

摘要

随着第五代移动通信技术的正式商业应用,预期今后几年来人们对无线通信网络流量的需求会倍速增长,世界也将实现无所不在的无线连接,但网络复杂、硬件成本高昂以及能源消耗较大是今后的无线通信所亟需解决的重要问题,因此需要寻找低成本、低能耗的高速无线传输方案。在目前的候选新技术中,智能反射面(Reconfigurable Intelligent Surface, RIS)以其独特的低成本、低能耗、可编程、易部署等特点脱颖而出,成为提升通信系统传输性能的一种可行的解决方案。

随着人工智能技术应用领域的进一步拓展,基于深度学习的人工智能技术被广泛应用于功率分配、波束成形和信道估计等通信领域。本文研究基于深度学习的RIS辅助MISO系统中联合波束成形算法,从而提升基站—用户的整体通信质量。对此,本文开展了以下分析和研究:

首先,对基于RIS辅助的无线通信系统进行建模并确定优化问题。考虑RIS辅助的多用户MISO系统场景,由于障碍物的存在,通信质量可能会遭受很大影响,通过合理部署RIS并调整其反射特性,在基站和用户之间建立一个通信质量较高的辅助性反射链路。文章以用户的和速率为指标,研究下行链路通信系统中基站和RIS联合波束成形的设计优化问题。

其次,分析了基于LMMSE信道估计+BCD算法波束成形、基于深度学习信道估计+BCD算法波束成形算法的原理,并阐述了基于BCD算法进行求解RIS辅助的MISO系统中联合波束成形的过程。然后对深度学习算法的网络结构进行设计,使用Python环境仿真,利用TensorFlow框架搭建神经网络,经过训练、测试及优化,最终确定基于深度学习的联合波束成形算法。

最后,将基于深度学习的RIS辅助MISO系统联合波束成形算法与对比算法进行比较,并在相同场景下进行仿真,分别探究在不同的导频长度、下行传输功率、用户数量与和速率的关系,对仿真结果进行对比分析。仿真结果表明,基于深度学习的RIS辅助MISO系统中联合波束成形算法优于对比的传统算法,提高了系统性能,降低了复杂度,还具有一定的泛化能力。

关键词: 智能反射面; 深度学习; 波束成形; MISO系统

ABSTRACT

With the formal commercial application of the fifth generation of mobile communication technology, it is expected in the next few years to people's demand for wireless communication network traffic will times the speed of growth, and the world will realize ubiquitous wireless connections, but complex network, high hardware cost and high energy consumption are the important problems to be solved in future wireless communication. Therefore, it is necessary to seek a high-speed wireless transmission scheme with low cost and low energy consumption. Among the current candidate technologies, Reconfigurable Intelligent Surface stands out for its unique characteristics of low cost, low energy consumption, programmable and easy deployment, and is a feasible solution to improve the transmission performance of communication systems.

With the further expansion of artificial intelligence applications, artificial intelligence based on deep learning has been widely used in communication fields such as power distribution, beamforming and channel estimation. This paper studies the joint beamforming algorithm in RIS-assisted MISO system based on deep learning, so as to improve the overall communication quality between base station and user. In this regard, this paper carries out the following analysis and research:

Firstly, the RIS-assisted wireless communication system is modeled and the optimization problem is determined. Considering the RIS-assisted multi-user MISO system scenario, the communication quality may be greatly affected due to the existence of obstacles, so an auxiliary reflection link with high communication quality can be established between the base station and the user by reasonably deploying RIS and adjusting its reflection characteristics. In this paper, the design optimization of base station and RIS combined beamforming in downlink communication system is studied based on the user's sum rate.

Secondly, the principle of channel estimation based on LMMSE and beamforming based on BCD algorithm, channel estimation based on deep learning

and beamforming based on BCD algorithm is analyzed, and the process of solving RIS assisted MISO system based on BCD algorithm is described. Then, the network structure of the deep learning algorithm is designed. Python environment simulation is used to build the neural network using TensorFlow framework. After training, testing and optimization, the joint beamforming algorithm based on deep learning is finally determined.

Finally, the joint beamforming algorithm of RIS-assisted MISO system based on deep learning is compared with the comparison algorithm, and the simulation is carried out in the same scene to explore the relationship between different pilot length, downlink transmission power, number of users and speed, and the simulation results are compared and analyzed. The simulation results show that the joint beamforming algorithm in RIS assisted MISO system based on deep learning is superior to the traditional comparison algorithm, which improves the system performance, reduces the complexity, and has certain generalization ability.

Keywords: Reconfigurable Intelligent Surface; Deep Learning; Beamforming; MISO System

目 录

摘要.....	I
ABSTRACT.....	II
第 1 章 绪 论.....	1
1.1 研究背景及意义.....	1
1.2 国内外研究现状.....	3
1.3 论文主要研究内容与结构安排.....	6
1.3.1 研究内容.....	7
1.3.2 结构安排.....	7
第 2 章 RIS 辅助的通信系统中关键技术及相关原理.....	9
2.1 毫米波.....	9
2.2 大规模天线技术.....	10
2.2.1 MISO 技术.....	10
2.2.2 Massive MIMO 技术.....	11
2.3 波束成形技术.....	12
2.4 智能反射面基本原理.....	15
2.4.1 RIS 硬件结构.....	15
2.4.2 RIS 辅助无线通信系统信号模型.....	16
2.5 本章小结.....	17
第 3 章 深度学习理论基础.....	18
3.1 神经网络.....	18
3.1.1 神经元模型.....	18
3.1.2 激活函数.....	19
3.1.3 深度神经网络.....	22
3.1.4 损失函数.....	23
3.1.5 反向传播算法.....	24

3.2 图神经网络	24
3.3 卷积神经网络	25
3.4 优化算法	27
3.4.1 随机梯度下降法	27
3.4.2 Momentum 算法	28
3.4.3 AdaGrad 算法	28
3.4.4 RMSProp 算法	29
3.4.5 Adam 算法	29
3.5 本章总结	30
第 4 章 基于 BCD 算法的 RIS 辅助 MISO 系统中联合波束成形	31
4.1 系统模型与问题建模	31
4.2 基于 BCD 算法的联合波束成形	33
4.3 仿真结果及分析	36
第 5 章 基于深度学习的 RIS 辅助 MISO 系统中联合波束成形	38
5.1 问题建模	38
5.2 神经网络设计及网络结构	40
5.3 网络训练和测试	44
5.4 仿真结果及分析	45
5.5 本章小结	50
第 6 章 总结与展望	51
6.1 论文工作总结	51
6.2 未来展望	52
参考文献	53
致 谢	58
攻读硕士学位期间所取得的科研成果	60

第 1 章 绪 论

1.1 研究背景及意义

自第一代移动通信技术提出至今，经过了几十载的发展，现如今的移动通讯技术已经使人类的生活方式产生了巨大的改变，渗入经济社会发展和人类日常生活中的方方面面，未来将会更广泛地影响我们的生活^[1]。随着物联网概念的提出以及新兴无线业务的迅速发展，智能设备数量的持续增长，无线网络流量需求呈指数级增长^[2]。所以迫切需要在 5G 甚至未来的 6G 通信网络中寻求新技术，以满足日益增长的通信带宽需求。

近年来，我国无线通信产业发展迅速，5G 移动通信技术已进入商用阶段。按照美国 GSA 去年 8 月公布的数据，共有 70 多个国家和地区的超过 170 多家运营商，已经上线了 5G 商用服务，还有 285 家运营商，正在投资部署 5G。而我国的 5G 建设步伐，更是走在了世界的前列。截至今年 2 月份末，国内 5G 基站总数量已达到惊人的 150.6 万个，占全球的 60% 以上。换句话说，世界上每五个 5G 基站中就有三个位于中国。5G 的关键技术包括边缘计算、Massive MIMO、超密集组网、毫米波通信、非正交多址、基于 OFDM 优化的波形、SDN 以及 NFV 等技术。

目前，全球 5G 国家各采用不同的频段来满足自身 5G 商用网络部署的实际需求^[3]。5G 的主要频段是 Sub-6G 和 mmWave，Sub-6GHz 实际上就是现有的 6GHz 以下的频段发展而来，而毫米波频段则是基于 30-300GHz 的高频频段^[4]，属于 5G 发展中异军突起的新势力。毫米波通信在 5G 中受到广泛重视的主要原因，一方面是由于许多高质量的频段在 4G LTE 之前的发展中被消耗，因此留给 5G 网络的频段并不多；另一方面，毫米波在传输速率与可用带宽上有优势，能满足 5G 对于大容量与高速率的传输要求，实现更多人们构想中的未来 5G 使用场景，向毫米波频段演进已成为移动通信网络演进的必然趋势^[5]。

我国目前仅商用了 Sub-6GHz 频段的 5G，而并未商用毫米波频段的 5G。这是由于毫米波的信号衰减大、易被阻挡、覆盖距离短的缺点。无线电磁波的波长和频率成反比，高频率下的绕射能力差。因此，毫米波频段的 5G 其覆盖能力较

弱，这也是国内不能在第一时间商用毫米波通信的主要原因。将毫米波通信与 Massive MIMO 相结合，被认为是 5G 和未来无线通信网络中最重要的两项技术^[6]。由于毫米波波长短、天线尺寸小、易于集成，为大规模多天线阵列在毫米波系统中的使用提供了极大的便利。因此，可以在有限的空间内配置一个大维度的天线阵列来产生足够的波束成形增益来补偿毫米波信道极高的路径损耗^[7]。毫米波频段大量的频谱资源有利于大规模天线的集成，也可以克服传统无线通信系统频谱资源匮乏的这一瓶颈问题，波束成形是这两项技术中的关键技术。

毫米波 Massive MIMO 通信系统中配有大量的天线，若为每个天线都配置一条昂贵的射频链路，将会导致天线数目的增长，无法负担为每根天线都配有一条 RF 射频链的成本，这种结构在毫米波 Massive MIMO 系统中的应用很难实现，也不现实。于是为了降低成本，混合波束成形结构便应运而生，使用模拟波束成形和数字波束成形相结合，可以保持足够的波束成形增益。使用毫米波技术会影响传输距离和信道质量，这可以通过波束成形技术来解决。混合波束成形已经成为毫米波 Massive MIMO 通信系统中最优先考虑的预编码方案^[8]，但在使用这些系统时造成的成本和能源开销仍然是一个问题。所以，5G 和未来的无线网络仍然需要探索新型节能但又经济高效的解决方案。

近年来，业界开始研究智能反射面（Reconfigurable Intelligent Surface, RIS）技术。RIS 具有实时可编程电磁特性^[9]，实时编程是一次革命性的技术飞跃，它允许超表面改变其电磁特性，从而实现传统超材料无法实现的各种功能^[10]。通过软件控制反射重新配置无线传播环境^[11]，总的来说，智能反射面具有实现简单、成本低、功耗低、时延低、复杂度低等明显优点，是提高通信系统传输性能的切实可行的解决方案，而 RIS 辅助的无线通信具有高性能、低能耗、高能效等特征，使其成为提高通信系统吞吐量的可行方案^[12]。RIS 辅助无线通信是未来 5G/6G 中颇有前景的关键技术之一。然而，作为一种颠覆性技术，随着对 RIS 研究和理解的逐步深入，还有更多的实际问题和挑战需要解决。

当前 RIS 辅助无线通信主要挑战主要涉及被动波束成形、RIS 信道获取等方面。在 RIS 辅助的波束成形设计时，由于 RIS 不具有计算单元，造成波束成形中最优相移设计的挑战性。另外，需要联合设计 RIS 的相移和基站的波束成形，以此来优化网络性能。一般情况下，RIS 的性能取决于相移向量的优化，相移向

量是信道与无线电之间的函数。RIS 元件的被动性质具有低复杂性和能效，不需要功率放大器和数据转换器。这种被动的性质使系统具有大规模的信号系数，导致信道估计更加困难，对联合波束成形也带来了挑战^[13]。因此，RIS 辅助的无线通信系统中联合波束成形算法研究和分析对通信领域具有重要意义。

随着人工智能的不断发展，AI (Artificial Intelligence) 技术正在掀起人类社会的新一轮技术革命。深度学习 (Deep Learning, DL) 是机器学习领域中一种新兴的科研方向，机器学习是实现人工智能的必由之路。深度学习作为人工智能技术的一个重要研究方向，也在搜索技术、自然语言处理等相关领域获得了很多成果^[14]，成功地解决了以前的一系列难题。随着通信场景复杂性不断增加，面临的困难也更多，有时候传统的方法求解会比较复杂，于是引入了深度学习，以此来解决无线通信系统中的一些问题，比如本文的波束成形过程中非凸问题。目前，深度学习技术广泛应用于信道估计^{[15][16]}、波束成形^[17]和功率分配^[18]等领域，与传统的算法相比，基于 DL 的方法可以实现快速计算。这些令人满意的特性使得它在无线通信的许多实际应用中更具有吸引力。

由于障碍物的存在，通信质量可能受到极大影响。通过合理部署 RIS 并调节其反射特性，可以在基站与用户中间建立一个通信质量较高的辅助反射链路，进而提高基站-用户的整体通信质量^[11]。当前 RIS 辅助的 MISO 系统中波束成形存在着一些问题与挑战。比如传统算法复杂度高，计算时延大、RIS 处的最优反射波束成形难以计算与实现、实现效果不如理论预期、很难精确有效估计 RIS 辅助的无线通信系统中的信道状态信息等。这些问题的进一步研究和处理对无线通信领域具有重要意义，而深度学习是一种新的研究方法，对解决类似问题有很好的效果，可以显著降低计算复杂度，且性能令人满意^[19]。基于此，本文研究采用深度学习设计 RIS 辅助多输入单输出 (MISO) 系统中联合波束成形。因此，采用深度学习的方法构建一种有效的波束成形算法对于 RIS 辅助的无线通信系统是有必要而且有研究价值的。

1.2 国内外研究现状

近年来，人们对将人工智能应用于无线通信系统的设计和优化产生了浓厚的兴趣，人们一致认为人工智能将成为未来无线通信系统的核心。近几年，很多国

内外学者对深度学习进行了广泛地研究,并基于深度学习方法在无线通信系统中成功实现信道估计与信号检测等^[20]。但对于使用深度学习方法去研究联合波束成形的并不广泛,尤其在于 RIS 辅助毫米波大规模 MISO 系统联合波束成形中。RIS 作为无线通信系统中的辅助元件,适合在无线网络中大规模部署,能够显著提高其频谱和能效的成本效益,与典型的无线通信系统不同,对 RIS 辅助无线通信技术的研究旨在打破无线系统或网络设计的基本范式,达到可以提高系统传输性能的目的。目前深度学习与无线通信技术相结合还有进一步优化的空间,也能够使系统的性能再次得到提高。文献[21]-[35]分别从 RIS 在 MISO 系统中波束成形算法展开研究以及基于深度学习算法的设计展开研究。

在不含 RIS 辅助的 MISO 系统中波束成形中,主要目标是消除数据流或用户之间的干扰,提高吞吐量。近年来,国内外学者对混合波束成形算法也做了大量的研究和分析。文献[21]-[24]中提出的窄带通道中混合波束成形已经得到了较好的研究。在文献[23]中,提出了基于正交匹配追踪算法的混合波束成形,利用毫米波信道的稀疏特性将预编码问题表示为稀疏重构问题,实现近乎最佳的全数字波束成形性能。在文献[22]中,提出了一种基于码本的波束空间奇异值分解的混合波束成形算法,避免了矩阵求逆的计算。与文献[22]和[23]不同,文献[21]和[24]以误比特率(Bit Error Rate, BER)为优化指标,分别探究了基于几何均值分解的基带波束成形和基于码本的模拟波束成形算法。

随着 RIS 的出现,波束成形变得更加灵活和可控。因此,本文提出了 RIS 辅助的 MISO 系统中联合波束成形。利用毫米波大带宽的优点和 RIS 的阻塞效应,可以显著提高吞吐量和覆盖率。文献[25]证明了 RIS 能够在期望的方向上形成联合波束成形,并在文献[26]中将 RIS 与解码转发中继进行了比较,指出具有大量反射单元的 RIS 可以获得更高的能量效率。文献[27]则提出了使用一种交替优化算法来解决基于 RIS 辅助的无线通信系统的联合发射和 RIS 反射波束成形的优化问题。文献[28]则利用半正定松弛算法获得了反射波束成形的次优解。当使用 RIS 作为反射阵列时,在文献[29]中得到了 RIS 辅助单天线收发系统的误差性能,提出了一种在 RIS 辅助 MISO 系统中与基站联合设计的方法,并采用交替优化技术解决了传输功率最小化问题。文献[30]提出了一种由分布式 RIS 辅助的多用户毫米波系统,基站和用户之间存在障碍物,通过使用 RIS 扩大毫米波信号的覆盖

范围。首先建立了一个联合主被动波束成形问题，以最大化加权和速率。然后针对具有挑战性的非凸问题，提出了一种具有闭合表达式的交替迭代算法，并对主被动波束成形变量进行解耦。

目前，深度学习被广泛应用于通信系统，解决了一些传统算法难以解决的问题，比如在进行爆炸性质量数据处理和计算数学上难以解决的高运算等问题，并且取得了不错的效果。深度学习算法通常比传统的迭代优化算法要快得多。文献[31]中指出传统方法需要大量的计算，提出了一种基于深度强化学习的反射波束成形设计方法。在 RIS 辅助通信系统背景下，针对被动波束成形设计提出了不同类型的学习方法。文献[32]中采用无监督学习的方法对定制的深度神经网络进行离线培训和在线部署，并进行实时训练，使用了两阶段的网络对被动波束成形进行训练。文献[33]使用了监督学习，训练后的深度神经网络在目标用户处输入测量的位置信息，以输出 RIS 的最佳相位配置，以便将信号功率聚焦在预期位置。

文献[35]中利用深度强化学习(Deep Reinforcement Learning, DRL)研究了基站传输波束成形矩阵和 RIS 相移矩阵的联合设计。基于 DRL 的算法，其中通过与环境的试错交互，在连续状态和行动的背景下，通过观察预先定义的奖励来获得联合设计。文献[36]提出了集成深度学习协调波束成形算法，通过对上行链路训练学习得到下行链路的波束成形向量信息，优于传统估计下行信道算法。

尽管上述文献提出的方案在 RIS 辅助移动通信系统中都做出了一定的创新与贡献，但仍然存在一些问题与挑战，具体包括：

首先，RIS 的最优反射波束成形难以计算和实现。一方面，对于反射波束成形的设计问题，很难直接用数学方法求得最优解，而且大部分都是比较复杂的非凸优化问题，难以直接求得最优解。目前，在上述大部分文献的研究中，主要采用交替优化方法来解决。然而由于得到最优解需要多次迭代，使时间复杂度比较高。另一方面，上述文献中的交替优化方案也有得到了反射波束成形的次优解，但解决方案对应的反射元参数也可能无法实际部署，会造成执行效果不如理论预期的问题。RIS 相移的单元模量约束和主被动联合波束成形的耦合也给联合波束成形的优化设计带来了极大的挑战。

其次，在 RIS 辅助 MISO 毫米波通信系统中，很难准确有效地估计信道状态信息。由于 RIS 具有相对简单的实现和廉价无源元件的特性，而且不包含任何射

频处理电路，所以很难估计系统 CSI。虽然目前研究人员已提出多种信道估计方案，但信道估计精度不太能满足要求，不能进一步用于 RIS 辅助 MISO 系统中的联合波束成形设计。然而，由于缺乏足够精确的信道估计方案，考虑到 RIS 的部署需要处理基站和用户之间的多个信道链路，并且为了进一步提高传输性能，需要联合设计 BS 的波束成形和 RIS 的反射波束成形，大多数关于系统性能优化的研究都假设系统中所有信道的 CSI 都是完全已知的。本文也令所有 CSI 已知，探究基于深度学习方法将接收到的导频信号直接映射到 RIS 的相移矩阵和 BS 的波束成形矩阵。

文献中大多为单个用户和基站之间的通信场景，然而现实场景有多个用户和多个基站之间的通信。文献[32]中提出的以传统方案得到的波束成形矩阵作为标签训练神经网络的方法，其性能受到传统方案的限制，并且没有充分利用神经网络强大的近似能力。对于现有的一对一神经网络波束成形系统，在实际应用中，当接收机为多个用户时，文献[33]采用一对一的通信系统和方法，需要分别建立多个系统，增加了训练开销。文献[35]将深度学习方法应用于智能反射面无线通信中，对接收到的导频信号进行映射，证明了提出的机器学习图神经网络框架能够比传统的基于信道估计的方法更有效地利用导频。本文也尝试用图神经网络去构建网络架构，实现基于深度学习的 RIS 辅助 MISO 系统中联合波束成形。

本文提出了一种基于深度学习的 RIS 辅助 MISO 系统中联合波束成形设计方法，具体来说，他们将无线传播看做是一个深度图神经网络(Graph Neural Networks,GNN)，通过训练，无线网络学会了 RIS 的传播原理并配置 RIS，并且多输入单输出(MISO)系统可以有效提升通信网络容量。传统优化算法虽然可以取得不错的性能，但算法的复杂度较高。而一些启发式的方法例如迫零法、正则迫零法，虽然复杂度低，但是性能却大打折扣。深度学习作为人工智能的一种实现方式，相比于传统的迭代优化算法，可以大大降低计算复杂度，并且性能较为优异。但由于深度学习网络难以部署在通信系统的硬件环境中，并且缺少有效的信道建模技术，因此，如何在保证性能好复杂度低的基础上，探究基于深度学习的方法去设计实现 RIS 辅助 MISO 系统中联合波束成形算法是值得进一步研究的。

1.3 论文主要研究内容与结构安排

1.3.1 研究内容

本文研究深度学习在智能反射面辅助的 MISO 通信系统中波束成形联合设计问题。由于障碍物的存在，可以通过合理部署 RIS 并调整其反射特性，在基站和用户之间建立一个通信质量较高的辅助反射链路^[11]，并以此改善基站-用户的整体通信质量。主要研究内容如下：

(1) 分析和比较 LMMSE 信道估计+BCD 算法波束成形、基于深度学习的信道估计+BCD 算法波束成形两个算法的原理，考虑一个 RIS 辅助的下行链路多用户 MISO 系统，构建出系统模型以及优化问题，给出基于 BCD 算法进行求解联合波束成形过程，仿真探究所提算法的性能，为进一步优化算法提供基础。

(2) 提出了一种基于深度学习神经网络的联合波束成形算法。通过采用一个图神经网络架构模型之间的交互，可以从接收到的导频直接学习映射到 BS 所需的波束成形矩阵和在 RIS 的反射相移矩阵，最大化多个用户的和速率。首先，对基于 RIS 辅助的 MISO 无线通信系统构建深度学习网络模型，并进行问题建模，然后对网络和结构进行设计，使用 Python 环境仿真，利用 TensorFlow 框架搭建网络，对搭建的网络进行训练测试，并进行优化，最后确定基于深度学习的算法。

(3) 将基于深度学习的 RIS 辅助 MISO 系统中联合波束成形算法，同 RIS 辅助的 MISO 系统中 LMMSE 信道估计+BCD 算法波束成形、LMMSE 信道估计+BCD 算法波束成形两个对比算法进行比较，在相同场景下进行仿真，分别探究在不同的导频长度、下行传输功率、用户数量与和速率的关系，并对仿真结果进行对比分析，仿真结果表明，基于深度学习的 RIS 辅助 MISO 系统中联合波束成形所获得的性能最好，并具有良好的泛化能力，可推广到不同用户数量的通信系统。

1.3.2 结构安排

本文共分六章，各章内容如下：

第一章为绪论。本章首先阐述了智能反射面辅助 MISO 通信系统中联合波束成形的研究背景和意义，接着阐述了国内外的研究现状，本文的主要研究内容和后续章节的结构安排。

第二章介绍了 RIS 辅助的通信系统中关键技术及相关原理。首先介绍了毫米

波、大规模天线技术，其次阐述毫米波可以很好地与大规模 MIMO 相结合，接着又阐述了波束成形技术的相关原理以及智能反射面的基础知识，为接下来在本文中 RIS 辅助 MISO 系统联合波束成形打下了理论基础。

第三章介绍了深度学习的几个重要理论基础，包括神经网络中的神经元模型、最常用的激活函数、深度神经网络模型和损失函数、反向传播算法以及常用的几种优化算法，还介绍了本文在 RIS 辅助的 MISO 系统中联合波束成形中所使用的图神经网络及卷积神经网络的基本原理，为后续的章节中的系统的模型建立、问题建模和优化算法求解提供了理论基础。

第四章阐述了基于 BCD 算法进行求解联合波束成形过程及其仿真结果。首先提出了一种分块迭代算法次优解决方案；然后阐述了如何应用 BCD 算法对四个变量进行求解的过程，得到 RIS 反射矩阵和波束成形矩阵；最后仿真出 LMMSE 信道估计+BCD 算法求波束成形情况下的和速率与传输功率的关系。为下一章基于深度学习方法实现联合波束成形提供了对比方法。

第五章提出基于深度学习的联合波束成形方案。首先对神经网络结构进行设计，之后进行网络的训练与测试，最后对仿真结果进行对比分析，与 LMMSE 信道估计+BCD 算法波束成形、基于深度学习的信道估计+BCD 算法波束成形两个算法进行比较，分别探究在不同的导频长度、下行传输功率、用户数量与和速率的关系，仿真结果表明，基于深度学习的 RIS 辅助 MISO 系统中联合波束成形所获得的性能最好。

第六章对本文进行总结，给出本文的不足之处以及未来的研究方向。

第 2 章 RIS 辅助的通信系统中关键技术及相关原理

2.1 毫米波

毫米波（Millimeter Wave, mmWave）一般指的是波长范围在 1 毫米至 10 毫米之间的无线电波，根据电磁波的频率与波长之间的关系可得，毫米波的频率介于 30-300GHz 之间，公式为：

$$f = \frac{c}{\lambda}, \quad c = 3 \times 10^8 \text{ m/s.} \quad (2-1)$$

毫米波频段已被国际电信联盟指定为“极高频”频段。由奈奎斯特第一准则可知，通信速率和带宽是正比关系。毫米波频段同中低频段相比其频谱资源更丰富，易得到连续的大带宽，可以给用户带来高速率的传输体验。又因为运营商只有有限的频谱，又受到成本的约束，所以基本上不能给用户最大载波带宽。但毫米波频段下的最大单载波带宽能够实现 400MHz，数据速率可实现 10Gbit/s。因此，在未来移动通信中毫米波具有很重要的作用。

与传统的无线通信技术相比，使用毫米波通信的优点^[37]在于：一旦采用了毫米波频段，将会比采用 4G-LTE 频段时的频谱带宽翻十倍，传输速率也就可以大幅度提高^[38]。由于波长较短，应用在无线通信系统中可以使天线的尺寸较短，即使配备很多天线也不会占用太多空间，可以使通信系统更加小型化，另外毫米波还具有可靠性比较高，方向性较好等优点。

尽管毫米波频段有以上几种优点，但是应用在移动通信系统上还存在困难，这是由于毫米波自身的天然缺点所导致的。毫米波缺点展开阐述如下：

(1) 信号衰减大。信号在传播时会有较大的信号衰减，主要原因在于信号存在吸收以及散射^[39]。根据通信中的弗里斯传输公式：

$$P_r = P_t \frac{G_t G_r \lambda^2}{(4\pi R)^2} \quad (2-2)$$

其中， G_t 和 G_r 为发送和接收的天线增益， P_t 和 P_r 为发送和接收功率。由式 (2-2) 可得接收功率与波长成正比。毫米波的波长更短，接收功率更小，也有更高的传输损耗。但毫米波的传播过程中的衰减主要和天气好坏、空气中氧气含量和湿度等因素有关。其中毫米波的路径损耗和雨水衰减对传输的传播影响最大。

路径损耗：波长越短，毫米波的路径损耗越大，由以下公式可得出此结论：

$$\text{PathLoss} = \left(\frac{4\pi d}{\lambda}\right)^2 \quad (2-3)$$

其中， λ 表示波长， d 表示距离。通过公式还可以看出，路径损耗与距离的平方成正比，毫米波的传播的衰减较大。

(2) 易被阻挡。在现实中的环境中基站到接收端不会只有空气，周围总会有一些障碍物，比如树木、楼房等，不能够穿墙传输而被阻挡。

(3) 覆盖距离短。波长与传播距离成正比，导致传播距离较短。理想化的自由空间传播损耗如式(2-4)所示，在非理想的传播条件下，传播损失要比理想化更多^[40]。

$$\text{PL}(\text{dB}) = 20 \times \log_{10}(d) + 20 \times \log_{10}(f) + 92.45 \quad (2-4)$$

从以上毫米波的缺点来看，毫米波很难被用于移动通信系统。但大规模 MIMO 与毫米波相结合，可通过天线增益和波束成形技术弥补覆盖距离短的不足。

2.2 大规模天线技术

2.2.1 MISO 技术

MISO 技术是指发射机有多个发射天线，而接收机只有一根接收天线，这种传输系统叫作多输入单输出，即 MISO。这种方式也叫发射分集，用以改善通信质量。MISO 技术主要应用在 Wi-Fi 领域和移动通信领域，根据接收和发送端天线数量的不同，可以分为 MIMO、MISO、SIMO、SISO 等方式。本文系统建模中所涉及的是 MISO 系统，原理图如图 2.1 所示。

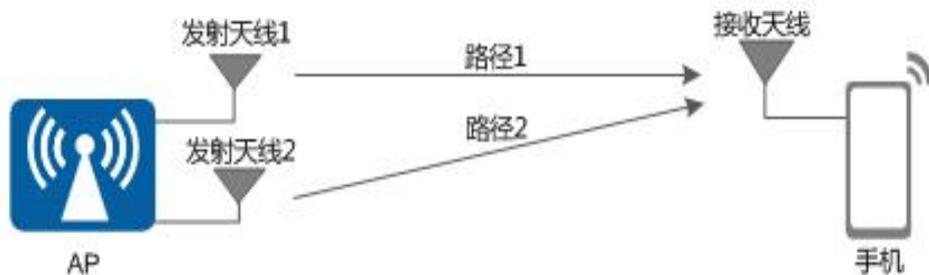


图 2.1 MISO 原理框图

Figure 2.1 MISO block diagram.

图 2.2 中 x 为发送信号， n 为加性噪声值， H 为信道矩阵，则图 2.2 中接收端接收信号可以表示为：

$$y = Hx + n \quad (2-5)$$

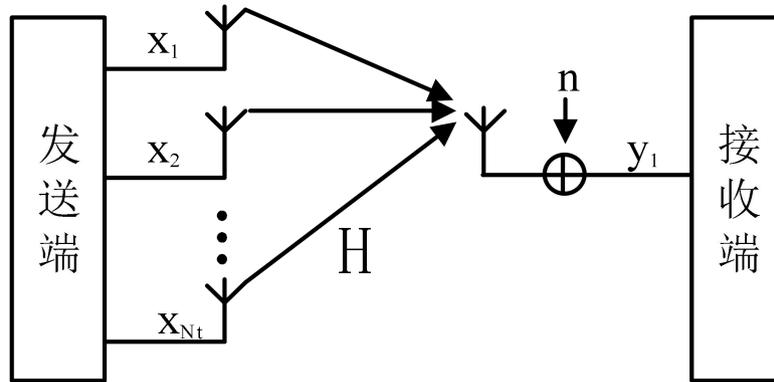


图 2.2 MISO 原理框图

Figure 2.2 MISO block diagram.

2.2.2 Massive MIMO 技术

Massive MIMO，是在第五代移动通信（5G）中增强网络覆盖、用户体验、系统容量的核心技术，该技术可以提高分集增益以及复用增益，以达到更高的传输速率^[41]。

在 Massive MIMO 阵列下，能够把信号能量集中成较窄的波束准确发送到用户，也使传播距离增加，另外特别窄的波束能够准确覆盖用户，极大的降低对邻近社区的干扰，所以大规模 MIMO 更加实用。极窄的波束可以从图 2.3 比较直观的看到，图 2.3 是一种使用了混合模数波束成形架构的一百二十八根天线的 Massive MIMO 基站的波束图样，对八个角度的用户可以生成八个窄波束。从图中可以看出，在一定的区域范围内，即便几个用户互相的距离非常近也可以被准确地区分出来。

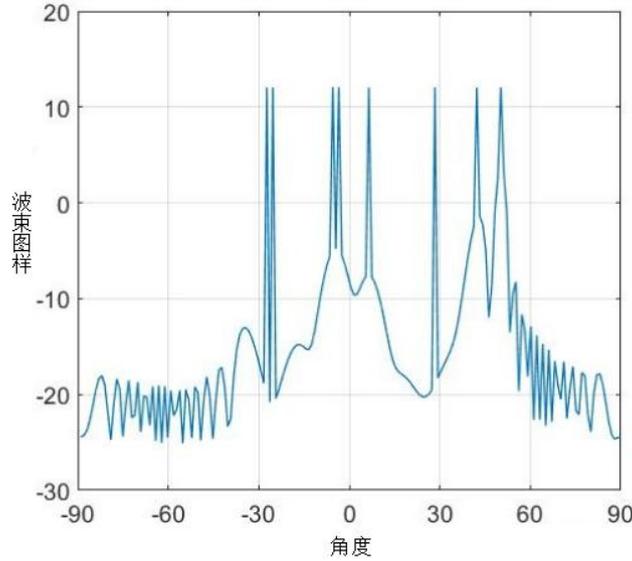


图 2.3 Massive MIMO 基站的波束图样

Figure 2.3 Beam pattern of massive MIMO Base Stations.

和传统 MIMO 技术进行比较, Massive MIMO 具有可以提升传输质量, 还可以降低小区之间的干扰^[42], 实现对小区边缘更好覆盖等优点。

研究发现大规模 MIMO 和毫米波结合能取得很好的效果^[43]。大规模 MIMO 的波束成形能力, 提升了覆盖能力, 解决了毫米波传不远的的问题。因为天线尺寸和信号波长成正比, 且天线尺寸在毫米波频段中通常很小, 所以可以布置在毫米波系统中而不会浪费太大的空间。在有限的空间内可配备大规模的天线阵列以产生足够的波束成形增益, 补偿毫米波信道极为严重的路径损耗^[44]以及克服恶劣天气对毫米波的影响。

2.3 波束成形技术

波束成形技术是把信号以一种能量集中和定向方式发送给无线终端的技术, 能够改善终端接收的信号质量, 使吞吐量得以提高。波束成形通过调节发送天线信号的幅度和相位, 最后进行叠加, 使波束集中于个别方向, 波束成形在空间上看就是对准了个别方向的波束。波束成形通常定义为对基阵各阵元进行线性时不变滤波再求和, 得到波束输出, 再对基阵各阵元输出进行一定的处理, 从而形成基阵空间指向性的技术。一个波束成形器可以对空间某方位的信号有响应, 而抑制其他方位的信号。以均匀线阵为例, 对窄带波束成形模型分析, 理论公式如式(2-6)所示。

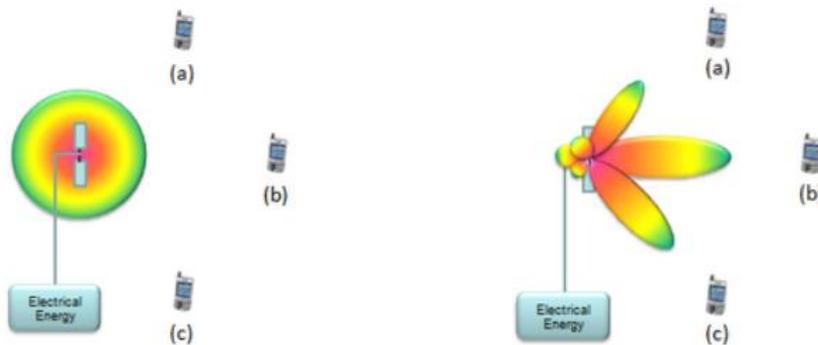
$$\begin{aligned}
 x_1(t) &= s(t)e^{j\omega t} \\
 x_2(t) &= s(t)e^{j\omega t} e^{j\frac{2\pi}{\lambda}d \sin \theta} \\
 &\vdots \\
 x_N(t) &= s(t)e^{j\omega t} e^{j\frac{2\pi}{\lambda}(N-1)d \sin \theta}
 \end{aligned} \tag{2-6}$$

写成矩阵形式为：

$$X(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_N(t) \end{bmatrix} = s(t)e^{j\omega t} \begin{bmatrix} 1 \\ e^{j\frac{2\pi}{\lambda}d \sin \theta} \\ \vdots \\ e^{j\frac{2\pi}{\lambda}(N-1)d \sin \theta} \end{bmatrix} = s(t)a(\theta) \tag{2-7}$$

其中 $a(\theta)$ 为方向矢量或导向矢量，波束成形主要是针对各个接收信号 x 进行权重相加。

波束成形技术不可或缺的原因可以通过图 2.4 简单直接的看出。如图 2.4 所示的两个天线系统，假定这两个天线系统发射的总能量完全相同，在图 a 中，天线系统可以三百六十度地向空间中的各个方向发送信号，如果不指定角度，周围的三个用户接收到的能量基本都相同，但那些没发送到用户的能量就被浪费掉了。在图 b 中，波束成形的辐射方向集中在少数几个方向，使得指向用户的辐射能量较不指向用户的部分更强烈，像手电筒的光束一样，这也是为什么叫波束成形的原因。多天线情况下，波束成形给无线通讯带来了更大的想象空间，尤其在毫米波频段以及更高频率的频段，定向传输能量和信息存在很大的优势。



(a) 正常辐射辐射方向图

(b) 波束成形辐射方向图

图 2.4 波束成形辐射方向对比图

Figure 2.4 Beamforming radiation direction comparison diagram.

4G 系统中的天线数量较少，所以通常都是数字波束成形，系统结构框图如图 2.5 中所示，每根天线都配有一个独立的射频链路，达到对信号的幅度和相位进行调节的目的，但射频链路成本比较昂贵，比如数模转换器，硬件开支较大，且和天线数呈正比。如果在毫米波频段仍然一根天线配一个射频链路的话，会有一个不可能接受的造价和功耗，这又是一个巨大的挑战。模拟波束成形拥有简单的结构，但只支持单流传输，所以很难与数字波束成形的性能进行比较。成本约束了 Massive MIMO 的使用，要克服降低成本问题首先要减少射频链路的数量，将数字波束成形划分为两个部分，分别由低维的数字波束成形和高维的模拟波束成形来实现，进而达到减少射频链路数量的目的，这便是混合波束成形。

混合波束成形有共享型结构和分离型两个典型子阵列结构^{[45][46]}，前者全连接，后者部分连接。混合波束成形结构相比于数字波束成形，射频链路数量相对较少，同时可以多流传输^[47]。混合波束成形系统结构如图 2.6 所示。

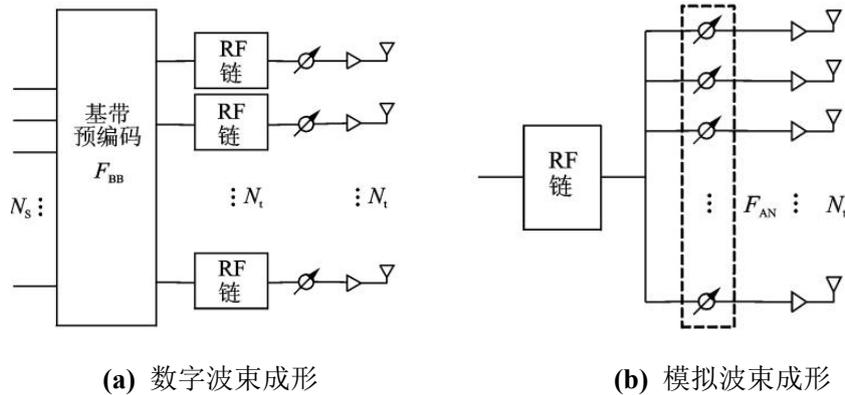


图 2.5 数字波束成形及模拟波束成形系统结构框图

Figure 2.5 Structure diagram of digital beamforming and analog beamforming systems.

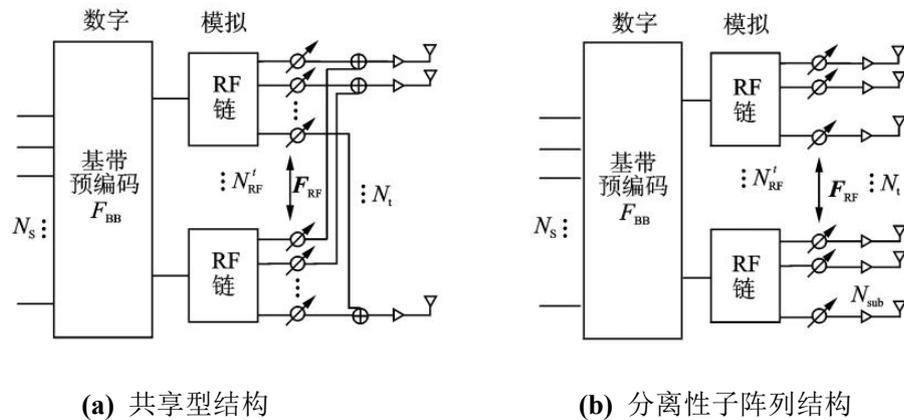


图 2.6 混合波束成形两种典型结构框图

Figure 2.6 Block diagram of two typical structures of mixed beamforming.

波束成形与毫米波技术融合的优点在于,毫米波的应用能够为信号传输提供更大的带宽。而波束成形则可以缓解频谱利用问题,使 5G 通信更加强大。由于受到硬件以及场景的约束,绝大部分 5G 前的波束成形算法都无法照搬在混合波束成形结构下,所以本文研究了基于深度学习的 RIS 辅助 MISO 系统中联合波束成形算法。

2.4 智能反射面基本原理

网络复杂度高、硬件成本昂贵以及逐渐增涨的高消耗是未来无线通信需要解决的关键问题。因此,有必要寻求低成本低能耗的高速无线传输解决方案。在 5G 新技术的候选当中,智能反射表面(Reconfigurable Intelligent Surface,RIS)由于其具有容易部署、低成本以及低时延等显著优点脱颖而出,使其成为提高通信系统传输性能的可行解决方案,业界也将其视为当前最有前景的第六代移动通信(Sixth Generation, 6G)无线通信技术,而且基于 RIS 的新型无线通信系统有望通过联合优化设计实现整体性能最优。下面阐述 RIS 的硬件结构及应用场景以及 RIS 辅助无线通信系统信号模型。

2.4.1 RIS 硬件结构

RIS 是一种超薄的二维人工超材料,通常由大规模单元阵列反射元素、铜板和阵列控制模块构成,RIS 硬件结构图如图 2.7 所示,这些又由金属元件、电介质和可调元件组成,其具有低损耗,低成本,低剖面等特性。智能反射面的使用主要基于一种能够被数字控制的元件,通过设计元件的外形、尺寸、方向或排布,能够适当地改变入射信号的一定的幅度相位,进而改变它的信号响应。通过使用 PIN 二极管,场效应晶体管以及 MEMS 开关等元件,调整电磁单元的物理特性,来改变 RIS 辐射特性,实现波吸收、聚焦、极化等物理现象,从而达到动态调整电磁波的目的。

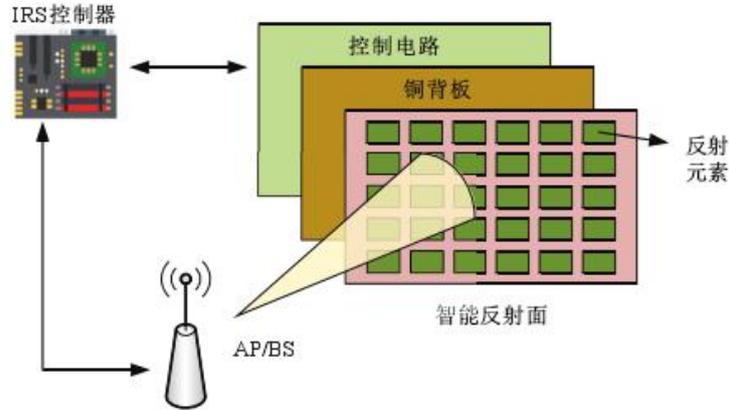


图 2.7 RIS 硬件结构图

Figure 2.7 RIS hardware structure diagram.

2.4.2 RIS 辅助无线通信系统信号模型

将智能反射面放置在基站和用户中间，RIS 上的每个反射元素都能够对入射信号做出相位与幅度上的改变，这样可以利用智能反射面，使用户更好地接收基站发送的信号。本文研究在障碍物阻挡的场景下，通信质量可能会受到很大影响。通过 RIS 辅助可以形成通信质量较高的反射链路，从而使用户能够很好的接收到基站的信号，故没有考虑基站与用户直接链路的情况。该系统由基站、用户和具有 n 个无源发射单元的 RIS 组成，另外假设基站和用户都只配有单天线，RIS 辅助无线通信系统信号模型具体如图 2.8 所示。

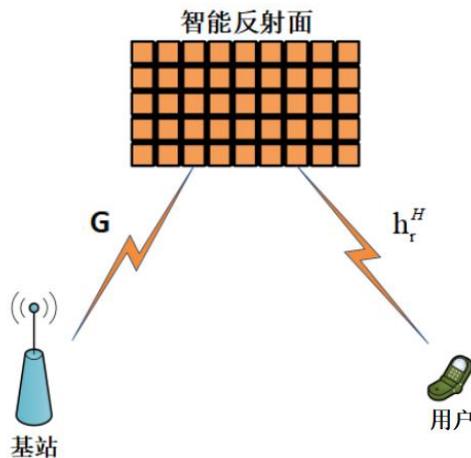


图 2.8 RIS 辅助无线通信系统信号模型

Figure 2.8 Signal model of RIS-assisted wireless communication system.

忽略由于硬件导致的反射误差以及约束条件下，现有一个有 m 个反射元素

的 RIS，反射系数用 v 表示、幅度用 β 表示、相移用 θ 表示，有：

$$v = \beta e^{j\theta} \quad (2-8)$$

其中 $\beta \in [0, 1]$ ， $\theta \in [0, 2\pi)$ ，结合式(2-8)可得 v 的可行集为： $|v| \leq 1$ 。

若对角矩阵用 diag 表示，则 RIS 反射相移矩阵 θ 可表示为：

$$\theta = \text{diag}v = \text{diag}(\beta_1 e^{j\theta_1}, \dots, \beta_m e^{j\theta_m}) \quad (2-9)$$

用户接收到的信号 y 为：

$$y = h_r^H \theta G x + n \quad (2-10)$$

其中， G 表示为基站到 RIS 的基带等效信道， h_r^H 表示为 RIS 到用户的基带等效信道， x 表示为发送信号， n 表示为加性高斯白噪声。

2.5 本章小结

本章主要介绍了 RIS 辅助的通信系统中关键技术及相关原理，首先介绍了毫米波的特点，阐述了使用毫米波通信的优点与缺点，其次介绍了大规模天线技术，说明毫米波可以很好地与大规模 MIMO 相结合，然后介绍了波束成形技术的相关原理，阐述了为什么使用波束成形技术以及使用波束成形技术的优点；最后介绍了什么是智能反射面，RIS 的硬件结构及其辅助无线通信系统信号模型。为接下来在本文中 RIS 辅助 MISO 系统联合波束成形打下了理论基础。

第 3 章 深度学习理论基础

深度学习是在 2006 年由 Hinton 等研究人员首先提出来的，是人工智能算法的创新。随着对深度学习算法的研究和逐渐应用，人工智能技术在大数据、自然语言处理等领域取得了很大成就^[48]。

近年来，研究者们对将人工智能应用于无线通信系统的设计和优化产生了浓厚的兴趣，认为人工智能是未来无线通信系统的核心功能，未来通信系统也将成为智能通信系统^[49]。特别是人工智能中的深度学习算法更是成为研究的热点，也成功用于无线通信系统。本章主要阐述深度学习中的理论基础，主要包括神经元模型、激活函数层、深度和卷积神经网络以及本文在 RIS 辅助的毫米波大规模 MISO 系统中联合波束成形中所使用的图神经网络等。

3.1 神经网络

3.1.1 神经元模型

深度学习的研究起源于人工神经网络。Warren McCulloch 和 Walter Pitts 在二十世纪四十年代受生物学中神经元的启发，提出了一种与神经元相似的 M-P 神经元模型，该模型通过模仿传统的生物神经元模型得到。典型生物神经元结构如图 3.1 所示。该模型的输出 $f(x)=h(g(x))$ ，其中 $g(x)=\sum_i x_i$ ，模型预测输出值是利用 $g(x)$ 的值完成的，如图 3.2 所示。若 $g(x) \geq 0$ ，则输出为 1；若 $g(x) < 0$ ，则输出为 0。M-P 神经元模型由于缺乏学习能力，因此仅用来进行固定逻辑的判断。

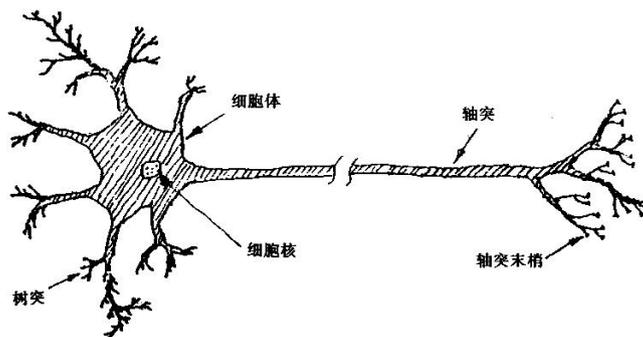


图 3.1 典型生物神经元结构

Figure 3.1 Typical biological neuron structure.

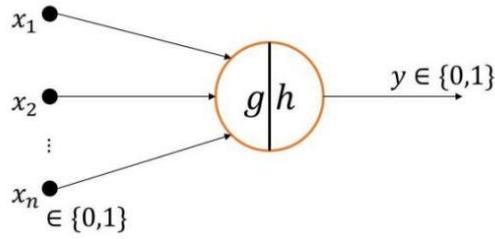


图 3.2 M-P 神经元模型

Figure 3.2 M-P neuron model.

神经网络的基础组成是神经元。1957 年，Frank Rosenblatt 提出了一个能够自动学习权重的神经元模型，每个神经元都可以看做是一个感知机，神经元数学模型如图 3.3 所示。令神经元的输入用 $X=[x_1, x_2, x_3, \dots, x_n]^T$ 进行表示，神经元间的连接权重为 $w_1, w_2, w_3, \dots, w_n, n = 0, 1, \dots, n$ ，偏置参数用 b 表示，非线性激活函数用 f 表示， y 为输出结果。可得图 3.3 中所示的神经元模型的输出为：

$$y=f(w_1 x_1 + w_2 x_2 + w_3 x_3 + \dots + w_n x_n + b) \quad (3-1)$$

式(3-1)是一个标量形式，使用矩阵形式可以简化为：

$$y=f(W^T X+b) \quad (3-2)$$

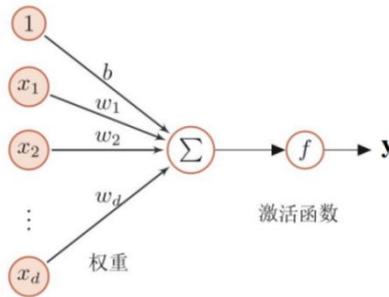


图 3.3 神经元数学模型

Figure 3.3 Mathematical model of neurons.

3.1.2 激活函数

在神经元中加入激活函数可以为线性模型引入非线性元素而变成了非线性模型，激活函数可以使深度神经网络的表达能力更加强大。最常见的激活函数有 Sigmoid 函数、tanh 函数、Relu 函数三种。

(1) Sigmoid 函数

Sigmoid 函数作为广泛使用的神经网络激活函数之一。该函数将输入映射到

区间 (0,1) 的输出, 这种输出与概率分布范围 [0,1] 契合, 可以把输出转换成概率, 或者用于表示输入的归一化。函数表达式为:

$$f_{\text{Sigmoid}}(x) = \frac{1}{1 + e^{-x}} \quad (3-3)$$

其函数图像如图 3.4。

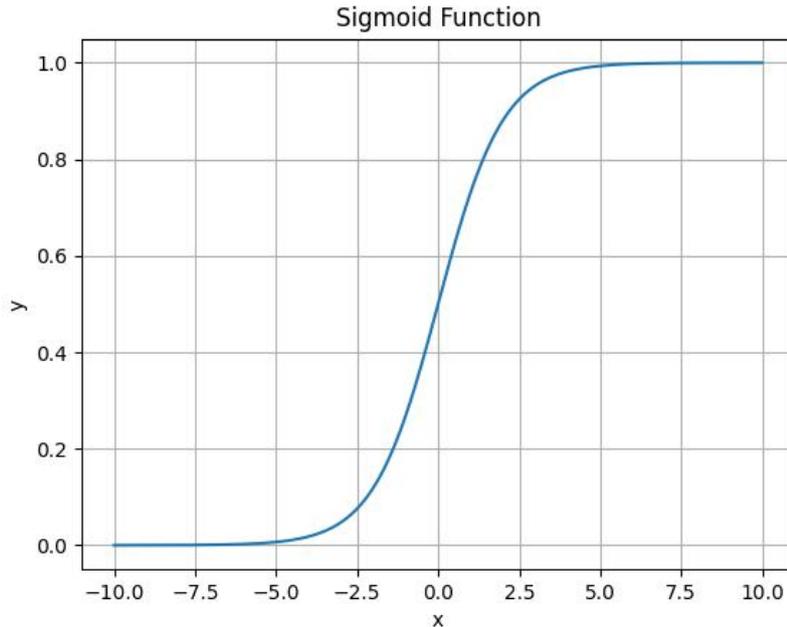


图 3.4 Sigmoid 函数

Figure 3.4 Sigmoid Function.

从图 3.4 中可以看出, Sigmoid 函数中心对称、单调递增且连续可导, 导数为其本身的函数。优点在于能够把 $x \in R$ 的输入压缩到 $x \in (0,1)$ 区间, 不足之处则是该函数具有饱和性, 这是由于函数两侧导数近似为 0, 满足左饱和右饱和, 即

$$\lim_{x \rightarrow \infty} f'(x) = 0 \quad (3-4)$$

函数的饱和性, 使得神经网络在进行反向传播时容易产生梯度消失, 不能够完成深层网络的训练, 成为阻挡深度学习发展的一个因素。

(2) tanh 函数

tanh 函数, 是双曲正切函数的简称。和 Sigmoid 函数不同之处在于输出值的范围从 (0,1) 变为了 (-1,1), 因此可以把它看做是 Sigmoid 经过下移和拉伸后所得。tanh 对应的函数表达式为:

$$f_{\tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = 2f_{\text{Sigmoid}}(2x) - 1 \quad (3-5)$$

其函数图像如图 3.5 所示。

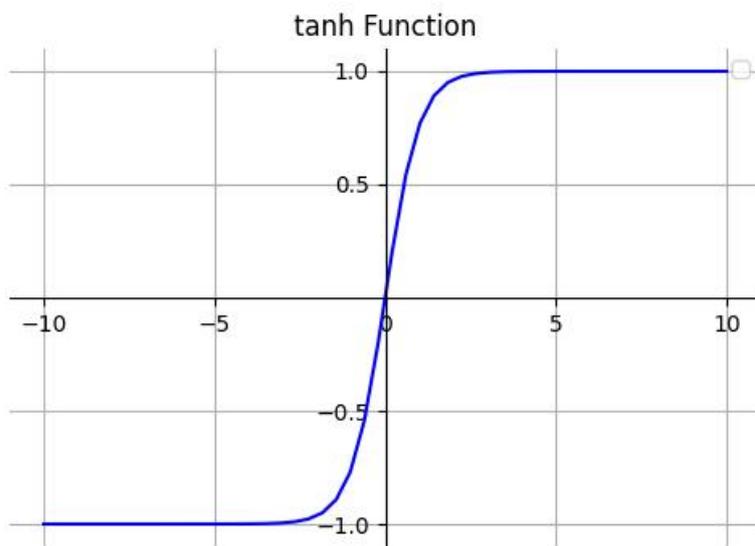


图 3.5 tanh 函数

Figure 3.5 tanh Function.

图 3.5 的 tanh 函数是一个奇函数，值的范围为(-1, 1)，其斜率相对 sigmoid 函数来说要更大一点。输入为负数的话，输出也为负数；同理输入为正数，输出也是正数。该函数仍然没有解决反向传播时的梯度消失问题。

(3) ReLU 函数

自从 2012 年 AlexNet 模型中应用了 ReLU 函数之后，ReLU 函数应用越来越广泛。ReLU 函数定义为：

$$f_{\text{ReLU}}(x) = \max(0, x) \quad (3-6)$$

可得其导数为：

$$\frac{d}{dx} f_{\text{ReLU}}(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (3-7)$$

ReLU 函数如图 3.6 所示。

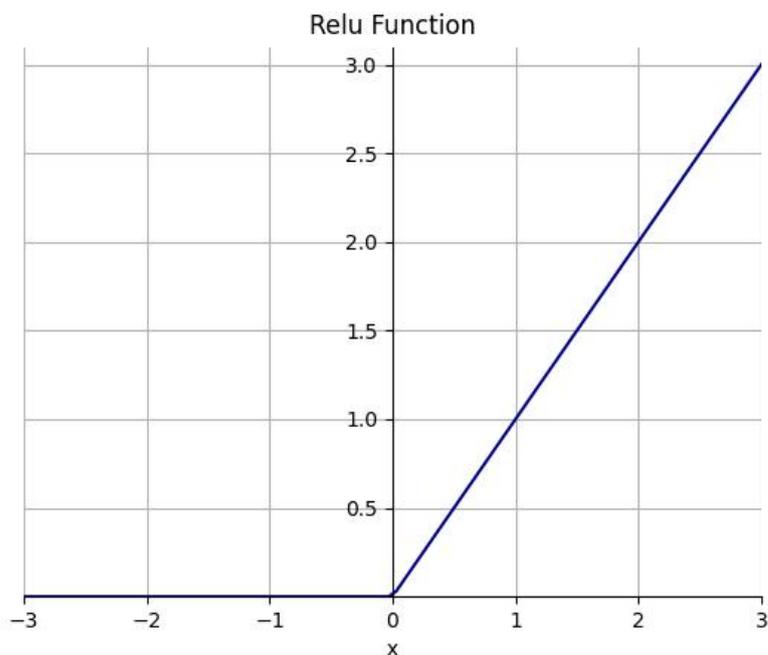


图 3.6 ReLU 函数

Figure 3.6 ReLU Function.

从图 3.6 可以比较直观的了解 ReLU 函数为分段线性函数,负半轴值为零,正半轴单调递增。函数的单侧抑制,能够使神经网络具备稀疏激活性。并且训完成的网络也是稀疏的,表明 ReLU 函数可以引导适度稀疏。ReLU 相比于其他激活函数的优点,在于它具有更强的表达能力,并且在 ReLU 函数的正区间的导数是一个常数,所以不会产生梯度消失,让模型收敛速度在一个相对稳定的状态。

3.1.3 深度神经网络

深度神经网络也可简单理解为具有很多隐藏层的神经网络。又被叫做多层神经网络,也被叫做多层感知机 (MLP)。深度神经网络的输出和输入之间学习到一个非线性关系,并获得式(3-2)的输出结果。深度神经网络的隐藏层可以有很多层,这样可以达到提高模型表达能力的目的,层数越多,复杂度也越高;深度神经网络也可以有多个输出,使深度神经网络能够广泛应用于分类回归、降维、聚类等领域。

深度神经网络分为输入层、隐藏层和输出层三类,如图 3.7 所示,一般来说第一层为输入层,中间为隐藏层,最后一层为输出层。

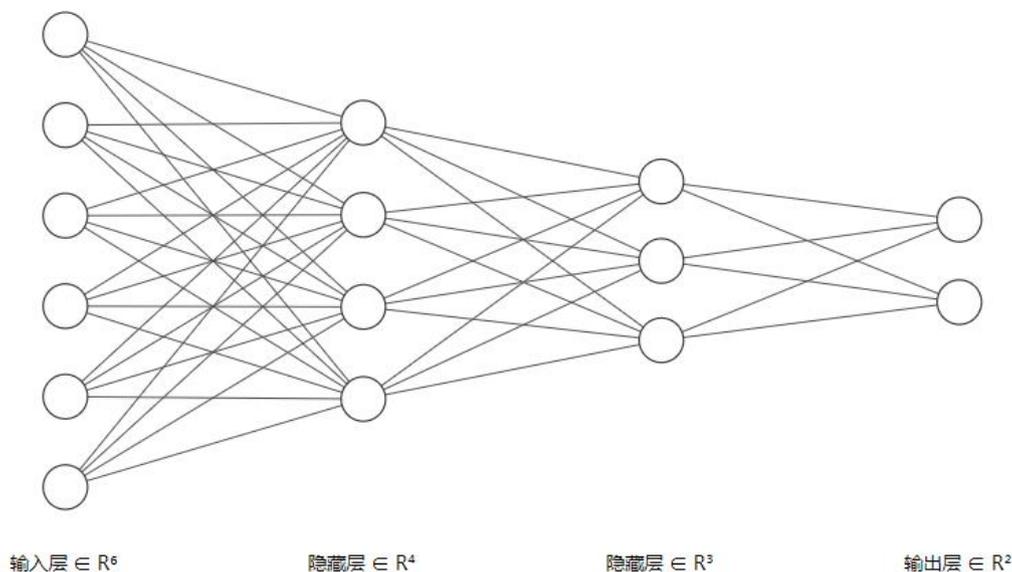


图 3.7 深度神经网络模型

Figure 3.7 Deep neural network model.

图 3.7 是深度全连接的神经网络，上一层的每个神经元均与其下一层的任意一个神经元相连。如果所有层计算都是线性函数，那么就失去了隐藏层多层的意义，所以在中间层加入了非线性激活函数，除输入层外，所有节点的输出值都输出一个浮点数值，输出层在最后输出的时候，因为前面的运算值的范围不是很统一，所以通过激活函数定义的公式对输出层的所有值进行处理从而得出输出结果，也可以看成神经网络的前向传播。

3.1.4 损失函数

通过前向传播在输出层得出结果，但得到的结果和实际结果不一样，不符合我们的要求，通过损失函数得到预测值与真实值的差值，也就是损失值。在获得损失值之后，模型通过反向传播去更新各参数，减少真实值与预测值的差值，使预测数值趋近于真实值，以此实现学习的目的。通常使用合适的损失函数，可以获得较好性能的模式。常见的损失函数有式(3-8)中的交叉熵损失函数和式(3-9)中的均方误差损失函数，交叉熵损失函数描述了实际与期望输出概率之间的相似度。本文中所使用的便是自定义的交叉熵损失函数。

$$L(Y|f(x)) = - \sum_{i=1}^N Y_i \log f(x_i) \quad (3-8)$$

$$L(Y|f(x)) = -\frac{1}{n} \sum_{i=1}^N (Y_i - f(x_i))^2 \quad (3-9)$$

3.1.5 反向传播算法

反向传播（Back Propagation, BP）算法中采用了梯度下降法更新网络参数，正向传播可以计算出上一层的误差，接着用上一层的误差来表示当前层误差，通过链式求导的方法。从后向前依次递推获得每个层的节点参数的损失函数的偏导，并基于导函数调整相关参数。从而得到每层权值梯度误差，再通过优化算法优化网络参数实现学习。

反向传播算法的过程^[50]简述为：

输入数据集：\$(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(m)}, y^{(m)})\$，其中 \$x^{(i)} \in \mathbb{R}^n\$，激活函数为 \$\sigma(x)\$，有 \$l\$ 层，\$l=0, 1, 2, \dots, L\$。正向传播得神经元输出结果为：

$$\begin{cases} z^{(l)} = w^{(l)} a^{(l-1)} + b \\ a^{(l)} = \sigma(z^{(l)}) \end{cases} \quad (3-10)$$

(1) 得到输出层误差：

$$\delta^{(L)} = \nabla_{a^{(L)}} \mathcal{C}(\theta) \odot \sigma'(z^{(L)}) \quad (3-11)$$

(2) 得到反向传播误差：

$$\delta^{(l)} = ((w^{(l+1)})^T \delta^{(l+1)}) \odot \sigma'(z^{(l)}) \quad (3-12)$$

(3) 权重、偏置、学习率分别用 \$w\$、\$b\$、\$\alpha\$ 表示，则权重和偏置更新为：

$$\begin{cases} w_{jk}^{(l)} = w_{jk}^{(l)} - \alpha \frac{\partial \mathcal{C}(\theta)}{\partial w_{jk}^{(l)}} \\ b_j^{(l)} = b_j^{(l)} - \alpha \frac{\partial \mathcal{C}(\theta)}{\partial b_j^{(l)}} \end{cases} \quad (3-13)$$

即

$$\begin{cases} w_{jk}^{(l)} = w_{jk}^{(l)} - \alpha a_k^{(l-1)} \delta_j^{(l)} \\ b_j^{(l)} = b_j^{(l)} - \alpha \delta_j^{(l)} \end{cases} \quad (3-14)$$

3.2 图神经网络

图神经网络（Graph Neural Networks, GNN）在 2005 年由 Gori 等人首先提出^[51]，通过对神经网络领域的一些成果进行了研究整理，提出了一种可以对图结构

数据进行处理的网络模型，该模型又在 2009 年被 Scarselli 等人进行了详细的介绍。最近几年，图神经网络受到很多学者的关注和研究。这是由于图神经网络可以处理非欧几里得数据，通过点以及边对非欧几里得数据进行建模，这是传统的神经网络仅能应对结构化的数据所达不到的。最简单图神经网络模型如图 3.8 所示。

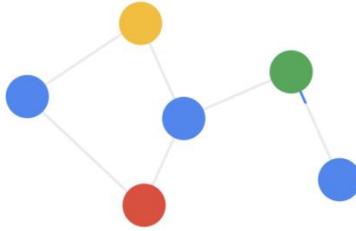


图 3.8 简单的图神经网络模型

Figure 3.8 A simple graph neural network model.

同神经网络中最基本的网络结构全连接层（MLP）相比较，图神经网络多了一个邻接矩阵。特征矩阵乘以权重矩阵，全连接单层神经网络和图神经网络的计算公式分别如式(3-15)和(3-16)所示。

$$H = \sigma(XW) \quad (3-15)$$

$$H = \sigma(AWX) \quad (3-16)$$

由式(3-16)可知，图神经网络的计算过程可以近似于聚合邻接矩阵的过程。将该节点周围的节点的 Embedding 提取到一个矩阵当中，再将该节点本身和提取到的节点做一个汇聚操作，将周围的节点信息包括自己本身相加起来作为模型的输入，也有一些相加或者平均的操作，这样经过几步迭代之后，该节点就汇聚很大范围的信息了，用来更新该节点。我们本文所研究 RIS 辅助联合波束成形便是使用图神经网络的聚合等操作来完成所有节点的更新，获得较好的性能。

3.3 卷积神经网络

卷积神经网络（CNN）是一种具有卷积结构的前馈神经网络，由输入层、若干个卷积层和池化层、全连接层及输出层构成，卷积层和池化层交替连接，降低了权值的数量以及模型的复杂度，可以让网络容易被优化，并且使过拟合风险降低。

卷积层中有多个可学习的卷积核，上一层的输出项的集合 I_j^l 与卷积核 K 进行卷积操作，可以得到卷积层 1 的第 j 单元的输出项 a_j^l 计算公式为：

$$a_j^l = f(b_j^l + \sum_{i \in I_j^l} a_j^{l-1} * K_{ij}^l) \quad (3-17)$$

由输入项 I 、卷积核 K 、步长 s 可得到卷积层输出的计算公式为：

$$N = \frac{I - K}{s} + 1 \quad (3-18)$$

如果使用三维卷积层进行示例可以如图 3.9 所示，卷积核 K 使用预先设定的步长进行滑动。图中的输入项特征图的大小是 $7*7$ ，也就是 $I=7$ ，卷积核大小为 $3*3$ ，也就是 $K=3$ ，步长为 1 即 $s=1$ ，由式(3-18)可得输出项的大小 $N=5$ ，值为 4。

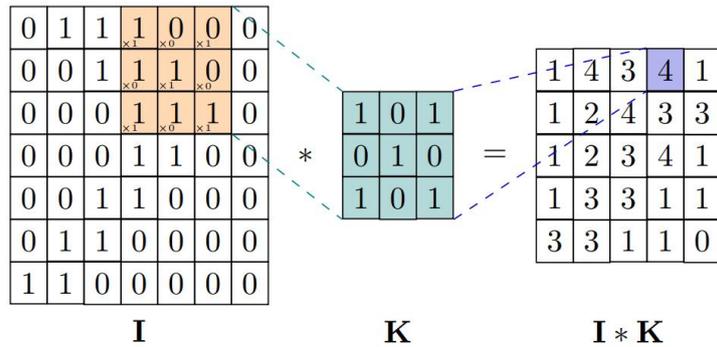


图 3.9 卷积操作示例图

Figure 3.9 Example of a convolution operation.

卷积层后面通常是池化层，两者交替连接，一一对应。最常用到的有平均池化、最大池化、最小池化和随机池化等池化函数。平均池化和最大池化如图 3.10 所示，左边表示平均池化，右半部分表示最大池化。池化操作可以使卷积神经网络的泛化能力增强。虽然卷积神经网络被广泛的应用在各种领域中，但怎样有效地训练层数很深的深度神经网络仍然是一个需要去研究解决的问题。

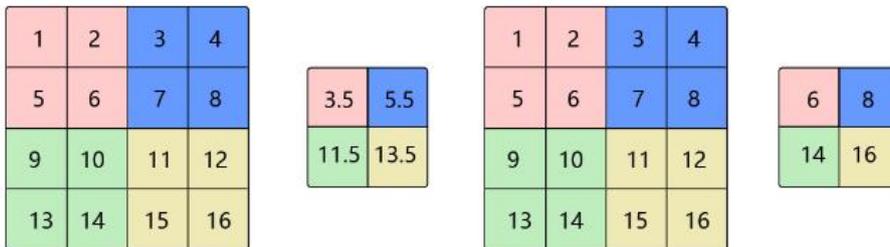


图 3.10 平均池化和最大池化

Figure 3.10 Average pooling and maximum pooling.

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/997155063114006040>