

4-15-2024

## Element Grouping Faceted Fully Connected Network Based on RIS

Shunhu Hou

*Graduate School, Space Engineering University, Beijing 101416, China, hshhsc2022@163.com*

Shengliang Fang

*School of Space Information, Space Engineering University, Beijing 101416, China, eeifslyl@163.com*

Qingyao Zeng

*Graduate School, Space Engineering University, Beijing 101416, China*

Mengtao Wang

*Graduate School, Space Engineering University, Beijing 101416, China*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact [xtfzxb@126.com](mailto:xtfzxb@126.com).

---

## Element Grouping Faceted Fully Connected Network Based on RIS

### Abstract

**Abstract:** In view of the over-fitting problem that caused by multiple parameters and high memory usage of the full connection layer of neural network in training, a RIS-based element grouping areal fully connected neural network (RGFCNN) is proposed for the first time based on the structural characteristics of reconfigurable intelligence surface (RIS). Based on the structural characteristics of RIS, the network is optimized on traditional FCNN. A novel transmission surface attention mechanism is designed for the effective feature extraction of data. Compared with the traditional FCNNs, the proposed network does not arrange the data in one-dimensional manner. Instead, a element grouping strategy is proposed for the neural network construction, which directly groups the two-dimensional surface data, carries out the fully connected processing on each group, and concatenates the output of each group. The experimental results show that, on the public available communication signal datasets with IQ data features, RGFCNN has better recognition accuracy when SNR is greater than 0 dB, and the training parameters are approximately 1/6 of the original.

### Keywords

reconfigurable intelligence surface (RIS), fully-connected neural network(FCNN), element grouping strategy, IQ signal, modulation recognition

### Recommended Citation

Hou Shunhu, Fang Shengliang, Zeng Qingyao, et al. Element Grouping Faceted Fully Connected Network Based on RIS[J]. Journal of System Simulation, 2024, 36(4): 1017-1027.

# 基于RIS的元素分组面状全连接网络

侯顺虎<sup>1</sup>, 方胜良<sup>2\*</sup>, 曾庆尧<sup>1</sup>, 王孟涛<sup>1</sup>

(1. 航天工程大学 研究生院, 北京 101416; 2. 航天工程大学 航天信息学院, 北京 101416)

**摘要:** 针对神经网络全连接层在训练中参数量多、所占内存多、易产生过拟合问题, 从智能超表面(reconfigurable intelligence surface, RIS)结构特征出发, 提出了一种基于RIS的元素分组面状全连接神经网络(RIS-based element grouping areal fully connected neural network, RGFCNN)。借鉴RIS的结构特征, 在传统全连接神经网络上进行优化。设计了透射面注意力机制用于数据有效特征提取, 相比于传统的全连接网络, 该网络没有对数据进行一维排列, 而是提出了一种运用于神经网络构建的元素分组策略, 直接对二维面状数据进行分组全连接处理, 各组处理输出进行数据串联。实验结果表明: 在公开的具有IQ数据特征的通信信号数据集上, RGFCNN在信噪比大于0 dB时具有更好的识别精度, 而训练参数是原来的大约1/6。

**关键词:** 智能超表面; 全连接神经网络; 元素分组策略; IQ信号; 调制识别

中图分类号: TP183

文献标志码: A

文章编号: 1004-731X(2024)04-1017-11

DOI: 10.16182/j.issn1004731x.joss.23-0304

**引用格式:** 侯顺虎, 方胜良, 曾庆尧, 等. 基于RIS的元素分组面状全连接网络[J]. 系统仿真学报, 2024, 36(4): 1017-1027.

**Reference format:** Hou Shunhu, Fang Shengliang, Zeng Qingyao, et al. Element Grouping Faceted Fully Connected Network Based on RIS[J]. Journal of System Simulation, 2024, 36(4): 1017-1027.

## Element Grouping Faceted Fully Connected Network Based on RIS

Hou Shunhu<sup>1</sup>, Fang Shengliang<sup>2\*</sup>, Zeng Qingyao<sup>1</sup>, Wang Mengtao<sup>1</sup>

(1. Graduate School, Space Engineering University, Beijing 101416, China;

2. School of Space Information, Space Engineering University, Beijing 101416, China)

**Abstract:** In view of the over-fitting problem that caused by multiple parameters and high memory usage of the full connection layer of neural network in training, a RIS-based element grouping areal fully connected neural network (RGFCNN) is proposed for the first time based on the structural characteristics of reconfigurable intelligence surface (RIS). Based on the structural characteristics of RIS, the network is optimized on traditional FCNN. A novel transmission surface attention mechanism is designed for the effective feature extraction of data. Compared with the traditional FCNNs, the proposed network does not arrange the data in one-dimensional manner. Instead, a element grouping strategy is proposed for the neural network construction, which directly groups the two-dimensional surface data, carries out the fully connected processing on each group, and concatenates the output of each group. The experimental results show that, on the public available communication signal datasets with IQ data features, RGFCNN has better recognition accuracy when SNR is greater than 0 dB, and the training parameters are approximately 1/6 of the original.

**Keywords:** reconfigurable intelligence surface (RIS); fully-connected neural network(FCNN); element grouping strategy; IQ signal; modulation recognition

收稿日期: 2023-03-16

修回日期: 2023-05-23

第一作者: 侯顺虎(2000-), 男, 硕士生, 研究方向为空间网络电磁安全. E-mail: hshsc2022@163.com

通讯作者: 方胜良(1968-), 男, 教授, 博导, 博士, 研究方向为电子对抗. E-mail: ceifsllyl@163.com

## 0 引言

未来十年通信网络容量将千倍增长，无处不在的无线连接将成为现实，但高度复杂的网络、高成本的硬件和日益增加的能源消耗成为未来无线通信面临的关键问题<sup>[1-2]</sup>。研究创新、高效、频谱及资源友好的未来无线网络解决方案势在必行。智能超表面(reconfigurable intelligent surface, RIS)以其独特的低成本、低功耗、可编程、易部署等特点脱颖而出<sup>[3-6]</sup>。

RIS 是一种具有可编程电磁特性的人工电磁表面结构，由超材料技术发展而来，具有电磁特性实时可编程的特点。其基本原理由文献[7]提出并实验验证，引发全球跟进。RIS 通常由大量精心设计的电磁单元排列组成，通过给电磁单元上的可调元件施加控制信号，可以动态地控制这些电磁单元的电磁性质，进而实现以可编程的方式对空间电磁波进行主动的智能调控，形成幅度、相位、极化和频率等参数可控制的电磁场<sup>[8-11]</sup>。这一机制提供了 RIS 的电磁世界和信息科学的数字世界之间的接口，对于未来无线网络的发展极具吸引力。

文献[7]提出了数字编码和现场可编程超材料。通过控制超材料的空间数字编码 01 序列，实时可编程地操控电磁波的空间分布，可以控制超表面参数达到反射或者透射电磁波的作用，因此产生了反射系数与透射率的概念<sup>[12]</sup>。文献[13]进一步提出了时间数字编码超材料，实现了对电磁波频谱的实时可编程操控。文献[14]提出了信息超材料的概念，将无源模拟超表面与数字有源可编程超表面对多维电磁波的调控统一起来，可将数字信息论和信号处理中的理论方法用到超表面的设计中，建立物理世界与数字世界的桥梁，进一步衍生出信息超材料。文献[15]提出了一种新的 RIS 元素分组策略，每个组由一组相邻的 RIS 元素组成，这些元素具有相同的反射系数。与直接估计每个 RIS 元素的信道并共同设计其反射系数的方法相

比，RIS 元素的分组利用了相邻 RIS 元素之间的信道相关性，显著降低了所需的训练开销以及 RIS 系数设计的复杂性。

智能超表面发展的越来越迅速，AI 技术的引入，解决了复杂场景中的非线性拟合问题，在模型不准甚至无模型的条件下达到了比传统技术更优的效果<sup>[16-19]</sup>。IMT-2030(6G)推进组关于智能超表面的技术研究报告第二版中提出未来 AI 应用于 RIS 的必要性，同时总结了 RIS 的关键技术挑战，并对 RIS 智能技术未来发展趋势做出了概括。其中一项是基于 RIS 的新型神经网络结构。

深度学习中的神经网络利用一种分层的互联结构来模拟人脑神经元之间的连接<sup>[20-21]</sup>。2022 年《智能超表面技术研究报告》分析了当前 RIS 面临的关键性挑战技术，其中一条就是探索基于 RIS 的新型神经网络结构。具体来说，RIS 神经网络以电磁信号为信息传输媒质，将 RIS 中的电磁单元作为神经元，其权重为可编程透射系数，是模型的可训练部分，可采用多层 RIS 作为透射层进行特征选取，多层 RIS 也可以设置权重；将多层 RIS 作为全连接层，相邻层之间的电磁单元以电磁波传播方式进行互连。这种 RIS 神经网络不仅可以实现图像分类等深度学习应用，还有望构造新型的无线通信编解码器来实现射频信号的直接处理与收发。因此，本文模仿 RIS 的结构原理，提出了一种基于元素分组策略的面状全连接网络。借鉴 RIS 结构特征，在传统神经网络上的结构优化，对于未来实现基于超材料的人工电磁表面深度神经网络具有借鉴意义。

## 1 相关工作

### 1.1 数据集介绍

RML2016.10A 是 O'Shea T J 由 GNU Radio 软件平台仿真生成的开源数据集，数据集中数字调制的数据内容为 ASCII 形式的莎士比亚作品，并采用白化随机确保字符和比特概率相等出现，模

拟调制的数据内容为断断续续的声音信号。传输信道模型包含了热噪声和多径衰落等物理环境噪声, 并考虑了包括采样率偏移、噪声、中心频率偏移和衰落等随机信道和设备缺陷的模型等<sup>[22-23]</sup>。

数据集包括 3 种数制信号 BPSK、QPSK、8PSK 和 8 种模拟调制信号 16QAM、64QAM、BFSK、CPFSK、PAM4、WB-FM、AM-SSB、AM-DSB, 一共 220 000 个调制信号, 每种调制方式有 20 000 个调制信号。信噪比从 -20~18 dB 间隔 2 dB 一共被分为了 20 种信噪比, 也就是每一种调制方式的一种信噪比下的调制信号有 1 000 个。每个调制信号的 size 是 [2, 128], 2 对应输入信号是正交的 IQ 两路信号, 128 对应每个信号有 128 个采样点。此仿真数据集和真实信号高度相似, 在此数据集上进行实验, 对于将模型推广到真实信号的数据集上具有重要意义。

### 1.2 RGFCNN 网络模型

本文模仿 RIS 的结构原理, 提出一种基于元素分组策略的面状全连接网络, 如图 1 所示。输入特征首先经过三层透射面 (characteristic

transmission layer), 透射面形状与输入特征形状相同。透射面上每一个神经元对应一个透射率 (transmissivity), 也叫透射系数 (transmission coefficient), 是可训练部分, 可以对输入特征进行特征选择。同时三层透射面附加了一个通道注意力机制 (channel attention module), 给三个面也附加了可训练的权重<sup>[24-25]</sup>。经过透射输出后的数据与原输入进行相加运算, 保证了特征的不丢失。

经过特征选择后的输出数据进行元素分组 (element grouping), 每一组进行全连接, 相当于一种局部全连接。最后各组的全连接输出拼接在一起, 并进行分类, 大大降低了模型训练参数。如果分组合理, 相比原始的全连接层, 能更好地利用局部元素之间的相关性, 有助于网络结果精度的提高。相比于原来的全连接层, 元素分组局部全连接一定程度上可以解决过拟合的问题。

假设输入数据为  $D_{input}$ , 并且

$$D_{input} = [H, W, C] \tag{1}$$

式中:  $H$  为输入数据尺寸的高度;  $W$  为输入数据尺寸的宽度;  $C$  为输入数据特征的通道数。

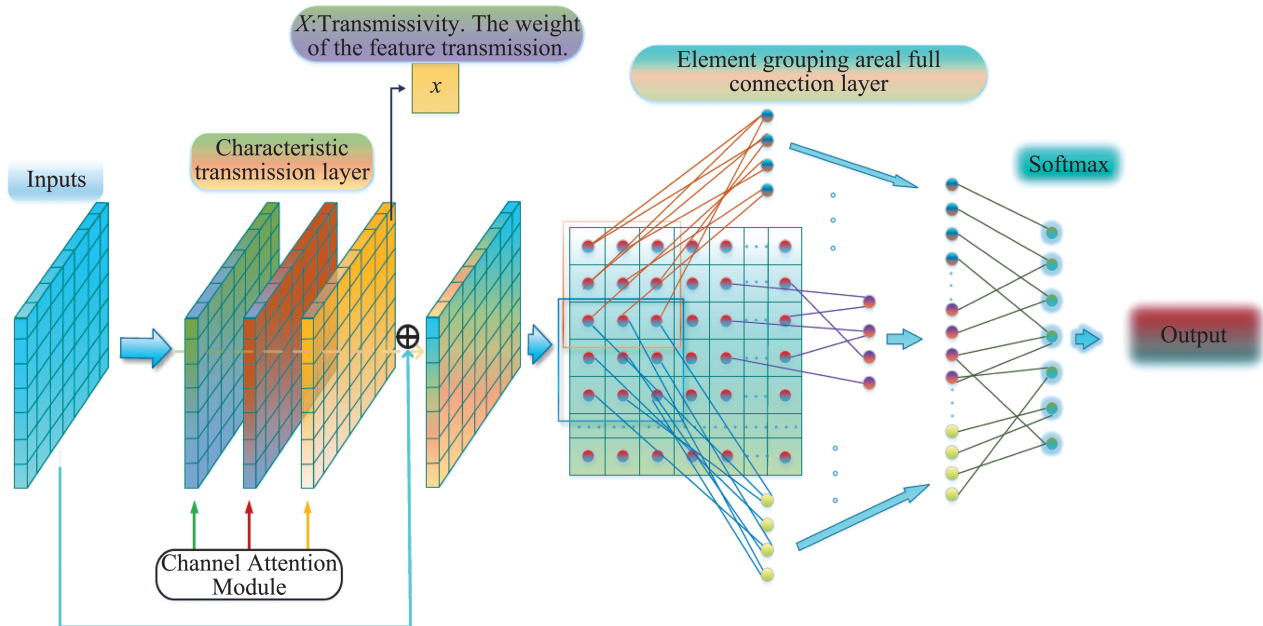


图 1 RGFCNN 结构  
Fig. 1 RGFCNN structure

设矩阵  $\mathbf{L}_{\text{trans}}$  表示透射层,  $\mathbf{L}_{\text{trans}}^{(i)}$  表示第  $i$  层透射面,  $i=1, 2, \dots, n, n \in N$ , 则有

$$\mathbf{L}_{\text{trans}}^{(i)} = [\mathbf{H}^{(i)}, \mathbf{W}^{(i)}] = \begin{bmatrix} x_{1,1}^{(i)} & x_{1,2}^{(i)} & \dots & x_{1,W}^{(i)} \\ x_{2,1}^{(i)} & x_{2,2}^{(i)} & \dots & x_{2,W}^{(i)} \\ \vdots & \vdots & \ddots & \vdots \\ x_{H,1}^{(i)} & x_{H,2}^{(i)} & \dots & x_{H,W}^{(i)} \end{bmatrix} \quad (2)$$

式中:  $x_{H,W}^{(i)}$  为第  $i$  层透射面第  $H$  行第  $W$  列的透射率大小。为了方便表示,  $\mathbf{L}_{\text{trans}}^{(i)}$  中没有写出通道  $C$ , 实际上透射面会根据输入的数据通道数进行设置。透射率在各个通道中都是随机初始化并能在训练过程中实时更新的。

透射率  $x$  服从  $[0, 1]$  上的均匀分布, 概率密度函数为

$$f(x) = \begin{cases} 0, & x < 0 \text{ or } x > 1 \\ 1, & 0 \leq x \leq 1 \end{cases} \quad (3)$$

设  $F(x)$  为  $x$  的概率分布函数, 则  $x$  的概率分布表示为

$$F(x) = \begin{cases} 0, & x < 0 \\ x, & 0 \leq x < 1 \\ 1, & x \geq 1 \end{cases} \quad (4)$$

这样一来, 就把透射面上的透射系数限定在  $[0, 1]$  的范围内, 在神经网络训练过程中, 该部分是可以经过反向传播事实更新的。能够自动地让有利于损失函数减小的输入特征透过, 而淡化其他不利于损失函数减小的特征。

在智能超表面的研究工作中, 通过灵活地控

制每一个超表面的状态能够实现对电磁波信号的调控。基于这一思想, 在多层透射面中又加入了通道注意力机制, 负责控制附加给每一个透射面的权重, 整个透射层相当于一个结合空间和通道的注意力机制, 如图2所示。

透射面  $\mathbf{L}_{\text{trans}}^{(i)}$  的集合:

$$\mathbf{R}(\mathbf{L}_{\text{trans}}) = [\mathbf{L}_{\text{trans}}^{(1)}, \mathbf{L}_{\text{trans}}^{(2)}, \dots, \mathbf{L}_{\text{trans}}^{(n)}], i=1, 2, \dots, n, n \in N \quad (5)$$

分别计算  $\mathbf{R}(\mathbf{L}_{\text{trans}})$  中每一个透射面  $\mathbf{L}_{\text{trans}}^{(i)}$  上所有透射系数  $x$  的最大池化值和平均池化值:

$$\mathbf{M}(\mathbf{L}_{\text{trans}}) = [\max(\mathbf{L}_{\text{trans}}^{(1)}), \max(\mathbf{L}_{\text{trans}}^{(2)}), \dots, \max(\mathbf{L}_{\text{trans}}^{(n)})] \quad (6)$$

$$\mathbf{A}(\mathbf{L}_{\text{trans}}) = [\text{avg}(\mathbf{L}_{\text{trans}}^{(1)}), \text{avg}(\mathbf{L}_{\text{trans}}^{(2)}), \dots, \text{avg}(\mathbf{L}_{\text{trans}}^{(n)})] \quad (7)$$

通道注意力机制的权重:

$$\mathbf{C}(\mathbf{L}_{\text{trans}}) = \mathbf{M}(\mathbf{L}_{\text{trans}}) + \mathbf{A}(\mathbf{L}_{\text{trans}}) = [\text{Channel\_weight}(\mathbf{L}_{\text{trans}}^{(1)}), \text{Channel\_weight}(\mathbf{L}_{\text{trans}}^{(2)}), \dots, \text{Channel\_weight}(\mathbf{L}_{\text{trans}}^{(n)})] \quad (8)$$

$$\text{Channel\_weight}(\mathbf{L}_{\text{trans}}^{(i)}) = \max(\mathbf{L}_{\text{trans}}^{(i)}) + \text{avg}(\mathbf{L}_{\text{trans}}^{(i)}) \quad (9)$$

融入了通道注意力机制的透射面:

$$\mathbf{T}(\mathbf{L}_{\text{trans}}) = \mathbf{R}(\mathbf{L}_{\text{trans}}) \cdot \mathbf{C}(\mathbf{L}_{\text{trans}}) \quad (10)$$

经过透射层的输出结果:

$$\mathbf{D}_{\text{out}} = \text{Multiply}(\mathbf{D}_{\text{input}}, \mathbf{T}(\mathbf{L}_{\text{trans}})) + \mathbf{D}_{\text{input}} \quad (11)$$

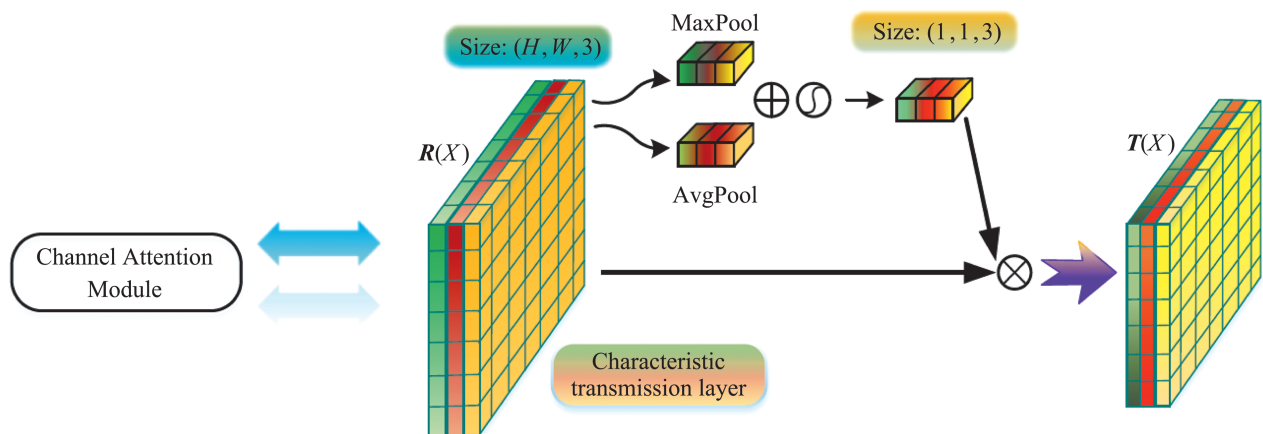


图2 通道注意力机制结构  
Fig. 2 CAM structure

Multiply( $a, b$ )表示  $a$  与  $b$  中对应元素相乘, 与原输入进行相加运算是为了保证特征不丢失。由于数据经过透射面尺寸未发生改变, 输出后的结果为

$$D_{out}=[H^T, W^T, C^T] \quad (12)$$

采取元素分组策略将  $D_{out}$  划分为小尺寸的各组数据, 通道数不变, 分别进行全连接:

$$D_{out} = \begin{bmatrix} \mathbf{g}_{1,1} & \mathbf{g}_{1,2} & \dots & \mathbf{g}_{1,W/w} \\ \mathbf{g}_{2,1} & \mathbf{g}_{2,2} & \dots & \mathbf{g}_{2,W/w} \\ \vdots & \vdots & & \vdots \\ \mathbf{g}_{H/h,1} & \mathbf{g}_{H/h,2} & \dots & \mathbf{g}_{H/h,W/w} \end{bmatrix} \quad (13)$$

$\mathbf{g}_{mn}=[h^{(k)}, w^{(k)}, C]$ 表示  $D_{out}$  中第  $k$  个分组, 由于每一组的分组尺寸是一致的, 因此该组元素尺寸为

$$\text{Group\_size} = [h, w, C] \quad (14)$$

$$h < H, w < W, H \% h = 0, W \% w = 0 \quad (15)$$

设置第  $k$  组进行全连接的输入元素为  $a_1^{(k)}, a_2^{(k)}, \dots, a_{hw}^{(k)}$ , 同时设第  $k$  组经过全连接后得到的输出为  $D_{group\_out}^{(k)}=[b_1, b_2, \dots, b_k]^T$ , 则有

$$D_{group\_out}^{(k)} = \begin{bmatrix} W_{1,1} & W_{1,2} & \dots & W_{1,hw} \\ W_{2,1} & W_{2,2} & \dots & W_{2,hw} \\ \vdots & \vdots & & \vdots \\ W_{k,1} & W_{k,2} & \dots & W_{k,hw} \end{bmatrix} \begin{bmatrix} a_1^{(k)} \\ a_2^{(k)} \\ \vdots \\ a_{hw}^{(k)} \end{bmatrix} + \begin{bmatrix} c_1 \\ c_2 \\ \vdots \\ c_k \end{bmatrix} \quad (16)$$

式中:  $W$ 为神经网络全连接层权重;  $c$ 为偏置。

各个分组全连接输出的集合为

$$N_{all\_nodes} = [D_{group\_out}^{(1)}, D_{group\_out}^{(2)}, \dots, D_{group\_out}^{(k)}, \dots, D_{group\_out}^{(final)}] \quad (17)$$

输入数据经过透射层, 然后划分各分组进行局部全连接得到输出, 拼接成总的节点数, 网络模型构建完成。

## 2 改进的模型方法

### 2.1 全连接层

本文使用的数据集是 IQ 信号, 数据格式为  $[2, 128]$ , 采用一层全连接层<sup>[26]</sup>对数据进行分类作为对比模型, 隐藏神经元个数为 128, 如图 3 所示。

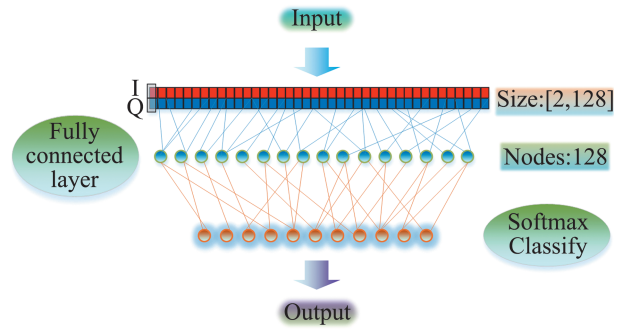


图 3 FCNN 结构图  
Fig. 3 FCNN structure diagram

采用传统的全连接网络, 输入数据所有元素都要与全连接层中的每一个节点进行连接, 这样不仅会大大提升参数量, 还会经常出现过拟合的现象。本文所选择的普通 FCNN 模型是信号调制识别领域在分类前常用的全连接网络, 节点数设置为 128, 很多信号识别网络如 CLDNN、MCLDNN 等在分类前会使用一层或者两层隐藏节点数为 128 的 FCNN 进行特征的汇总, 便于分类。

### 2.2 基于元素分组的面状全连接网络

针对本文使用的数据, 输入数据格式为  $[128, 2]$ , 采取的元素分组策略为: 将输入的数据划分为 8 组, 每一组数据格式为  $[16, 2]$ , 按组进行全连接, 小组内全连接层隐藏神经元个数为 16。最后拼接在一起总的神经元个数为 128, 与对比模型保持一致。使用元素分组方法时, 针对每一组元素尺寸大小的选取, 要尽可能地保证每一组元素局部特征的完整性从而保证模型的识别性能。对于 IQ 信号, 每一组元素中要包含这一段信号的时序特征, 这就要求元素分组不能太小, 防止出现局部时序特征截断或者特征不明显的情况。同时, 元素分组尺寸不能过大, 过大后模型需要训练的参数会大大增加, 这违背了该方法的初衷。因此, 针对不同的输入数据, 需要灵活地找到一种元素分组策略, 既能包含所需要的局部特征, 保证模型的准确性, 又能大大减少训练参数量, 减少内存占用和成本。这需要在构建模型时针对输入数据采取多种分组方法进行对比实验, 找到一种相

对更加合适的策略。一般而言，根据多次实验所得经验，元素分组尺寸选择输入数据尺寸的0.125~0.25较为合适。具体的面状全连接网络结构如图4所示。

本次所用数据集输入数据为 $D_{input}$ ，并且

$$D_{input}=[128, 2, 1] \quad (18)$$

采用的透射层为3层，即 $L_{trans}^{(i)}$ ， $i=1, 2, 3$ ，表示第 $i$ 层透射面。则有

$$L_{trans}^{(i)}=[H^{(i)}, W^{(i)}]=\begin{bmatrix} x_{1,1}^{(i)} & x_{1,2}^{(i)} \\ x_{2,1}^{(i)} & x_{2,2}^{(i)} \\ \dots & \dots \\ x_{128,1}^{(i)} & x_{128,2}^{(i)} \end{bmatrix} \quad (19)$$

透射面 $L_{trans}^{(i)}$ 的集合：

$$R(L_{trans})=[L_{trans}^{(1)}, L_{trans}^{(2)}, L_{trans}^{(3)}] \quad (20)$$

分别计算 $R(L_{trans})$ 中每一个透射面 $L_{trans}^{(i)}$ 上所有透射系数 $x$ 的最大池化值和平均池化值：

$$M(L_{trans})=[\max(L_{trans}^{(1)}), \max(L_{trans}^{(2)}), \max(L_{trans}^{(3)})] \quad (21)$$

$$A(L_{trans})=[\text{avg}(L_{trans}^{(1)}), \text{avg}(L_{trans}^{(2)}), \text{avg}(L_{trans}^{(3)})] \quad (22)$$

通道注意力机制的权重：

$$C(L_{trans})=M(L_{trans})+A(L_{trans})= [\text{Channel\_weight}(L_{trans}^{(1)}), \text{Channel\_weight}(L_{trans}^{(2)}), \text{Channel\_weight}(L_{trans}^{(3)})] \quad (23)$$

$$\text{Channel\_weight}(L_{trans}^{(i)})=\max(L_{trans}^{(i)})+\text{avg}(L_{trans}^{(i)}) \quad (24)$$

融入了通道注意力机制的透射面：

$$T(L_{trans})=R(L_{trans}) \cdot C(L_{trans}) \quad (25)$$

经过透射层的输出结果为

$$D_{out}=\text{Multiply}(D_{input}, T(L_{trans}))+D_{input} \quad (26)$$

由于数据经过透射面尺寸未发生改变，输出后的结果为

$$D_{out}=[128, 2, 1] \quad (27)$$

采取元素分组策略将 $D_{out}$ 划分为小尺寸的小组数据，通道数不变，分别进行全连接。每组尺寸为 $[16, 2, 1]$ ，共8组：

$$D_{out}=[g_1 \ g_1 \ \dots \ g_8] \quad (28)$$

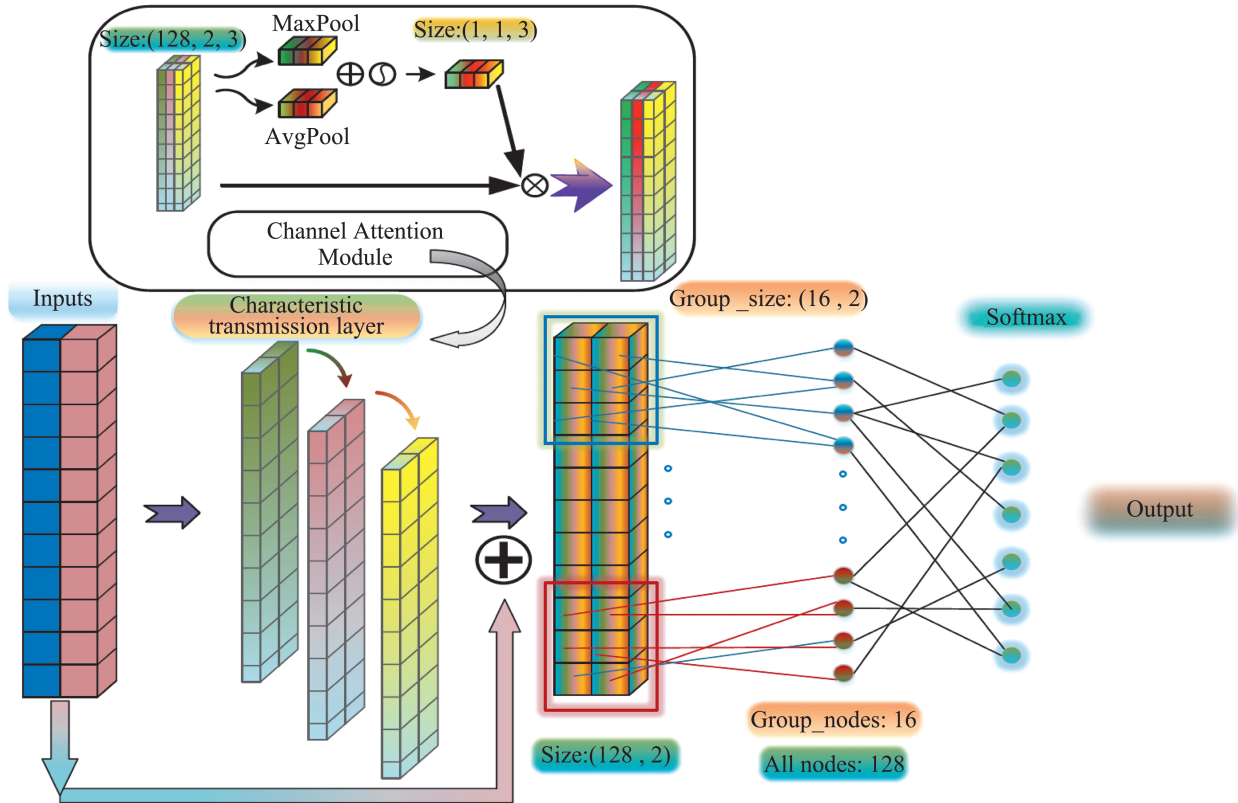


图4 RGFCNN结构图

Fig. 4 RGFCNN structure diagram

<http://www.china-simulation.com>



设置每组进行全连接的隐藏节点数为 16, 经过每组全连接输出后, 拼接在一起得到总节点数为 128。

### 3 实验

#### 3.1 实验环境及参数设置

本次实验是在一台 NVIDIA GeForce RTX 3060 Laptop GPU Windows 11 64 位操作系统上进行的, CPU 型号为 AMD Ryzen 7 5800H with Radeon Graphics 3.20 GHz, 内存 16 G。配饰的环境为 CUDA11.2+ cudnn8.1.1+Tensorflow2.6.0, 编程语言为 Python3.8。

实验随机抽取全部数据集的 60% 为训练集, 20% 为验证集, 20% 为测试集。训练时 Epoch 大小为 30, Batchsize 大小设置为 128, 使用基于随机梯度下降的 Adam 优化器, 交叉熵损失函数

Cross Entropy, 初始学习率为 0.001, 每训练 10 个 Epoch 学习率减半, 分类函数选择 Softmax。

#### 3.2 实验验证

针对本次实验所用的数据集, 在构建 RGFCNN 网络时针对元素分组尺寸的不同进行了对比试验, 目的在于选出最合适的元素分组策略。具体参数如表 1 所示。

在 RML2016.10a 数据集上, 4 种网络对 11 类调制信号的识别准确率结果如图 5 所示。

从图 5 可以得出, RGFCNN4 与 RGFCNN3 的识别效果明显比 RGFCNN1 和 RGFCNN2 好。而 RGFCNN3 与 RGFCNN4 效果相差很小, 几乎一样, 但是 RGFCNN4 的参数数量远远多于 RGFCNN3。因此, 选择 RGFCNN3 网络中的元素分组策略更加合适。

表 1 不同网络参数  
Table 1 Different network parameters

参数	RGFCNN1	RGFCNN2	RGFCNN3	RGFCNN4
输入数据尺寸	(128, 2)	(128, 2)	(128, 2)	(128, 2)
透射层数目	3	3	3	3
元素分组单元尺寸	(4, 2)	(8, 2)	(16, 2)	(32, 2)
元素分组全连接隐藏节点数	4	8	16	32
总的隐藏节点数	128	128	128	128
训练参数量	4 113	4 423	6 423	10 575

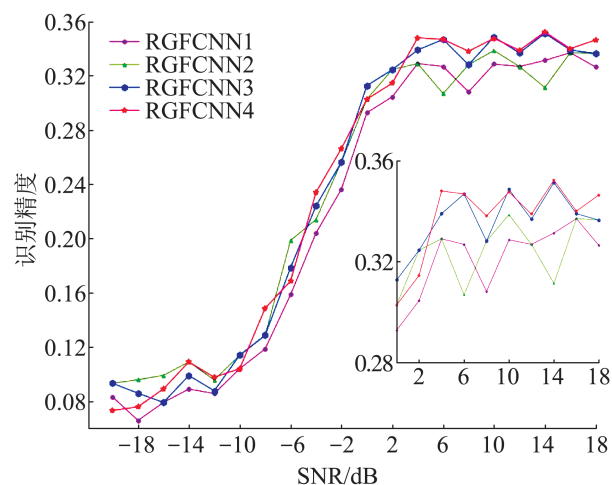


图 5 不同分组策略实验对比  
Fig. 5 Comparative experiments with different grouping strategies

对 RGFCNN 进行对比实验, 以普通 FCNN 为基准进行比较, 选取 RGFCNN3 中的元素分组策略。两个网络的结构参数如表 2 所示。

表 2 两种网络结构对比  
Table 2 Comparison of two network structures

参数	FCNN	RGFCNN
输入数据尺寸	(128, 2)	(128, 2)
透射层数目		3
元素分组单元尺寸		(16, 2)
元素分组全连接隐藏节点数		16
总的隐藏节点数	128	128
训练参数量	34 315	6 423

由表 2 可得, RGFCNN 网络训练参数量是 FCNN 的 1/6。证明了元素分组策略在神经网络构建时能够减少训练参数量的优越性。如果输入数

据尺寸更大的话，如输入图片数据，该元素分组策略能够实现更高倍率的参数压缩量。

图6展示了在公开的RML2016.10a数据集上，2个网络在20个不同信噪比上对11类调制信号的识别精度对比图。

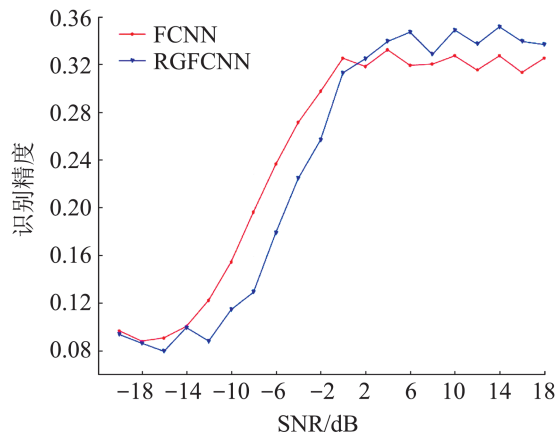


图6 不同网络识别精度图

Fig. 6 Different network recognition accuracy graph

由图6得出，RGFCNN网络在信噪比大于0 dB时具有显著的识别效果，因为当信噪比大于0 dB时，输入的IQ信号数据特征明显，这样RGFCNN网络的透射层能够有效地提取目标特征，并能凭借元素分组全连接网络使用更少的参数量达到更好的识别效果。元素分组不仅减少了训练参数量，同时也能够更好地利用分组内特征之间的相关性，一定程度上解决过拟合问题。图7~8分别是FCNN与RGFCNN网络在训练过程中的训练精度与验证精度随训练次数的变化情况。

由图7~8可得，在训练过程中，FCNN网络的验证精度随着训练次数的增多反而有降低，与训练精度相差越来越大，出现了过拟合现象。而RGFCNN则不然，验证精度甚至比训练精度还要高，一定程度上解决了过拟合问题。

信号调制识别领域，在信噪比范围内的最高识别精度和当信噪比大于0 dB时的平均识别精度是评价一个网络识别性能的两大标准。本文对比实验中，2个网络的最高识别精度与平均识别精度对比如图9所示。

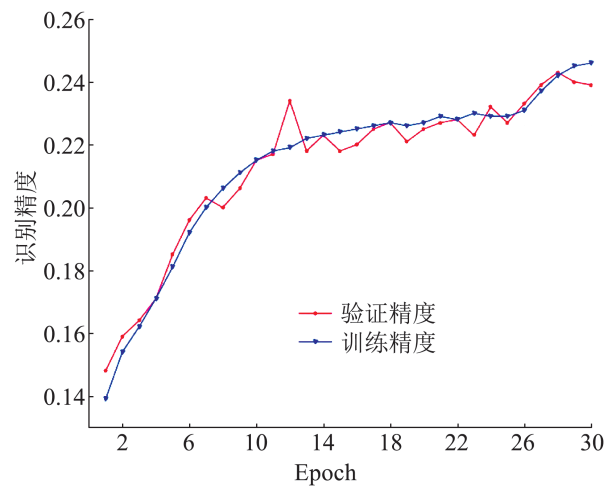


图7 RGFCNN训练验证

Fig. 7 RGFCNN training validation




图8 FCNN训练验证

Fig. 8 FCNN training validation

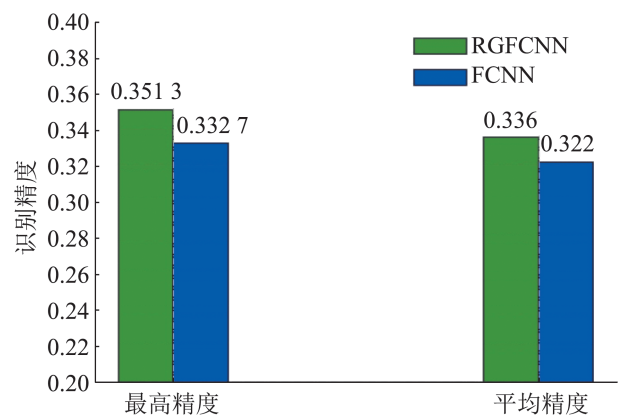


图9 最高识别精度和平均识别精度对比图

Fig. 9 Maximum recognition accuracy and average recognition accuracy comparison chart

由图 9 可得, RGFCNN 网络在信噪比范围内实现的最高识别率为 0.351 3, 相比 FCNN 网络提高了 0.018 6; 当信噪比大于 0 dB 时, RGFCNN 网络的平均识别率为 0.336, 相比 FCNN 提高了 0.014。可见, RGFCNN 网络用了 FCNN 网络 1/6 的参数量, 能实现更高的识别精度。

以上实验过程以隐藏节点数为 128 的 FCNN 网络作为对比, 通过对比实验, 建立了分组尺寸为 [16, 2] 的元素分组全连接网络, 发现在高信噪比下 RGFCNN 识别精度更高, 而所使用的参数量约为原来的 1/6。现在保持元素分组尺寸不变, 将隐藏节点数分别设置为 64、256、512、1 024, 进一步对比 2 种网络的识别精度以及参数量, 通过改变参数增加对比实验来说明 RGFCNN 网络的优势, 如表 3 所示。

表 3 不同网络参数  
Table 3 Different network parameters

网络名称	分组节点数	总节点数	参数量
FCNN-64	/	64	17 163
RGFCNN-64	8	64	3 607
FCNN-128	/	128	34 315
RGFCNN-128	16	128	6 423
FCNN-256	/	256	68 619
RGFCNN-256	32	256	12 055
FCNN-512	/	512	137 227
RGFCNN-512	64	512	23 319
FCNN-1024	/	1 024	274 443
RGFCNN-1024	128	1 024	45 847

由表 3 可得, 随着隐藏节点数的增多, FCNN 网络所需的参数量越来越多, 对于内存和显存的要求也越来越高, 而 RGFCNN 网络参数一直保持在 FCNN 网络参数总量的大约 1/6, 大大减少了训练参数量, 减少的参数量随着隐藏节点数的增加更为明显。

将 10 种网络对 11 类调制信号的识别结果对比图绘制如图 10 所示。

由图 10 可得, RGFCNN 网络在高信噪比条件下识别准确率均要比对应的 FCNN 高, 验证了

RGFCNN 网络在高信噪比条件下对信号特征提取的优势。随着隐藏节点数的增多, 无论是 FCNN 还是 RGFCNN, 无论是高信噪比还是低信噪比条件下, 识别准确率均有提高。但是当隐藏节点数为 1 024 时, 在低信噪比条件下识别准确率优势明显, 但是在高信噪比条件下 FCNN 识别效果反而不好, 由此可以得出, 隐藏节点数不是越大越好, 当达到一定数量后, 训练参数过大会出现过拟合现象, 识别准确率不增反降。当隐藏节点数为 1 024 时, RGFCNN 虽然也出现了识别准确率降低的问题, 但是仍然保持在较好的水平。可见 RGFCNN 网络不仅大大减少了训练参数量, 还可以提高高信噪比条件下对各类信号的识别准确率。

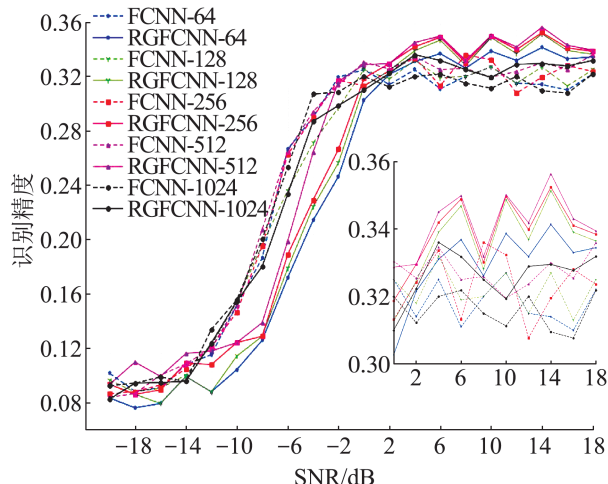


图 10 10 种网络结果对比图  
Fig. 10 Comparison chart of results of ten networks

### 4 结论

本文借鉴 RIS 的结构原理, 提出了一种基于元素分组策略的面状全连接网络—RGFCNN。提出了神经网络中透射面的概念, 并结合通道注意力机制构成了一种新型的结合空间和通道的注意力机制。实验证明: 相比原始的全连接层, RGFCNN 网络能更好地利用局部元素之间的相关性, 有助于网络识别精度的提高。不仅在高信噪比下实现了更加优越的识别准确率, 而且大大降低了网络参数量, 所用参数约是 FCNN 的 1/6, 节

省了内存。同时有效地解决了神经网络在训练过程里存在的过拟合问题。

目前只是单独验证了全连接层的识别性能，在日后的工作里，会逐步结合卷积神经网络、循环神经网络等验证整体网络精度，减少整体网络的参数训练量。

### 参考文献:

- [1] 赵亚军, 郁光辉, 徐汉青. 6G移动通信网络: 愿景、挑战与关键技术[J]. 中国科学(信息科学), 2019, 49(8): 963-987.  
Zhao Yajun, Yu Guanghui, Xu Hanqing. 6G Mobile Communication Networks: Vision, Challenges, and Key Technologies[J]. Scientia Sinica(Informationis), 2019, 49(8): 963-987.
- [2] Tariq F, Khandaker M R A, Wong K K, et al. A Speculative Study on 6G[J]. IEEE Wireless Communications, 2020, 27(4): 118-125.
- [3] 高子路, 孙韶辉, 李丽. 面向新一代移动通信的智能超表面技术综述[J]. 电信科学, 2022, 38(10): 20-35.  
Gao Zilu, Sun Shaohui, Li Li. Overview of Reconfigurable Intelligent Surface for New-generation Mobile Communication[J]. Telecommunications Science, 2022, 38(10): 20-35.
- [4] 张磊, 崔铁军. 时空编码数字超材料和超表面研究进展[J]. 中国科学基金, 2021, 35(5): 694-700.  
Zhang Lei, Cui Tiejun. Recent Progress of Space-time-coding Digital Metamaterials and Metasurfaces[J]. Bulletin of National Natural Science Foundation of China, 2021, 35(5): 694-700.
- [5] 张磊, 陈晓晴, 郑熠宁, 等. 电磁超表面与信息超表面[J]. 电波科学学报, 2021, 36(6): 817-828.  
Zhang Lei, Chen Xiaoqing, Zheng Yining, et al. Electromagnetic Metasurfaces and Information Metasurfaces[J]. Chinese Journal of Radio Science, 2021, 36(6): 817-828.
- [6] Yu Nanfang, Genevet P, Kats M A, et al. Light Propagation with Phase Discontinuities: Generalized Laws of Reflection and Refraction[J]. Science, 2011, 334(6054): 333-337.
- [7] Cui Tiejun, Qi Meiqing, Wan Xiang, et al. Coding Metamaterials, Digital Metamaterials and Programmable Metamaterials[J]. Light: Science & Applications, 2014, 3(10): e218.
- [8] Mehmet Ali Aygül, Mahmoud Nazzal, Hüseyin Arslan. Deep Learning-based Optimal RIS Interaction Exploiting Previously Sampled Channel Correlations[C]//2021 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway, NJ, USA: IEEE, 2021: 1-6.
- [9] Xu Meng, Zhang Shun, Ma Jianpeng, et al. Deep Learning-based Time-varying Channel Estimation for RIS Assisted Communication[J]. IEEE Communications Letters, 2022, 26(1): 94-98.
- [10] 朱正. 基于深度学习的太赫兹超表面设计方法研究[D]. 成都: 电子科技大学, 2021.  
Zhu Zheng. Terahertz Metasurface Design Method Based on Deep Learning[D]. Chengdu: University of Electronic Science and Technology of China, 2021.
- [11] 安建成. 面向可重构智能表面的信道估计与被动波束赋形技术研究[D]. 成都: 电子科技大学, 2021.  
An Jiancheng. Channel Estimation and Passive Beamforming for Reconfigurable Intelligent Surface-assisted Communications[D]. Chengdu: University of Electronic Science and Technology of China, 2021.
- [12] Tang Wankai, Chen Mingzheng, Chen Xiangyu, et al. Wireless Communications with Reconfigurable Intelligent Surface: Path Loss Modeling and Experimental Measurement[J]. IEEE Transactions on Wireless Communications, 2021, 20(1): 421-439.
- [13] Zhang Lei, Chen Xiaoqing, Liu Shuo, et al. Space-time-coding Digital Metasurfaces[J]. Nature Communications, 2018, 9(1): 4334.
- [14] Cui Tiejun, Li Lianlin, Liu Shuo, et al. Information Metamaterial Systems[J]. iScience, 2020, 23(8): 101403.
- [15] Yang Yifei, Zheng Beixiong, Zhang Shuowen, et al. Intelligent Reflecting Surface Meets OFDM: Protocol Design and Rate Maximization[J]. IEEE Transactions on Communications, 2020, 68(7): 4522-4535.
- [16] Ahmet M Elbir, Mishra K V. A Survey of Deep Learning Architectures for Intelligent Reflecting Surfaces[EB/OL]. (2022-07-21) [2023-01-22]. <https://arxiv.org/abs/2009.02540>.
- [17] Zhang Shunbo, Zhang Shun, Gao Feifei, et al. Deep Learning Optimized Sparse Antenna Activation for Reconfigurable Intelligent Surface Assisted Communication[J]. IEEE Transactions on Communications, 2021, 69(10): 6691-6705.
- [18] Huang Chongwen, Mo Ronghong, Chau Yuen. Reconfigurable Intelligent Surface Assisted Multiuser MISO Systems Exploiting Deep Reinforcement Learning[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(8): 1839-1850.
- [19] Feng Keming, Wang Qisheng, Li Xiao, et al. Deep Reinforcement Learning Based Intelligent Reflecting Surface Optimization for MISO Communication Systems[J]. IEEE Wireless Communications Letters,

- 2020, 9(5): 745-749.
- [20] Zuo Chao, Qian Jiaming, Feng Shijie, et al. Deep Learning in Optical Metrology: A Review[J]. *Light: Science & Applications*, 2022, 11(1): 39.
- [21] Choudhary K, DeCost B, Chen Chi, et al. Recent Advances and Applications of Deep Learning Methods in Materials Science[J]. *npj | Computational Materials*, 2022, 8(1): 59.
- [22] O'Shea T J, West N. Radio Machine Learning Dataset Generation with GNU Radio[C]//*Proceedings of the 6th GNU Radio Conference*. Tempe, AZ: GNURadio, 2016.
- [23] Xuan Qi, Li Xiaohui, Chen Zhuangzhi, et al. Deep Transfer Clustering of Radio Signals[EB/OL]. (2021-07-26) [2023-02-19]. <https://arxiv.org/abs/2107.12237>.
- [24] Sanghyun Woo, Jongchan Park, Lee J Y, et al. CBAM: Convolutional Block Attention Module[C]//*Computer Vision-ECCV 2018*. Cham: Springer International Publishing, 2018: 3-19.
- [25] Haeyun Lee, Jinhyoung Park, Jae Youn Hwang. Channel Attention Module with Multiscale Grid Average Pooling for Breast Cancer Segmentation in an Ultrasound Image[J]. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 2020, 67(7): 1344-1353.
- [26] Du Miao, Yu Qin, Fei Shaomin, et al. Fully Dense Neural Network for the Automatic Modulation Recognition [EB/OL]. (2019-12-07) [2023-03-07]. <https://arxiv.org/abs/1912.03449>.