法比 GGAMP 方法的 SNR 增益约为 4 dB。




图 5 不同脉冲噪声抑制方法的 MSE 对比

不同脉冲噪声抑制方法的 BER 对比如图 6 所示。由图 6 可知, 所有方法的 BER 都随 SNR 的增大而减小, 本文提出的 CSR-WaveNet 方法在整个 SNR 范围内显著优于其他方法, 验证了本文方法在脉冲噪声抑制性能方面的优越性, 特别是在

BER = 10^{-3} 时, 本文方法比 GGAMP 方法的 SNR 增益约为 3 dB。




图6 不同脉冲噪声抑制方法的BER对比

不同脉冲噪声稀疏度下的BER对比如图7所示。由图7可知, 当脉冲噪声的稀疏度变大, 相应的BER会增大, 这是因为短时间内的脉冲噪声干扰越多, 对NOMA系统的性能影响越大。尽管随着脉冲噪声的稀疏度的变大, 相应的BER性能受到影响, 但是本文方法的脉冲噪声估计性能均优于其他方法。




图7 不同脉冲噪声稀疏度下的BER对比

两用户下行NOMA系统的BER对比如图8所示。由图8可知, 两个用户的BER随SNR增大而减小, 但远距离用户的BER低于近距离用户, 这是因为远距离用户获得了更多的功率分配, 并且

在SIC中没有误差累积。在BER = 10^{-3} 时, 相较GGAMP方法, 本文所提方法在近用户和远用户中都可以获得约3 dB的SNR增益。




图8 两用户下行NOMA系统的BER对比

不同脉冲噪声抑制方法随信号干扰噪声比 (signal to interference plus noise ratio, SINR) 变化的BER对比如图9所示, 通过不同SINR模拟了接收端受到不同强度脉冲噪声干扰的情形。由图9可知, 所有方法的BER都随SINR的增大而减小, 本文提出的CSR-WaveNet方法在整个SINR范围内显著优于其他方法, 从而验证了本文方法对脉冲噪声抑制的鲁棒性优于其他方法, 特别是在BER = 10^{-2} 时, 本文方法比GGAMP方法的SINR增益约为3 dB。




图9 不同脉冲噪声抑制方法随SINR变化的BER对比



4 结束语

针对NOMA系统中存在的脉冲噪声干扰问题, 本文提出了一种基于CSR-WaveNet神经网络的脉冲噪声抑制方法。本文利用CSR-WaveNet代替传统的压缩感知算法, 通过学习脉冲噪声的特征, 进而实现对噪声的精确估计, 通过CSR-WaveNet的巨大感受野, 使得神经网络能够更有效地学习脉冲噪声的特性, 从而更精确地重构脉冲噪声, 进而提升脉冲噪声估计的效果。仿真结果证明, 相较现有技术, 本文所提方法的BER更低。

参考文献:

- [1] YANG P, XIAO Y, GUAN Y L, et al. Single-carrier SM-MIMO: a promising design for broadband large-scale antenna systems[J]. IEEE Communications Surveys & Tutorials, 2016, 18(3): 1687-1716.
- [2] SHIN W, VAEZI M, LEE B, et al. Non-orthogonal multiple access in multi-cell networks: theory, performance, and practical challenges[J]. IEEE Communications Magazine, 2017, 55(10): 176-183.
- [3] LANDA I, VÉLEZ M, ARRINDA A. Impulsive noise measurements from consumer electronic devices[C]//Proceedings of the 2018 IEEE Conference on Antenna Measurements & Applications (CAMA). Piscataway: IEEE Press, 2018: 1-4.
- [4] CHEFFENA M. Industrial wireless sensor networks: channel modeling and performance evaluation[J]. EURASIP Journal on Wireless Communications and Networking, 2012(1): 297.
- [5] SELIM B, MUHAIDAT S, SOFOTASIOS P C, et al. Radio-frequency front-end impairments: performance degradation in nonorthogonal multiple access communication systems[J]. IEEE Vehicular Technology Magazine, 2019, 14(1): 89-97.
- [6] SELIM B, ALAM M S, EVANGELISTA J V C, et al. NOMA-based IoT networks: impulsive noise effects and mitigation[J]. IEEE Communications Magazine, 2020, 58(11): 69-75.
- [7] LAKEW W Y, AL-DWEIK A, ABOU-KHOUSA M A. Impulsive noise mitigation in NOMA-OFDM systems using time-domain interleaving for smart grid applications[C]//Proceedings of the 2024 IEEE 8th Energy Conference (ENERGYCON). Piscataway: IEEE Press, 2024: 1-6.
- [8] ELGENEDY M, AWADIN M M, HAMILA R, et al. Sparsity-based joint NBI and impulse noise mitigation in hybrid PLC-wireless transmissions[J]. IEEE Access, 2018, 6: 30280-30295.
- [9] LIN J, NASSAR M, EVANS B L. Impulsive noise mitigation in powerline communications using sparse Bayesian learning[J]. IEEE Journal on Selected Areas in Communications, 2013, 31(7): 1172-1183.
- [10] AL-NAFFOURI T Y, QUADEER A A, CAIRE G. Impulse noise estimation and removal for OFDM systems[J]. IEEE Transactions on Communications, 2014, 62(3): 976-989.
- [11] KORKI M, ZHANG J X, ZHANG C S, et al. Block-sparse impulsive noise reduction in OFDM systems: a novel iterative Bayesian approach[J]. IEEE Transactions on Communications, 2015, 64(1): 271-284.
- [12] BAI T, ZHANG H M, ZHANG J K, et al. Impulsive noise mitigation in digital subscriber lines: the state-of-the-art and research opportunities[J]. IEEE Communications Magazine, 2019, 57(5): 145-151.
- [13] FENG X, WANG J F, KUAI X Y, et al. Message passing-based impulsive noise mitigation and channel estimation for underwater acoustic OFDM communications[J]. IEEE Transactions on Vehicular Technology, 2022, 71(1): 611-625.
- [14] REN G F, QIAO S S, HEI Y. Asynchronous impulsive noise mitigation in OFDM using adaptive threshold compressive sensing[C]//Proceedings of the WAMICON 2014. Piscataway: IEEE Press, 2014: 1-5.
- [15] SAHA T, SRIVASTAVA S, KHARE S, et al. An improved algorithm for basis pursuit problem and its applications[J]. Applied Mathematics and Computation, 2019, 355: 385-398.
- [16] ZARMEHI N, MARVASTI F. Removal of sparse noise from sparse signals[J]. Signal Processing, 2019, 158: 91-99.
- [17] JIN Z Y, ZHANG X Y, TAN S Y, et al. An impulsive noise mitigation method based on all subcarriers assisted Gaussian generalized approximate message passing[C]//Proceedings of the 2022 2nd International Conference on Computer Science, Electronic Information Engineering and Intelligent Control Technology (CEI). Piscataway: IEEE Press, 2022: 365-369.

[作者简介]



胡进 (2000—), 男, 宁波大学信息科学与工程学院硕士生, 主要研究方向为无线通信中的脉冲噪声抑制问题。



李有明 (1963—), 男, 博士, 宁波大学信息科学与工程学院教授, 主要研究方向为无线宽带通信、电力线通信、协作中继、认知无线电等。