智能反射面辅助安全通信中的基于深度学习的联合波束成形设计

Chi Zhang、Yiliang Liu、*IEEE* 会员和 Hsiao-Hwa Chen，*IEEE* 会士

arXiv:2304.01702v1 [cs.IT] 4 Apr 2023

摘要—**本文研究了智能反射面（IRS）辅助的多输入多输出多天线窃听（MIMOME）系统中的物理层安全（PLS）。具体而言，我们考虑一种实际场景：无法获得窃听者的瞬时信道状态信息（CSI），并假设窃听信道服从瑞利信道。为降低现有智能反射面辅助物理层安全方案的复杂度，我们提出一种低复杂度的基于深度学习（DL）的方法，联合设计发射机波束成形与智能反射面，其中通过设计预编码向量和相移矩阵来最小化保密中断概率。仿真结果表明，与传统交替优化（AO）算法相比，所提出的基于深度学习的方法在显著降低计算复杂度的同时，可实现相近的性能。**

索引词—**智能反射面；物理层安全；联合波束成形设计；深度学习。**

I. 引言

智能反射面（IRS）是一种二维电磁超表面，由大量低成本无源单元构成，能够改变无线传播环境，从而提升无线通信系统的性能[1]。物理层安全（PLS）是一种信息安全技术，利用无线信道的随机性实现机密通信 [2]。由于智能反射面能够改善合法信道的质量，同时减弱被窃听信道的质量，这两种技术结合后具有互补优势 [3]。

在 [4] 和 [5], 中，作者研究了智能反射面辅助的单输入单输出（SISO）和多输入单输出（MISO）通信系统的物理层安全（PLS），并通过交替优化（AO）算法最大化系统的保密速率。在 [6],中，作者将其扩展至多用户场景，并发送人工噪声（AN）以提升安全性能。此外， [7] 聚焦于一种新颖的智能反射面辅助物理层安全方案，其中部署智能反射面，将来自发射机的接收信号调制为人工噪声信号。然而，上述研究大多基于已知窃听者瞬时信道状态信息（CSI）的假设。 [8]的作者在未知窃听者CSI的情况下，通过联合优化预编码、智能反射面相移矩阵和人工噪声来研究物理层安全，但没有适当的指标来评估物理层安全性能。 [9]中的工作采用了一种大量随机样本，而非窃听者的统计信道状态信息，但所提出的优化算法需要考虑所有随机样本，这会消耗大量计算资源。在 [10], 中，作者基于窃听者的统计信道状态信息研究了物理层安全，并推导出保密中断概率表达式作为安全度量。然而，对于最小化保密中断概率这一优化问题，所提出的交替优化算法复杂度非常高。

为解决 CSI 问题，我们考虑一种基于窃听者的统计信道状态信息的智能反射面辅助物理层安全场景。与 [10], 不同，我们认为大尺度衰落不可忽略，因此在计算保密中断概率时考虑大尺度衰落。受基于机器学习的研究工作 [12]–[14], 启发，我们提出一种低复杂度深度学习（DL）方法，用于设计发射机波束成形和相移矩阵，以最小化保密中断概率。该方法基于无监督学习，无需数据集标签。

II. 系统模型

考虑如图1所示的智能反射面辅助多输入多输出多天线窃听（MIMOME）系统，其中，配备有 N_t根天线的发射机（Alice）为一名配备有 N_r根天线的合法用户（Bob）提供服务，并由一个具有 N_s 个反射单元的智能反射面辅助。同时，存在一名配备有 N_e 根天线的窃听者（Eve），用于接收来自Alice和智能反射面的信号。Alice到Bob、Alice到智能反射面以及智能反射面到Bob的合法信道分别表示为$\mathbf{H}_b \in \mathbb{C}^{N_r\times N_t}$、$\mathbf{H} \in \mathbb{C}^{N_s\times N_t}$和$\mathbf{G}_r \in \mathbb{C}^{N_r\times N_s}$。Alice到Eve以及智能反射面到Eve的窃听信道分别表示为$\mathbf{H}_e \in \mathbb{C}^{N_e\times N_t}$ 和 $\mathbf{G}_e \in \mathbb{C}^{N_e\times N_s}$。假设所有信道均遵循准静态平坦衰落信道模型，且Alice能够完美估计合法信道$\mathbf{H}_b$、$\mathbf{G}_r$和$\mathbf{H}$ [15],，而Alice未知窃听信道$\mathbf{H}_e$ 和$\mathbf{G}_e$ 的瞬时信道状态信息。此外，为不失一般性，我们进一步假设窃听信道服从瑞利衰落。

令 s 为遵循 $\mathbb{E}\left[|s|^2\right]=1$ 的单流保密信号，则 Bob 和 Eve 处的接收信号可表示为

$$\mathbf{y}=\left(\mathbf{H}_b+\mathbf{G}_r\mathbf{\Theta}\mathbf{H}\right)\mathbf{w}s+\mathbf{n}, \tag{1}$$

$$\mathbf{y}_e=\left(\mathbf{H}_e+\mathbf{G}_e\mathbf{\Theta}\mathbf{H}\right)\mathbf{w}s+\mathbf{n}_e, \tag{2}$$

其中 $\mathbf{\Theta}=\text{diag}\left(e^{j\theta_1},\ e^{j\theta_2},\ \cdots,\ e^{j\theta_{N_s}}\right)$ 表示相移矩阵，θ_n 是智能反射面第 n 个单元引入的相移。$\mathbf{w} \in \mathbb{C}^{N_t\times 1}$ 是预编码向量，且

C. Zhang（电子邮箱：maye1998@163.com）现就职于中国哈尔滨工业大学电子与信息工程学院。Y. Liu（电子邮箱：liuyiliang@xjtu.edu.cn）现就职于中国西安交通大学网络空间安全学院。Hsiao-Hwa Chen（电子邮箱：hshwchen@mail.ncku.edu.tw）现就职于台湾国立成功大学工程科学系。

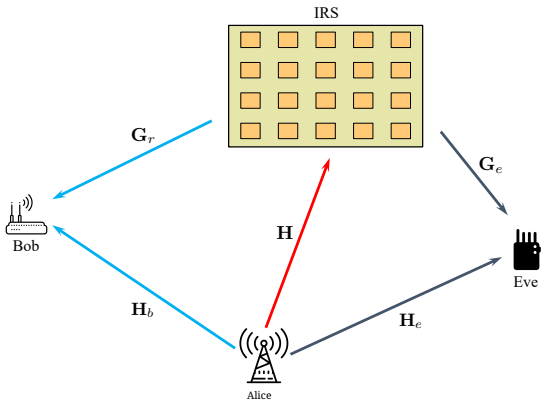


图 1. IRS辅助MIMOME系统。

满足 $\|\mathbf{w}\|^2 = P_t$，其中 P_t 是 Alice 的发射功率。$\mathbf{n} \sim \mathcal{CN}(\mathbf{0},\ \sigma^2 \mathbf{I}_{N_t})$ 和$\mathbf{n}_e \sim \mathcal{CN}(\mathbf{0},\ \sigma_e^2 \mathbf{I}_{N_e})$ 分别是 Bob 和 Eve 处的加性高斯白噪声（AWGN）。

为了最大化 Bob 处的信噪比（SNR），采用最大比合并（MRC）策略时，相应的接收信号向量 $\mathbf{w}_r = [(\mathbf{H}_b + \mathbf{G}_r\mathbf{\Theta}\mathbf{H})\mathbf{w}]^H / \|(\mathbf{H}_b + \mathbf{G}_r\mathbf{\Theta}\mathbf{H})\mathbf{w}\|$ 为[2]。我们考虑最坏情况，即 Eve 在相干时间内完全了解$\mathbf{H}_e$、$\mathbf{G}_e$、$\mathbf{H}$、$\mathbf{G}_r$、$\mathbf{\Theta}$和$\mathbf{w}$。于是，Eve 也可以采用 MRC 策略最大化 SNR。因此，Bob 和 Eve 处的信道容量分别为

$$C_m = \log_2\left[1 + \frac{P_t}{\sigma^2}\|(\mathbf{H}_b + \mathbf{G}_r\mathbf{\Theta}\mathbf{H})\,\mathbf{b}\|^2\right], \tag{3}$$

$$C_w = \log_2\left[1 + \frac{P_t}{\sigma_e^2}\|(\mathbf{H}_e + \mathbf{G}_e\mathbf{\Theta}\mathbf{H})\,\mathbf{b}\|^2\right], \tag{4}$$

其中，C_m 和 C_w 分别为主信道容量和窃听信道容量，$\mathbf{b} = \mathbf{w}/\sqrt{P_t}$ 为归一化预编码向量。

然而，由于窃听信道$\mathbf{H}_e$ 和$\mathbf{G}_e$ 未知，无法计算保密容量C_s，其中 $C_s = [C_m - C_w]^+$。因此，我们选择保密中断概率作为物理层安全（PLS）的安全度量，其定义为保密容量 C_s 小于目标物理层安全编码率 R_s的概率。保密中断概率定义为

$$P_{\text{out}}(R_s) = P(C_s \le R_s \mid \text{Transmission}) \tag{5a}$$

$$= P\left(\|(\mathbf{H}_e + \mathbf{G}_e\mathbf{\Theta}\mathbf{H})\,\mathbf{b}\|^2 \ge \phi\right), \tag{5b}$$

其中 $\phi = \sigma_e^2\left(2^{C_m - R_s} - 1\right)/P_t$。

本文假设窃听信道 $\mathbf{H}_e$ 和 $\mathbf{G}_e$ 均服从瑞利衰落，即 $\mathbf{H}_e = \beta_d\mathbf{Z}$ 和 $\mathbf{G}_e = \beta_r\mathbf{C}$，其中 $\mathbf{Z} \sim \mathcal{CN}_{N_e,\ N_t}(\mathbf{0},\ \mathbf{I}_{N_e} \otimes \mathbf{I}_{N_t})$，而 $\mathbf{C} \sim \mathcal{CN}_{N_e,\ N_s}(\mathbf{0},\ \mathbf{I}_{N_e} \otimes \mathbf{I}_{N_s})$。注意，$\otimes$、$\beta_d$ 和 β_r 分别表示克罗内克积、$\mathbf{H}_e$ 和 $\mathbf{G}_e$的大尺度衰落因子。

为推导保密中断概率的表达式，我们引入如下辅助随机变量 X。

$$X = \|(\mathbf{H}_e + \mathbf{G}_e\mathbf{\Theta}\mathbf{H})\,\mathbf{b}\|^2 \tag{6a}$$

$$= \|\beta_d\mathbf{Z}\mathbf{b} + \beta_r\mathbf{C}\mathbf{\Theta}\mathbf{H}\mathbf{b}\|^2. \tag{6b}$$

保密中断概率可表示为

$$P_{\text{out}}(R_s) = 1 - F_X(\phi), \tag{7}$$

其中 $F_X(\cdot)$ 是 X的累积分布函数（CDF）。利用伽马分布 [10], [11],，我们可以推导出保密中断概率的近似表达式，如下：[1]

$$P_{\text{out}}(R_s) = \frac{1}{\Gamma(N_e)}\Gamma\left(N_e, \frac{\phi}{\beta_d^2 + \beta_r^2\|\mathbf{\Theta}\mathbf{H}\mathbf{b}\|^2}\right), \tag{8}$$

其中 $\Gamma(m) = \int_0^\infty t^{m-1}e^{-t}\,\mathrm{d}t$ 是伽马函数，而 $\Gamma(m,\ n) = \int_n^\infty t^{m-1}e^{-t}\,\mathrm{d}t$ 是上不完全伽马函数。

在本研究中，我们旨在通过优化 Alice 处的 $\mathbf{\Theta}$ 和智能反射面处的$\mathbf{b}$ 来设计联合波束成形，以最小化保密中断概率。此外，随着$\mathbf{H}\mathbf{b}$增大，保密中断概率$P_{\text{out}}\|^2)$ [10]会降低。因此，优化问题可表述为

$$\max_{\mathbf{\Theta},\mathbf{b}} \quad \frac{\phi}{\beta_d^2 + \beta_r^2\|\mathbf{\Theta}\mathbf{H}\mathbf{b}\|^2}, \tag{9a}$$

$$\text{s.t.} \quad \mathbf{b}^H\mathbf{b} = 1, \tag{9b}$$

$$|e^{j\theta_n}| = 1, \forall n = 1, \cdots, N_s. \tag{9c}$$

值得注意的是，带有非凸单位模约束式 (9c) 的优化问题不存在可用的全局最优解。因此，[10] 提出了一种传统的交替优化算法来求解该问题，但其计算复杂度非常高。下一节中，我们将提出一种计算复杂度低得多的基于深度学习的方法。

III. 基于深度学习的联合波束成形设计

本节中，我们提出一种低复杂度的基于深度学习的联合波束成形网络（JBFNet），用于求解问题 (9)。JBFNet 的详细架构如图 2 所示，可分为两部分。一部分称为“PhaseNet”，用于预测智能反射面的相移矩阵 $\mathbf{\Theta}$；另一部分称为“BeamNet”，用于预测预编码向量$\mathbf{w}$。在以下小节中，我们将详细讨论 JBFNet 的设计问题。

A. PhaseNet

如图3所示，PhaseNet采用多层卷积神经网络（CNN）结构，该结构常用于图像处理问题，并已被证明在波束成形设计和信道估计等通信问题中非常有效 [12], [13]。此外，与常用的全连接网络（FCN）相比，CNN对二维数据具有更强的特征提取能力。

根据 [16], ，可通过训练信道数据获得相移矩阵 $\mathbf{\Theta}$，因此我们选择合法信道$\mathbf{H}_b$、$\mathbf{G}_r$和$\mathbf{H}$ 作为PhaseNet的输入，这些输入均为二维矩阵。为了提升JBNet在特征方面的能力

[1]关于公式（8）的详细推导，请参阅 https://github.com/MayeZhang/DL-IRSBF-PLS。

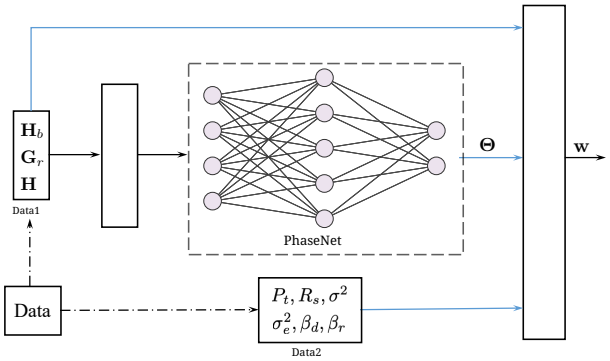


图 2. 用于联合波束成形设计的 JBNet 架构，其中数据由 Data1 和 Data2 组成。

提取时，需要对输入数据$\mathbf{H}_b$，$\mathbf{G}_r$，$\mathbf{H}$} 进行预处理。定义$\mathbf{F}_n = \mathbf{g}_{r,\ n}\mathbf{h}_n^H$，其中$\mathbf{g}_{r,\ n}$是$\mathbf{G}_r$的第 n列，$\mathbf{h}_n^H$是$\mathbf{H}$的第 n行。具体而言，$\mathbf{F}_n$ 也是与智能反射面的第 n个单元对应的级联信道。因此，公式（1）中的信道可改写为

$$\mathbf{H}_b + \mathbf{G}_r\boldsymbol{\Theta}\mathbf{H} = \mathbf{H}_b + \sum_{n=1}^{N_s} e^{j\theta_n}\mathbf{F}_n. \tag{10}$$

具体而言，原始数据 X $\in \mathbb{C}^{N_r \times N_t \times (N_s+1)}$ 可视为具有 $N_s + 1$ 个通道的 $N_r \times N_t$ 图像，即 X $= [\mathrm{H}_b; \mathrm{F}_1; \mathrm{F}_2; \cdots; \mathrm{F}_{N_s}]$。神经网络的输入数据必须为实数，而由 CSI 组成的原始数据 X 是复数。为解决这一问题，提取 X 中每个元素的实部、虚部和绝对值，构成一个新的三维矩阵，即 X $= \{\Re(\mathrm{X})\ \Im(\mathrm{X}), \mathrm{Abs(X)}\}$。请注意，$\Re$(X)、$\Im$(X) 和 Abs(X) 默认按照卷积神经网络的通道维度进行组合，即 X $\in \mathbb{R}^{N_r \times N_t \times 3(N_s+1)}$。此外，也可以根据实际参数设置灵活选择组合维度。例如，当接收天线的数量 $N_r = 2$，导致生成的“小图像”不利于特征提取时，可以沿第一维度进行组合，即 X $\in \mathbb{R}^{3N_r \times N_t \times (N_s+1)}$。

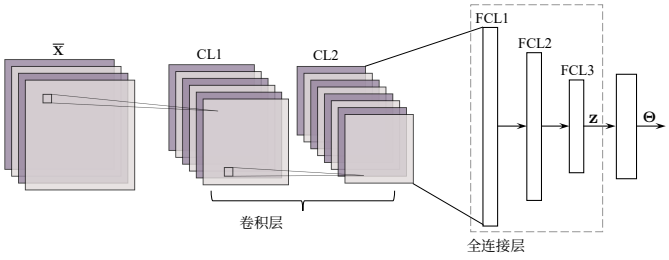


图3. 基于卷积神经网络的 $\boldsymbol{\Theta}$ PhaseNet框架。

如图3所示，预处理后的数据 $\mathbf{X}$ 经过两个卷积层（CL）和三个全连接层（FCL），最终由 Lambda层输出结果。我们将 CL1 设计为包含 256 个大小为 2×2 的滤波器，将 CL2 设计为包含 512 个大小为 2×2 的滤波器；FCL1 和 FCL2 分别包含 $64N_s$ 和 $16N_s$ 个神经元。特别地，FCL3 的神经元数量设为 N_s，与智能反射面的数量相同。

反射单元。为防止神经网络过拟合，在每两层之间插入一个批归一化（BN）层；除 FCL3 外，我们采用修正线性单元（ReLU）作为激活函数。具体而言，FCL3 采用“Sigmoid”作为激活函数，因此输出值 $\mathbf{z}$ 可以压缩到 (0,1) 之间。然后，我们可以通过 Lambda 层得到智能反射面相移矩阵 $\boldsymbol{\Theta} = \mathrm{diag}\left[\exp(j \cdot 2\pi\mathbf{z})\right]$。

B. BeamNet

对于任意给定的相移矩阵 $\boldsymbol{\Theta}$，目标函数式(9a)可转换为

$$\frac{\phi}{\beta_d^2 + \beta_r^2\|\boldsymbol{\Theta}\mathbf{H}\mathbf{b}\|^2} = c\left(\frac{\mathbf{b}^H\left(t\mathbf{I}_{N_t} + \mathbf{Q}_1\right)\mathbf{b}}{\mathbf{b}^H\left(\beta_d^2\mathbf{I}_{N_t} + \mathbf{Q}_2\right)\mathbf{b}}\right), \tag{11}$$

其中，$c = \sigma_e^2/(2^{R_s}\sigma^2)$、$t = \sigma^2(1 - 2^{R_s})/P_t$、$\mathbf{Q}_1 = (\mathbf{H}_b + \mathbf{G}_r\boldsymbol{\Theta}\mathbf{H})^H(\mathbf{H}_b + \mathbf{G}_r\boldsymbol{\Theta}\mathbf{H})$，以及$\mathbf{Q}_2 = \beta_r^2\mathbf{H}^H\mathbf{H}$。根据广义瑞利商，最优$\mathbf{b}$ 为

$$\mathbf{b}^* = \mathrm{eigvec}_{\lambda_{\max}}\left[\left(\beta_d^2\mathbf{I}_{N_t} + \mathbf{Q}_2\right)^{-1}\left(t\mathbf{I}_{N_t} + \mathbf{Q}_1\right)\right], \tag{12}$$

其中，$\mathrm{eigvec}_{\lambda_{\max}}(\mathbf{X})$是矩阵$\mathbf{X}$对应于最大特征值的特征向量，$\lambda_{\max}$ 是$\mathbf{X}$的最大特征值。因此，最优波束成形向量可表示为$\mathbf{w}^* = \sqrt{P_t}\mathbf{b}^*$。

总之，BeamNet根据PhaseNet预测的 $\boldsymbol{\Theta}$、Data1和Data 2 $= \{P_t, R_s, \sigma^2, \sigma_e^2, \beta_d, \beta_r\}$，通过计算式(12)得到最优$\mathbf{w}^*$。

C. 损失函数

与传统的监督学习不同，JBNet采用无监督学习，无需额外的 $\boldsymbol{\Theta}$ 和 $\mathbf{b}$ 标签。在我们的设计中，损失函数直接与目标函数式 (9a) 相关。

$$\mathrm{Loss} = -\frac{1}{K}\sum_{k=1}^{K}\frac{\phi_k}{\left(\beta_{d,k}^2 + \beta_{r,k}^2\|\boldsymbol{\Theta}_k\mathbf{H}_k\mathbf{b}_k\|^2\right)}, \tag{13}$$

其中，K 表示训练集中每个批次的样本数。请注意，神经网络的训练方向是使损失函数最小化，这恰好对应于式 (9a) 中 $\phi/\left(\beta_d^2 + \beta_r^2\|\boldsymbol{\Theta}\mathbf{H}\mathbf{b}\|^2\right)$ 的增大。

D. 网络训练

根据 PhaseNet 和 BeamNet，JBNet 的全部输入数据由 Data1 和 Data2 组成，即数据 $=\{\mathbf{H_b}, \mathbf{G_r}, \mathbf{H}\ P_t, R_s, \sigma^2, \sigma_e^2, \beta_d, \beta_r\}$。为充分训练 JBFNet，我们分别随机生成了 8×10^5 和 2×10^5 个数据样本用于训练和验证。此外，我们将最大训练轮次设为 2000，批量大小设为 1000。优化器设为采用自适应矩估计（Adam），初始学习率为 0.01。为加快收敛并防止过拟合，当验证损失连续 15 个轮次未下降时，学习率按 0.3 的因子衰减，并采用耐心值为 20 的早停策略。所有训练

这些处理过程使用 Python 3.8、Cuda 11.1 和 PyTorch 1.9.0 实现，运行于配备 GeForce GTX 1080 Ti GPU 的 PC 上。

IV. 仿真结果

本节给出所提出的基于深度学习的方法的仿真结果。仿真采用参数 $N_t = 4, N_r = 2, N_e = 2$，噪声方差 $\sigma^2 = \sigma_e^2$ 均归一化为 1，P_t 以相对于σ^2的 dB 值定义。假设合法信道 $\mathbf{H}_b$、$\mathbf{H}$ 和 $\mathbf{G}_r$ 均为相互独立的瑞利衰落信道，窃听信道 β_d 和 β_r 的大尺度衰落因子在 (0,1) 内随机生成。所有仿真结果均取 1000 个信道实现的平均值，并将所提出的基于深度学习的方法与以下方案进行比较：

- **无智能反射面**：预编码向量 $\mathbf{w}$ 采用最大比传输（MRT）策略，即$\mathbf{w} = \sqrt{P_t}\text{eigvec}_{\lambda_{\max}}\left(\mathbf{H}_b^H\mathbf{H}_b\right)$。根据公式（8），保密中断概率计算为 $P_{\text{out}}(R_s) = \Gamma\left(N_e, \phi/\beta_d^2\right)/\Gamma(N_e)$，其中 $\phi = \sigma_e^2\left(2^{C_m - R_s} - 1\right)/P_t$ 和 $C_m = \log_2\left(1 + P_t\lambda_{\max}/\sigma^2\right)$。
- **随机相位**：每个单元的相移 θ_n 均在 $[0, 2\pi]$处随机生成，然后根据随机 $\boldsymbol{\Theta}$和式（12）计算$\mathbf{w}$ 。
- **交替优化算法**：采用 [10]中提出的AO-SDR算法和AO-Man算法求解式（9）的优化问题。

图4展示了不同智能反射面单元数量 N_s下的保密中断概率。可以看出，随着 N_s 增加，所提出的JBNet和两种AO算法（AO-SDR和AO-Man）均能降低保密中断概率，且JBNet与这两种AO算法之间的差距较小。此外，随机相位方案的保密中断概率略优于不使用智能反射面的情况。需要注意的是，随着 N_s 增加，随机相位方案的性能变化不大，因为Bob和Eve从智能反射面获得的增益相近。

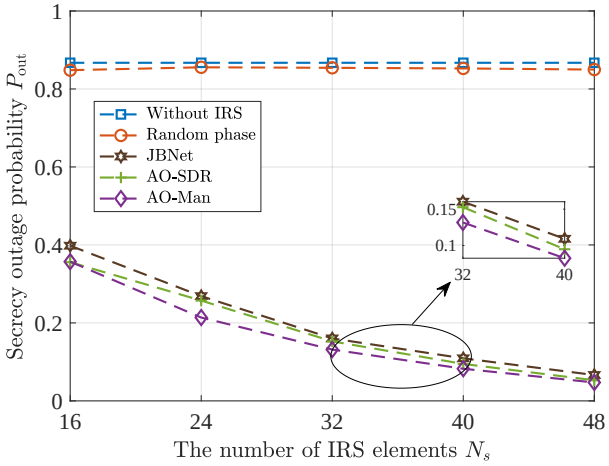


图4. 当信噪比 $= 10$ 为 N_s dB且$R_s = 3.5$ bit/s/Hz时，不同 N_s 下的保密中断概率。

图 5 展示了信噪比对保密中断概率的影响。值得注意的是，该性能JBNet、AO-SDR algorithm 和 AO-Man algorithm 的性能随信噪比变化不大。然而，这并不意味着提高信噪比毫无用处。随着信噪比提高，可以在保持较低保密中断概率的同时，略微提升保密速率。此外，当 $N_s = 48$ 时，JBNet 的性能与两种 AO 算法非常接近，且远优于未使用智能反射面的情况。特别是，存在一个较低的
当 $P_t/\sigma_e^2 \to \infty$ 时不使用智能反射面的界限，证明见附录。

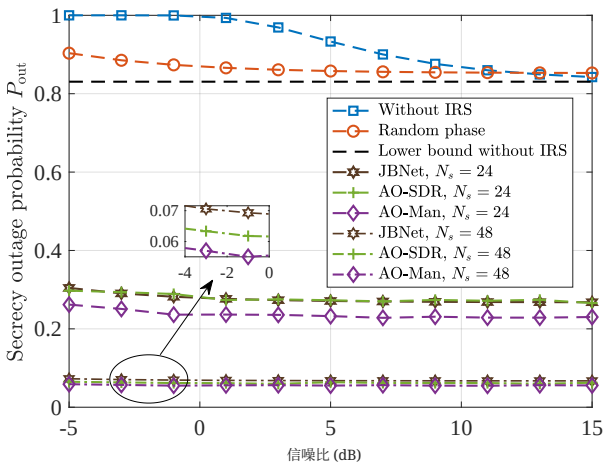


图 5. 当 $R_s = 3.5$ bit/s/Hz 时，保密中断概率随信噪比的变化。

图 6 展示了物理层安全编码率 R_s 对保密中断概率的影响。从图中可以看出，随着 R_s 增大，所有方案的保密中断概率均会上升。在这种情况下，可以采用一些方法来提高物理层安全编码率，例如增加智能反射面单元数量 N_s，或增加天线数量 N_t 和 N_r。例如，图 6 还给出了 $N_s = 24$ 和 $N_s = 48$ 的仿真曲线对比。

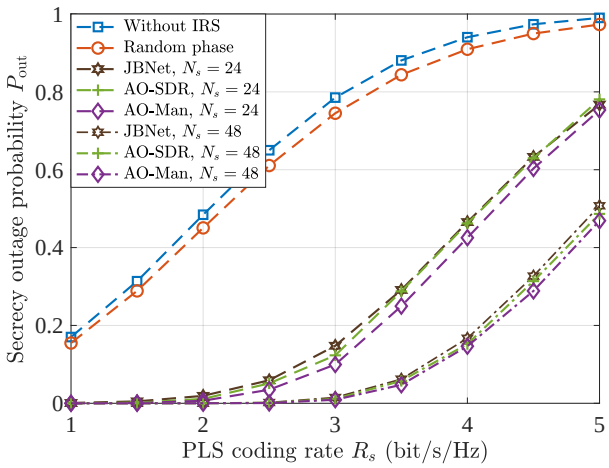


图 6. 当信噪比为 $= 10$ dB 时，保密中断概率随 R_s 的变化。

图7展示了不同智能反射面单元数量下总计20次仿真的运行时间 N_s。为进行公平比较，所有方案均在配备Intel i5-8259U 2.3GHz中央处理器的同一硬件平台上执行。可以看出，两个交替优化算法的运行

时间随着 N_s的增加而显著增加，而JBNet的运行时间几乎保持不变。注意， $N_s = 16$ 的运行时间长于$N_s = 24$，因为 $N_s = 16$ 是仿真的第一轮，程序在启动时需要额外花费一些时间。根据 [10],，AO-SDR算法和AO-Man算法的计算复杂度分别为 $\mathcal{O}(K_{\max}(N_s^{4.5} + N_s^2 N_t + N_t^3))$和 $\mathcal{O}(K_{\max}(N_s^4 + N_s^2 N_t + N_t^3))$，其中 $K_{\max}$为最大迭代次数。神经网络训练完成后，参数即被固定，因此求解优化问题式（9）将转化为一些简单的矩阵计算，基于深度学习的方法的计算复杂度近似为 $\mathcal{O}(N_s^2 + N_t N_r N_s)$ [14]。因此，所提出的JBFNet具有更低的计算复杂度。

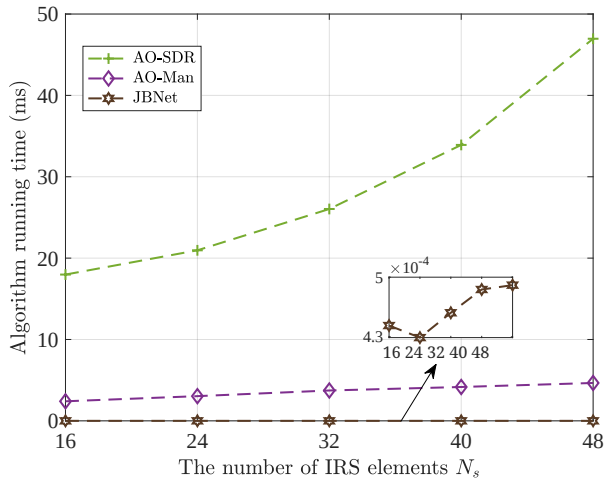


图 7. 信噪比为 $= 10$ dB、 $R_s = 3.5$ bit/s/Hz 时的运行时间。

V. 结论

我们推导了保密中断概率的表达式，并提出了一种低复杂度的基于深度学习的方法，用于IRS辅助的MIMOME系统中的联合波束成形设计。为降低求解优化问题的复杂度，我们设计了神经网络的数据预处理方法、网络结构和损失函数。仿真结果表明，所提出的基于深度学习的方法在保密性能方面接近传统AO算法，同时显著降低了计算复杂度。未来，我们将把所提出的模型扩展到更实际、更具挑战性的场景，例如具有离散相移的IRS、幅度与相位耦合等。

附录

在不采用智能反射面的物理层安全情形下，式（5a）中的 $P_t/\sigma_e^2 \to \infty$、 ϕ 可改写为

$$\phi = \frac{\sigma_e^2\left(2^{C_m - R_s} - 1\right)}{P_t} \tag{14a}$$

$$= \frac{\sigma_e^2 \|\mathbf{H}_b \mathbf{b}\|^2}{\sigma^2 2^{R_s}} + \frac{\sigma_e^2}{P_t}\left(\frac{1}{2^{R_s}} - 1\right) \le \frac{\sigma_e^2 \lambda_{\max}}{\sigma^2 2^{R_s}}, \tag{14b}$$

其中， $\lambda_{\max}$ 是$\mathbf{H}_b$的最大特征值。因此，保密中断概率满足

$$P_{\text{out}}(R_s) = \frac{1}{\Gamma(N_e)}\Gamma\left(N_e, \phi/\beta_d^2\right) \tag{15a}$$

$$\ge \frac{1}{\Gamma(N_e)}\Gamma\left(N_e, \frac{\sigma_e^2 \lambda_{\max}}{\sigma^2 2^{R_s}\beta_d^2}\right). \tag{15b}$$

注意，式（15b）是无IRS时保密中断概率的下界，如图5所示。

参考文献

[1] Q. Wu 和 R. Zhang，“迈向智能可重构环境：智能反射面辅助无线网络”，*IEEE Commun. Mag.*，第 58 卷，第 1 期，第 106–112 页，2019 年 1 月。[2] Y. Liu、H.-H. Chen 和 L. Wang，“面向下一代无线网络的物理层安全：理论、技术与挑战”，*IEEECommun.Surveys Tuts.*，第 19 卷，第 1 期，第 347–376 页，2016 年第一季度。[3] A. Almohamad、A. M. Tahir、A. Al-Kababji、H. M. Furqan、T. Khattab、M. O. Hasna 和 H. Arslan，“通过智能反射面实现智能安全无线通信：简要综述”，*IEEE Open J. Commun. Soc.*，第 1 卷，第 1442–1456 页，2020 年 9 月。[4] H. Shen、W. Xu、S. Gong、Z. He 和 C. Zhao，“智能反射面辅助多天线通信的保密速率最大化”，*IEEE Commun. Lett.*，第 23 卷，第 9 期，第 1488–1492 页，2019 年 9 月。[5] M. Cui、G. Zhang 和 R. Zhang，“通过智能反射面实现安全无线通信”，*IEEE Wireless Commun. Lett.*，第 8 卷，第 5 期，第 1410–1414 页，2019 年 10 月。[6] D. Xu 、 X. Yu 、 Y. Sun 、 D. W. K. Ng 和 R. Schober，“ 安全 IRS 辅助多用户 MISO 系统的资源分配”，载于*2019 IEEE Globecom*研讨会*(GC Wkshps)*。IEEE，2019 年，第 1–6 页。[7] S. Xu、J. Liu 和 Y. Cao，“ 智能反射面赋能的物理层安全：信号抵消还是干扰？ ”，*IEEE Inter- net Thing J.*，第 9 卷，第 2 期，第 1265–1275 页，2022 年 1 月。[8] H.-M. Wang、J. Bai 和 L. Dong，“在没有窃听者CSI的情况下通过智能反射面辅助安全传输”，*IEEE Signal ProcessingLett.*，第 27 卷，第 1300–1304 页，2020 年 7 月。[9] B. Feng、Y. Wu、M. Zheng、X.-G. Xia、Y. Wang 和 C. Xiao，“大型智能表面辅助的物理层安全传输”，*IEEE Trans. Signal Process.*，第 68 卷，第 5276–5291 页，2020 年 9 月。[10] Y. Liu、Z. Su、C. Zhang 和 H.-H. Chen，“可重构智能表面辅助 MI-MOME 系统中保密中断概率的最小化”，*arXiv:2205.00204*，2022 年 4 月。[11] T. Van Chien、L. T. Tu、S. Chatzinotas 和 B. Ottersten，“智能反射面增强通信系统的覆盖概率与遍历容量”，*IEEE Commun. Lett.*，第 25 卷，第 1 期，第 69–73 页，2021 年 1 月。[12] S. Liu、M. Lei 和 M.-J. Zhao，“智能反射面辅助 MISO-OFDM 系统的深度学习信道估计”，载于*2020 IEEE* 第 *92* 届车辆技术会议 *(VTC2020-Fall)*。IEEE，2020 年，第 1–5 页。[13] H. Song、M. Zhang、J. Gao 和 C. Zhong，“基于无监督学习的可重构智能表面辅助无线网络有源与无源联合波束成形设计”，*IEEE Commun. Lett.*，第 25 卷，第 3 期，第 892–896 页，2021 年 3 月。[14] A. M. Elbir 和 S. Coleri，“传统及 RIS 辅助大规模 MIMO 中的联邦学习信道估计”，*IEEE Trans. Wireless Commun.*，第 21 卷，第 6 期，第 4255–4268 页，2022 年 6 月。[15] X. Wei、D. Shen 和 L. Dai，“RIS辅助无线通信的信道估计——第一部分：基础、解决方案与未来机遇”，*IEEE Commun. Lett.*，第 25 卷，第 5 期，第 1398–1402 页，2021 年 5 月。[16] J. Gao、C. Zhong、X. Chen、H. Lin 和 Z. Zhang，“ 无源波束成形的无监督学习 ”，*IEEE Commun. Lett.*，第 24 卷，第 5 期，第 1052–1056 页，2020 年 5 月。