

面向不确定 CSI 随机接入网络的深度稳健资源分配

吴伟华¹, 柴冠华¹, 杨清海¹, 刘润滋²

(1. 西安电子科技大学通信工程学院, 陕西 西安 710071;

2. 西安建筑科技大学信息与控制工程学院, 陕西 西安 710055)

摘 要: 针对无线随机接入网络中通信信道状态信息 (C-CSI) 和干扰信道状态信息 (I-CSI) 均不确定的情况, 提出了一种深度稳健资源分配架构。该资源分配架构将无线网络的资源优化目标看作一个学习问题, 利用深度神经网络 (DNN) 以无监督的方式学习最优资源分配策略。通过将不确定的 CSI 建模为椭圆形状的不确定性集合, 提出了一个由 2 个 DNN 级联构成的网络结构, 第一个是不确定的 CSI 处理单元, 第二个是功率控制单元。然后, 提出了一种交替迭代训练算法用于联合训练 2 个级联的 DNN 单元。最后, 仿真比较了稳健学习策略和非稳健学习策略下的网络性能, 验证了所提算法的有效性。

关键词: 深度神经网络; 随机接入网络; 稳健优化; 无线资源分配

中图分类号: TP393

文献标识码: A

doi: 10.11959/j.issn.1000-436x.2020148

Deep and robust resource allocation for random access network based with imperfect CSI

WU Weihua¹, CHAI Guanhua¹, YANG Qinghai¹, LIU Runzi²

1. School of Telecommunications Engineering, Xidian University, Xi'an 710071, China

2. School of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China

Abstract: A deep and robust resource allocation framework was proposed for the random access based wireless networks, where both the communication channel state information (C-CSI) and the interference channel state information (I-CSI) were uncertain. The proposed resource allocation framework considered the optimization objective of wireless networks as a learning problem and employs deep neural network (DNN) to approximate optimal resource allocation policy through unsupervised manner. By modeling the uncertainties of CSI as ellipsoid sets, two concatenated DNN units were proposed, where the first was uncertain CSI processing unit and the second was the power control unit. Then, an alternating iterative training algorithm was developed to jointly train the two concatenated DNN units. Finally, the simulations verify the effectiveness of the proposed robust leaning approach over the nonrobust one.

Key words: deep neural network, random access network, robust optimization, wireless resource allocation

1 引言

本文研究了随机接入网络中的资源分配问题, 它

是长期演进未授权频谱网络 (LTE-U, long term evolution-unlicensed)^[1]、车联网 (IoV, Internet of vehicle)^[2] 和物联网 (IoT, Internet of things)^[3] 等研究热点的关键

收稿日期: 2020-04-14; 修回日期: 2020-06-26

基金项目: 国家自然科学基金资助项目 (No.61801365, No.61701365, No.61971327); 中国博士后科学基金资助项目 (No.2018M643581); 陕西省自然科学基金资助项目 (No.2019JQ-152, No.2020JQ-686); 中央高校基本科研业务费专项资金资助项目; 陕西省博士后科研基金资助项目

Foundation Items: The National Natural Science Foundation of China (No.61801365, No.61701365, No.61971327), China Postdoctoral Science Foundation (No.2018M643581), The Natural Science Foundation of Shaanxi Province (No.2019JQ-152, No.2020JQ-686), Research Funds for the Central Universities, Postdoctoral Foundation of Shaanxi Province

技术。在随机接入机制下，同一感知范围内的节点可以通过竞争协议共享频谱，如载波侦听多址接入（CSMA, carrier sense multiple access）技术。对于那些位于载波侦听外、干扰范围内的设备，需要精心设计功率控制方案，以确保相互干扰在侦听的阈值以下。

在随机接入无线网络中，衰落信道的状态信息称为传输链路的信道状态信息（CSI, channel state information），包括通信 CSI（C-CSI, communication-CSI）和不同感知范围内链路之间的干扰信道状态信息（I-CSI, interference-CSI）。尽管先前工作^[4-5]都提出了一些随机接入无线网络的资源分配方案，然而它们考虑的都是瞬时系统的性能。由于无线网络的信道状态信息都是随机变化的，因此在设计资源分配时应满足平均开销约束的前提下最大化系统的平均性能。然而，优化系统的平均性能会给功率控制带来很大的困难。这是因为所有无线网络中的功率控制都可以看作关于网络状态的函数。在考虑系统的平均性能时，功率控制变成了关于衰落信道状态稠密集的函数，这导致功率控制具有很高的维数。无线网络中的非线性收发电路和多小区间的相互干扰通常会导致一个非凸的资源管理问题。然而，在大多数情况下，非凸优化问题没有闭式解，需要通过注水（water-filling）^[6]算法或加权最小均方差（WMMSE, weighted minimum mean square error）^[7]等迭代算法获得次优解。在这些方案中，需要多次迭代实现算法收敛，这势必会导致一个较大的时延。考虑到深度神经网络（DNN, deep neural network）可以用于处理大规模、高维度和高复杂度问题的特性，它被广泛应用于解决通信网络中的资源分配问题。文献[8]提出了一种监督学习的方法，用于近似基于 WMMSE 算法的资源分配策略。但需要指出的是，基于监督学习的资源管理策略所获得的网络性能不会超过 WMMSE 算法。除此之外，文献[9]引入了非监督学习方法直接训练深度神经网络获得最优的网络性能。通过在 DNN 的损失函数中添加违反约束的惩罚项，可以将约束优化问题转化为无约束的 DNN 训练问题，从而保证利用 DNN 获得的结果是可行的。然而，惩罚因子属于神经网络中的超参数，确定惩罚因子需要消耗大量的计算资源。

由于“学习优化”方法可以用 DNN 来代替传统的优化算法，因此它已经被应用到许多网络资源管理的场景^[10-11]。文献[12]表明“学习优化”方法

的计算时间复杂度远小于传统算法。通过使用无监督的学习策略，“学习优化”方法可以避免训练大量的标签数据^[13-15]。基于“学习优化”框架，本文将随机接入无线网络中的功率控制问题看作一个学习问题。通过无监督训练，得到一个能够近似最优功率控制函数的 DNN 架构。

考虑到信道估计和量化的误差、信道反馈的时延和其他限制因素，获得的 C-CSI 和 I-CSI 通常都是不确定的^[16]。根据这些不确定的 CSI，DNN 得到的功率控制方案会造成网络性能的下降。文献[17-18]表明，不确定 CSI 下的功率控制将导致传输速率的剧烈波动。更重要的是，它可能对其他链路造成超过预先设定阈值的干扰，从而导致网络中断。因此，有必要设计一个稳健的 DNN 架构，能够在 CSI 不确定情况下进行稳定的传输。

基于以上考虑，本文提出了一个面向不确定 CSI 随机接入网络的深度稳健资源分配框架。所提框架采用无监督学习策略，将无线网络的优化目标视为一个学习问题。首先，为了解决不确定的 CSI 问题，利用稳健优化技术将优化问题转化为一个稳健问题。随后，提出了一个由 2 个神经网络单元构成的级联 DNN 架构：一个是不确定 CSI 处理单元，另一个是功率控制单元。不确定的 CSI 首先输入不确定的处理单元中，以获得可行的 CSI 值。然后，功率控制单元根据处理后的 CSI 值得到最优功率控制方案。最后，提出了一种交替迭代训练算法来联合训练不确定 CSI 处理单元和功率控制单元。

2 系统模型

在本文考虑的场景中，多个无线链路共用同一频谱资源，这些链路通过使用 CSMA 协议访问频谱。为了确定传输机会和避免碰撞，在数据传输之前，链路需要感知信道状态。如图 1 所示，本文将链路 n 的载波感知范围内的链路集表示为 C_n ，将载波感知范围外、干扰范围内的链路集表示为 I_n 。用 $\mathbf{h} = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_N]^T \in H$ 表示通信链路 C-CSI。此外， \mathbf{h} 的概率分布可以用 $m(\mathbf{h})$ 表示。I-CSI 表示为 $\mathbf{g} = [\mathbf{g}_1, \mathbf{g}_2, \dots, \mathbf{g}_N]$ ，其中 $\mathbf{g}_n = [\mathbf{g}_{i,n}]_{i \in I_n}$, $i \in I_n, n \in N$ 。 \mathbf{g} 的概率分布可以用 $m(\mathbf{g})$ 表示。一般来说，链路的资源分配可以看作 C-CSI 和 I-CSI 的函数，即 $\mathbf{p}(\mathbf{x}) \in P$ ，其中 $\mathbf{x} = (\mathbf{h}, \mathbf{g})$ 。在饱和流量的假设下，可以认为在相同 CSMA 范围内的链路之间的接入机会是均等的^[19-20]。因此链路 n 的传输机会可以通

过 $\frac{1}{1+|C_n|}$ 计算, 即接入时间平均分配给 $(1+|C_n|)$ 个链路。

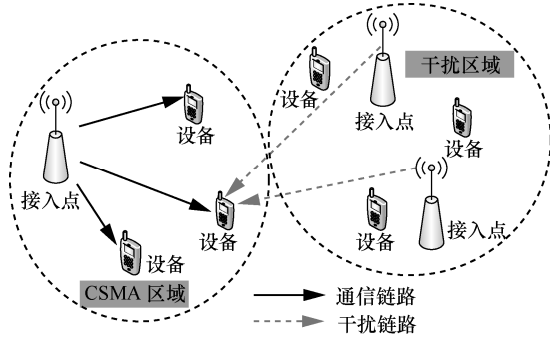


图1 系统模型

因此, 链路 n 的吞吐量可以表示为

$$R_n(\mathbf{p}(\mathbf{x}), \mathbf{x}) = \frac{aB}{1+|C_n|} \text{lb} \left(1 + \frac{p_n h_n}{N_0 B} \right) = ab_n \text{lb} \left(1 + \frac{p_n h_n}{N_0 B} \right), \forall n \in N \quad (1)$$

其中, a 表示信道传输效率, B 和 N_0 分别表示带宽和高斯白噪声的功率密度。

在随机接入无线网络中, 假如链路 n 受到来自 I_n 的干扰小于预先定义的阈值就可以接入信道, 即

$$\sum_{i \in I_n} p_i g_{i,n} + N_0 \leq Q_n, \forall n \in N \quad (2)$$

其中, Q_n 表示干扰阈值。

本文的目标是找到使系统遍历吞吐量最大化的资源分配函数 $\mathbf{p}(\mathbf{x})$ 。这个问题可以表示为

$$\begin{aligned} P^* &= \max_{\mathbf{p}(\mathbf{x})} \mathbb{E} \left\{ \sum_{n=1}^N ab_n \text{lb} \left(1 + \frac{p_n h_n}{N_0 B} \right) \right\} \\ \text{s.t. } &\mathbb{E} \left\{ \sum_{i \in I_n} p_i g_{i,n} + N_0 \right\} \leq Q_n, \forall n \in N \\ &\mathbf{p}(\mathbf{x}) \in P \end{aligned} \quad (3)$$

求解该优化问题有许多困难。首先, 优化变量 $\mathbf{p}(\mathbf{x})$ 是一个函数, 这表明式(3)属于高计算复杂度的函数优化问题。如果无线信道有 d 个离散值, 则需要计算 $Nd^{|d|}$ 个资源分配变量。其次, 信道分布函数 $m(\mathbf{h})$ 和 $m(\mathbf{g})$ 都是未知的。最后, C-CSI 和 I-CSI 都不可避免地具有误差, 这将影响系统性能并导致干扰超过预定义的阈值。

3 基于椭圆不确定集的稳健优化

在实际的无线网络中, 由于回程链路容量有限

或信道估计的误差, 参数 \mathbf{h} 和 \mathbf{g} 是不确定的。因此, 本文假设 C-CSI 和 I-CSI 中的部分状态信息可用。根据文献[21]可知, 不确定 C-CSI 和 I-CSI 虽然没有统计规律, 但却是有界的。本文利用椭圆集来描述不确定 CSI 的范围, 然后提出稳健优化方法来解决不确定 CSI 的问题。

3.1 信道的不确定性

链路 n 上的 I-CSI 可以建模成估计 CSI 和一个加性误差之和

$$\mathbf{g}_n = \hat{\mathbf{g}}_n + \Delta \mathbf{g}_n, \forall n \in N \quad (4)$$

其中, \mathbf{g}_n 、 $\hat{\mathbf{g}}_n$ 和 $\Delta \mathbf{g}_n$ 分别是确定值、估计值和误差值向量。为了对 I-CSI 的误差进行建模, 并表示不同不确定信道的相关性, 误差范围被建模成如下椭圆集

$$G_n = \left\{ \mathbf{g}_{i,n} \mid \left\| \mathbf{M}_n (\mathbf{g}_n - \hat{\mathbf{g}}_n) \right\| \leq \eta_n \right\}, \forall n \in N \quad (5)$$

其中, $\mathbf{M}_n \in R^{K \times K}$ 表示加权矩阵, R 表示实数集, $\|\cdot\|$ 表示一般范数, η_n 表示不确定范围的误差界。在实际的无线网络中, 有多种测量 η 的方法。例如, 可以通过计算信道模拟器生成的信道增益估计值与真实值之间的差来测量。此外, 还可以根据信道误差的特定分布来计算 η 。

同理, C-CSI 表示为

$$\mathbf{h} = \hat{\mathbf{h}} + \Delta \mathbf{h} \quad (6)$$

其中, \mathbf{h} 、 $\hat{\mathbf{h}}$ 和 $\Delta \mathbf{h}$ 分别是确定值、估计值和信道误差。因此 C-CSI 的误差范围可以建模为

$$H = \left\{ \mathbf{h}_n \mid \left\| \mathbf{K} (\mathbf{h} - \hat{\mathbf{h}}) \right\| \leq \delta \right\} \quad (7)$$

其中, $\mathbf{K} \in R^{K \times K}$ 是一个可逆的加权矩阵。确定 δ 使用和式(5)相同的方法。

为了优化最坏情况, 同时考虑所有不确定的参数, 稳健最大化问题可以表示为

$$\begin{aligned} O_R^* &= \max_{\mathbf{p}(\mathbf{x})} \min_{\mathbf{h}} \mathbb{E} \left\{ \sum_{n \in N} a_n b_n \text{lb} \left(1 + \frac{p_n h_n}{N_0 B} \right) \right\} \\ \text{s.t. } &\mathbb{E} \left\{ \sum_{i \in I_n} p_i g_{i,n} + N_0 \right\} \leq Q_n, \forall n \in N \\ &\mathbf{h} \in H, \mathbf{g} \in G_n, \forall n \in N, \mathbf{p}(\mathbf{x}) \in P \end{aligned} \quad (8)$$

不难看出, 若无线信道都是确定的, 式(8)将简化为式(3)。由于干扰约束的无限性, 式(8)属于半无限规划问题, 这类问题很难处理。此外, 内层关于 \mathbf{h} 的吞吐量的极小化是一个凹极小化问题, 一般是 NP 难问题。

3.2 不确定的 I-CSI 的等效最坏情况

为了保证所有 \mathbf{g} 满足干扰约束, 需要

$$\mathbb{E} \left\{ \max_{\mathbf{g}_n \in G_n} \mathbf{p}_n^\top \mathbf{g}_n + N_0 \right\} \leq Q_n, \forall n \quad (9)$$

其中, $\mathbf{p}_n = [p_i]_{1 \leq i \leq n}$ 。存在如下等价转化

$$\begin{aligned} \max_{\mathbf{g}_n \in G_n} \mathbf{p}_n^\top \mathbf{g}_n &= \mathbf{p}_n^\top \hat{\mathbf{g}}_n + \\ \eta_n \max_{\mathbf{g}_n \left\| \frac{\mathbf{M}_n(\mathbf{g}_n - \hat{\mathbf{g}}_n)}{\eta_n} \right\| \leq 1} \mathbf{p}_n^\top (\mathbf{M}_n^{-1} \mathbf{M}_n (\mathbf{g}_n - \hat{\mathbf{g}}_n)) &= \\ \mathbf{p}_n^\top \hat{\mathbf{g}}_n + \eta_n \left\| \mathbf{M}_n^{-1} \mathbf{p}_n \right\|^* & \end{aligned} \quad (10)$$

其中, $\|\cdot\|^*$ 表示对偶范数。例如, 对于由

$$\|\cdot\|_a = \left(\sum_{k=1}^K |x_k|^a \right)^{\frac{1}{a}}$$

定义的线性范数, a 表示线性范数的阶, 对应的对偶数范数为 $b = 1 + \frac{1}{a-1}$ 阶的线性范数。因此, 约束式(9)可以重新写成

$$\mathbb{E} \left\{ \mathbf{p}_n^\top \mathbf{g}_n + \eta_n \left\| \mathbf{M}_n^{-1} \mathbf{p}_n \right\|^* + N_0 \right\} \leq Q_n, \forall n \quad (11)$$

将式(11)结果代入式(8), 获得转换后的优化问题为

$$\begin{aligned} O_R^* &= \max_{\mathbf{p}(\mathbf{x})} \mathbb{E}_h \left\{ \sum_{n \in N} a_n b_n \text{lb} \left(1 + \frac{p_n h_n}{N_0 B} \right) \right\} \\ \text{s.t. } &\mathbb{E} \left\{ \mathbf{p}_n^\top \mathbf{g}_n + \eta_n \left\| \mathbf{M}_n^{-1} \mathbf{p}_n \right\|^* + N_0 \right\} \leq Q_n, \forall n \in N \\ &\mathbf{h} \in H, \forall n \in N, \mathbf{p}(\mathbf{x}) \in P \end{aligned} \quad (12)$$

然而, 内层关于 \mathbf{h} 的吞吐量的极小化仍然是一个凹极小化问题, 这使函数优化变量 $\mathbf{p}(\mathbf{x})$ 仍然难以求解。

3.3 基于 DNN 的学习

为了克服函数变量优化的困难, 可以使用深度学习框架。利用参数化的方法来近似资源分配函数, 即

$$\phi(\boldsymbol{\theta}, \hat{\mathbf{x}}) = \mathbf{p}(\hat{\mathbf{x}}) \quad (13)$$

其中, $\boldsymbol{\theta} \in R^q$, $\hat{\mathbf{x}} = (\hat{\mathbf{h}}, \hat{\mathbf{g}})$ 。

定理 1 假设 $\mathbf{p}(\hat{\mathbf{x}})$ 是定义在稠密集 $X \in \{\hat{\mathbf{x}}\}$ 的连续函数。对于由 sigmoid 函数构成的 DNN $\phi(\boldsymbol{\theta}, \hat{\mathbf{x}})$, 存在 $\varepsilon \geq 0$ 使

$$\sup_{\hat{\mathbf{x}} \in X} \|\mathbf{p}(\hat{\mathbf{x}}) - \phi(\boldsymbol{\theta}, \hat{\mathbf{x}})\| \leq \varepsilon \quad (14)$$

定理 1 的证明可以参考文献[22]。定理 1 表明, 对于给定的集合 X , 存在一个参数为 $\boldsymbol{\theta}$ 的 DNN, 它能够在任意小的误差范围内近似任意连续函数 $\mathbf{p}(\mathbf{x})$ 。因此, 可以用精心设计的 DNN $\phi(\boldsymbol{\theta}, \hat{\mathbf{x}})$ 来表征未知的资源分配函数 $\mathbf{p}(\mathbf{x})$ 。

接下来, 本文通过构造 DNN 来有效地解决资

源分配问题。DNN 由若干层组成, 每一层由一个线性操作和一个激活函数组成。特别地, 对于一个 L 层的 DNN, 记为 $l = \{1, \dots, L\}$, 第 l 层的维数为 q_l 。对于第 l 层, 首先由 $\mathbf{W}_l \in R^{q_{l-1} \times q_l}$ 和 $\mathbf{b}_l \in R^{q_l}$ 构成线性运算, 然后通过激活函数 $\sigma: R^{q_l} \rightarrow R^{q_l}$ 进行非线性运算。如果第 l 层输入为 $\mathbf{w}_{l-1} \in R^{q_{l-1}}$, 则第 l 层的输出为 $\mathbf{w}_l := \sigma(\mathbf{W}_l \mathbf{w}_{l-1} + \mathbf{b}_l)$ 。DNN 输出 \mathbf{w}_L 与第一层输入 \mathbf{w}_0 相关。为了满足隐藏的约束 $\mathbf{p}(\mathbf{x}) \in P$, 将输出层的激活函数 σ_L 定义为凸集 P 上的投影运算 $\prod_P(\mathbf{w}_L) = \arg \min_{\mathbf{p} \in P} \|\mathbf{w}_L - \mathbf{p}\|$ 。激活函数 σ 和 DNN 的层数是通过仿真确定的超参数。DNN 的线性权重矩阵 \mathbf{W}_l 和偏置 \mathbf{b}_l 通过学习获得。因此, 对于式(12)中的资源分配问题, 可以用一个 L 层 DNN $\phi(\boldsymbol{\theta}, \hat{\mathbf{x}})$ 来学习, 即

$$\phi(\boldsymbol{\theta}, \hat{\mathbf{x}}) = \prod_P(\sigma_L(\mathbf{W}_L \sigma_{L-1}(\mathbf{W}_{L-1}(\dots(\sigma_1 \mathbf{w}_0 + \mathbf{b}_0) + \mathbf{b}_{L-1}) + \mathbf{b}_L)) \quad (15)$$

其中, $\boldsymbol{\theta} = \{\mathbf{W}_l, \mathbf{b}_l : \forall l = 1, \dots, L\}$ 。

3.4 级联 DNN 架构

在式(12)中, 优化变量 $\mathbf{p}(\mathbf{x})$ 和 \mathbf{h} 相互耦合。由于内层是一个凹极小化问题, 无法得到关于 \mathbf{h} 的闭式解, 但是其最优解可以看作网络状态的函数, 即 $\mathbf{h}(\hat{\mathbf{x}})$ 。为了使 2 个最优变量解耦, 本文提出一个交替迭代算法来求解式(12)。在这个方法中, 首先根据可行的 $\mathbf{h}(\hat{\mathbf{x}})$ 求解 $\mathbf{p}(\hat{\mathbf{x}})$, 也就是式(12)的外层最大化问题。然后, 基于前一次迭代得到的资源分配解, 求得最优 $\mathbf{h}(\hat{\mathbf{x}})$, 也就是式(12)的内层极小化。基于这个交替迭代过程, 本文提出了 2 个级联神经网络架构, 如图 2 所示。第一个架构用于处理估计的信道状态信息 $\hat{\mathbf{x}}$, 第二个架构用于资源分配 $\mathbf{p}(\hat{\mathbf{x}})$ 。接下来, 详细讨论这 2 个神经网络。




图 2 级联神经网络的结构

3.4.1 解决内层最小化问题

在资源分配之前，需要将估计的信道状态信息 $\hat{\mathbf{h}}$ 处理为可行值。这可以通过引入一个 DNN 来实现，表示为

$$\mathbf{h}(\hat{\mathbf{x}}) = \varphi(\hat{\mathbf{x}}, \mathbf{w}) \quad (16)$$

其中， $\mathbf{w} \in R^q$ 为该 DNN 的参数。然后，求解内层关于参数 \mathbf{w} 的最小化问题。由 Jensen 不等式可知

$$\begin{aligned} \mathbb{E} \left\{ a_n b_n \text{lb} \left(1 + \frac{p_n h_n}{N_0 B} \right) \right\} &\leq a_n b_n \text{lb} \left(1 + \mathbb{E} \left\{ \frac{p_n h_n}{N_0 B} \right\} \right) = \\ &a_n b_n \text{lb} \left(1 + \frac{\mathbb{E} \{ p_n \} h_n}{N_0 B} \right) \end{aligned}$$

令集合 $\Omega = (\mathbf{w} | \varphi(\hat{\mathbf{x}}, \mathbf{w}) \in H)$ ，内层的问题转化为

$$\begin{aligned} O_\varphi^* &= \min_{\mathbf{w} \in \Omega} \sum_{n=1}^N a_n b_n \text{lb} \left(1 + \frac{\tilde{p}_n \varphi(\hat{\mathbf{x}}, \mathbf{w})}{N_0 B} \right) \\ \text{s.t. } &\| \mathbf{K}(\varphi(\hat{\mathbf{x}}, \mathbf{w}) - \hat{\mathbf{h}}) \| \leq \delta \end{aligned} \quad (17)$$

其中， $\tilde{p}_n = \mathbb{E}\{p_n\}$ 为无线链路的平均功率， $\mathbf{P}_{\text{av}} = (\tilde{p}_1, \tilde{p}_2, \dots, \tilde{p}_N)$ 。事实上，每个链路的发射功率是无法提前预知的，神经网络的输入状态只能是估计的 C-CSI 的 $\hat{\mathbf{x}}$ 。因此，平均功率 \tilde{p}_n 被视为一个常数。然而，在训练过程的每一步都需要平均功率。本文根据训练过程中第二个神经网络的输出来计算平均功率，如图 2 所示，在得到输出功率的平均值后，将其反馈给第一个神经网络，直到训练过程收敛。

求解式(17)中的优化问题需要学习参数 \mathbf{w} ，因此引入与约束相关的非负乘子 μ 。拉格朗日方程可以表示为

$$\begin{aligned} L(\mathbf{w}, \mu) &= \sum_{n=1}^N a_n b_n \text{lb} \left(1 + \frac{\tilde{p}_n \varphi(\hat{\mathbf{x}}, \mathbf{w})}{N_0 B} \right) - \\ &\mu \left(\| \mathbf{K}(\varphi(\hat{\mathbf{x}}, \mathbf{w}) - \hat{\mathbf{h}}) \| - \delta \right) \end{aligned} \quad (18)$$

对偶函数定义为

$$d(\mu) = \min_{\mathbf{w}} L(\mathbf{w}, \mu) \quad (19)$$

对偶问题写为

$$D_\varphi^* = \max_{\mu \geq 0} G(\mu) \quad (20)$$

在计算极小化式(17)的最优解时，需要研究原问题 O_φ^* 和对偶问题 D_φ^* 之间的误差，即对偶间隙。

对于如式(17)所示的凹极小化问题的对偶间隙，可以用定理 2 来解释^[23]。

定理 2 假设存在一个严格可行点 \mathbf{h} ，它满足式(17)中严格不等式的约束条件。若 $\hat{\mathbf{x}}$ 概率分布中没有正的概率点，则对偶间隙为 0，即 $D_\varphi^* - O_\varphi^* = 0$ 。

由定理 2 可知，式(17)的对偶间隙为 0。然后，本文提出一种原始-对偶优化方法来训练神经网络。 μ' 的更新可通过投影次梯度法计算，即

$$\mu^{t+1} = \mu' - \gamma \nabla_{\mu'} L(\mathbf{w}, \mu) \quad (21)$$

在给定 μ' 下，原式(18)是一个凹极小化问题，一般是 NP 难问题。然而，基于 DL 技术，可以通过 DNN 的训练来近似其最优值。DNN 对应的损失函数为

$$\begin{aligned} \text{loss} &= \sum_{n=1}^N a_n b_n \text{lb} \left(1 + \frac{\tilde{p}_n \varphi(\hat{\mathbf{x}}, \mathbf{w})}{N_0 B} \right) - \\ &\mu' \left(\| \mathbf{K}(\varphi(\hat{\mathbf{x}}, \mathbf{w}) - \hat{\mathbf{h}}) \| - \delta \right) \end{aligned} \quad (22)$$

然后，通过式(21)和式(22)，利用基于原始-对偶的训练算法，联合优化 DNN 参数和对偶变量 μ 。

3.4.2 处理外层最大化问题

在第一个神经网络之后，将可行的 C-CSI 的 \mathbf{x} 输入第二个参数为 $\varpi \in R^q$ 的资源分配神经网络中，即

$$\mathbf{p}(\mathbf{x}) = X(\mathbf{x}, \varpi) \quad (23)$$

则外部最大化问题可以表示为

$$\begin{aligned} P_X^* &= \max_{\varpi} \mathbb{E} \left\{ \sum_{n=1}^N a_n b_n \text{lb} \left(1 + \frac{X(\mathbf{x}, \varpi) h_n}{N_0 B} \right) \right\} \\ \text{s.t. } &\mathbb{E} \{ X(\mathbf{x}, \varpi) \hat{\mathbf{g}}_n + \eta_n \| \mathbf{M}_n^{-1} X(\mathbf{x}, \varpi) \|^* + N_0 \} \leq Q_n, \\ &\forall n \in N, X(\mathbf{x}, \varpi) \in P \end{aligned} \quad (24)$$

引入与约束相关的非负乘子 λ ，式(24)的拉格朗日函数由目标均值和加权约束组成，表示为

$$\begin{aligned} L(\varpi, \lambda) &= \mathbb{E} \left\{ \sum_{n=1}^N a_n b_n \text{lb} \left(1 + \frac{X(\mathbf{x}, \varpi) h_n}{N_0 B} \right) \right\} - \\ &\sum_{n \in N} \lambda_n (\mathbb{E} \{ X(\mathbf{x}, \varpi) \hat{\mathbf{g}}_n + \eta_n \| \mathbf{M}_n^{-1} X(\mathbf{x}, \varpi) \|^* + N_0 \} - Q_n) \end{aligned} \quad (25)$$

对偶函数定义为

$$D(\lambda) = \min_{\varpi} L(\varpi, \lambda) \quad (26)$$

同时对偶问题为

$$D_X^* = \max_{\lambda \geq 0} D(\lambda) \quad (27)$$

因此，拉格朗日乘子可以通过投影次梯度法来计算

$$\boldsymbol{\lambda}^{t+1} = \boldsymbol{\lambda}^t - \gamma \nabla_{\boldsymbol{\lambda}} L(\boldsymbol{\theta}^t, \boldsymbol{\lambda}^t) \quad (28)$$

同时，第二个神经网络的损失函数为

$$\begin{aligned} \text{loss} = & \frac{1}{S} \sum_{x \in X} f(X(x, \boldsymbol{\omega}), \hat{x}) - \\ & \frac{1}{S} \sum_{x \in X} \sum_{n \in N} \lambda_n z_n(X(x, \boldsymbol{\omega}), x) \end{aligned} \quad (29)$$

其中

$$\nabla_{\boldsymbol{\lambda}_n} L(\boldsymbol{\theta}^t, \boldsymbol{\omega}^t) = \frac{1}{S} \sum_{x \in X} z_n(X(x, \boldsymbol{\omega}), \hat{x}) - Q_n$$

$$f(X(x, \boldsymbol{\omega}), \hat{x}) = \sum_{n=1}^N a_n b_n \ln \left(1 + \frac{X(x, \boldsymbol{\omega})}{N_0 B} \right)$$

$$z_n(X(x, \boldsymbol{\omega}), \hat{x}) = X(x, \boldsymbol{\omega}) \hat{\mathbf{g}}_n + \eta \left\| \mathbf{M}_n^{-1} X(x, \boldsymbol{\omega}) \right\|^2 + N_0$$

在式(28)和式(29)中，通过 min-batch 样本集合 X 上的样本均值来近似平均系统性能和平均约束。接下来，给出基于交替迭代的训练算法，如算法 1 所示。在该算法中， $\mathbf{P}_{\text{total}}$ 和 \mathbf{P}_{av} 分别是多时隙的总发射功率和平均发射功率。

算法 1 交替迭代训练算法

全局初始化: $t = 0, \boldsymbol{\omega}^0, \boldsymbol{\lambda}^0, \boldsymbol{\mu}^0, \mathbf{P}_{\text{total}}^0 = 0, \mathbf{P}_{\text{av}}^0 = 0$;

repeat: 令 $t = t + 1$;

1) 内层最小化

局部初始化: $t_1 = 0, \boldsymbol{\omega}^{t_1} = \boldsymbol{\omega}^t, \boldsymbol{\mu}^{t_1} = \boldsymbol{\mu}^t$

repeat:

令 $t_1 = t_1 + 1$;

根据式(21)和式(22)更新 $\boldsymbol{\omega}^{t_1}$ 、 $\boldsymbol{\mu}^{t_1+1}$

until 收敛

2) 外层最大化

局部初始化: $t_2 = 0, \boldsymbol{\omega}^{t_2} = \boldsymbol{\omega}^{t_1}, \boldsymbol{\lambda}^{t_2} = \boldsymbol{\lambda}^{t_1}$,

$$\mathbf{P}_{\text{total}}^{t_2} = \mathbf{P}_{\text{av}}^{t_2}$$

repeat:

令 $t_2 = t_2 + 1$; 取样一个 batch $S \in X$;

根据式(28)和式(29)更新 $\boldsymbol{\omega}^{t_2}$ 、 $\boldsymbol{\lambda}^{t_2}$;

$$\mathbf{P}_{\text{total}}^{t_2} = \mathbf{P}_{\text{total}}^{t_2-1} + X(x, \boldsymbol{\omega}), \quad \mathbf{P}_{\text{av}}^{t_2} = \frac{\mathbf{P}_{\text{total}}^{t_2}}{t_2}$$

until 收敛

until 收敛

4 仿真结果

在仿真过程中，假设 6 个 CSMA 网络共用同一频谱，并且不同 CSMA 网络中链路之间的干扰关系如图 3 所示。在图 3 中，每个三角代表一个 CSMA 网

络，三角之间的连线表示 2 个不同的 CSMA 网络存在相互干扰。




图 3 不同 CSMA 网络之间的干扰关系

为了方便起见，用 $Q = Q_n, \forall n$ 表示所有链路的干扰阈值。用 $\eta = \eta_n, \forall n$ 和 $\delta = \delta_n, \forall n$ 表示所有参数不确定范围的标准化误差界。在仿真过程中， $\delta = \frac{\|\mathbf{g}_n - \hat{\mathbf{g}}_n\|}{\hat{\mathbf{g}}_n}$ ， $\eta = \frac{\|\mathbf{h}_n - \hat{\mathbf{h}}_n\|}{\hat{\mathbf{h}}_n}$ 。其中， $\delta = 0.2$ ， $\eta = 0.2$ 。未授权频谱上的路径损耗可以建模为 $\text{PL}(d) = -15.3 - 50 \lg(d[m])$ [24]。需要注意的是，CSMA 网络采用时分多址接入 (TDMA, time division multiple access) 方式工作，假设网络在饱和状态下工作，所以每一个 CSMA 网络 (三角形) 有且仅有一条链路处于传输状态。因此，在每一时刻 t ，需要统计的信息包括 6 个 CSMS 网络的 C-CSI (6 个三角形) 和对应的 14 个 I-CSI (7 条连线)。不确定性处理单元神经网络的输入为 C-CSI，输出为准确的 C-CSI，设置了 2 个隐藏层，输入层、隐藏层、输出层的神经元个数分别为 6、12 和 6。资源分配单元的输入为准确 C-CSI 和 I-CSI，输出为 CSMA 网络的发射功率，设置了 3 个隐藏层，输入层、隐藏层和输出层的神经元个数分别为 20、40 和 6。此外，DNN 采用 sigmoid 激活函数，权重的初始化采用标准正态分布。两个 DNN 单元都属于全连接神经网络。通信网络参数设置如表 1 所示。

表 1 通信网络参数设置

网络参数	数值大小
CSMA 链路个数	6
设备之间的距离 d	10~100 m 随机取值
带宽 B/MHz	6
传输效率 a	0.6
路径损耗 PL	$-15.3 - 50 \lg(d[m])$
高斯白噪声功率谱密度 $N_0/(\text{dBm} \cdot \text{Hz}^{-1})$	-174
干扰阈值 Q/dBm	33
最大发射功率 P_{max}/W	10

为了确保输出值在一定的范围内，最后一层隐藏层的输出被输入 sigmoid 函数中进行缩放。在仿真中，本文假设 P 的范围为 $[0,10]$ 。为了减少信道增益的最大值和最小值之间的巨大差异，输入数据采用了归一化技术^[11]。在原变量和对偶变量的更新中，采用 min-batch 梯度下降的方法，min-batch 大小设置为 10。从总样本集（通过信道建模随机生成）中选取 min-batch 大小的数据作为一次训练的样本。DNN 的学习率为 0.001。此外，训练集由 10 000 个样本组成，并在 5 000 个样本的测试集上测试训练 DNN 的性能。训练和测试都在 Python 3.6 和 tensorflow 1.4.0 上执行。

第一个仿真研究了不确定的 C-CSI 对系统吞吐量性能的影响。本文比较了稳健策略和非稳健策略。图 4(a)描绘了训练过程中的系统吞吐量性能，图 4(b)给出了基于测试信道集的系统吞吐量的概率密度函数 (PDF, probability density function)。由图 4(a)可知，经过 10 000 次训练之后，稳健算法可以收敛。此外，由于 C-CSI 值的估计误差，非稳健策略下的瞬时吞吐量波动较大。与非稳健策略相比，稳健策略的吞吐量较小。从图 4(a)观察到，稳健策略对应的吞吐量较稳定。通过图 4(b)可以说明，在稳健策略下，系统吞吐量的 PDF 成为一个尖锐的脉冲。这是因为稳健策略有一个不确定处理单元，它可以在不确定的 C-CSI 范围内最小化系统吞吐量的波动。

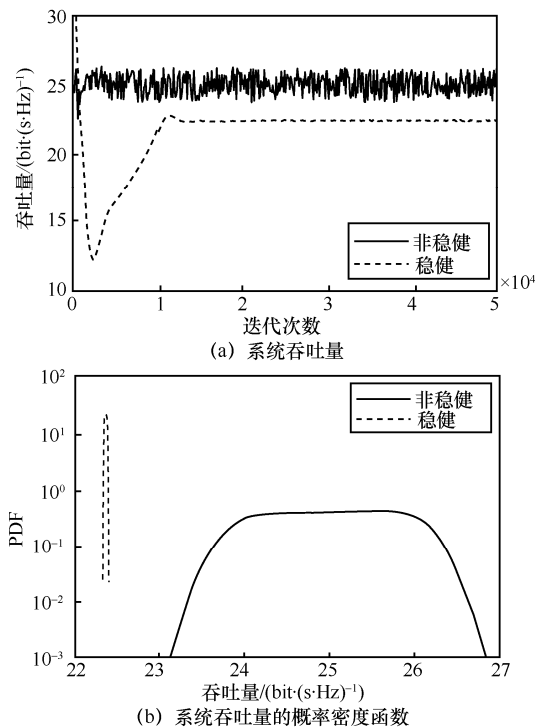


图 4 不确定的 C-CSI 对吞吐量的影响

图 5 给出了不确定的 I-CSI 对干扰约束的影响，即 $\sum_{i \in I_n} p_i g_{i,n} + N_0 - Q_n$ 。从图 5(a)可以看出，经过 10 000 次训练后，训练算法能够收敛。图 5(b)给出了基于测试信道集的干扰约束 PDF。结果表明，非稳健策略违反干扰功率约束的概率接近 0.5。然而，稳健策略总是满足干扰约束。这是因为稳健策略对应的是最坏情况下的优化。在不确定的 I-CSI 情况下，要严格约束其他网络所产生的干扰。




图 5 不确定的 I-CSI 对干扰约束的影响

图 6 说明了不同策略下的网络吞吐量与干扰阈值 Q 的关系。在图 6 中，理想非稳健策略将输入 CSI 视为准确 CSI，因此可以将其获得的吞吐量视为理论上限。图 6 中不同策略下的吞吐量随着干扰门限 Q 的增加而增加，这是由于干扰门限随着发射功率增加，导致系统的吞吐量上升。图 6 还表明，稳健策略下的吞吐量小于上限。这是因为稳健策略中部分功率用于满足干扰约束。此外，与非稳健策略下的有效吞吐量相比，稳健策略的吞吐量显著提高。这表明了稳健操作的必要性。




图 6 不同的策略的系统吞吐量与干扰阈值的关系

图 7 比较了稳健策略和非稳健策略的性能。结果表明，随着 δ 的增大，稳健策略的吞吐量有所降低。此外，当 δ 较小时，稳健策略比非稳健策略更有效；当 δ 较大时，这种优势更明显。这是因为在任何情况下，稳健策略都能满足干扰约束。此外，随着 δ 的增加，稳健策略下的吞吐量急剧下降，而非稳健策略下的吞吐量几乎保持不变。这是因为稳健策略有一个不确定处理单元，它以牺牲部分吞吐量为代价稳定系统的传输。虽然非稳健策略下的吞吐量保持不变，但波动很大，如图 4 所示。




图 7 稳健和非稳健策略下的系统吞吐量与所有 CSI 不确定的关系

5 结束语

本文研究了面向不确定的 CSI 随机接入网络中基于学习的资源分配问题。根据不确定的 CSI 模型，给出了一种不确定处理策略，并提出了一个由不确定 CSI 处理单元和功率控制单元构成的级联 DNN 架构。随后，提出了交替迭代训练算法，用于联合训练不确定处理单元和功率控制单元。最


后，仿真结果揭示了不确定 CSI 模型下 DNN 的性能。

参考文献:

- [1] HUANG Y, CHEN Y, HOU Y T, et al. Recent advances of LTE/Wi-Fi coexistence in unlicensed spectrum[J]. IEEE Network, 2018, 32(2): 107-113.
- [2] ZHENG K, ZHENG Q, CHATZIMISIOS P, et al. Heterogeneous vehicular networking: a survey on architecture, challenges, and solutions[J]. IEEE Communications Surveys & Tutorials, 2015, 17(4): 2377-2396.
- [3] 钱志鸿, 王雪. 面向 5G 通信网的 D2D 技术综述[J]. 通信学报, 2016, 37(7): 1-14.
- [4] QIAN Z H, WANG X. Reviews of D2D technology for 5G communication networks[J]. Journal on Communications, 2016, 37(7): 1-14.
- [5] WU W, YANG Q, LIU R, et al. Protocol design and resource allocation for LTE-U system utilizing licensed and unlicensed bands[J]. IEEE Access, 2019, 7: 67068-67080.
- [6] WU W, YANG Q, LIU R, et al. Online spectrum partitioning for LTE-U and WLAN coexistence in unlicensed spectrum[J]. IEEE Transactions on Communication, 2020, 68(1): 506-520.
- [7] YU W, GINIS G, CIOFFIFI J M. Distributed multiuser power control for digital subscriber lines[J]. IEEE Journal on Selected Areas in Communications, 2002, 20(5): 1105-1115.
- [8] SHI Q, RAZAVIYAYN M, LUO Z Q, et al. An iteratively weighted MMSE approach to distributed sum-utility maximization for a MIMO interfering broadcast channel[J]. IEEE Transactions on Signal Processing, 2011, 59(9): 4331-4340.
- [9] SUN H, CHEN X, SHIQ, et al. Learning to optimize: training deep neural networks for wireless resource management[C]//2017 IEEE 18th International Workshop on Signal Processing Advances in Wireless Communications. Piscataway: IEEE Press, 2017: 1-6.
- [10] HEE W, CHO D H, KIM M. Resource allocation for multi-channel underlay cognitive radio network based on deep neural network[J]. IEEE Communication Letter, 2018, 22(1): 1942-1945.
- [11] DMER S, HOYDIS C J, BRINK S T. Deep learning based communication over the air[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1): 132-143.
- [12] EISEN M, ZHANG C L, CHAMMON F O, et al. Learning optimal resource allocations in wireless systems[J]. IEEE Transactions on Signal Processing, 2019, 67(10): 2775-2790.
- [13] LEE H, LEE S H, QUEK T Q. Deep learning for distributed optimization: applications to wireless resource management[J]. IEEE Journal on Selected Areas in Communications, 2019(PP): 1.
- [14] 廖晓闽, 严少虎, 石嘉, 等. 基于深度强化学习的蜂窝网资源分配算法[J]. 通信学报, 2019, 40(2): 11-18.
- [15] LIAO X M, YAN S H, SHI J, et al. Deep reinforcement learning based resource allocation algorithm in cellular networks[J]. Journal on Communications, 2019, 40(2): 11-18.
- [16] LEE W, KIM M, CHO D. Transmit power control using deep neural network for underlay device-to-device communication[J]. IEEE Communications Letters, 2019, 8(1): 141-144.
- [17] KERRET P, GESBERT D, RILIPPONE M. Team deep neural networks for interference channels[C]//2018 IEEE International Conference on Communications Workshops. Piscataway: IEEE Press, 2018: 1-6.

- [16] AI-KHASIB T, SHENOUDA M B, LAMPE L. Dynamic spectrum management for multiple-antenna cognitive radio systems: Designs with imperfect CSI[J]. IEEE Transactions on Wireless Communications, 2011, 10(9): 2850-2859.
- [17] MPLARI N, PARSAEEFARD S, AZMI P, et al. Robust ergodic uplink resource allocation in underlay OFDMA cognitive radio networks[J]. IEEE Transactions on Mobile Computing, 2016, 15(2): 419-431.
- [18] PARSAEEFATD S, SHARAFAT A R. Robust worst-case interference control in underlay cognitive radio networks[J]. IEEE Transactions on Vehicular Technology, 2012, 61(8): 3731-3745.
- [19] SAGARI S, BAYSTING S, SAHA D, et al. Coordinated dynamic spectrum management of LTE-U and Wi-Fi networks[C]//2015 IEEE International Symposium on Dynamic Spectrum Access Networks. Piscataway: IEEE Press, 2015: 1-12.
- [20] LIEW S C, KAI C H, LEUNG H C, et al. Back-of-the-envelope computation of throughput distributions in CSMA wireless networks[J]. IEEE Transactions on Mobile Computing, 2010, 9(9): 1319-1331.
- [21] MALLICK S, DEVARAJAN R, LOODDRICHEH R A, et al. Robust resource optimization for cooperative cognitive radio networks with imperfect CSI[J]. IEEE Transactions on Wireless Communications, 2014, 14(2): 907-920.
- [22] SUN H, CHEN X, SHI Q, et al. Learning to optimize: Training deep neural networks for interference management[J]. IEEE Transactions Signal Process, 2018, 66(20): 5438-5453.
- [23] RIBEIRO A. Optimal resource allocation in wireless communication and networking[J]. EURASIP Journal on Wireless Communications and Networking, 2012, 2012(1): 272-285.
- [24] YIN R, YU G, MAAREF A, et al. A framework for co-channel interference and collision probability tradeoff in LTE licensed-assisted access networks[J]. IEEE Transactions on Wireless Communications, 2016, 15(9): 6078-6090.


[作者简介]



吴伟华(1988-),男,河北石家庄人,博士,西安电子科技大学讲师,主要研究方向为无线资源分配、人工智能、随机网络优化及其在LTE-U网络中的应用。



柴冠华(1996-),男,山西大同人,西安电子科技大学博士生,主要研究方向为人工智能、网络资源分配。



杨清海(1976-),男,山东高密人,博士,西安电子科技大学教授,主要研究方向为自主通信、内容交付网络和LTE-A技术等。



刘润滋(1988-),女,山东潍坊人,博士,西安建筑科技大学副教授,主要研究方向为无线网络、空间网络中的资源管理和性能分析。