



中国人工智能系列白皮书

——深度学习

中国人工智能学会

二〇二三年九月

《中国人工智能系列白皮书》编委会

主任：戴琼海

执行主任：王国胤

副主任：陈杰 何友 刘成林 刘宏 孙富春 王恩东
王文博 赵春江 周志华

委员：班晓娟 曹鹏 陈纯 陈松灿 邓伟文 董振江
杜军平 付宜利 古天龙 桂卫华 何清 胡国平
黄河燕 季向阳 贾英民 焦李成 李斌 刘民
刘庆峰 刘增良 鲁华祥 马华东 苗夺谦 潘纲
朴松昊 钱锋 乔俊飞 孙长银 孙茂松 陶建华
王卫宁 王熙照 王轩 王蕴红 吾守尔·斯拉木
吴晓蓓 杨放春 于剑 岳东 张小川 张学工
张毅 章毅 周国栋 周鸿祎 周建设 周杰
祝烈煌 庄越挺

《中国人工智能系列白皮书----深度学习》编写组

季向阳 徐龙 陈杰 高伟 王旭 陈小龙 张利
赵铁松 陈炜玲 孙文青 赵栋 钟昱丰

目 录

第 1 章 人工智能历史与现状	1
1.1 人工智能的概念和起源	1
1.1.1 人工智能的概念	1
1.1.2 人工智能的起源	2
1.2 人工智能的黄金时代	3
1.2.1 感知机	4
1.2.2 贝叶斯网络	4
1.2.3 模式识别	6
1.2.4 人机对话	7
1.2.5 知识表示	8
1.2.6 计算机视觉	8
1.3 人工智能的冬天	9
1.4 人工智能的复兴期	12
1.4.1 机器学习	12
1.4.2 自然语言处理	14
1.4.3 神经网络	15
1.4.4 遗传算法	15
1.4.5 深蓝超级计算机	16
1.5 人工智能的爆发期	17
1.5.1 卷积神经网络	17
1.5.2 生成对抗网络	18
1.5.3 变分自动编码器	19
1.5.4 迁移学习	19
1.5.5 知识图谱	20

1.5.6	自动驾驶	21
1.5.7	AlphaGO	22
1.5.8	AlphaFold	23
1.5.9	ChatGPT	23
1.6	人工智能的未来	25
1.6.1	可信人工智能	25
1.6.2	多模态预训练模型	25
1.6.3	多任务模型	26
1.6.4	基于人工智能的网络安全	26
1.6.5	边缘计算和联合学习	26
1.6.6	人机协作与交互	27
1.6.7	从大数据转向多样化小数据	27
1.6.8	人工智能伦理	28
1.6.9	人工智能平台的操作化	28
第2章	深度学习模型	29
2.1	卷积神经网络	29
2.1.1	卷积层	30
2.1.2	激活函数	32
2.1.3	池化层	33
2.1.4	全连接层	33
2.2	经典的网络模型	33
2.2.1	LeNet 网络模型	33
2.2.2	AlexNet 网络模型	34
2.2.3	VGG 网络模型	36
2.2.4	GoogLeNet 网络模型	37
2.2.5	ResNet 网络模型	39

2.2.6 ShuffleNet 网络模型	40
2.2.7 Vision Transformer 模型	41
2.2.8 递归神经网络	42
2.3 人类视觉感知特性与深度学习模型	46
2.3.1 人类视觉感知特性	46
2.3.2 人类视觉感知特性启发的深度学习模型	47
2.4 注意力机制与深度学习模型	49
2.4.1 注意力机制研究进展	49
2.4.2 注意力模型基本框架	51
2.5 U 型网络	57
2.5.1 U 型网络结构简介	57
2.5.2 改进的 U 型网络	59
2.6 本章小结	63
第 3 章 人工智能大模型	116
3.1 引言	116
3.2 人工智能大模型概述	119
3.3 关键技术和算法	121
3.4 应用领域和案例研究	124
3.5 人工智能多模态大模型	126
3.6 人工智能大模型在生命科学领域上的探索	133
3.7 技术挑战和解决方案	135
3.8 未来发展方向和展望	138
第 4 章 深度学习与图像描述生成及视觉定位	144
4.1 图像描述生成	144
4.1.1 图像字幕关键技术	145
4.1.2 图像描述生成方法	151

4.1.3 未来趋势展望	157
4.2 视觉定位	160
4.2.1 视觉定位关键技术	161
4.2.2 视觉定位生成方法	163
4.2.3 挑战及未来发展方向	166
第 5 章 深度学习在编码中的应用	173
5.1 引言	173
5.2 智能图像编码压缩	173
5.2.1 编解码器框架设计	174
5.2.2 编解码器优化技术	180
5.3 智能视频编码压缩	183
5.3.1 基于残差编码的框架	184
5.3.2 基于条件熵编码的框架	186
5.3.3 其它类型的架构	190
5.3.4 编码配置优化技术	193
5.4 视觉数据压缩新趋势	195
5.4.1 隐式神经表示	195
5.4.2 多模态视觉数据压缩	197
5.4.3 面向人机混合的智能编码	198
5.5 本章小结	199
第 6 章 深度学习的特征及模型压缩	66
6.1 背景介绍	66
6.2 深度学习模型压缩	66
6.2.1 剪枝	67
6.2.2 知识蒸馏	69
6.2.3 量化	71

6.3 深度学习模型中间层特征压缩	86
6.3.1 基于图像/视频编解码框架的中间层特征压缩	90
6.3.2 基于比特分配的中间层特征压缩	95
6.3.3 基于深度学习网络架构的中间层特征压缩	97
6.3.4 中间层特征压缩三类方法的比较与分析	99
6.3.5 思考与展望	102
6.4 本章小结	104
第7章 深度学习在天文学研究中的应用	213
7.1 深度学习在射电天文成像中的应用	215
7.2 深度学习在恒星观测中的应用	216
7.3 深度学习探究天文事件的物理机制	219
7.4 深度学习在太阳物理研究中的应用	220
7.5 深度学习在太阳耀斑预报建模中的应用	225
7.5.1 太阳耀斑	225
7.5.2 耀斑的性质	227
7.5.3 耀斑预报建模	228
7.5.4 提取耀斑先兆特征揭示耀斑发生的触发机理	231
7.5.5 磁图分辨率对耀斑预报的影响	234
7.6 从紫外、极紫外图像生成磁图的动态深度学习模型	239
7.7 深度学习用于太阳活动区磁图超分辨	243
7.8 深度学习用于太阳极紫外图像过曝光修复	247
7.9 基于深度学习的日冕物质抛射预报	249
7.9.1 日冕物质抛射	249
7.9.2 日冕物质抛射的多波段观测	249
7.9.3 日冕物质抛射的性质	251
7.9.4 日冕物质抛射预报	253

第 8 章 雷达智能信息处理	273
8.1 引言	273
8.2 基于深度学习的雷达信号处理	273
8.2.1 噪声与杂波抑制	273
8.2.2 目标信号增强	277
8.2.3 雷达目标检测	279
8.2.4 阵列雷达信号处理	282
8.3 基于深度学习的雷达图像处理	285
8.3.1 雷达低分辨图像处理	285
8.3.2 雷达高分辨图像处理	291
8.4 雷达智能信息处理发展趋势	299
8.4.1 小样本目标检测	299
8.4.2 无监督或弱监督目标检测	306
8.4.3 多维多通道特征融合检测	309
8.4.4 可解释人工智能	310
第 9 章 深度学习与智慧海洋相关应用	322
9.1 海洋图像处理	322
9.2 海洋媒体信息质量感知	326
9.3 水下机器视觉	330
第 10 章 深度学习与医工结合相关应用	340
10.1 医学影像	340
10.1.1 常见医学图像类型	340
10.1.2 常见的医学图像分析任务	341
10.2 病理分析	343
10.3 辅助诊断	352
第 11 章 深度学习在大数据处理中的应用	362

11.1 天文大数据	362
11.1.1 天文大数据概述	363
11.1.2 天文大数据目标及挑战	365
11.1.3 天文大数据理论及技术	366
11.1.4 应用实例	368
11.2 医疗大数据	374
11.2.1 医疗大数据概述	374
11.2.2 医疗大数据目标及挑战	379
11.2.3 医疗大数据理论及技术	382
11.2.4 应用实例	384
11.3 金融大数据	398
11.3.1 金融大数据概述	398
11.3.2 金融大数据目标及挑战	401
11.3.3 金融大数据理论及技术	402
11.3.4 应用实例	406
11.4 本章小结	412
第 12 章 深度学习在三维点云技术中的应用	417
12.1 点云感知定义概述	417
12.2 点云感知建模	419
12.2.1 质量评价概述	419
12.2.2 点云质量建模	420
12.2.3 点云显著性概述	425
12.2.4 显著性检测	426
12.3 深度学习点云压缩	428
12.3.1 国内外研究进展	428
12.3.2 基于深度学习的点云压缩	431

12.3.3 云压缩标准	433
12.4 深度学习点云增强	435
12.4.1 点云压缩修复	435
12.4.2 点云补全	442
12.4.3 点云上采样	445
12.5 技术展望	446

第 1 章 人工智能历史与现状

1.1 人工智能的概念和起源

1.1.1 人工智能的概念

人工智能（Artificial Intelligence, AI）是一门研究如何使计算机能够模拟人类智能行为的科学和技术，目标在于开发能够感知、理解、学习、推理、决策和解决问题的智能机器。人工智能的概念主要包含以下几个方面：

（1）人工智能的目标是模拟人类的智能行为。人工智能致力于使计算机能够像人类一样感知世界、理解信息、进行学习和决策，涵盖视觉、语音、自然语言处理、机器学习等领域的研究和应用。

（2）人工智能的学习能力。人工智能强调计算机能够从数据中学习，并根据学习的结果不断优化自己的性能。机器学习是人工智能的重要分支，涉及到许多算法和模型，如监督学习、无监督学习、强化学习等。

（3）人工智能可以解决问题。人工智能的一个主要目标是使计算机能够解决各种复杂问题，包括图像识别、语音识别、自然语言处理、自动驾驶、医疗诊断等。通过深度学习等技术，计算机可以从大量数据中提取有用的信息，从而实现更高效的问题解决方法。

（4）人工智能的自主性与多样性。理想的人工智能系统应该能够独立地进行学习、决策和行动，而不需要持续的人类干预。人工智能涉及到多个子领域，包括机器学习、计算机视觉、自然语言处理、专家系统、智能控制等。这些子领域有着不同的研究方法和技术，共同构成了人工智能的多样性。

人工智能的发展不仅涉及到理论研究，还需要大量的实践和应用。随着计算能力和数据量的增加，人工智能在各个领域都有了显著的应用，包括自动驾驶、智能语音助手、推荐系统、医疗诊断、金融风控等。人工智能的发展将深刻地影响人类社会的方方面面，同时也带来

了一系列的伦理和社会问题，需要人们共同思考和解决。

1.1.2 人工智能的起源

人工智能的起源可以追溯到早期科幻小说的人工智能（弗兰肯斯坦）、阿西莫夫的机器人三定律、阿兰·图灵的计算机博弈论、图灵测试以及 1956 年达特茅斯会议中人工智能概念的提出。

- 科幻小说的人工智能（弗兰肯斯坦）

人工智能的早期概念在文学中有所体现，其中最著名的例子是玛丽·雪莱的 1818 年作品《弗兰肯斯坦》。这部小说描写了一位年轻的科学家维克多·弗兰肯斯坦通过研究死尸和化学实验创造出了一个人造人。尽管这并非现代意义上的人工智能，但这部小说引发了人们对于人工创造生命的担忧以及对科学与道德之间冲突的思考。弗兰肯斯坦对自己所创造的生命失去了控制，最终导致灾难性后果，这为人工智能伦理和道德问题提供了一个早期的警示。

- 阿西莫夫的机器人三定律

在 20 世纪中期，美国作家艾萨克·阿西莫夫为科幻小说创造了机器人三定律。这些定律首次出现在他 1942 年发表的作品《转圈圈》（Runaround, 《我，机械人》（I, Robot）中的一个短篇）中，后来成为科幻文学中一个广为人知的概念。机器人三定律包括：

第一定律：一个机器人不得伤害人类或因不采取行动导致人类受到伤害。

第二定律：一个机器人必须服从人类的命令，除非这些命令与第一定律相冲突。

第三定律：一个机器人必须保护自己，除非这样做与前两定律相冲突。

机器人三定律引发了人们对人工智能伦理和道德的深入讨论。阿西莫夫的作品探讨了机器人与人类的关系，以及如何确保人工智能的安全和符合道德准则。

- 阿兰·图灵的计算机博弈论和图灵测试

阿兰·图灵是计算机科学和人工智能的奠基人之一。他在 1950 年发表的论文《计算机与智能》中探讨了计算机是否能够表现出智能，并提出了著名的图灵测试，即由一个裁判通过键盘与隐藏在另一个房间的一个人和一台计算机进行对话，如果裁判不能通过对话判断哪个是人，哪个是计算机，那么可以认为计算机具备了智能。

图灵测试成为人工智能领域中重要的测评方法，同时也引发了科学家们对于机器具有智能与思维可能性的关注与研究，为人工智能的发展奠定了基础。

- 人工智能概念的提出

在图灵测试的提出之后，人工智能领域的研究日益活跃。1956 年夏天，达特茅斯学院召开了一次重要的研讨会，这次会议被认为是人工智能学科的正式开始。会议聚集了一批科学家，包括约翰·麦卡锡、马文·明斯基、艾伦·纽厄尔、赫伯特·西蒙等。他们共同讨论了如何使用计算机来模拟人类的智能行为，并对人工智能的未来发展进行了探讨。

在达特茅斯会议上，人工智能的概念被正式提出：人工智能是一门旨在开发计算机能够模拟人类智能行为的科学。会议为人工智能的研究和发展奠定了基础，并激发了科学家对于人工智能的探索和发展热情。随着时间的推移，人工智能得到了显著的发展，成为计算机科学领域一个重要的研究方向。

1.2 人工智能的黄金时代

人工智能发展的黄金时代是 20 世纪 60-70 年代。在这段时间里，人们开始探索使用计算机模拟人类智能的可能性。本节将介绍该时期人工智能发展的六个重要方面：感知机、贝叶斯网络、模式识别、人机对话、知识表示、计算机视觉。

1.2.1 感知机

感知机是人工神经网络的早期模型，最早由美国学者弗兰克·罗森布拉特于 1957 年提出，但是它的发展和研究真正迅速起来是在 1960 年代末和 1970 年代初。感知机在当时被认为是一种具有潜力的智能系统，对人工智能的发展产生了深远的影响。感知机作为神经网络的先驱，也为深度学习技术做出了重要的贡献。

感知机模型是一种单层的前馈神经网络，其基本单元是人工神经元（也称为感知机元）。这些神经元接收输入，通过学习调整权重，然后产生输出。感知机的主要目标是通过学习过程自动分类输入数据。在这个过程中，感知机学习如何根据输入数据的特征将其分成不同的类别。

在 1960 年代和 1970 年代早期，感知机的研究吸引了很多注意力，它被认为是实现人工智能的重要途径之一。然而，随着时间的推移，人们逐渐认识到感知机存在一些局限性，尤其是在解决复杂问题上的能力较弱。具体来说，感知机只能解决线性可分问题，即只能对线性可分的数据进行分类。这意味着对于复杂的非线性问题，感知机无法有效地处理。这一发现导致了感知机的研究进入了一个低谷期，人们对其效用产生了质疑。

1969 年，美国学者马文·明斯基和西蒙·佩珀特在一篇著名的论文中证明了感知机无法解决异或问题，也被称为感知机的 **Minsky 问题**。这个结果进一步加剧了人们对感知机的批评，认为它在解决实际问题中是有限的。虽然感知机在解决复杂问题上存在局限性，但它仍为人工智能的发展奠定了基础。随着时间的推移，人们逐渐发现神经网络的潜力，特别是深度学习的崛起，促使了更多对神经网络的探索。

1.2.2 贝叶斯网络

贝叶斯网络作为一种概率图模型，对人工智能的发展产生了深远的影响。贝叶斯网络也称为贝叶斯信念网络或概率图模型，该网络最

早由美国数学家托马斯·贝叶斯提出，它是一种通过节点之间的概率关系表示变量之间相互依赖关系的图模型。它通过有向无环图（Directed Acyclic Graph, DAG）来表示变量之间的依赖关系，并使用概率分布来描述这些依赖关系。

与传统的神经网络不同，贝叶斯网络采用概率论的方法来推断和预测数据，其具有更好的解释性和推理能力。贝叶斯网络的主要优势在于其可以通过观察到的数据来更新概率分布，从而实现对未知变量的预测和推理。贝叶斯网络的主要特点包括：

（1）不确定性建模。贝叶斯网络能够有效地处理不确定性问题。它使用概率分布来表示变量之间的依赖关系，使得模型能够处理不完整或不准确的数据，并对未知变量进行推理和预测。

（2）有向无环图结构。贝叶斯网络的图结构是有向无环图，意味着变量之间的依赖关系是有方向性的，不存在回路。这样的结构使得模型具有清晰的因果关系，并且易于解释。

（3）数据集集成。贝叶斯网络可以集成来自不同来源的数据集，并融合先验知识进行学习和推理。这种数据集集成的能力使得模型更加全面和强大。

（4）可解释性。相比于一些黑盒模型，贝叶斯网络具有更好的可解释性。图结构能够直观地表示变量之间的依赖关系，帮助人们理解模型的决策过程。

（5）适应小样本数据。贝叶斯网络在处理小样本数据时表现出色。由于贝叶斯方法可以通过先验知识和概率推理来填补数据不足的问题，因此在数据量有限的情况下仍然能够有效地进行预测和推理。

基于上述特点，贝叶斯网络在自然语言处理、图像识别、医学诊断等领域取得了广泛应用。随着人工智能技术的不断发展，贝叶斯网络将继续发挥重要作用，为数据分析、决策支持等领域提供有效的建模和推理方法。

1.2.3 模式识别

随着计算机技术的不断发展和人工智能领域的兴起，模式识别得到了更多的关注和研究。在 20 世纪 60 年代和 70 年代，模式识别成为计算机科学、人工智能和模式识别领域的重要研究方向之一。许多基本的模式识别算法和方法也在这个时期提出和发展，如 k-最近邻算法和动态时间规整算法，为后来的人工智能发展奠定了基础。

K-最近邻（K-Nearest Neighbor, KNN）算法最初由托马斯·科弗和乔伊·哈特于 1968 年提出，是一种惰性学习方法。KNN 分类算法，是一个理论上比较成熟的方法，也是最简单的机器学习算法之一。该方法的思路是：如果一个样本在特征空间中的 k 个最相似（即特征空间中最邻近）的样本中的大多数属于某一个类别，则该样本也属于这个类别。KNN 算法中，所选择的邻居都是已经正确分类的对象。该方法在分类决策上只依据最邻近的一个或者几个样本的类别来决定待分样本所属的类别。KNN 方法虽然从原理上也依赖于极限定理，但在分类决策时，只与极少量的相邻样本有关。由于 KNN 方法主要靠周围有限的邻近的样本，而不是靠判别类域的方法来确定所属类别的，因此对于类域的交叉或重叠较多的待分样本集来说，KNN 方法较其他方法更为适合。

动态时间规整算法（Dynamic Time Warping, DTW）是一种用于序列匹配和模式识别的重要方法。它最早由日本学者板仓于 1975 年提出，用于解决语音信号之间的时间拉伸和压缩问题。在提出之初，DTW 主要用于语音信号的时间对齐，它通过动态规划的方式寻找两个时间序列之间的最优匹配路径，使得序列之间的相似性得到最大化。随着研究的深入，DTW 算法得到了扩展和改进。研究人员将其应用于手写体识别、行为识别、生物信息学等领域，取得了显著的成果。受益于计算机硬件性能的提升和算法的不断优化，DTW 算法的应用范围不断扩大，成为序列匹配和模式识别领域的重要工具。它不仅在

学术研究中得到广泛应用，还被应用于工业控制、医学诊断、音乐检索等实际应用中。随着人工智能技术的不断发展，DTW 算法将继续发挥重要作用，并为更广泛的领域提供解决方案。

1.2.4 人机对话

人机对话（Human-Computer Dialogue）成为人工智能领域的重要探索之一。人机对话是一种让机器能够理解和运用自然语言与人进行通信的技术，是实现人工智能与人类自然交流的关键。早期的人机对话主要集中在基于规则的问答系统。其中最著名的项目之一是由约瑟夫·魏泽恩鲍姆于 1966 年开发的 ELIZA。

ELIZA 的设计灵感来自心理治疗师的角色，它通过简单的模式匹配和替换，回应用户的输入。尽管 ELIZA 并没有真正的理解能力，但这种模拟人类对话的能力在当时引起了公众的极大关注。ELIZA 能够以一种类似心理治疗师的方式与用户进行对话，回应他们的问题并提出追问，使得用户产生了一种在与真实人类对话的错觉。当用户输入类似“我感到难过”时，ELIZA 会回复类似“你为什么感到难过？”的问题，从而引导用户进一步表达自己的情感。

除了 ELIZA，还有一些其他早期的人机对话系统。例如，1968 年，特里·维诺格拉德开发的 SHRDLU 让机器人在虚拟的方块世界中移动积木块，用户可以通过指令让机器人进行相应操作。另外，1971 年出现的名为 PARRY 的聊天机器人被设定成一个患有精神分裂症的患者，拥有自己的情感状态。虽然这些系统都有一定的局限性，但它们为后来更先进的自然语言处理研究奠定了基础。

在当时的技术条件下，这些早期的人机对话系统已经展现了计算机在语言理解和对话方面的潜力。虽然它们与当今的智能对话系统相比还显得简单，但它们为人工智能的发展提供了宝贵的经验和启示。随着技术的不断进步，人机对话的研究也在不断深入，如今的智能对话系统已经可以实现更加智能化和自然的对话交互。

1.2.5 知识表示

在 20 世纪 60-70 年代，科学家们开始研究如何有效地储存和组织知识，以使计算机能够学习和推理，从而衍生出知识表示的研究。这个研究涉及认知科学和人工智能领域，并且是这两个领域共同存在的一个挑战。在认知科学中，知识表示涉及人类如何存储和处理信息。而在人工智能领域，知识表示的主要目标是将知识储存起来，使得程序能够处理并表现出类似人类智慧的行为。然而，目前知识表示领域仍然没有一个完美的解决方案。

阿兰·科尔梅劳尔等人在 1969 年提出的 Prolog 编程语言是一种基于逻辑的语言，它使用谓词逻辑来表示事实和规则，使得计算机能够通过推理来解决问题。Prolog 在人工智能领域推动了逻辑编程的发展，并为知识表示的研究提供了重要的思路。在 Prolog 中，知识被以“事实-规则”的形式来表达。例如，我们可以定义“鸟类是有羽毛的”、“企鹅是一种鸟类”等事实，以及“如果动物有羽毛并且不能飞，那么它是一只企鹅”等规则。计算机可以通过对这些事实和规则进行逻辑推理，来回答问题和解决问题。同一时期，用于知识表示学习的框架理论不断提出，马文·明斯基等学者在知识表示领域进行深入研究。

尽管在那个时期，知识表示和神经网络的发展还受到一些限制，但这些里程碑事件为人工智能的未来发展奠定了基础，并为后来在知识表示和神经网络研究领域取得巨大进展打下了基础。如今，随着计算机技术的飞速发展，人工智能在知识表示和神经网络方面取得了显著进步，这使得人工智能的应用变得更加广泛和普遍。

1.2.6 计算机视觉

在 20 世纪 60-70 年代，计算机视觉 (Computer Vision) 也成为人工智能研究的重要方向之一。然而，由于当时计算机性能和图像处理算法的限制，计算机视觉的研究进展缓慢。当时，早期的计算机视觉

项目如“Blocks World”和“夏季视觉项目”等，试图在虚拟方块世界中进行物体识别和视觉系统的构建。虽然存在许多问题，但这些项目为后来的计算机视觉研究奠定了基础。

另一个重要进展是大卫·马尔于1970年提出的“计算视觉理论”。这一理论将视觉系统分为三个层次：原始视觉表示、2.5D表面表示和3D对象表示。在原始视觉表示阶段，视觉系统通过感知图像中的基本特征，如边缘和角点，来构建简单的图像表示。在2.5D表面表示阶段，视觉系统对图像进行更深层次的分析，形成物体的表面和深度信息。最后，在3D对象表示阶段，视觉系统通过整合多个2.5D表面信息，得出对物体的整体认知。这一理论为后来的计算机视觉算法的发展提供了理论基础，使得计算机在理解和处理图像方面取得了巨大进步。

综上所述，20世纪60-70年代是人工智能领域取得重要突破的关键时期。感知机、贝叶斯网络、模式识别、人机对话、知识表示和计算机视觉等成为该时期的研究重点，为后来人工智能的发展奠定了坚实基础。虽然当时的技术条件受到限制，但这些里程碑事件为今天的智能对话系统、知识图谱和计算机视觉等技术的成熟提供了重要经验和启示。

1.3 人工智能的冬天

20世纪60年代的人工智能繁荣期表现为人工智能研究和应用的大爆发，但之后随之而来的寒冬发生在20世纪80年代。这主要是因为人工智能繁荣期开展的许多项目未能兑现承诺，人工智能研究者对该领域的进展感到越来越失望。这导致了资金削减，许多人工智能研究者被迫放弃项目，甚至离开该领域。根据英国科学研究委员会的莱特希尔报告，人工智能并未实现当初的宏伟目标，在其各个领域中的发现都跟当时所设想的相差甚远。这导致了正在进行的人工智能项目数量显著减少，许多仍在进行的研究项目由于缺乏资源而无法取得

重大进展。

造成该年代人工智能寒冬的主要原因如下：

(1) 技术局限。1) 知识表示问题。早期的人工智能系统使用符号逻辑来表示知识，但这种方法在处理不确定性和模糊性方面存在困难，导致系统表现不稳定。2) 计算能力不足。人工智能研究需要大量的计算资源，然而当时的计算机性能相对较低，这限制了复杂算法和模型的实现。3) 数据稀缺。人工智能需要大量的数据来进行学习和训练，但在 80 年代，获取和存储数据的成本非常高，这导致数据集的规模有限。4) 缺乏有效应用。尽管人工智能技术在研究领域取得了一些成果，但其在实际应用中仍受限，即无法解决真实世界中的复杂问题，这使得资金支持受到影响。

(2) 公众预期落空。在 60 年代和 70 年代，人工智能在公众和媒体中被高度宣传，许多人对未来人工智能的前景充满期待。然而，当 80 年代初的人工智能系统无法达到公众预期的智能水平时，公众和投资者的热情开始降温。

(3) 政府和企业投资削减。由于人工智能技术进展缓慢，政府和企业逐渐减少了对其研究的资金投入。之前的投资者和政策制定者开始对人工智能的前景感到怀疑，他们认为人工智能的发展可能需要更长时间，需要更多的投资和耐心。

(4) 专家系统局限。人工智能早期的主要研究方向之一是专家系统，然而这些系统在实际应用中也受到局限。虽然他们在某些特定领域取得了一定成功，但这其知识表示和推理能力有限，无法解决更加复杂和泛化的问题。

(5) 商业化挑战。80 年代初的人工智能技术商业化困难。许多潜在的应用领域并未准备好采用人工智能技术，导致了商业投资的不足。

综上所述，20 世纪 80 年代人工智能领域资金短缺的问题主要是

由技术局限、公众预期落空、政府和企业投资削减、专家系统局限以及商业化挑战等因素共同造成的结果。尽管人工智能面临挑战，但该领域并未完全消失。一些研究者在此期间继续致力于人工智能项目，并取得了重要进展。

20 世纪 80 年代的人工智能发展大致如下：

1980 年：WABOT-2 在早稻田大学建成。WABOT 的出现使得这个个人形机器人能够与人们进行交流，阅读乐谱，并在电子风琴上演奏音乐。

1982 年：日本国际贸易产业省拨款 8.5 亿美元用于“第五代计算机”项目，该项目旨在开发可以交谈、翻译语言、解释图片并表现出类似人类推理的计算机。

1984 年：史蒂夫·巴伦执导的电影《电子情缘》上映。情节围绕着一个男人、女人和一个名为“Edgar”的有感知能力的个人电脑之间的爱情三角关系展开。

1984 年：在人工智能协会上，人工智能理论家罗杰·尚克和认知科学家马文·明斯基警告了人工智能寒冬，这是人工智能研究的兴趣和资金会减少的第一个实例。他们的警告在三年内成为现实。

1986 年：梅赛德斯-奔驰在恩斯特·迪克曼斯的指导下建造并发布了一辆配备摄像头和传感器的无人驾驶货车。它能够在没有其他障碍物和人类驾驶员的道路上以每小时 55 英里的速度行驶。

1988 年：计算机科学家和哲学家朱迪亚·珀尔出版了《智能系统中的概率推理》。珀尔还因发明贝叶斯网络而受到赞誉，这是一种“概率图模型”，通过有向无环图表示一组变量及其依赖关系。

1988 年：程序员和两个聊天机器人 Jabberwacky 和 Cleverbot（于 1990 年代发布）的发明者罗洛·卡彭特，开发了 Jabberwacky 以“以有趣、娱乐和幽默的方式模拟自然人类聊天”。这是一个通过聊天机器人与人们进行交流的人工智能的例子。

总的来说，20 世纪 80 年代的人工智能寒冬是人工智能发展史上的一个重要里程碑，它展示了人工智能研究和发展的挑战和局限性。它也成为投资者和政策制定者的一则警示故事，让他们认识到围绕人工智能的炒作有时可能夸大其辞，而该领域的进展需要持续的投资和承诺。

1.4 人工智能的复兴期

20 世纪 80 年代，由于计算能力和数据量的限制，人工智能技术陷入了低谷。但随着计算机硬件的发展和算法的改进，人工智能开始走出低谷，进入复兴期。在此阶段，人工智能在机器学习、自然语言处理、神经网络、遗传算法和超级计算机等领域有了显著的进步。

1.4.1 机器学习

机器学习是人工智能的核心技术之一，其目标是使计算机系统能够通过数据来学习和改善性能。在复兴期，许多经典的机器学习算法如支持向量机（Support Vector Machine, SVM）、条件随机场（Conditional Random Field, CRF）、Boosting 算法等被提出并广泛应用。

- 支持向量机

SVM 通过构建一个最大间隔的超平面，使得数据点离超平面的距离最大化，从而实现分类或回归任务。在发展初期，SVM 主要应用于二分类问题。后来，研究者们对 SVM 进行了扩展，使其可以用于多分类和回归问题。SVM 的发展得益于统计学和优化理论的进展，特别是核函数的引入，使得 SVM 能够处理复杂的非线性问题。由于 SVM 具有较好的特征选择能力和较高的准确性，其能够处理高维稀疏的文本特征，可有效地对文本进行分类和标注，因此被广泛应用于文本分类、情感分析、命名实体识别等任务。此外，SVM 能够通过训练样本学习到分离不同类别的超平面，从而能够对新的图像进行分类和识别，因此 SVM 也常被用于图像分类、目标检测、人脸识别等

任务。

- 条件随机场

CRF 是一种用于序列标注和结构化预测的概率图模型，它能够对标记序列的依赖关系进行建模，它可以考虑上下文信息，并通过学习训练数据中的相关特征来预测给定输入序列的标记。其最早由拉弗蒂等人提出。CRF 的缺点主要是收敛速度慢，训练时间长，模型复杂度高。但 CRF 可以自然地将上下文标记间的联系纳入模型的考虑中，从而灵活地设计特征，因而它也是自然语言处理领域最常用也是表现最好的模型之一。在实际应用中，CRF 主要用于序列标注问题，如命名实体识别、词性标注、句法分析等，相比于其他统计模型，它能够更好地利用上下文信息，提高标注的准确性。

- Boosting 算法

Boosting 是一种集成学习方法，其目标是通过组合多个弱学习器来构建一个强大的学习器。罗伯特·夏柏尔于 1990 年提出最初的 Boosting 算法。但该算法需要知道一些实践中难以事先得知的信息，这导致其仅具备理论意义。在此基础上，罗伯特·夏柏尔和约夫·弗洛恩德于 1996 年提出改进算法 AdaBoost(Adaptive Boosting)。AdaBoost 是 Boosting 算法的先驱，它通过调整每个样本的权重来逐步增强弱分类器的表现。其仅需 10 行代码但却十分有效，并且经修改推广能应用于诸多类型的任务。杰罗姆·弗里德曼于 1999 年提出了 GBM (Gradient Boosting Machines) 算法，它是一种梯度提升算法，通过最小化损失函数的负梯度来训练新的分类器，进一步优化预测结果。相较于 AdaBoost，GBM 能够处理更一般化的损失函数，从而更好地拟合复杂的数据集。GBM 与 AdaBoost 一样均为现代 Boosting 算法的基础。

它们的提出和广泛应用促进了机器学习算法的发展，并为后续的深度学习和神经网络等技术的兴起提供了重要的思路和方法。此外，

SVM, CRF 和 Boosting 的成功应用也使得人们对于模型的可解释性的重要性有了更深入的认识, 为后续的研究提供了启示。

1.4.2 自然语言处理

随着计算机运算能力的提高以及大型数据库的建立, 自然语言处理领域经历了一些重要的发展, 研究人员提出了高效的文本表示方法, 并开始借助大数据的力量, 开发了一系列新的工具和技术来建立统计模型。这些模型使用机器学习算法来分析文本, 并且通过对大规模数据集的学习来不断提高正确性和鲁棒性。其中的代表性算法为词袋模型 (Bag of Words, BAG)。

1990 年代初期, 普林斯顿大学开展了一个名为 WordNet 的项目, 建立了一个大规模的英语词汇数据库。WordNet 将单词组织成义项集, 描述了单词之间的语义关系, 为语义分析和词义消歧等任务提供了重要的资源。

在文本表示任务中, 词袋模型是自然语言处理领域中一种常用的文本表示方法。它将一个文本看作一个由单词组成的集合, 忽略单词之间的顺序和语法结构, 仅统计每个单词在文本中出现的频率或存在与否。具体来说, 词袋模型将文本转化为一个向量, 向量的每个维度对应一个单词, 值表示该单词在文本中的出现次数或存在与否。词袋模型在文本分类、情感分析、文本生成等任务中, 可以作为输入特征, 帮助机器学习算法理解和处理文本数据。

词袋模型为信息检索和搜索引擎的发展提供了基础。通过将查询文本和文档表示为词袋模型, 可以计算它们之间的相似度, 并实现相关性排序, 从而提高搜索结果的准确性和效率。总的来说, 词袋模型的发展奠定了自然语言处理和人工智能领域的基础, 为后续技术的爆发提供了重要的支持和启发。它简单而有效的表示方式, 为文本处理和信息检索提供了基本工具和思路。同时, 其发展也促进了对文本特征提取和表示方法的深入研究, 推动了自然语言处理技术的发展和创

新。

1.4.3 神经网络

塞普·霍克赖特和尤尔根·施密特胡伯于 1997 年提出长短期记忆网络 (Long Short-Term Memory, LSTM)，它是一种重要的循环神经网络 (Recurrent Neural Network, RNN) 架构，专门用于处理序列数据，如文本、语音、时间序列等。设计 LSTM 的目的是解决传统 RNN 在处理长序列数据时容易出现的梯度消失和梯度爆炸问题，从而能够更好地捕捉长期依赖关系。

LSTM 的核心思想是引入了一种称为“记忆单元”的结构，记忆单元可以在长期时间跨度内保留信息，从而实现对长期依赖的建模。记忆单元由一个单元状态和三个门控（输入门、遗忘门和输出门）组成，它们协同工作来控制信息的输入和输出。单元状态是 LSTM 的关键组成部分，用于保存序列中的信息，它允许 LSTM 有效地保持长期以来关系，从而避免了传统 RNN 中的梯度消失问题。在门控中，输入门决定哪些新输入的信息需要被更新到单元状态中，它通过 Sigmoid 激活函数来生成一个在 0-1 之间的值，表示要更新的程度。遗忘门控制单元状态中哪些信息需要被遗忘，通过 Sigmoid 激活函数生成一个 0 到 1 之间的值来表示要保留的信息量。输出门决定从当前单元状态中输出哪些信息，控制信息在 LSTM 中的流动。

LSTM 的灵活性和能力使其在自然语言处理、语音识别、机器翻译和时间序列预测等任务中取得了重要的成就。尽管后来出现了更复杂的模型如 Transformer，但 LSTM 作为序列建模的基础和重要工具，在研究和实践中仍然具有重要地位。

1.4.4 遗传算法

遗传算法 (Genetic Algorithms, GA) 是一种演化计算技术，其灵感来源于生物学中的遗传和进化过程。遗传算法通过模拟生物进化机制来搜索最优解，逐代优化种群中的个体，并通过遗传操作（选择、

交叉和变异)来产生新的解。进入 1990 年代后,遗传算法不仅应用领域有所扩大,且利用遗传算法进行优化和规则学习的能力也显著提高。新的理论和方法在应用研究中的迅速发展也为遗传算法增添了新的活力。

其重要发展可列为:

(1)遗传算法与其他算法的界限逐渐模糊,正日益与神经网络、模糊推理等其他智能计算方法相互渗透结合,这对 21 世纪新的智能计算技术发展有重要的意义。

(2)并行处理的遗传算法的研究十分活跃,已经渗透到了新一代智能计算机体系的结构组成中,并成为重要一环。

(3)遗传算法正与人工生命的新型研究领域相结合。生物的自适应、进化和免疫等现象是人工生命的重要研究对象,遗传算法在其中可发挥一定作用。

(4)遗传算法和进化计算理论日益结合。进化计算理论同遗传算法一样,也是模拟自然界生物进化机制的智能计算方法,有相同之处,也有各自的特点,将两者结合成为当时热点。

1.4.5 深蓝超级计算机

1997 年,人工智能领域发生了一件里程碑事件:美国 IBM 技术人员研制的“深蓝”超级计算机在常规时间控制下以 3.5:2.5 (2 胜 1 负 3 平)战胜了当时世界排名第一的职业国际象棋棋王-卡斯帕罗夫。这也是历史上第一个成功在标准国际象棋比赛中打败世界冠军的计算机系统,在当时引发了不小的轰动和人们对机器与人工智能快速发展的焦虑。

尽管深蓝并没有使用传统意义上的人工智能技术,例如机器学习或神经网络,但它仍然采用了一些高级算法和专家系统来支持其下棋决策。深蓝的设计依赖于基于规则的推理系统,它使用了大量的开局库、图书馆和搜索算法来评估每一种可能的棋局,并通过搜索算法在

数十亿个可能的走法中找到最佳的下一步。此外，深蓝还利用了并行计算的能力，通过多个处理单元同步计算以提高计算速度和效率。这种并行计算技术在当时来说是非常先进的，为深蓝在短时间内进行大规模计算提供了支持。

深蓝的胜利对后续人工智能技术的发展产生了重要影响，其主要表现在三个方面：

(1) 提高了人们对计算机在复杂任务上的实力认识。深蓝战胜国际象棋世界冠军将计算机在复杂智力任务上的能力展示给了全世界，这加速了人工智能技术的研究及应用进程。

(2) 推动了搜寻算法和决策优化技术的研究。深蓝采用的搜索算法是在有限时间内评估数亿个可能走法并找到最佳决策的关键。这促使研究者在搜寻算法和决策优化领域进行更深入的研究，为其他领域的问题解决提供了启示。

(3) 推动了并行计算技术的发展。这对后续人工智能技术的发展起到了积极推动作用，尤其在大规模数据处理和复杂模型训练方面。

1.5 人工智能的爆发期

人工智能的发展在 2010 年左右进入了一个爆发期，深度学习作为人工智能最有前景的算法，得到了大规模的应用，其在机器视觉、自然语言处理、机器翻译、生物蛋白质计算等领域均取得了许多令人瞩目的成就。

1.5.1 卷积神经网络

在图像分类领域，2012 年提出的深度卷积网络 AlexNet 是对传统图像分类算法的革命，其在当年举办的 ILSVRC（基于大规模通用物体识别数据库 ImageNet 上的大规模图像识别比赛）比赛中取得了突破性成就，其将 Top5 识别错误率从 26.2% 降到了 15.3%；此后，出现了更多更深的、更优秀的深度卷积网络。

AlexNet 网络结构主要由 8 个学习层组成，含 5 个卷积层和 3 个

全连接层。5 个卷积层中每个卷积层都包含卷积核、偏置项、ReLU 激活函数和局部响应归一化模块。前两个全连接层后面都连接了 ReLU 函数、Dropout 处理，最后一个全连接层连接的是 softmax 函数进行分类。AlexNet 使用了分布式 GPU 训练，将卷积层和全连接层分别放到不同的 GPU 上进行并行计算，提高了训练速度。

继 AlexNet 之后，每年的 ILSVRC 竞赛大家几乎都使用深度卷积网络，因而诞生了更深的 ZFNet, GoogleNet, VGG 和 ResNet。在对深度学习网络的研究中，人们发现对于深度学习网络，如果只是简单地增加网络层数，训练时会出现网络退化现象，即随着网络深度的增加，训练集的训练误差会逐渐下降，然后趋于饱和，但当再增加网络层数时，网络就会迅速退化，即训练集误差增大。残差网络是解决退化问题的一个重要方法。残差网络具有良好的性能，是深度学习领域的一个重要突破，受到了学者们的广泛关注。残差网络的基本模块是残差单元，其主要由卷积层、批处理归一化层和 ReLU 激活函数堆叠而成。残差网络的标准框架为：给定输入数据，残差网络将输入数据依次输送到卷积层、ReLU 和批处理归一化层，然后将获得的结果送到多个残差单元，再将得到的结果输入到归一化层和多个全连接层，最后得到最终的输出结果。研究者们也对残差网络做出了部分改进，主要体现在残差单元和网络框架上。

1.5.2 生成对抗网络

生成对抗网络 (Generative Adversarial Net, GAN) 是重要的深度学习模型之一。GAN 包含两个模型，一个是生成模型 (generative model)，另一个是判别模型 (discriminative model)。生成模型的目标是生成看起来真实的、和原始数据接近的实例，其实质是获取真实数据的概率分布。判别模型的目标是判断给定的实例是真实的还是人为伪造的。在训练阶段，生成模型的任务就是尽量生成真实的图片去欺骗判别模型，判别模型的任务就是把生成模型生成的图片和真实的图

片分辨出来。二者通过相互对抗训练，使网络达到博弈均衡来实现更好的学习效果，即让判别模型无法准确判断输入数据是真实的还是伪造的。GAN 被广泛应用在各个领域，如图像增强、风格迁移、序列数据生成和视频生成等。GAN 目前面临的主要问题是模式崩溃，具体是由于判别器不能很好的惩罚生成器，从而使生成器在一个极小的分布区域内发生崩塌，导致了生成结果缺乏多样性。

1.5.3 变分自动编码器

杨立昆称对抗训练是“过去十年里 ML 最有趣的想法”。尽管 GAN 很有趣，也有前景，但它只是深度生成模型家族的一部分。另一个主流深度生成模型是变分自动编码器(Variational AutoEncoder, VAE)。

VAE 模型是一种包含隐变量的生成模型，其能够提供隐空间中观察结果的概率描述，它利用神经网络训练得到两个函数（也称为推断网络和生成网络），进而生成训练数据中不包含的数据。VAE 模型在生成多种复杂数据方面已经显示出了巨大的潜力，包括手写数字图像、人脸图像、门牌号图像、CIFAR 图像、场景物理模型、分割图像以及从静态图像进行预测等。VAE 模型具有连续的隐空间，这样可以使随机采样和插值更加方便。VAE 可以处理各种类型的数据，序列的或非序列的，连续的或离散的，甚至有标签的或无标签的，这使它们成为非常强大的生成工具。但是 VAE 存在一个主要缺点是它们生成的输出模糊，VAE 模型有时会产生不现实的、模糊的样本。

1.5.4 迁移学习

尽管 VAE 模型已经取得了较好的生成效果，但其作为无监督学习方法终究存在局限性，因此我们介绍一种使用较少训练数据便能进行监督学习的模型：迁移学习。由于直接对目标域从头开始学习成本太高，因此我们期望运用已有的相关知识来辅助尽快地学习新知识，也就是把现有的经验迁移过去。迁移学习是机器学习的一个分支，大多使用神经网络的方法，以训练模型为主，通常就是拿一套模型的参

数去做另一套的初始值减少模型训练的复杂度。迁移学习按照学习方式可以分为四类：

(1) 基于样本。对不同的样本给予不同的权重，样本越相似，权重越高。高权重样本优先级更高，完成迁移；

(2) 基于特征。将目标域和训练数据域映射到同一空间，最小化二者对应点的距离，完成迁移；

(3) 基于模型。把模型和样本结合起来，通过调整模型参数完成迁移；

(4) 基于关系。发掘相似场景的关系，两组中如果有一组训练数据域和目标域的关系可确定，可以迁移到另一组相似数据上。

迁移学习通常适用于下面的一些场景：

(1) 大部分数据样本是无标注的，要继续增加更多的数据标注，需要付出巨大的成本。此时，利用迁移学习思想，可以寻找一些和目标数据相似而且已经有标注的数据，利用数据之间的相似性对知识进行迁移，提高对目标数据的预测效果或者标注精度。

(2) 模型想要具有更强的泛化能力,但是数据样本较少。当前机器学习的成功应用依赖于大量有标签数据的可用性。然而，高质量有标签数据总是供不应求。传统的机器学习算法常常因为数据量小而产生过拟合问题，因而无法很好地泛化到新的场景中。

(3) 数据来自不同的分布时。传统的机器学习算法假设训练和测试数据来自相同的数据分布。然而在许多情况下，数据分布不仅会随着时间和空间而变化，也会随着不同的情况而变化，因此我们可能无法使用相同的数据分布来对待新的训练数据。在不同于训练数据的新场景下，已经训练完成的模型需要在使用前进行调整。

1.5.5 知识图谱

深度学习不仅在学界取得了长足的进步同时也在工业界得到越来越广泛的关注和更多垂直行业的场景应用，比如知识图谱和自动驾

驶领域。

什么是知识图谱，本质上，知识图谱的主要目标是描述真实世界中存在的各种实体和概念，以及他们之间的关系，因此可以认为是一种语义网络。从发展的过程来看，知识图谱是在自然语言处理的基础上发展而来的。知识图谱和自然语言处理有着紧密的联系。知识图谱与深度学习的结合可以从语义层面理解用户意图，改进搜索质量。例如，为搜索引擎提供更精准的搜索结果：知识图谱可以建立实体之间的关系，对于搜索词语，通过关联实体，可以为搜索引擎提供更准确、更丰富的搜索结果，帮助用户更快速地找到所需信息。知识图谱可以帮助问答系统进行自然语言理解，对用户的提问进行深入分析，从而抽取其中的实体、属性、关系等信息。这种语义理解可以让问答系统更好地理解用户的意图，从而给出更加准确的答案。

1.5.6 自动驾驶

自动驾驶技术的进步，主要得益于深度学习和人工智能的进步。在自动驾驶开发中，深度学习可以用于实现车辆的感知、决策和控制等功能。

在使用深度学习进行自动驾驶开发时，需要使用大量标注的图像和视频数据来训练神经网络模型。这些模型可以实现车辆的视觉感知功能，例如识别道路、车辆、行人和障碍物等。此外，深度学习还可以用于实现车辆的决策和控制功能，例如预测车辆的行驶路径、速度和方向等。

在地图构建和定位中：深度学习可以帮助自动驾驶车辆进行高精度地图构建和实时定位，从而支持自动驾驶车辆的路径规划和决策。在这种应用中，输入可能是车辆的传感器数据，如摄像头、激光雷达和 GPS 等，输出可能是车辆在地图上的精确位置、速度和方向等信息。

在行为规划和决策中：深度学习可以帮助自动驾驶车辆进行行为

规划和决策，从而实现对车辆的控制和驾驶。在这种应用中，输入可能是车辆的传感器数据和地图信息，输出可能是车辆的转向、制动、加速和路径选择等控制信号。

在驾驶员状态检测中：深度学习可以帮助自动驾驶车辆检测驾驶员的状态，如疲劳、分神和情绪等，从而提高驾驶员的安全性和舒适性。在这种应用中，输入可能是车内的摄像头和传感器数据，输出可能是驾驶员的情绪和注意力等状态信息。

1.5.7 AlphaGO

随着算力、算法和数据的发展，AlphaGO、AlphaFold 和 ChatGPT 等大模型的横空出世和应用给人工智能带来了新的繁荣。

AlphaGo 是 DeepMind 公司开发的计算机围棋程序。围棋作为一种复杂的策略游戏，过去一直被认为是人工智能领域的挑战之一，因为其庞大的状态空间和难以预测的走棋可能性。然而，AlphaGo 采用了神经网络和蒙特卡洛树搜索等先进技术，成功解决了这一难题。2016年3月，AlphaGo 与韩国围棋冠军李世石进行了一系列五局比赛，结果 AlphaGo 以 4:1 的成绩取得了胜利。这是人工智能历史上的一次里程碑，也是计算机在围棋对弈上首次战胜顶级人类选手。AlphaGo 的成功激发了人工智能领域的研究和发展，它证明了深度强化学习在复杂游戏中的潜力，为其他领域的 AI 应用提供了启示。人工智能在游戏中的成功也为人们展示了 AI 在真实世界问题中的应用前景。

AlphaGo 的胜利引起了讨论人机合作的重要性。与传统意义上的人机竞赛不同，AlphaGo 向世界展示了 AI 与人类棋手相互协作的可能性，使得 AI 在许多领域发挥辅助作用，而不是取代人类。总体来说，AlphaGo 的起源和发展标志着人工智能领域的一次重大突破。它的成功在围棋领域产生了深远的影响，并且激发了更多对于人工智能和深度学习的研究和探索。同时，AlphaGo 的胜利也为人们揭示了人工智能在解决复杂问题和推动科技进步中的巨大潜力。

1.5.8 AlphaFold

AlphaFold 是由 DeepMind 开发的蛋白质结构预测系统。它的起源可以追溯到 2016 年,当时 DeepMind 的团队成功开发了 AlphaGo,一款在围棋领域取得显著成就的人工智能程序。受 AlphaGo 的启发,DeepMind 决定将类似的技术应用于解决蛋白质结构预测的挑战。经过多年的研究和开发,DeepMind 在 2020 年推出了 AlphaFold 2.0 版本,这是一个基于深度学习和神经网络的蛋白质折叠预测系统。AlphaFold 的发展经历了多个版本迭代,通过不断改进算法和模型,最终取得了卓越的预测性能。

AlphaFold 的成功对科学和医学领域的影响有以下几个方面:(1) 加速蛋白质研究。AlphaFold 的高准确性使得科学家能够更快速地预测和分析蛋白质的结构和功能,加速了蛋白质学研究的进展。(2) 推动药物研发。蛋白质结构预测对于药物研发至关重要。AlphaFold 的准确预测能力为药物设计提供了更多的目标蛋白质结构,帮助科学家开发更有效的药物。(3) 解决蛋白质结构空缺问题。在过去,蛋白质结构的实验测定速度较慢,导致蛋白质结构库中存在大量空缺。AlphaFold 的出现弥补了这一缺失,为科学家提供了更全面的蛋白质结构信息。(4) 启发更多 AI 在生物学中的应用。AlphaFold 的成功证明了深度学习和神经网络在生物学领域的潜力,为更多 AI 技术在生物学研究中的应用提供了动力。

总的来说,AlphaFold 的起源、发展和应用对蛋白质学和生物学领域产生了巨大的影响。它为蛋白质结构预测带来了突破性的进展,为科学家提供了强大的工具,加速了蛋白质研究和药物研发的进程。

1.5.9 ChatGPT

ChatGPT 是由 OpenAI (人工智能研究实验室) 开发的自然语言处理模型。它基于 GPT (Generative Pre-trained Transformer) 架构,是一种基于 Transformer 的大规模预训练语言模型。GPT 系列起源于

GPT-1，后来发展为 GPT-2 和 GPT-3，而 ChatGPT 则是 GPT-3 的特定应用版本，专注于对话式交互。GPT-3 是 ChatGPT 的基础，它在训练过程中使用了大规模的互联网文本数据集。通过预训练大量的语言模型，GPT-3 能够学习到丰富的语言知识和语义理解。随后，OpenAI 对 GPT-3 进行了微调和优化，将其打造成适用于对话式交互的 ChatGPT。

ChatGPT 被设计为一个开放式对话系统，可以与用户进行自然而流畅的交流。它在多个应用领域展现了广泛的用途，包括：（1）问题解答和信息检索。ChatGPT 可以回答用户的问题，提供实时信息检索，并为用户提供准确的答案。（2）编程辅助。ChatGPT 可以为程序员提供代码提示、语法建议和解决问题的方法。（3）写作和创意。ChatGPT 可以帮助创作者生成文本内容，包括文章、故事、诗歌等。（4）教育和学习。ChatGPT 可以作为在线学习平台，为学生提供解答和辅导。（5）自然语言理解。ChatGPT 有助于自然语言处理任务，如文本分类、情感分析等。

ChatGPT 的出现在自然语言处理领域产生了巨大的影响。ChatGPT 开创了更自然、更流畅的人机交互方式，使得人工智能系统能够更加贴近人类的语言表达和需求。ChatGPT 可以根据用户的交互和反馈进行个性化的学习和适应，提供更具个性化的服务。ChatGPT 的广泛应用拓展了人工智能在各个领域的应用可能性，为企业、教育、媒体等领域提供了更多的创新解决方案。ChatGPT 推动了自然语言理解和生成领域的研究，为自然语言处理技术的进步和发展提供了重要动力。

尽管 ChatGPT 在许多方面取得了显著进展，但仍然存在挑战，如确保准确性、避免偏见和不当内容等。然而，随着技术的不断改进和优化，ChatGPT 将继续为人工智能领域的发展带来新的契机与可能性。

1.6 人工智能的未来

随着对人类意识和思维信息过程模拟的不断深入，人工智能在各个领域日益受到关注，并逐渐应用于机器人、医疗、制造、环保、网络建设等行业。人工智能的吸引力和颠覆性使其成为几乎每个行业的研究趋势。此外，随着科学技术的不断发展，人工智能的应用将不断出现在人们日常生活中越来越多的方面。经调研，人工智能的未来发展有以下趋势。

1.6.1 可信人工智能

可信人工智能指确保人工智能技术在安全、隐私、公平和可解释性方面做到可信赖的能力，其目标是让人类能够信任、理解和控制人工智能系统，从而提高人工智能的社会效益和道德责任。然而，可信人工智能面临几个主要的技术风险：（1）安全风险。深度学习算法的设计漏洞和恶意攻击可能导致人工智能系统失效或被篡改，影响其可靠性和稳定性。（2）隐私风险。训练数据的收集、使用和共享可能侵犯和滥用个人隐私。（3）公平风险。数据中存在的偏见和歧视可能被算法进一步固化或放大，导致智能决策出现偏差或歧视。（4）可解释风险。算法的复杂性和不确定性以及模型运行的自主性可能导致人工智能系统出现“黑箱”问题。通过不断改进算法设计、加强安全措施、采用隐私保护技术、消除数据偏见以及提高模型的可解释性，可以逐步实现可信人工智能的目标。

1.6.2 多模态预训练模型

多模态预训练模型代表着人工智能从单一模态智能向多模态融合的通用智能发展的进程，其目标在于增强模型的通用人工智能能力，消除各模态之间的信息障碍，逐步规范模型的行为和逻辑。目前，CLIP和BEiT等项目在多模态预训练模型技术上取得了显著进展。通过结合多领域知识，构建统一、跨场景、多任务多模态的基础模型已成为人工智能的重要发展方向。大模型将成为未来的基础设施，实现对图

像、文本和音频的统一知识表示，从而实现具备推理、回答问题、总结和创造能力的认知智能的进化。

1.6.3 多任务模型

通常，人工智能模型被赋予特定目标，但仅考虑单一目标可能导致次优的结果。多任务模型可以同时处理多个不同领域和任务，例如图像检索、目标检测、视觉问答、自然语言理解等。多任务模型的优势在于充分利用不同任务之间的相关性和互补性，提高模型的泛化能力和效率，同时减少参数数量和计算资源的消耗，实现更通用和灵活的人工智能应用。多任务大模型能更好地模拟人类的认知过程，实现跨领域和跨模态的知识融合和迁移。此外，它还为复杂和开放的场景，如自动驾驶、机器人、智能医疗等，提供更强大的感知和理解能力。通过统一的架构和参数处理各种不同的输入和输出，多任务模型还能简化人工智能系统的设计和部署。

1.6.4 基于人工智能的网络安全

人工智能和机器学习技术在检测和应对网络安全威胁方面扮演着日益关键的角色。在企业网络安全架构中应用人工智能不仅提高了效率和数据防御准确性，还为网络攻击提供了改进手段。自动化恶意软件广泛应用，特别是对物联网设备构成的威胁不断增长。物联网设备缺乏安全考虑，用户也很少关注其安全性，使其成为攻击首选目标。在网络安全防御方面，自动化可以节省网络安全团队的时间和成本。团队面临频繁事件、内部威胁和设备管理挑战，许多日常任务需要自动化处理，以便更好地应对关键任务。通过自动化这些常规任务，不仅释放人力资源，还能在更短时间内获得更准确的结果。

1.6.5 边缘计算和联合学习

边缘计算是未来人工智能发展的一大趋势。它将智能计算和数据处理能力推向网络边缘，接近数据源和设备。这意味着在边缘设备上可以实现更实时的智能决策和推理，而不需要依赖云端服务。边缘计

算的优势在于它带来了更低的延迟和更高的隐私保护，对于一些对实时性要求高、数据敏感的场景（如自动驾驶车辆、智能家居等）尤为重要。此外，联合学习作为一种新兴的合作学习模式，将多个设备或数据持有者联合起来，实现在本地端点上共同学习和优化模型，而不是将数据集中在一个地方。联合学习不仅保护了数据隐私，还能提高学习效率和模型的泛化能力。它在医疗领域、物联网环境下的智能决策等场景中具有巨大潜力，为人工智能的发展带来新的可能性。

1.6.6 人机协作与交互

未来的人工智能系统将更多地与人类实现紧密协作。人机协作是通过增强学习和自适应算法实现的，使机器能够从人类的反馈和指导中不断学习，并优化其行为。这种紧密的协作关系将有助于提高人工智能系统的个性化服务和用户体验，使其更好地适应不同用户的需求。同时，智能助理将成为未来人类日常生活中的重要伙伴。通过自然语言处理和人机交互技术，智能助理能够更好地理解用户意图，并为用户提供个性化的信息和建议。智能助理已经广泛被应用于智能手机、智能音箱等设备中，未来将进一步融入各个领域，如医疗保健、教育、金融等，为人类提供更智能化、便捷的服务体验。

1.6.7 从大数据转向多样化小数据

人工智能和机器学习模型在训练和优化过程中需要大量数据，然而突发事件可能导致历史数据的过时和不可靠。为了更有效地利用可用数据，多样化小数据成为了一种重要方法。即在小数据场景中，采用合成数据、少样本学习或自监督学习等技术，用较少的数据获取相应的知识。多样化数据分析和协同利用各种小型和大型、非结构化和结构化数据源，包括文本、图像、视频、音频、语音等，并寻找不同数据模态之间的关联性和多样性。这两种方法都减少了对大数据的依赖，提高了信息利用率和语义理解能力。它们可应用于多个领域，例如需求预测、安全检测、自适应自主系统等。这种以小数据为基础的

多样化方法，将在未来的人工智能发展中扮演着重要的角色，为数据不足或不完整的场景提供了更具有实际应用价值的解决方案。

1.6.8 人工智能伦理

随着人工智能技术的广泛应用，人工智能伦理和社会影响问题日益凸显。在发展人工智能的同时，我们必须重视伦理层面的考量。其中包括如何确保人工智能系统的决策是公正和无偏的，如何保护用户隐私和数据安全，以及如何确保人工智能在应用中不造成负面影响。未来，人工智能伦理的研究和实践将成为人工智能发展的重要一环，确保人工智能技术的应用更加合理和负责。同时，人工智能的广泛应用将对社会产生深远影响。包括就业市场、经济结构、教育体系、医疗保健等方面都需要积极探索如何应对相关的挑战和变革，最大程度地利用人工智能技术带来的潜在好处。

1.6.9 人工智能平台的操作化

人工智能平台的操作化对于推动业务转型显得紧迫而重要，因为它能够将人工智能项目从概念转化为生产，使企业能够依赖人工智能解决方案来解决各种问题。研究表明，只有一半的人工智能项目能够成功地从试点阶段进入生产阶段，而且这些成功进入生产的项目平均需要长达九个月的时间。然而，创新的人工智能编排和自动化平台以及模型操作化技术，提高了人工智能解决方案的可重用性、可扩展性和治理性，从而加速了人工智能的采用和增长。这些操作化的工具和平台使得企业能够更加高效地部署和管理人工智能项目，使其能够更快地在实际业务中产生价值，实现业务转型的目标。

第 2 章 深度学习模型

目前，深度学习作为人工智能的主流技术，在图像、视频、文本等高维数据相关的任务中取得了巨大的成果。本章首先介绍深度学习中的两类主要的网络结构卷积神经网络和递归神经网络，简要介绍了多种经典的网络结构；然后，通过阐明深度学习网络与人类视觉感知特性之间的联系，论述了注意力机制与 U 型网络结合，能够使深度学习网络更有效地模仿人类视觉感知特性。

2.1 卷积神经网络

卷积神经网络 (Convolutional Neural Networks, CNN) 是一类包含卷积计算且具有深度结构的前馈神经网络，是深度学习的代表算法之一。近年来，CNN 在计算机视觉任务中取得了巨大的成功，如图像分类、目标检测、图像分割等。例如，2012 年提出的 AlexNet 在当年的 ILSVRC (ImageNet Large-Scale Visual Recognition Challenge) 竞赛中获得冠军，开启了研究神经网络的热潮。随后来出现了众多性能更好的网络模型，例如 VGGNet、ResNet 等。一个卷积神经网络最基本的结构包含卷积层 (Convolution)、激活函数 (Active Function)、池化层 (Pooling)、全连接层 (Fully Connected)、输出层 (Output)。

图 2-1 展示了 CNN 的基本结构。将图像作为输入，首先经过卷积层，在卷积层中包含了用于提取特定特征的卷积核；之后经过激活函数，激活函数是用来加入非线性因素，提高网络表达能力，卷积神经网络中最常用的是 ReLU，Sigmoid 使用较少，因为 Sigmoid 会出现梯度消失的问题；池化层的作用在于降低网络模型中的参数量，从而遏制过拟合，并且能够提高网络对输入图像的移动、变形、扭曲的处理能力；全连接层的作用在于对卷积层和池化层输出的特征图（二维）进行降维，将学到的特征表示映射到样本标记空间；对于不同的问题，输出会使用不同的函数，softmax 函数用于分类问题，线性函数用于回归问题。




图 2-1 CNN 的基本结构

2.1.1 卷积层

在计算机视觉任务中，卷积神经网络之所以能够展现出如此优异的性能，主要归功于卷积神经网络中的卷积层。卷积层具有强大的特征提取能力，通过从输入图像中捕获的特征信息进而识别图像中的内容。输入图像的空间结构具有高度（Height, H）、宽度（Width, W）、通道数（Chanel, C）三个维度。特征提取是通过卷积层中的卷积核（滤波器）实现的，这些卷积核在高度和宽度维度上都远小于输入图像，但是在通道维度上与输入图像相同。特征提取的过程是通过卷积核在输入图像上滑动并做卷积运算完成的。因此，卷积层具有“参数共享”的特性，可以降低参数量，从而防止因参数过多引起过拟合，也减少了计算开销。

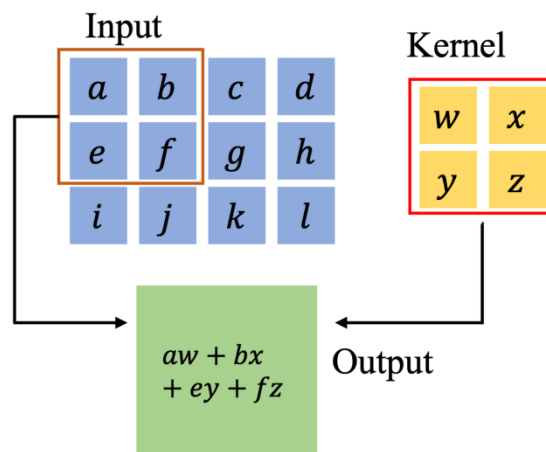


图 2-2 卷积过程

卷积运算如公式 2.1 所示。卷积核在输入图像上滑动所移动的像素数称为步长 (Stride)。卷积过程如图 2-2 所示。卷积依据卷积核开始做卷积运算时与输入图像重合的位置可分为三种模式, 分别是 Full、Same、Valid。Full 模式表示卷积核与输入图像刚重合时开始做卷积运算; Same 模式表示卷积核的中心与输入图像的边角重合时开始做卷积运算; Valid 模式表示卷积核与输入图像全部重合时开始做卷积运算。三种卷积模式如图 2-3 所示。因为卷积神经网络是一个深层结构, 输入图像边缘的信息在经过多层卷积后可能会丢失。所以在卷积前对输入图像进行数据填充 (Padding) 以防止边缘信息丢失。常见的数据填充形式是在图像四周补 0, 经过填充后的图像可以使用 Full 和 Same 两种模式进行卷积, 以捕获图像边缘的信息。卷积层的输出包含了从输入图像中提取到的特征信息, 因此卷积层的输出称为特征图 (Feature map)。特征图的大小与卷积核的大小、移动的步长、数据填充的层数有关。设输入图像的大小为 $n \times m$, 使用的尺度为 f 的卷积核对其进行卷积操作, 在卷积之前对其进行层数据填充 p , 卷积核移动步长为 s , 则输出特征图的大小可由公式 2.2 表示。特征图上的像素点在输入图像上映射的区域称为感受野 (Receptive field), 感受野如图 2-4 所示。

$$S(i, j) = (I * K)(i, j) \sum_m \sum_n I(i + m, j + n) K(m, n) \quad (2.1)$$

$$\text{Size}_{\text{feature}} = \left\lfloor \frac{n+2p-f}{s} + 1 \right\rfloor \times \left\lfloor \frac{m+2p-f}{s} + 1 \right\rfloor \quad (2.2)$$




图 2-3 Full, Same, Valid 三种卷积模式

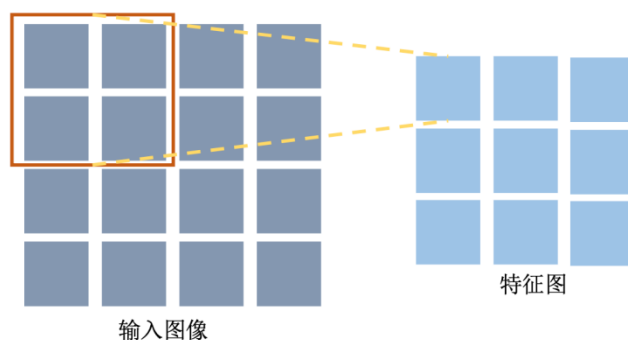


图 2-4 感受野

2.1.2 激活函数

在卷积层之后会加入一个激活函数，通过引入非线性元素来提高网络的表达能力。因为卷积运算本质上是一种加权求和的线性运算。线性运算为基础的网络模型表达能力有限，通过激活函数来引入非线性因素，从而提高网络模型的表达能力。

根据网络模型的复杂程度有多种激活函数可选择。浅层的网络模型可以使用 **sigmoid** 函数；**ReLU** 函数常用于深层网络模型；递归神经网络模型则使用 **tanh** 函数。在卷积神经网络中尽量避免使用 **sigmoid** 函数和 **tanh** 函数，因为会造成梯度消失。首选 **ReLU** 函数作为激活函数，**ReLU** 函数形式如公式 (2.3) 所示。相较于 **sigmoid** 函数和 **tanh** 函数，**ReLU** 函数只有线性关系，计算速度更快。当函数的输入是整数时，不存在梯度消失的问题。但是当输入是负数时，**ReLU** 函数会把负数强制性地置为 0，导致特征丢失；同时也无法利用梯度更新权值。因此，当 **ReLU** 函数失效时可以选用 **Leaky ReLU** 函数，其的形式如公式 (2.4) 所示。**Leaky ReLU** 函数避免了特征丢失、权值无法更新等问题。

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2.3)$$

$$f(x) = \begin{cases} \alpha, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2.4)$$

2.1.3 池化层

池化操作是将某一位置相邻输出的总体统计特征作为此位置的输出。常见的池化操作有最大池化（Max-Pooling）和均值池化（Mean-Pooling）。

池化层没有可训练的参数，但是需要指定池化核的大小、滑动步长以及池化类型。池化核的大小一般为 2×2 ，滑动步长为 2，两种池化方式的结果如图 2-5 所示。池化的过程本质上是一个对特征图采样的过程。在保留特征的同时减少参数计算量，防止过拟合。

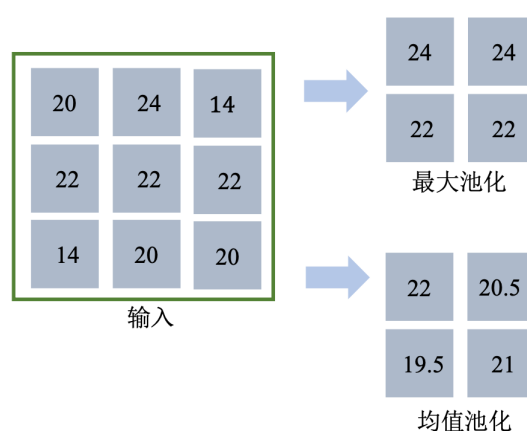


图 2-5 最大池化与均值池化

2.1.4 全连接层

作为卷积神经网络的最后一层，对上一层输出的特征图进行降维。卷积层、池化层、包括激活函数是将原始数据映射到隐层特征空间，而全连接层中的每个节点与上一层的所有节点连接，将学习到的特征表示映射到样本标记空间用于分类或者回归。因此全连接层的参数非常庞大。

2.2 经典的网络模型

2.2.1 LeNet 网络模型

LeNet [1]网络模型是最早的卷积神经网络模型之一，LeNet 包含了卷积神经网络中全部基本结构，即卷积层、激活函数、池化层和全连接层。在计算机视觉任务中展现了出色的性能，其性能与支持向量

机（Support Vector Machines, SVM）相媲美。LeNet 在手写数字识别任务中能够以低于 1% 的错误率完成识别任务。总体来看，LeNet 的结构分为两部分，分别是卷积密集块和全连接密集块。其架构图如图 2-6 所示。卷积密集块由两个卷积块组成，每个卷积块由卷积层、sigmoid 激活函数、均值池化层构成。卷积层中使用 5×5 的卷积核将输入图像映射到多个二维特征图。

第一个卷积层的输出包含 6 个通道，而第二个卷积层的输出则是 16 个通道。每层卷积输出的特征图会经过池化核大小为 2×2 、活动步长为 2 的池化层进行下采样。以减少参数计算量。卷积密集块输出的特征图会作为全连接密集块的输入，在特征图被输入之前需要对其进行维度转换，即二维特征图被展平成一维。

全连接密集块包含 3 个全连接层，其输出通道数分别为 120、84 和 10。若网络模型完成的是分类任务，则最后一个全连接层的输出维度与类别数相同。因为 LeNet 被用于手写数字识别，其最后一层的输出维度对应 0-9。




图 2-6 LeNet 架构图

2.2.2 AlexNet 网络模型

在 LeNet 提出后的很长一段时间里，神经网络并没有占据主导地位。直到 2012 年提出的 AlexNet[2] 在当年的 ILSVRC（ImageNet Large-Scale Visual Recognition Challenge）竞赛中获得冠军，开起了

研究神经网络的热潮。AlexNet 在 LeNet 的基础上将激活函数替换为 ReLU 激活函数，并且有更深的层次。AlexNet 主要由 5 个卷积层和 3 个全连接层构成。更多的卷积层可以捕捉到更多的特征，捕捉到的特征图如图 2-7 所示。底层的卷积层捕捉到了边缘、纹理等特征，为更高层的特征表示提供了基础。ImageNet 数据集为 3 通道的彩色图像尺寸为 $224 \times 224 \times 3$ ，为了处理如此大的图像，AlexNet 第一层的卷积核大小为 11×11 ，之后的卷积核大小缩小为 5×5 和 3×3 。池化层也改为了池化核为 3×3 ，滑动步长为 3 的最大池化，其与 LeNet 结构对比如表 2-1 所示。尽管 AlexNet 与 LeNet 结构相似，但是 ReLU 激活函数和最大池化的引入使 AlexNet 计算速度得意提升，并且避免了梯度消失的问题。更为重要的是，AlexNet 使用 GPU (Graphics Processing Unit) 加速训练。能够表征更大特征空间的参数量结合高效地训练，是 AlexNet 性能优异的重要原因。




图 2-7 AlexNet 第一层卷积层捕捉到的特征

表 2-1 AlexNet 与 LeNet 架构

Module	LeNet	AlexNet
输入	28×28	3×256×256
卷积层	5×5,2 层	11×11,1 层; 5×5,1 层; 3×3,3 层
池化层	均值池化	最大池化
全连接层	3 层	3 层

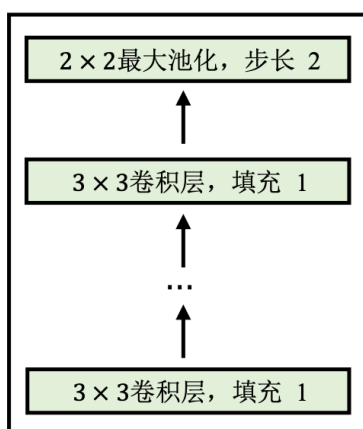


图 2-8 VGG 网络模型的基本结构

2.2.3 VGG 网络模型

尽管 AlexNet 在 2012 年的 ILSVRC 中大放异彩，证明了深度卷积神经网络 处理计算机视觉任务卓有成效。但是没有提供一个通用的深度卷积神经网络的构建方法。VGGNet [3]网络模型是由牛津大学视觉几何小组（Visual Geometry Group, VGG）提出，在引入块结构后通过循环程序快速构建深度卷积神经网络。一个 VGG 块如图 2-8 所示，都是由卷积层、激活函数和池化层构成。在卷积层中使用的全都是 3×3 的小卷积核，相比于 11×11 的大卷积核有更少的卷积参数，同时多个卷积核结合 ReLU 激活函数可以有更强的非线性表达能力。其中卷积层还包含了填充（Padding）以保持分辨率。正因为块结构的可重复性，VGGNet 可以构建不同层次的卷积神经网络，常见的有

VGG-16 和 VGG-19。如表 2-2 所示，展示不同层次的 VGGNet 架构。VGGNet 的优势在于块结构的引入简化了深度卷积神经网络的构建，但是随着网络模型深度的增加，神经网络的参数量也随之增加。

表 2-2 VGG-11,VGG-13,VGG-16, VGG-19 架构

VGG-11	VGG-13	VGG-16	VGG-19
input(224×224×3)			
1×conv3-128	2×conv3-64	2×conv3-64	2×conv3-64
Max-Pooling			
1×conv3-128	2×conv3-128	2×conv3-128	2×conv3-128
Max-Pooling			
2×conv3-256	2×conv3-256	3×conv3-256	4×conv3-256
Max-Pooling			
2×conv3-512	2×conv3-512	3×conv3-512	4×conv3-256
Max-Pooling			
2×conv3-512	2×conv3-512	3×conv3-512	4×conv3-512
Max-Pooling			
FC-4096			
FC-4096			
FC-1000			
Softmax			

2.2.4 GoogLeNet 网络模型

一般来说，提升网络性能最直接的办法就是增加网络深度和宽度，这也就意味着巨量的参数。但是，巨量参数容易产生过拟合也会大大增加计算量。提升网络层数可以提高模型的性能，但是会引入过量的参数导致网络过拟合现象。GoogLeNet[4]提出 Inception 架构，将全连接和一般的卷积的连接方式进行改进，转化为较稀疏的连接，保证网络结构稀疏性的同时也可以使用 GPU 进行矩阵的高性能计算。

GoogLeNet 网络深度共 22 层。Inception 模块如图 2-9 所示，对前一层网络的输出使用不同大小的卷积核提取特征，获得不同感受野的特征，然后将特征进行通道上的融合，达到多尺度的作用。为了方便对齐特征图后融合特征，分别对卷积核大小为 1、3 和 5 的卷积进行 0、1、2 大小的补零操作，保证卷积后的特征图大小一致，卷积操作后可以直接在通道维度上对特征进行叠加。由于 5×5 的卷积计算量太大，因此使用 1×1 的卷积核进行降维。改进后的 Inception 模块如图 2-10 所示。Inception 模块允许网络在每个块中的多个卷积过滤器大小之间进行选择，将这些模块堆叠在一起，偶尔使用步幅为 2 的最大池化层来将网格的分辨率减半。GoogLeNet 基于 Inception 模块进行设计，同时为了避免梯度消失，网络设计了另外的 2 个辅助的 softmax 分类层，用于在网络中部收集梯度并回传梯度，辅助的分类层在测试时会被移除。

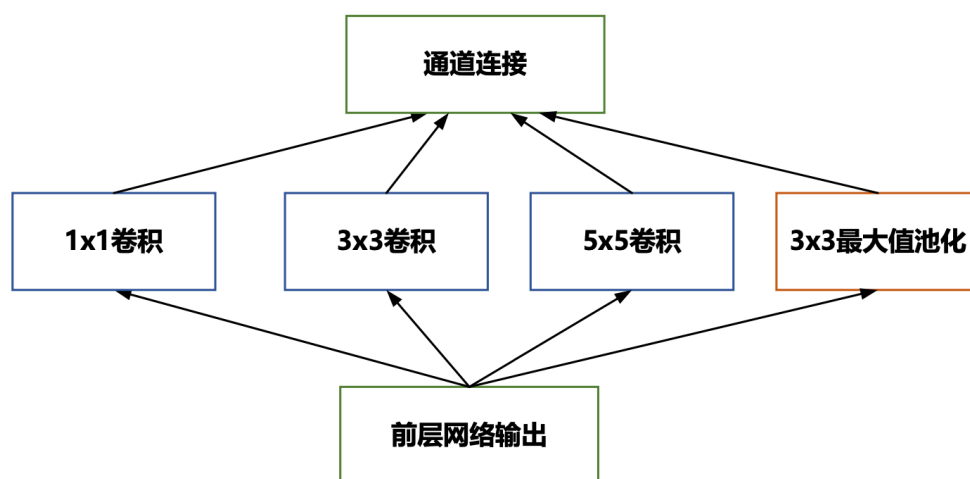


图 2-9 Inception 基本模块

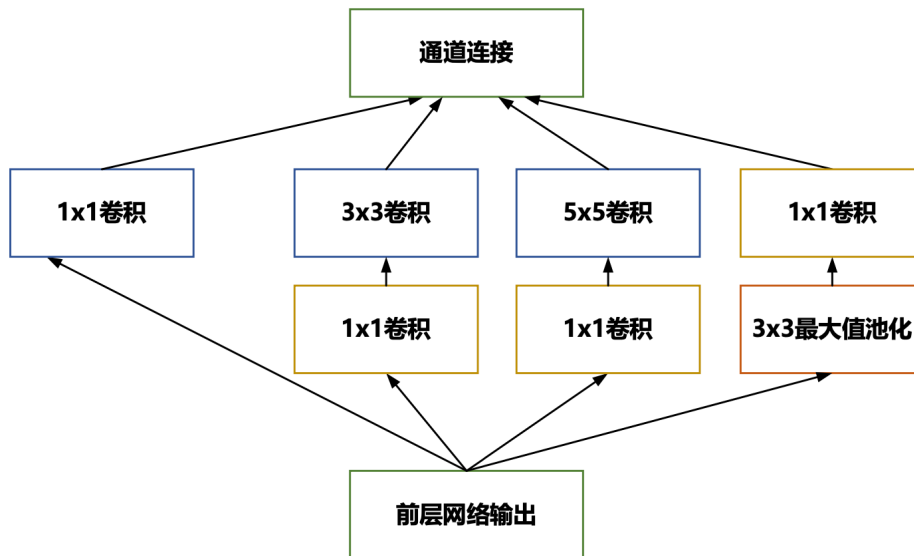


图 2-10 降维版 Inception 模块

2.2.5 ResNet 网络模型

随着网络模型深度的增加，反向传播过程中存在着梯度消失和梯度爆炸问题，这导致模型难以训练。甚至会出现随着网络模型深度的增加，网络模型的误差在训练过程中会出现先降低再上升的现象。为了解决以上问题，何恺明等人在 2015 年提出了 ResNet 网络模型 [5]，残差神经网络。常见的 ResNet 结构有 ResNet-18、ResNet-34、ResNet-50、ResNet-101 和 ResNet-152。其中 ResNet-18 和 ResNet-34 属于结构相似的浅层网络，而其余的结构属于深层结构。ResNet 同 VGGNet 一样由块结构组成，不同的是 ResNet 中的块结构在标准神经网络的基础上加入了跳跃连接，称为残差块 (Residual Block)，如图 2-11 所示。

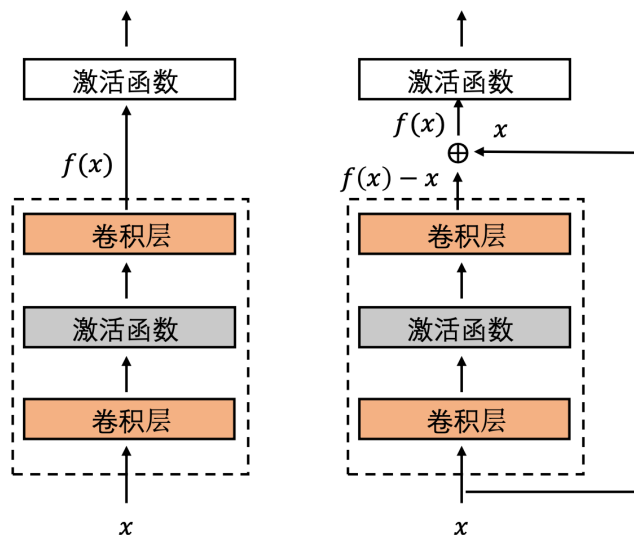


图 2-11 非残差结构（左）和残差结构（右）

2.2.6 ShuffleNet 网络模型

ShuffleNet 网络[6]提出主要是解决深度学习网络计算量太大的问题。如图 2-11 所示，(a) 表示具有深度卷积的单元模块；(b) 表示 ShuffleNet 单元，加入逐点卷积和通道洗牌操作；(c) 表示步长为 2 时的 ShuffleNet 单元。

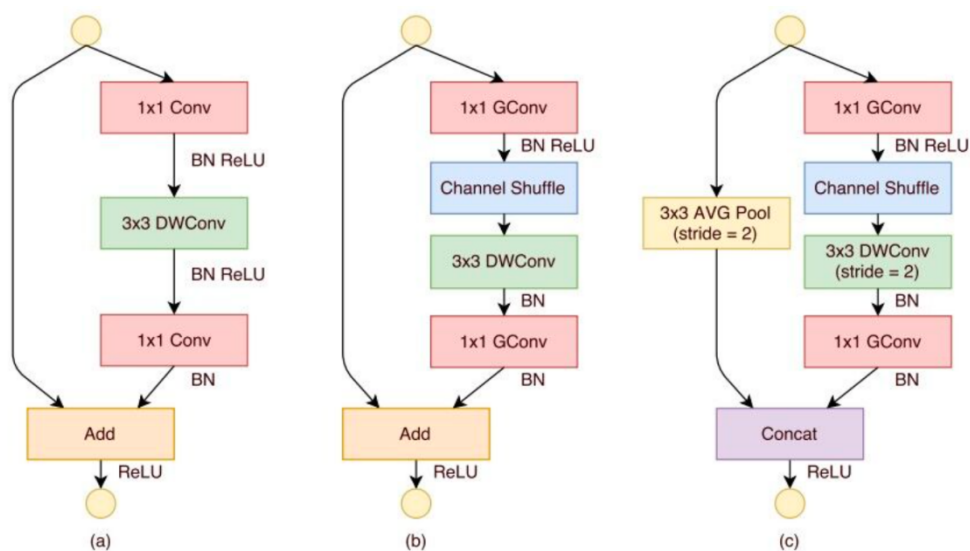


图 2-12 ShuffleNet 单元

在小型网络中，为了避免网络复杂度过高，因此卷积的通道数设置有限，这会导致网络精度下降。设计了通道稀疏连接方式，通过确保每个卷积只在相应的输入通道组上运行，组卷积大大降低了计算成本。然而，如果多个组卷积堆叠在一起，就有一个副作用：来自某个通道的输出只来自输入通道的一小部分。图 2-12 (a) 显示了两个堆叠的组卷积层的情况。很明显，来自某一组的输出只与组内的输入有关。这个属性阻止了通道组之间的信息流，并削弱了表示能力。

如果允许组卷积获得来自不同组的输入数据（如图 2-12 (b) 所示），那么输入通道和输出通道将完全相关。具体来说，对于上一组层生成的特征图，可以首先将每个组中的通道划分为几个子组，然后向下一层中的每个组提供不同的子组。这可以通过通道洗牌操作有效而优雅地实现（图 2-12 (c)）：假设一个卷积层， g 个组的输出有 $g \times n$ 个通道；首先将输出通道维度重塑为 (g, n) ，然后将其转平，作为下一层的输入。即使这两个卷积有不同数量的组，该操作仍然会生效。此外，通道洗牌也是可微的，这意味着它可以嵌入到网络结构中进行端到端训练。

2.2.7 Vision Transformer 模型

在自然语言处理（Natural Language Processing, NLP）任务中取得成功之后，基于 Vision Transformer (ViT) 的深度学习模型在计算机视觉任务中显示出了巨大的优势，如图像分类、目标检测和超分辨。例如，在图像分类中，传统的 CNN 模型，如 VGGNet 和 ResNet，在 ImageNet 上的准确率分别为 71.62% 和 78.63%，而基于 Transformer 的模型，如 ViT-Large (ViT-L)，可以达到 85.63%。CNN 的关键组成部分是卷积层，其权值通常以三维卷积核的形式表示。相反，Vision Transformer 主要由编码器 (Encoder) 构成，而编码器由多头自注意力机制 (Multi-Head Self Attention, MSA) 和多层感知机 (Multi-Layer Perceptron, MLP) 模块组成，其权值基本上是矩阵。

Vision Transformer 的输入通常是带有标记的一维序列。为了处理二维图像 $x \in \mathbb{R}^{H \times W \times C}$ ，Vision Transformer 将输入的图像重塑为一连串扁平化的二维方块 $x_p \in \mathbb{R}^{(N \times p^2 - C)}$ ，其中 H (Height) 和 W (Width) 是原始图像的分辨率，C (Channel) 是通道数，(P, P) 是每个二维方块的分辨率， $N = \frac{HW}{p^2}$ 是二维方块的数量，这决定了 Vision Transformer 输入的序列长度。Vision Transformer 第一层的输入可由公式 (2.5) 表示：

$$x_0 = [x_{\text{class}}; x_p^1 W; x_p^2 W; \dots; x_p^N W;] + E_{\text{pos}} \quad (2.5)$$

对于 MSA 和 MLP 模块，可以由公式 (2.6) 和 (2.7) 表示，MLP 模块由两个线性层和一个 GELU 层组成，包含参数 $W^1 \in \mathbb{R}^{D \times D_h}$ ， $W^2 \in \mathbb{R}^{D_h \times D_h}$ 和 $b \in \mathbb{R}^D$ ，

$$\text{MSA}(x_i) = \text{softmax}\left(\frac{Q_i K_i^T}{\sqrt{D}}\right) V W_i^{\text{msa}} \quad (2.6)$$

其中， $Q_i = x_i W_i^q$ ， $K_i = x_i W_i^k$ ， $V_i = x_i W_i^v$ ；

$$\text{MLA}(x_i) = \text{GELU}(x_i W^1 + b^1) W^2 + b^2 \quad (2.7)$$

一个典型的一层的 Vision Transformer 可以通过上述公式组合成如下形式：

$$x'_i = \text{MSA}(\text{LN}(x_i)) + x_{i-1} \quad (2.8)$$

$$x_i = \text{MLA}(\text{LN}(x'_i)) + x'_i \quad (2.9)$$

其中， $\text{LN}(\cdot)$ 表示正则化。

2.2.8 递归神经网络

人类不会每一秒都从头开始思考。当阅读文章时，人会根据对前文单词的理解来理解后续的内容。阅读过程中不会扔掉所有东西，重新开始思考。说明人的思维具有连续性。传统的神经网络无法做到这一点，不具有信息的记忆功能。递归神经网络 (Recurrent Neural Network, RNN) 解决了这个问题，它们是带有循环的网络，允许信息持续存在。如图 2-13 所示展示了一个递归神经网络的基本结构。左侧为递归神经网络折叠模式，A 表示循环神经网络的一个基本模块，

t 时刻的输入为 x_t , t 时刻的输出为 h_t , 循环神经网络允许信息从网络的一个步骤传递到下一个步骤。右侧为递归神经网络的展开式, 这种链状性质表明循环神经网络与序列数据密切相关。

在过去的几年里, 将递归神经网络应用于语音识别、语言建模、翻译、图像、字幕等领域, 取得了令人难以置信的成功。这些成功的关键是使用长短时记忆网络, 这是一种非常特殊的递归神经网络, 对于许多任务, 它比标准的递归神经网络要好得多。

递归神经网络的吸引力之一是它们可能能够将以前的信息连接到当前的任务。有时只需要查看最近的信息即可执行当前任务。例如, 考虑一个语言模型试图根据前面的单词预测下一个单词。如果试图使用网络预测 “the clouds are in the sky” 中的最后一个词, 则不需要任何进一步的上下文, 很明显下一个词是 sky。在这种情况下, 相关信息和需要它的地方之间的差距很小。但在某些情况下, 网络的预测需要结合更多上下文。考虑尝试预测文本 “我在法国长大..... 我说一口流利的法语” 中的最后一个词。最近的信息表明, 下一个词可能是一种语言的名称, 但如果想缩小哪种语言的范围, 则需要法国的上下文, 需要从很远的位置调取信息。递归神经网络很难进行长距离的连接信息, 因此 Hochreiter 等人提出了长短时记忆网络 (Long Short Term Memory network, LSTM), 解决了信息跨度大小不一致时的信息理解问题, 用于避免长期依赖问题。




图 2-13 RNN 基本结构

LSTM 和 RNN 的网络结构对比如图 2-14 所示，所有循环神经网络都具有神经网络重复模块链的形式。在标准 RNN 中，这个重复模块将具有非常简单的结构，例如单个 tanh 层。LSTM 也有这种链状结构，但重复模块有不同的结构。不是只有一个神经网络层，而是有四个，以一种非常特殊的方式进行交互。在图 2-14 中，每条线都带有一个完整的向量，从一个节点的输出到其他节点的输入。粉色圆圈代表逐点操作，如向量加法，而黄色框是学习的神经网络层。行合并表示串联，而行分叉表示其内容被复制并且副本转到不同的位置。LSTM 的关键是细胞状态，即贯穿图表顶部的水平线。细胞状态有点像传送带，它直接沿着整个链条运行，只有一些次要的线性交互。信息很容易原封不动地沿着它流动。LSTM 确实有能力删除或添加信息到细胞状态，由称为门的结构仔细调节。门是一种有选择地让信息通过的方式。它们由一个 sigmoid 神经网络层和一个逐点乘法运算组成。sigmoid 层输出介于 0 和 1 之间的数字，描述应该让多少成分通过。值为零表示“不让任何东西通过”，而值为 1 表示“让一切都通过”，LSTM 具有三个这样的门，以保护和控制单元状态。

(1) **遗忘门**：LSTM 的第一步是决定要从细胞状态中丢弃哪些信息。该决定由称为“遗忘门层”的 sigmoid 层做出。输入为上一阶段的隐藏层输出 h_{t-1} 和当前层的输入 x_t ，输出一个介于 0 之间的数字和 1，表示遗忘多少信息。遗忘门的数学表达式：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.10)$$

其中，sigmoid 函数形式为：

$$f(z) = \frac{1}{1+e^{-z}} \quad (2.11)$$

用语言模型示例进行解释，网络试图根据所有先前的单词预测下一个单词。在这样的问题中，细胞状态可能包括当前主体的性别，以便可以使用正确的代词。当看到一个新主体时，希望忘记旧主体的性别。

(2) 记忆门：下一步是决定要在细胞状态中存储哪些新信息。记忆门分为两个部分。首先使用 **sigmoid** 层决定将更新哪些值。接下来，使用一个 **tanh** 层创建一个新候选值 向量 C_t ，可以将其添加到状态。在下一步中，将结合这两者来创建对状态的更新。记忆门的数学表达式为：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_i) \quad (2.12)$$

$$C_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_c) \quad (2.13)$$

其中，**tanh** 的数学表达式为：

$$f(x) = \tanh(x) = \frac{2}{1+e^{-2x}-1}。 \quad (2.14)$$

用语言模型示例进行解释，即将新主体的性别添加到单元格状态，以替换遗忘门忘记的旧主体。

(3) 输出门：最后，需要决定要输出什么。此输出将基于细胞状态，但 将是过滤后的版本。首先使用一个 **sigmoid** 层，它决定要输出细胞状态的哪些部分。然后，把细胞状态通过 **tanh** 函数并将其和 **sigmoid** 门的输出相乘。输出门的数学表达式为：

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.15)$$

$$h_t = o_t * \tanh(C_t) \quad (2.16)$$

用语言模型举例，由于它只看到一个主语，它可能想要输出与动词相关的信息，以防接下来会发生什么。例如，它可能会输出主语是单数还是复数，以便知道如果接下来是动词应该变位的形式。

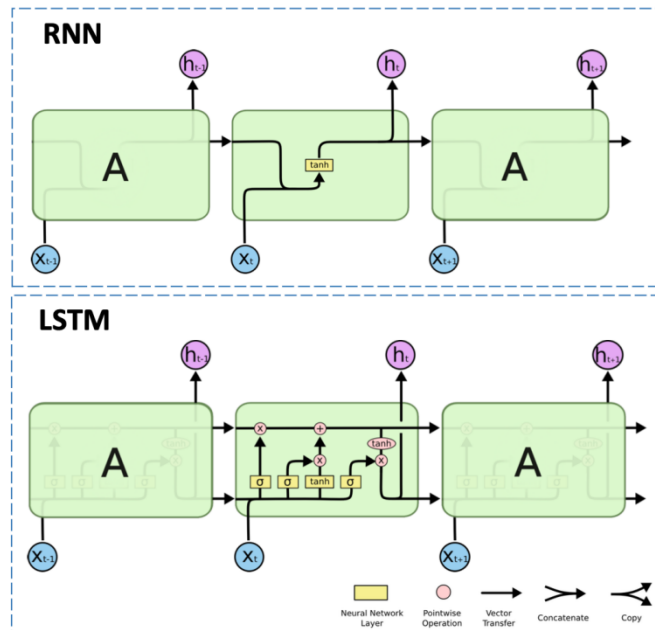


图 2-14 RNN 和 LSTM 网络结构对比

2.3 人类视觉感知特性与深度学习模型

2.3.1 人类视觉感知特性

视觉感知特性，即人类视觉系统感知图像信息的特性，是一个高度复杂的信息处理过程。理解人类对视觉信息的处理机制，有助于推动计算机视觉高性能算法研究。下面主要研究视觉关注、亮度及对比敏感度、视觉掩盖、视觉非局部约束这四个特性。

(1) 视觉关注：在纷繁复杂的外界场景中，人类视觉总能快速定位重要的目标区域并进行细致的分析，而对其他区域仅仅进行粗略感知甚至忽视。这种主动选择性的心理活动被称为视觉关注机制（Visual Attention）。视觉关注可由两种模式引起：一种是客观内容驱动的自底向上（bottom-up）关注模型，它是对场景刺激的一种无意识的、自发的反应，只取决于场景的内容特性，与观察者的记忆、意识无关，主要影响因素是底层图像特征；另一种是主观命令指导的自顶而下（top-down）关注模型，受意识支配、依赖于特定的命令，主要影响因素是高层的语义。

(2) 视觉掩盖：视觉信息间的相互作用或相互干扰将引起视觉掩盖效应。常见的掩盖效应有：1) 由于边缘存在强烈的亮度变化，人眼对边缘轮廓敏感，而对边缘的量度误差不敏感，即对比度掩盖；2) 图像纹理区域存在较大的亮度以及方向变化，人眼对该区域信息的分辨率下降，即纹理掩盖；3) 视频序列相邻帧间内容的剧烈变动（如目标运动或者场景变化），导致人眼分辨率的剧烈下降，即时域的运动掩盖及切换掩盖。

视觉掩盖效应使人眼无法察觉到一定阈值以下的失真，该阈值被称为恰可识别失真（Just Noticeable Distortion）。恰可识别失真阈值在实际图像处理中具有重要的指导意义。该阈值可以帮助人眼筛选出能察觉的信息而忽略其余不可察觉信息，从而减少图像处理的复杂度，且在一定条件下能改善图像的显示质量。

(3) 对比敏感度：由于视觉系统具有鲁棒性，无法分辨一定程度以内的边缘模糊，这种对边缘模糊的分辨能力称为对比灵敏度，即视觉系统能觉察到的对比度阈值的倒数。具体公式是：对比敏感度 = $1/\text{对比度阈值}$ ；对比度阈值越低，对比敏感度越高，视觉功能越好。

(4) 非局部约束：格式塔心理学强调了很多在视觉感知中的非局部性约束特征，如相似性、相近性、连续性和闭合性等。人的视觉感知往往会将符合这些特征的图像信息组织到一起，而通常情况下，这些特征也是区分对象是否属于同一目标的显著标志。

2.3.2 人类视觉感知特性启发的深度学习模型

人类视觉感知的四个特性与深度学习网络之间形成了密切关系，具体表现在以下几个方面：

1、视觉关注和掩盖与调节注意力模型的联系

视觉关注机制体现了人类视觉系统主动选择关注内容并加以集中处理的视觉特性，该特性能有效提升图像内容筛选、目标检索等图像处理能力。视觉掩盖能力能够区分出哪些信号是视觉系统能察觉、

感兴趣的，哪些信号是视觉系统无法察觉、可忽略的。二者结合，即对有效信息的增强和对无效信息的减弱，有助于提高人类对视觉信息的分析能力。在深度学习中，注意力机制已然成为最为流行的概念和实用工具。注意力机制模型根据实现原理，可分为调节注意力（Scaling Attention, SLA）和点积注意力（Dot-product Attention, DPA）。其中，SLA 集中在强调重要的特征通道和特征空间，而忽略不重要的特征。例如，挤压激励（SE）模块使用全局平均池化和一个线性层来计算每个通道的比例因子，然后相应地强化有效通道而弱化无意义通道。因此，SLA 有效地刻画了人类视觉的视觉关注和视觉掩盖两个感知特性，如图 2-15 所示。

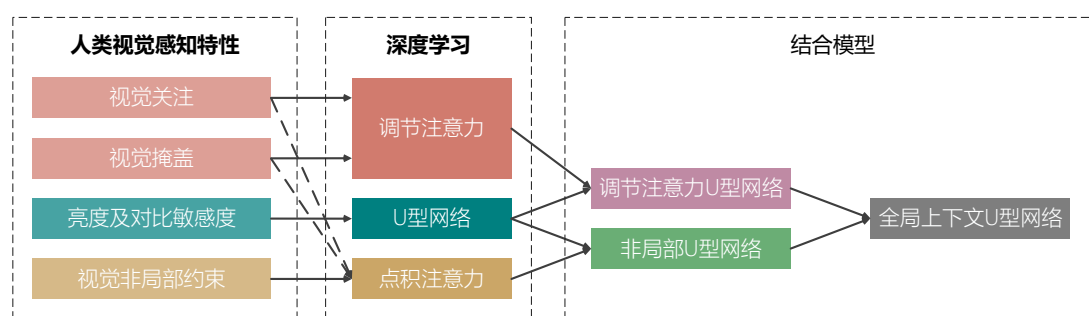


图 2-15 人类视觉感知特性与深度学习网络之间的联系

2、对比敏感度与 U 型网络的联系

对比敏感度说明，人类视觉系统非常关注物体的边缘，往往通过边缘信息获取目标物体的具体形状、解读目标物体等。U 型网络通过跳接结构，将能够表达边缘、纹理的细节信息传递到高阶特征中，从而帮助解码器更好地修复目标的细节。U 型网络的这种特性，反映的是物体的边缘、形状、纹理等信息对于人类视觉信息理解的重要性。因此，U 型网络在一定程度上刻画了人类视觉对比敏感度的特征。

3、非局部约束与点积注意力的联系

大量人类视觉研究发现，人脑处理视觉信息时并不是仅局限于局部区域的信息。人眼对全局的、语义的、简单结构的形状整体更容易

产生印象，而非局部细节信息。DPA 通过点积计算形式，获得询问特征向量任意一个位置与键(key)特征向量中全部位置之间的相关性，从而捕获位置与位置之间（像素与像素之间）的长距离依赖关系，实现全局上下文信息的建模。同时，学习到的全局上下文信息通过 softmax 得到空间上的注意力图，也可以起到对有效信息增强和无效信息弱化的作用。DPA 的全局上下文建模在一定程度上体现了人眼视觉关注、视觉掩盖和非局部约束等多个特征。

2.4 注意力机制与深度学习模型

视觉注意力机制是人类视觉所特有的大脑信号处理机制。人类视觉通过快速扫描全局图像，获得需要重点关注的目标区域，也就是一般所说的注意力焦点，而后对这一区域投入更多注意力资源，以获取更多所需要关注目标的细节信息，而抑制其他无用信息。这是人类利用有限的注意力资源从大量信息中快速筛选出高价值信息的手段，是人类在长期进化中形成的一种生存机制，人类视觉注意力机制极大地提高了视觉信息处理的效率与准确性。计算机视觉中的注意力机制从本质上讲和人类的选择性视觉注意力机制类似，核心目标也是从众多信息中选择出对当前任务目标更关键的信息。

2.4.1 注意力机制研究进展

2015-2017 年，自从注意力提出后，成为 NLP 的基本模型，各种各样的注意力模型被提出。在机器翻译 (Machine Translation)，文本摘要 (Text summarization)，文本理解/问答 (Text Comprehend (Q&A))，文本分类 (Text Classification) 等任务重也被广泛应用，该阶段出现的一些奠基性的基础工作如下文。

注意力模是在 2015 年 ICLR 发表的文章中首次被提出[7]。文章提出了经典的注意力结构用于机器翻译，被称为加性注意力 (Additive

Attention 或 Bahdanau Attention); 并形象直观地展示了注意力带来源语目标语的对齐效果, 解释深度模型到底学到了什么。

2015 年 EMNLP 在基础注意力模型上开始研究一些变化操作[8], 尝试不同的打分函数 (score-function), 不同的校准 (对齐) 函数 (Alignment-function)。文章中使用的乘性注意力 (Multiplicative Attention 或 Luong Attention) 结构也被广泛应用。

2015 年, [9]在图像说明 (Image Caption) 应用注意力模型, 首次提出软注意力 (Soft Attention) 和硬注意力 (Hard Attention) 的概念。

在上面几篇奠基之作之上, 2016 和 2017 年注意力模型得到广泛关注和拓展应用。例如分级注意力 (Hierarchical Attention), Attention over Attention, 多步式注意力 (multi-step Attention) 等。

直到 2017 年 Transformer 的提出, 使得注意力模型脱离 RNN 的限制, 具备更强大的表示学习能力, NLP 领域爆发了新一轮的活力, BERT、GPT 领跑各项 NLP 任务效果。2017 年 NeurIPS 文章提出 Transformer 结构[10] (涉及自注意力 (Self-attention), 多头注意力 (Multi-head Attention) 等注意力机制)。基于 Transformer 的网络可全部替代序列对齐 (Sequence-aligned) 的循环网络, 实现 RNN 不能实现的并行化, 并且使得长距离的语义依赖与表达更加准确。由于自注意力模型缺乏时序关系学习, 具有相对位置编码能力的通用 Transformer (Universal Transformer) 和更长距离位置编码的 Transformer-XL 被相继提出。

最早在计算机视觉应用形成一定影响力并得到广泛应用的是 2017 年的挤压激励网络 (Squeeze-and-Excite Networks, SENet) 和 2018 年的非局部网络 (Non-Local Network, NLNet)。SENet 的实质是通道注意力模型, 通过全局平均池化的方式聚合通道的全局信息。SENet 在 2017 年的 ImageNet2017 分类比赛上获得了冠军, 比之前的

工作有了较大的性能提升。NLNet 采样自注意力模型，能够对每个位置间的长距离依赖关系进行有效建模。但由于其巨大的内存消耗和计算复杂度，近几年很多非局部注意力改进模型根据结合律法则对 NLNet 进行优化。

2.4.2 注意力模型基本框架

注意力机制最早在 NLP 应用中被提出并发展，且大多模型都构建在 RNN 网络上。随着 Transformer 模型的提出，注意力模型开始采用编解码器网络而脱离了 RNN 的局限。之后，注意力模型被广泛应用于计算机视觉领域。视觉注意力模型与 NLP 注意力模型略有不同，具体地包含三个部分（如图 2-16 所示）：

1) 打分函数（score function），用于计算度量环境向量与当前输入向量的相似性，或找到当前环境下，应该关注哪些输入信息；

2) 校准函数（alignment function，在 NLP 中通常被称为对齐函数），计算注意力图（即注意力权重），通常都使用 sigmoid 函数起到门限（gate）作用，或 softmax 函数进行归一化；

3) 融合（fusion），即注意力权重/图以什么方式作用于输入，一般采用元素相加（Element-wise Addition）或元素相乘（Element-wise Product）。




图 2-16 注意力模型基本框架

根据注意力模型基本框架的三个部分的变化，可对不同注意力模型进行不同形式的分类：

(1) 硬注意力和软注意力：根据融合方式的不同，注意力模型可分为硬注意力（Hard Attention）和软注意力（Soft Attention）。硬注意力通过强化学习的方式完成，是一个不可微分过程。硬注意力是一

个随机采样过程，采样的概率分布即为校准函数输出的注意力图。因此，硬注意力的输出是某一个特定区域的输入向量。软注意力是一个带权求和的过程，对应权重是校准函数计算的注意力图。由于软注意力是可微分的，可以通过反向传播进行优化并直接嵌入到模型中进行训练，因此得到了广泛的应用。后文提及的所有注意力模型都属于软注意力范畴。

(2) 全局注意力和局部注意力：校准函数一般采用 sigmoid 函数或 softmax 函数。根据参与校准函数的集合不同，可分为全局注意力 (Global Attention) 和局部注意力 (Local Attention)。前者是全部输入成分参与校准函数；后者则选择一部分区域进行校准，局部区域的选择方式有单调校准和预测校准两种。由于基于 CNN 网络的模型对局部特征的学习能力已经足够强，复杂化的局部注意力带来的效果增益并不明显。

(3) 调节注意力、点积注意力和全局上下文注意力：不同注意力模型的差异主要体现在打分函数。打分函数在一定程度上决定了该注意力模型的基本特性，这对注意力 U 型网络的设计提供重要依据。

因此，根据打分函数的不同，注意力模型可分为调节注意力 (Scaling Attention, SLA)、点积注意力 (Dot-Product Attention, DPA) 和全局上下文注意力 (Global Context Attention, GCA)。

1) 调节注意力 (SLA)：调节注意力 (SLA；NLP 领域中也称为 Alignment-based Attention) 也可以采用图 2-2 的框架进行描述。其中打分函数的特点是：通过某种特征统计或变换模型计算关注 (focus) 区域，例如卷积层 (可变行卷积、残差注意力模型等) 或池化层 (挤压激励网络, CBAM, BAM 等)。与 DPA 模型相比，SLA 是只基于键 (key) 特征对图像中的显著性区域进行增强，其他区域相应的进行抑制，从而使得输出的特征具有更强的区分性。

以挤压激励（SENet）网络为例，该网络首先使用了通道的 SLA 模型。其网络结构如图 2-17 所示。SENet 认为，特征图的每个通道对应一种滤波器的滤波结果，即图片的某种特定模式的特征。对于最终的分类结果，这些模式的重要性是不同的，有些模式更重要，因此其全局的响应更大；有些模式不相关，其全局的响应较小。通过对不同通道的特征根据其全局响应值，进行响应的增强或抑制，就可以起到在通道上进行注意力分配的作用。首先对输入特征进行全局平均池化，即为挤压（squeeze）阶段，对得到的特征进行线性变换，即为激励（excite）阶段，最后将变换后的向量通过广播（broadcast），乘到原来的特征图上，就完成了对不同通道的增强或抑制。




图 2-17 挤压激励网络（SENet）中的注意力模型

残差注意力（Residual Attention）网络提出，在分类网络中，由于深层网络具有更大的视野域，可以看到更广的范围，因此网络深层能够表达图片的主体内容，而浅层网络只能看到每个位置及其邻域。因此，深层网络比浅层网络更关注于被分类的物体。如果将网络较深层的信息作为一种 mask（即注意力图），作用在较浅层的特征上，就能更好的增强浅层特征中对于最终分类结果有帮助的特征，抑制不相关的干扰特征。

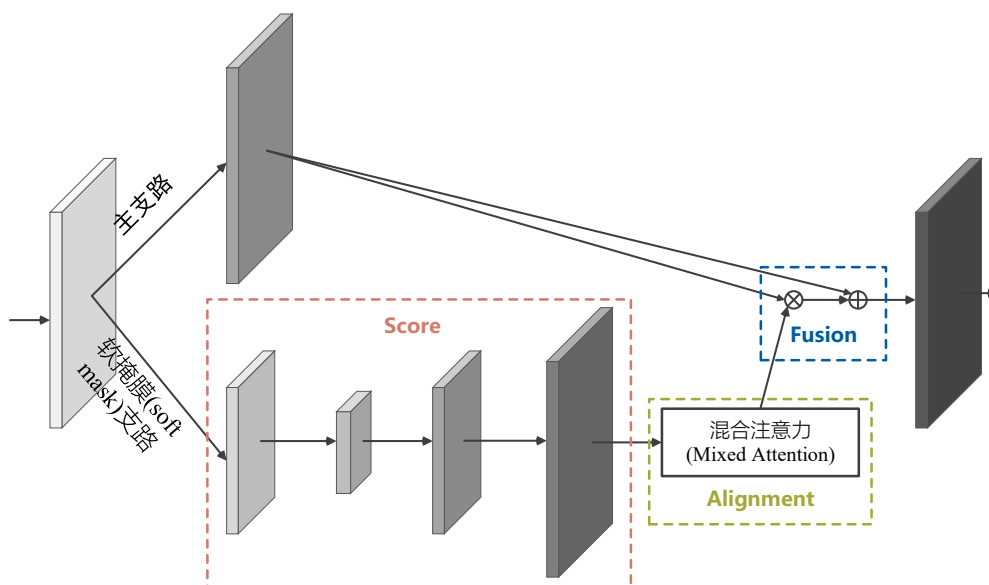


图 2-18 残差注意力 (residual attention) 网络中的注意力模型

如图 2-18 所示，软掩膜支路 (soft mask branch) 通过两次长步进下采样和两次长步进上采样作为打分函数，来提前获得更大的视野域。然后经过一个混合注意力 (Mixed Attention) 模型得到注意力图，并且将其作用在原来的特征上。因此，该模型是通过 bottom-up top-down 的前向传播方法来得到注意力图的，由于更大的视野域可以看到更多的内容，从而获得更多的注意力信息，使得输出的特征有更强的区分度。文章还提出了一个堆叠的网络结构，即残差注意力网络，中间多次采用这种注意力模块进行快速下采样和上采样。由于在视觉领域开启了前向传播的注意力机制的先河，之后的注意力机制都是采用这种前向传播过程中得到的注意力图进行增强，并且一般为了优化方便，都会以残差的方式进行。

2) 点积注意力 (DPA): 与 SLA 不同，在 DPA 中，通常包含三个特征向量，即询问 (query, Q) 向量、键 (key, K) 向量和值 (value, V) 向量。在自注意力模型中，Q、K、V 分别是输入特征通过三个不同卷积层得到的特征矩阵再经过拉伸变形得到的特征向量。将 Q 和 K 进行点积计算，可获得每个询问向量每个位置 (point, 或 pixel) 与键向量的相关性，相关性矩阵经过 softmax 归一化后，得到注意力图。

这个点积过程，对应于注意力模型基本框架中的打分函数和校准函数。注意力图与 V 再进行矩阵相乘，得到增强的输出特征图。该过程对应于注意力模型基本框架中的融合方式。

以双重注意力网络（Dual Attention Network, DANet）为例，其结构如图 2-19 所示。DANet 实现了自适应地集成局部特征和全局依赖。在传统的扩张 FCN 之上附加两种类型的注意力模块，分别模拟空间和通道维度中的语义相互依赖性。

位置注意力模块（position attention module）通过所有位置处的特征的加权和来选择性地聚合每个位置的特征。

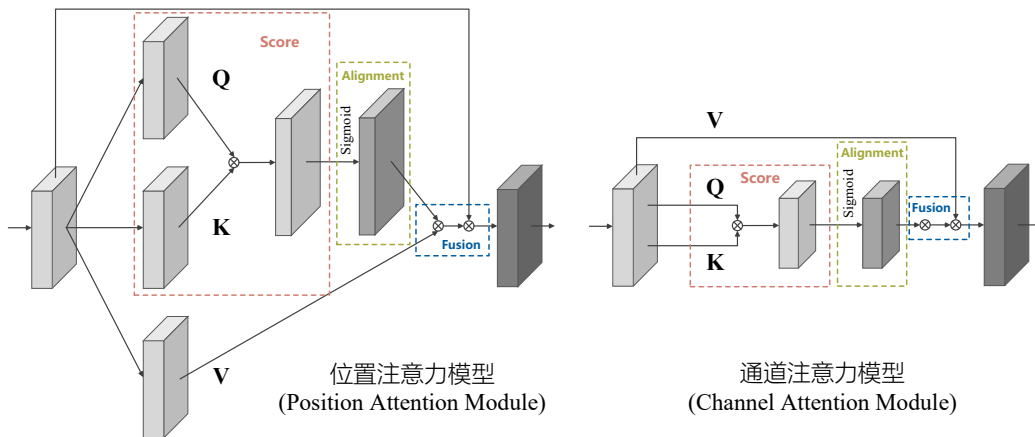


图 2-19 双重注意力网络（DANet）中的注意力模型

如图 2-19 左图可以看出，位置注意力模块其实质是一个自注意力模型。通道注意力模块（channel attention module）来模拟通道相互依赖性。图 2-19 右图中可以看出，通道注意力模块的实质也是自注意力模型，其中 $Q=K=V$ 就是输入本身，且得到的注意力图大小为 $C \times C$ ， C 为输入特征通道数，表现的是通道之间的相互关系。通过在局部特征上对丰富的上下文依赖关系建模，显著改善了分割结果。将两个注意模块的输出相加以进一步改进特征表示，这有助于更精确的分割结果。

自注意力模型中，针对每个像素点生成不同的权重值，对特征图进行加权处理，但计算量将大大增加。例如，对于一个 1024×1024 的特征图，其计算的注意力图大小为 $(1024 \times 1024) \times (1024 \times 1024)$ 。交叉形注意力网络（Criss-Cross Attention Network, CCNet）提出了一种有效的解决方案，即对于每个像素，CCNet 先通过一个交叉注意模块来获取其周围像素在交叉路径上的上下文信息；然后连续执行两次这样的注意力模块操作，每个像素最终都可以捕获所有像素的远程依赖关系，具体网络结构如图 2-20 所示。可以看出，CCNet 中的每个注意力模块，依然可以归结为一个 NPA 模型。不同于自注意力模型，一个交叉形注意力模块只计算 Q 与 K 对应同行和同列像素点之间的长距离依赖关系。即使这样的模块需要执行两次，但其计算量也大幅度降低。




图 2-20 交叉形注意力网络（CCNet）中的注意力模型

3) 全局上下文注意力（GCA）：全局上下文注意力不同于前面两种注意力模型，具体表现在：1) 不同于 SLA，其聚合方式采用的是与询问无关的上下文建模方式；2) 不同于 DPA，其上下文建模模块之后连结了一个激励模块（即 SENet 中的特征转换模块）。图 2-21 是全局上下文模块的基本结构，按照基本注意力结构，GCA 完成了两次注意力过程。这种结构使得 GCA 具备了长距离依赖关系建模能力和很强的泛化能力。

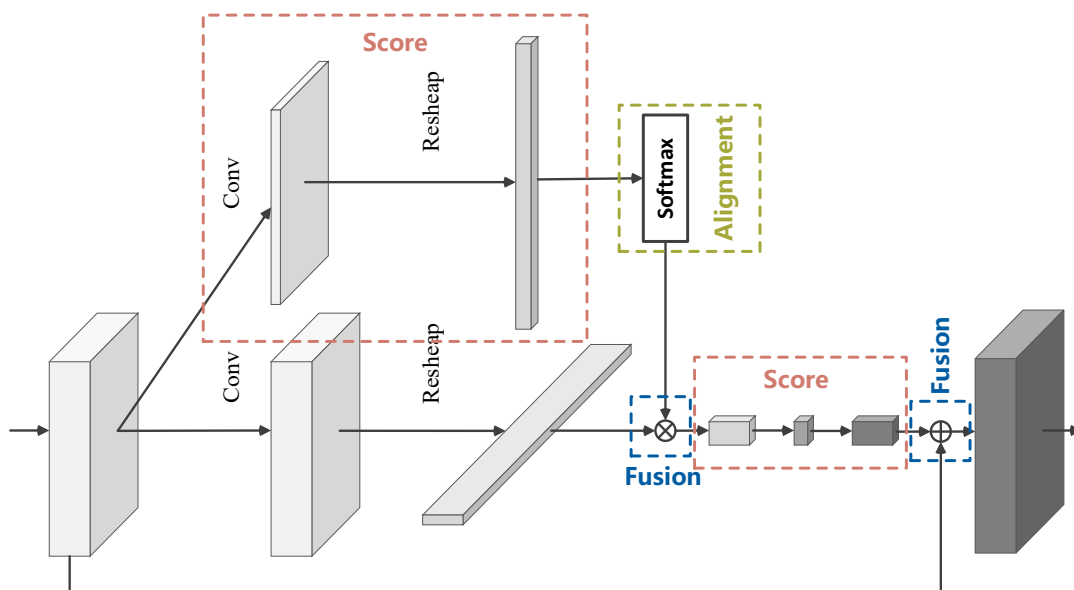


图 2-21 全局上下文注意力 (GCA) 模型结构 (图中简化了 ReLU 和 Layer 规范化层)

2.5 U 型网络

2.5.1 U 型网络结构简介

传统的 U 型网络结构[11]如其名呈现一个 U 字形, 结构如图 2-22 所示。其基本单元由卷积和池化构成: 左半边为编码器, 即是“下采样阶段”, 右半边为解码器, 即是“上采样阶段”; 中间的连线为跳跃连接, 将浅层的特征与深层的特征进行拼接。

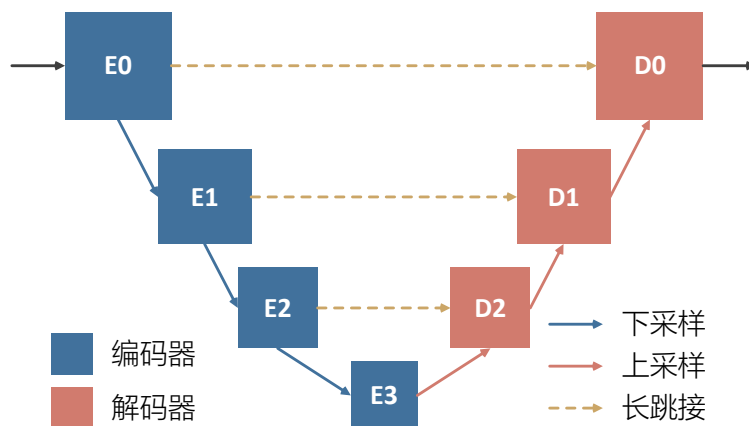


图 2-22 U 型网络基本框架

下采样阶段的作用可归结为：1) 增加对输入图像的一些小扰动的鲁棒性，比如图像平移，旋转等，保持特征的位移不变性；2) 将具体特征变换为抽象特征，提高网络泛化能力，有助于减少过拟合的风险；3) 降低运算量；4) 增加感受野的大小，学习更复杂的上下文特征。下采样技术一般采用池化（平均或最大池化）、步进卷积等。

上采样阶段的作用是引导编码器提取最重要的信息，同时把抽象的特征再还原解码到原图的尺寸。上采样技术包括池化、去卷积等。

跳接是把来自不同域内的特征进行拼接级联，其作用是：1) 因为浅层通常可以抓取图像的一些简单的特征，比如边界，颜色等，而深层经过的卷积操作多抓取到图像的一些抽象特征，将浅层特征和深层特征同时利用起来，能够使解码器包含由于编码器池化下采样而丢失的相关特征；2) 缓解梯度消失问题；3) 使网络能够学习不同金字塔阶层的特征。跳接的两组特征图在 FCN 中采用相加 (summation)，而在 U 型网络中采用级联 (concatenation)。

然而，传统 U 型网络存在一些不足之处：

(1) U 型网络编码器均为局部操作，无法整合全局信息，同时下采样丢失空间信息。U 型网络编码器通常会堆叠卷积层与下采样交叉在一起，逐渐减小特征图的空间尺寸。卷积操作、下采样操作都是局部操作，运用小卷积核进行特征提取。通过级联的方式叠加卷积和下采样操作产生较大卷积核，因此能够聚集较大范围信息。由于很多计算机视觉应用，如场景分割 (semantic segmentation)、图像修复 (image inpainting)、图像去雾/雨 (image dehazing/deraining) 等，通常受益于广泛的上下文信息，因此大多数模型需要深层的编码器，即堆叠更多的局部操作。这样会引入大量训练参数，尤其是在需要更多下采样的时候，因为通常这样特征映射的通道数会加倍。此外，下采样会丢失更多的空间信息。

(2) U 型网络编码器和解码器直接通过跳接相级联，而随着网络层数的加深，卷积层所输出的特征会越来越抽象，前几层网络所获得的特征可能是线条，边缘之类的特征，最后一层则可能是更加抽象的特征。直接连接方式过于粗糙，会造成连接的两个卷积层输入拥有较大的语义鸿沟 (semantic gap)，而这种语义鸿沟会加大网络的学习难度。

2.5.2 改进的 U 型网络

为了解决上述问题，学术界提出了很多具有影响力的模型，包括嵌套 U 型网络、注意力 U 型网络和非局部 U 型网络等。

(1) 嵌套 U 型网络: 嵌套 U 型网络 (Nested U-Net, 即 U-Net++) 的一个基本假设是：当所结合的浅层特征与深层特征语义相似 (semantically similar) 时，网络的优化问题会更简单。因此 U-Net++ 在传统 U 型网络的直接连接的基础之上增加了类似于 DenseNet 结构的卷积层，并融合了下一阶段卷积的特征。在每个阶段都应用于上述策略，则可以得到完整的 U-Net++ 结构。从图 2-23 中可以看出，U-Net++ 是由多个子 U-Net++ 组成的。通过深度监督 (deep supervision) 方法使得每个子网络可以用梯度反向传播进行优化，从而实现不同层级的 U-Net++ 同时训练。应用时，如果考虑时间因素，可以选择较少层级的子 U-Net++；而如果应用时考虑准确性，则选择较深层级的 U-Net++。这种能够同时训练嵌套网络并灵活应用的技术叫做剪枝。

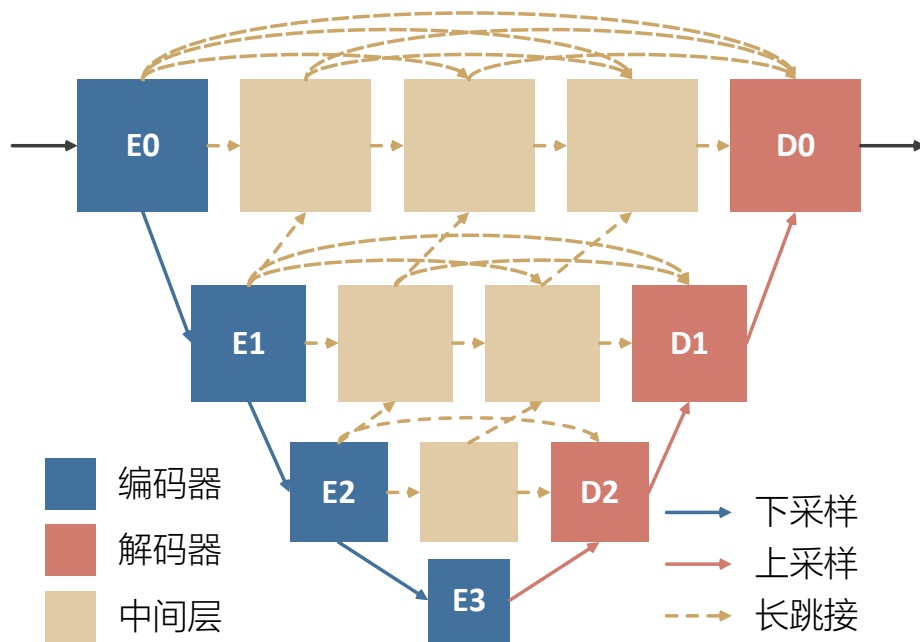


图 2-23 嵌套 U 型网络 (U-Net++) 基本框架

(2) **注意力 U 型网络**：注意力 U 型网络 (Attention U-Net) 模型以传统 U 模型为基础，从图 2-24 可以看出，注意力 U 型网络和传统 U 模型的区别在于进入解码器时，先将编码器提取的特征图和上一层解码器的输出送入门控注意力 (Attention Gate, AG)，再将 AG 的输出和上采样的上一层解码器输出级联。AG 的结构如图 2-11 所示。AG 的作用包括：1) 重新调整了解码器的输出特征。AG 模块生成一个门控信号，用来控制不同空间位置处特征的重要性，从而在一定程度上缓解了语义鸿沟的问题；2) 基于网格的门控，使注意系数更加特定于局部区域。与基于全局特征向量的门控相比，提高了密集度预测的性能。

注意力 U 型网络中的注意力门设计，其实质是用上一层解码器的抽象特征对解码器的输出进行空间上的有效区域增强和无效区域弱化。该注意力门有两个不足之处：1) 该门控模型考虑了编码器输出特征空间上的调整，但没有考虑通道上的调整；2) 对于所有的编码器特征图采用一张空间注意力图进行强化，没有考虑每个特征通道独自的功能。

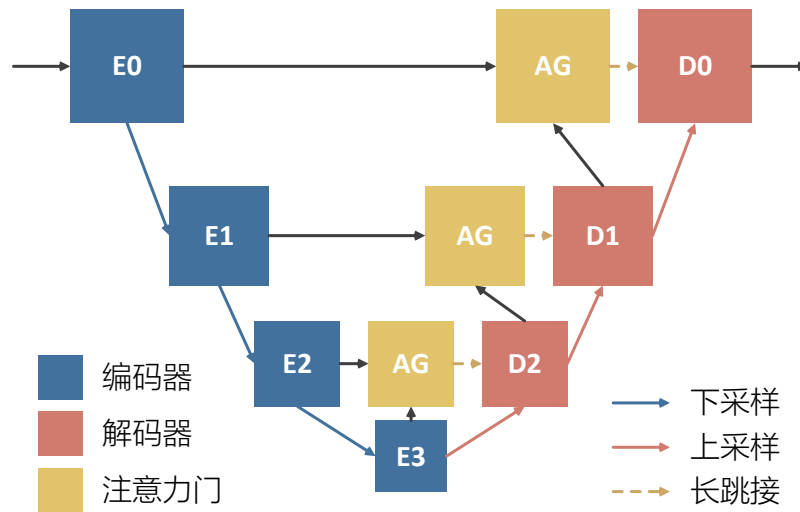


图 2-24 注意力 U 型网络 (Attention U-Net) 基本框架




图 2-25 注意力 U 型网络 (Attention U-Net) 中注意力门 (Attention Gate) 基本框架

(3) 非局部 U 型网络: 非局部 U 型网络 (Non-local U-Net) 解决了传统 U 型网络中, 编/解码器生成的特征图时仅采用了局部 CNN 和池化层。但在学习长距离依赖关系时, 需要大量堆叠卷积层, 这样的结构效率不高。为了解决以上问题, 非局部 U 型网络提出以下几点改进: 1) 基于自注意力模型提出了一个全局聚合模块 (global aggregation block), 用于在上/下采样时可以看到全图的信息。全局聚合模块的结构可以理解为一个多头自注意力模型 (Multi-head

Self-Attention) 的结构，即同时完成若干组自注意力操作；2) 将提出的全局聚合模块作为底层传输模块和编解码器模块（其中询问 Q 的卷积操作略有不同、残差路径设置不同），提高了 U 型网络的全局长距离依赖关系学习能力；3) 由于全聚合模块计算量较大，对 U 型网络做了参数上的优化，如将跳接时特征图的级联改为元素相加，一方面减少参数量，提高推理速度，另一方面相加可以视作残差连接，在训练中仍然有效。另外，由于非局部 U 型网络具备学习全局上下文的能力，网络不需要大量卷积层的堆叠，整个 U 型网络只有 3 个阶段。

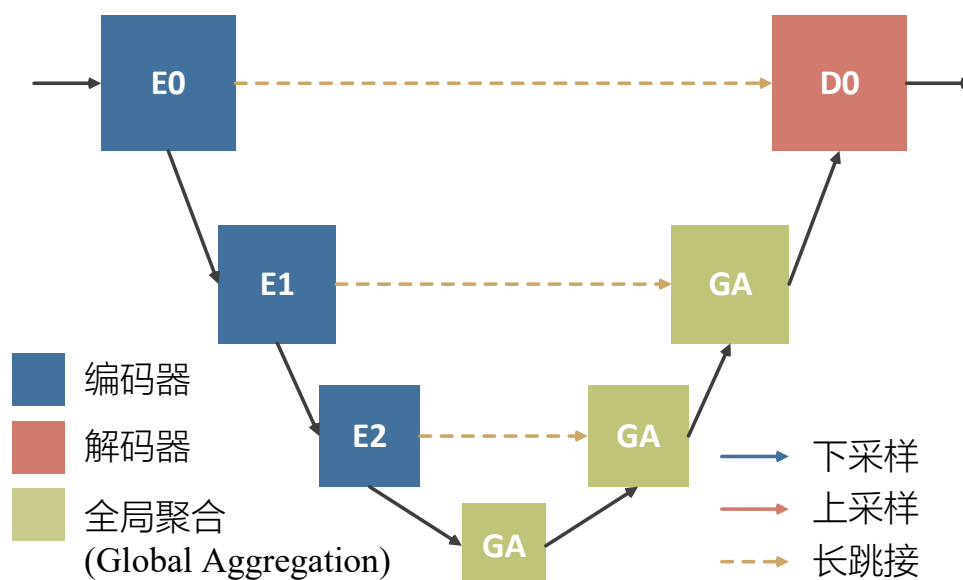


图 2-26 简化的非局部 U 型网络 (Non-local U-Net) 基本框架

非局部 U 型网络的不足表现在：1) 为了减少整个网络的训练参数，非局部 U 型网络选择跳接相加，而不是跳接级联，这种连接方式一方面没有有效地缓解语义鸿沟的问题，另一方面将低阶编码器特征图中的噪声直接加入了解码器中；2) 由于全局聚合模块的高内存消耗和高计算复杂度，其局限于使用在底层传输和解码器中，没有在低阶和编码器模块中使用。

2.6 本章小结

本章从人类视觉感知特征的角度分析了注意力模型和 U 型网络的原理和理论依据：调节注意力（SLA）模型的功能近似于人类视觉关注和视觉掩盖特征；点积注意力（DPA）模型的功能体现了人眼观察事物的非局部特征；U 型网络的特点，体现了人类视觉对边缘、形状信息的敏感。因此，将注意力模型与 U 型网络的结合，是多层次感知特征的结合，能更有效的映射和模仿人类视觉感知特征。

然后，分别对各种注意力模型和改进的 U 型网络展开深入探讨。针对注意力模型的研究工作表明，注意力模型的基本框架包括打分函数、校准函数和融合三个步骤。其中，校准函数和融合是注意力模型的基本，体现了模型对重要信息增强和无效信息弱化的作用。而根据应用场景的不同，影响注意力模型效果的环节在于打分函数的设计。根据打分函数计算方式的不同，将注意力模型分为 SLA、DPA 和 GCA。其中，SLA 是通过特征图空间或通道维度上的信息进行全局聚合得到有效信息的通道或空间上的分布特征；DPA 是通过特征图点乘的方式学习位置间的长距离依赖关系；GCA 通过计算与询问无关的全局上下文信息。

针对 U 型网络的研究中表明传统 U 型网络存在一定的不足，例如特征学习的局部性和跳接特征间的语义鸿沟等。现有的注意力 U 型网络在一定程度上解决了语义鸿沟问题，但没有解决全局上下文信息建模的问题。而现有的非局部 U 型网络较好的实现 U 型网络对全局上下文信息的建模，但由于非局部注意力模型的高计算复杂度，在 U 型网络结构上做出部分牺牲，一定程度上影响了网络对局部特征的学习能力和对噪声的抗干扰性。

参考文献

- [1] LeCun Y. LeNet-5, convolutional neural networks. URL: <http://yann.lecun.com/exdb/lenet>, 2015, 20(5): 14.
- [2] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks. Advances in neural information processing systems, 2012, 25.
- [3] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556, 2014.
- [4] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 1-9.
- [5] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.
- [6] Zhang X, Zhou X, Lin M, et al. Shufflenet: An extremely efficient convolutional neural network for mobile devices. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 6848-6856.
- [7] Bahdanau D, Cho K, Bengio Y. Neural machine translation by jointly learning to align and translate. arXiv preprint arXiv:1409.0473, 2014.
- [8] Luong M T, Pham H, Manning C D. Effective approaches to attention-based neural machine translation. arXiv preprint arXiv:1508.04025, 2015
- [9] Xu K, Ba J, Kiros R, et al. Show, attend and tell: Neural image caption generation with visual attention. In: International conference on machine learning. PMLR, 2015: 2048-2057.
- [10] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need. Advances in neural information processing systems, 2017, 30.
- [11] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. In: Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference,

Munich, Germany, October 5-9, 2015, Proceedings, Part III 18. Springer
International Publishing, 2015: 234-241.

第 3 章 深度学习的特征及模型压缩

3.1 背景介绍

深度神经网络是典型的过参数化建模，网络参数规模巨大，最新的语言大模型参数量达到了惊人的万亿量级。超大规模的网络对计算和存储的要求很高，无法广泛部署于实际场景中去，因此神经网络的压缩成为一个热门的研究领域。同时，深度学习模型中间层特征压缩与传输是深度学习领域新兴的一个研究热点，是实现前端-云端智能协作的一项重要技术手段。目前，越来越多的深度学习视觉任务以边缘-云端智能协作的方式进行部署，以实现用户端和服务端资源的负载平衡和高效利用。本章节对深度学习中的模型压缩以及中间层特征压缩技术的最新进展以及关键技术环节进行了全面综述。

3.2 深度学习模型压缩

近年来，卷积神经网络在计算机视觉任务中取得了无与伦比的成功，如分类、目标检测、分割等。例如，2012 年提出的 AlexNet[1] 在当年的 ILSVRC (ImageNet Large-Scale Visual Recognition Challenge) 竞赛中获得冠军，开启了研究神经网络的热潮。以至于后来出现了众多优秀的网络模型，例如 VGG[2]、ResNet[3] 等。

然而，卷积神经网络 (Convolutional Neural Network, CNN) 出色的任务性能也带来了许多不可避免的问题：1) 训练代价高。虽然用于训练网络模型的 GPU (Graphic Processing Unit, GPU) 算力不断的在发展，但是训练一个性能良好的网络往往可能要花费几天甚至几周的时间。此外，训练模型还需要巨大的数据集作支撑。2) 部署困难。一个训练好的网络模型之所以性能优异，离不开其复杂的网络结构和庞大的参数量。例如 AlexNet 拥有 5 层卷积层和 3 层全连接层，60 万个网络节点、0.61 亿个网络参数，需要 240MB 存储空间，当 AlexNet 对一副 224×224 大小的图像做分类时需要进行 7.29 亿次浮点运算。较大的内存占用和较高的计算复杂度阻碍了 CNN 在内存和计

算资源受限的终端部署。

为了减少存储和计算负担，许多学者致力于研究 CNN 的压缩技术。目前的 CNN 压缩技术大致可以分为剪枝 (Pruning)、知识蒸馏 (Knowledge Distillation)、和量化 (Quantization)。剪枝的思想旨在通过丢弃模型中非关键的冗余参数和连接来降低模型的参数量、简化模型的结构；知识蒸馏的思想是基于“教师-学生网络”，即已经训练好的神经网络（教师网络）的知识被提取到另一个神经网络（学生网络）中；量化是将浮点型的权值参数转换为低比特的定点整数，从而达到加速网络的训练和推理或者降低网络存储空间的效果。本章将以剪枝、知识蒸馏、量化的顺序进行介绍。

3.2.1 剪枝

模型剪枝使用最为广泛，它的基本思想是通过在预训练的深度神经网络模型中剪除冗余的、信息量少的权重，将网络结构稀疏化，从而降低内存开销，加速推理过程。剪枝方法包括非结构化剪枝和结构化剪枝。非结构化剪枝是最细粒度的方法，其操作对象是滤波 (filter) 中的每个权重；而结构化剪枝的操作对象是整个滤波器，乃至整个卷积层这样的结构化信息。

Hanson 等[4]提出了基于有偏权重衰减的剪枝方法，是对网络稀疏化最早的探索。Hassibi 等人[5]根据损失函数的 Hessian 矩阵减少了连接的数量，使网络结构高度稀疏化。Srinivas 和 Babu[6]从神经元之间存在冗余的角度出发，提出了一种不依赖训练数据的剪枝框架，计算节点的冗余程度并进行删除。Han 等人[7]提出批量减少整个网络中的参数量和运算量，该方法规定的三阶段剪枝流程被广泛沿用，即训练权重、模型剪枝、重训练。Chen 等人[8]提出了 HashedNets 模型，引入哈希函数，根据参数间汉明距离将权重分组，实现参数共享。然而，受限于底层硬件和计算库的支持，非结构化剪枝通常会构成非结构化的稀疏矩阵，在计算过程中会造成内存获取的不规则性，影响

硬件工作效率，降低计算速度。因此，近年来研究者们致力于探索基于结构化剪枝的压缩方法。

基于结构化剪枝的方法克服了无法对稀疏矩阵计算进行加速的问题。此类方法遵循滤波显著性准则（即判别滤波对于模型性能重要性的准则），直接批量地剪除非显著性滤波，达到压缩目的。Wen 等人[9]利用 Group Lasso 对模型中不同粒度的结构，包括滤波、通道、滤波形状、层深度（filters, channels, filter shapes, layer depth）进行正则化，并将此正则化项加入目标函数，进行结构化稀疏训练。Zhou 等人[9]向目标函数中加入稀疏性局限（sparse constraints），然后在训练阶段通过稀疏限制减少神经元数量。该方法针对其特殊的优化过程还提出前后项分裂法，其作用是在标准的反向传播过程中，可以绕过不易求导的稀疏限制项。通过计算滤波的范数值，直接判断滤波的重要性的方法也相继被提出[11]，该方法首先计算所有滤波的 L1 范数，逐层删除范数值低于阈值的滤波，同时移除该滤波在当前层生成的特征图（feature map）以及该特征图在下一层中对应的滤波通道，剪枝后再进行重训练，恢复模型的精度。Liu 等人[12]提出一种介于粗、细粒度之间的通道级别剪枝。该方法向存在于每个卷积层的批量标准化（Batch Normalization）中的缩放因子 γ 添加稀疏正则限制，并将此正则项加入目标函数，与模型损失函数联合训练，受正则化限制，部分缩放因子将衰减至接近 0 的区域。由于批量标准化中超参数 γ 的大小能够直接改变特征图的分布，进而影响模型的表达能力，因此较小的缩放因子对应着全局贡献度较低的通道，对这些通道进行剪除，再通过微调（fine-tune）恢复模型精度，有效降低了网络的复杂度。不同于前述方法，Luo 等人[13]越过当前层滤波，着眼于下一层滤波通道的显著性，建立了一个有效的通道选择优化函数，实现对下一层卷积核中冗余通道及其对应当前层滤波的剪枝。

上述非结构化、结构化剪枝属于人工设计的剪枝方案，设计过程

中需要人为考虑模型大小、推理速度和精度之间的权衡，因此人工设计往往需要耗费较长时间，部分设计可能只得到次优化的结果。近年来基于自主机器学习（AutoML）与神经架构搜索（Neural Architecture Search, NAS）的剪枝方案陆续被提出。He 等人[14]基于强化学习的思想，对精度损失进行惩罚，同时鼓励模型简化和加速，实现自动化剪枝。Yu 等人[15]提出一种单次不循环的方法，此法训练一个单一的可瘦身网络来近似不同通道结构网络的精度，然后迭代地评估训练后的可瘦身网络，在最大限度保持精度的前提下对各层进行贪婪剪枝。2020 年，滴滴 AI 实验室提出一种新的自动化压缩方法[16]。该方法是经验导向型的搜索方法，弥补了基于强化学习的搜索与剪枝问题不完全兼容的缺陷，通过自动搜索进程来确定剪枝策略组合、逐层剪枝比例以及其他超参数。

基于模型剪枝的压缩方法具有直观的物理意义，在实际应用中也展现出理想的压缩性能，但该方法也存在一定缺陷。首先，相比于其他压缩方法，基于 L1 或 L2 正则化的剪枝收敛较慢，需要更多次数的迭代训练。其次，剪枝相当于优化网络的整体结构，对具有不同结构特点的网络模型往往不能采用完全相同的剪枝策略。对于不同类型网络在不同训练数据集下的剪枝方法还不能完全统一。此外，人工设计的剪枝方法需要根据不同层级的敏感度，手动调节剪枝阈值，重复微调参数，实现过程繁琐。而自动化剪枝能够综合评估多种剪枝方案，自动搜索最优结构，确定复杂的超参数，但对于大型网络来说，搜索空间过于庞大，对算力要求极高，耗时较长。

3.2.2 知识蒸馏

基于知识蒸馏的方法的核心思想是将大型教师网络的知识迁移到小型网络中，这一过程是通过学习大型网络 softmax 函数的类别分布输出来完成的。Caruana 等人[17]首次提出基于知识迁移（Knowledge Transfer）的深度神经网络压缩方法。该方法主要研究

内置强分类器的集成模型，在输入经伪数据标记的样本后，经过训练，重现了大型原始网络的输出。

Hinton 等人[18]认为训练集中采用 one-hot 编码的标签信息熵极低，而 softmax 分类器输出的分类概率能够体现出模型对不同类别的置信度，同一个输入关于不同类别的置信度恰恰定义了数据层面丰富的相似结构，这些信息对网络来说有着极高的学习价值。因此，他们提出了完整的知识蒸馏 (Knowledge Distillation) 思想，如图 3-1 所示，通过教师-学生模式，将教师网络 softmax 分类器输出的软知识蒸馏出来，辅以硬知识，即真实标签，同时作为训练学生网络的知识，在提升训练效果的同时实现了对原网络的压缩。Romero 等人[19]的工作基于知识蒸馏的思想，提出将通道数多而层级较浅的大型网络压缩为通道数少而层级更深的学生网络，并将该网络称作 FitNets。该方法先确定双方网络相匹配的中间层级，然后将教师网络中部的特征图作为学生网络对应位置的近似目标，这在 softmax 输出的基础上进一步丰富了学生网络的先验知识。Zagoruyko 等[20]提出了注意力迁移方法 (Attention Transfer)，放宽了 FitNets 方法所提的假设。该方法所迁移的注意力图 (attention map) 是激活后的多通道特征图的总和。知识蒸馏领域还有一些延伸性研究。Goodfellow 等人[21]通过将知识从旧网络即时传输到新的更深或更广的网络，加速了实验进程。Korattikara 等人[22]中的方法基于在线学习的思想，以近似蒙特卡洛教师模型为目标，对学生模型进行参数化训练。Zhu 等人[23]用高阶隐层中的神经节点作为先验知识，这类神经节点具有与标签概率相当的信息量，但是更加的紧凑。采用“自学”思想的知识蒸馏方法近期也广受关注。Zhang 等人[24]提出一种通用的自体蒸馏训练框架。不同于传统蒸馏方法中，使学生网络输出逼近教师网络 softmax 输出的思想，自体蒸馏不借助外部网络，而是将网络本身切分，以深层网络的知识来指导浅层网络。工业应用中，知识蒸馏的训练可能会受到训练

数据匮乏以及教师网络内部结构未知的影响，蒸馏效果会大打折扣。为解决此问题，Chen[25]等人结合生成对抗网络思想，提出了一种不依赖于训练数据的蒸馏方法，该框架中将预训练的教师网络作为判别器，只训练生成器，最终得到与教师网络兼容性高的生成数据，将其作为蒸馏过程中学生网络的训练数据，从而弥补未知的教师网络内部结构对压缩效果造成的影响，提升了知识蒸馏在实际场景中的实用性。




图 3-1 知识蒸馏基本原理示意图

基于知识蒸馏的压缩方法相当于用一个神经网络训练另一个神经网络，将大型复杂网络的知识迁移至小型简易网络中，利用小型网络来实现拥有与大型网络相同优越的性能和良好的泛化能力，并且显著降低了所需存储空间和计算资源。知识蒸馏的缺陷之一是只能应用于具有 **soft-max** 分类器及交叉熵损失函数的分类任务，应用场景较为局限。另一个缺点是与其它类型的方法相比，基于知识蒸馏的压缩方法在大型数据集的表现略差。

3.2.3 量化

量化是指将高精度的 32 位浮点数 (FP32) 转换为低精度的 16 位浮点数 (FP16) 或 8 位定点数 (INT8)，甚至是更低比特的定点数。均匀量化是使用最广泛的方法，利用一个比例因子将浮点值映射到定点值。

$$x_q = clip\left(round\left(\frac{x}{\Delta}\right), -2^{b-1} - 1, 2^{b-1} - 1\right) \quad (1)$$

混合精度则是在模型中使用 FP32 和 FP16。通过牺牲一定的精度

来换取网络模型在训练和推理时所占用的计算资源。除此之外也有学者专注于减少模型存储空间的深度压缩工作。

量化方法按照量化流程主要分为两大类，量化感知训练(Quantization-Aware Training, QAT)[31]和训练后量化(Post-Training Quantization, PTQ)[32]。量化感知训练即训练时量化，为了和训练后量化在名称上对应，在后面的描述中使用训练时量化。图 3-2 展示了训练时量化和训练后量化的流程。训练时量化可以在训练的过程中弥补量化误差，从而生成精度下降较低的量化网络，但是训练网络模型需要训练集、较长的优化时间和超参数的调优。因此，当训练集不可用或需要快速部署时，训练时量化不是最优的选择。而训练后量化在训练后使用校准数据集对网络进行量化，可以实现快速量化和部署。校准数据集可以从训练集中随机抽取一小部分，也可以是无标签的真实数据集。量化方法在 CNN 压缩中表现出了极大的有效性和多功能性，无论训练后还是再训练，量化方法都可以在不同的速率-准确率权衡下获得非常低的比特率。

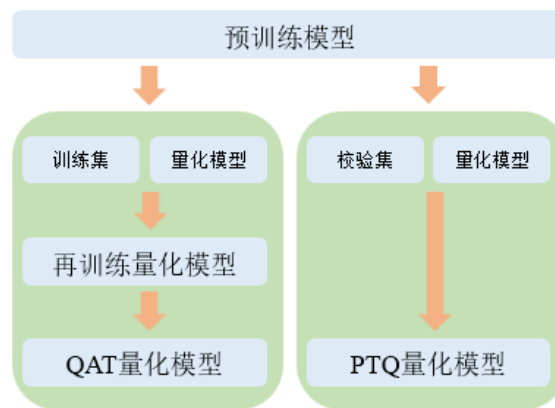


图 3-2 QAT 与 PTQ 量化流程

量化感知训练是训练相关的，即在模型训练时引入量化操作，在模型训练的总损失中融入了量化误差，以减少模型精度的丢失。除了可以优化权值的量化参数外，QAT 对于优化激活的量化参数更加有效，因为激活值是与输入数据强相关的。例如，参数化裁剪激活函数

(Parameterized Clipping Activation, PACT) [45]提出了一种新的激活量化方案，它可以在网络模型训练期间自动优化激活的量化参数。注意到用于量化的公式(1)是不可微的，因此在重新训练时反向传播阶段的梯度无法求得。一种通常的做法是使用直通估计器 (Straight-Through Estimator STE) 来近似梯度。QAT 虽然在量化的过程中需要额外的模型训练，但是能够使量化模型获得更高的精度。

训练后量化在不需要训练过程的情况下，就能将预训练的 FP32 模型量化为低比特的模型。PTQ 通常不需要数据或者只需要很少的校准数据集，因此，在数据缺乏以及需要快速部署的场景中，PTQ 通常是模型量化的最优选择。

3.2.3.1 二值量化和三值量化

当网络模型中的权值被量化到极低比特时，例如 2 比特，可以将使用位运算来代替乘法运算，以提升网络模型运行速度和降低硬件功耗。目前以这种方式量化的网络模型的有二值量化和三值量化两种类别。二值量化将权值量化到 1 比特，其中两个可表示的值通常为 $\{-1, +1\}$ 。使用这两个值，可以舍弃乘法运算，用加法、减法、和简单的逐位运算来替代网络模型中的计算。然而，如此低的比特表示往往会导导致网络模型的性能严重下降，因此研究人员开发了三元权值网络。三元权值网络的值被限制在 $\{-1, 0, +1\}$ 三个值之间，有助于恢复网络模型的性能。三元权值网络仍可使用位运算代替乘法运算，从而加速网络模型运行。

二元权值网络 (Binarized Weight Network, BWN) 是将网络模型的权值限制为 -1 和 +1 两个值。该想法首次被提出是在 BinaryConnect[32]中。在网络模型训练过程中，BinaryConnect 对权值进行二值化处理，即将原来权值的全精度浮点数值强制限制为 -1 和 +1，同时保留网络输入和各层之间的中间值的原有精度，特别需要强调的是更新网络模型参数时使用的仍然是全精度浮点数。在训练完成后，

由于权值只有两种值,可以使用更低的比特表示,从而降低存储开销。更重要的是,网络模型中权值二值化的特点可以用加法运算代替乘法运算来实现网络加速。借助于 BWN 出色的表现,人们开始在二元权值的基础上进行更深入的研究,以实现更进一步压缩。其中,同样是由 Matthieu Courbariaux 等人提出的二值神经网络(Binarized neural networks, BNN)^[34],在 BWN 的基础上通过进一步扩展二值化的对象,即将网络模型训练时的中间值也二值化。同样的,由于网络模型的参数是二值化的,乘法运算由加法运算来代替。在 BNN 这项工作中,提出了一种训练二值化神经网络的方法,即在推理时具有二值化权值和激活的神经网络,值得注意的是在网络模型训练时计算梯度使用的是二值化的参数。同时将大量的算术运算替换为位运算,这就意味着网络在训练和推理时能大幅提速。

同或网络(XNOR-Net)^[35]通过对网络模型中的权值和激活二值化,引入了一种简单、高效、准确的 CNN 近似。由于在 BNN 中权值的二值化是通过一种称为直接二值化的方法实现的,即根据权值的正负来决定权值是+1 还是-1,这样的方法势必会给每层的数据造成严重的误差。而在 XNOR-Net 中,为了弥补这种二值化带来的误差,引入了一个比例因子来对权值 w 进行近似二值化。这样在降低能耗和加速网络模型的同时还能保持网络模型的精度。在此基础上,同样是引入了一个比例因子来降低误差,XNOR-Net 对网络模型的每一层输入进行了二值化。然而,当参与卷积运算的操作数均为二值化的参数时,可以将卷积运算替换为同或运算和位计数运算,从 32 位浮点数之间的操作直接变成 1 位的同或门操作,这就是加速的核心。此外,XNOR-Net 还尝试了改变网络模型的结构。在一个典型的 CNN 模型中,卷积模块往往是卷积、批正则化、激活、池化的顺序;而在 XNOR-Net 中,将此顺序改为了批正则化、激活、卷积、池化,这样的尝试可以显著提高 XNOR-Net 的性能。因为在二值化之前先进行批

正则化可以保持输入数据零均值，因此在零处二值化可以减小量化误差。另外，池化层的输入如果是二值化的，在池化操作后会有严重的信息丢失。例如经过最大池化操作后的输出值大部分都是+1。这样的输出作为下一个卷积模块的输入会导致严重的误差。

最近提出的工作 Binary CNN (BCNN)^[36]对二元权值量化进行了拓展。BCNN 使用 1×1 的二元权值卷积核与 3×3 的普通卷积核为基本卷积块，如图 3-3 所示，构建了一种新的 CNN 架构。不同于传统 CNN 架构，BCNN 将输入图像拓展为 4 通道，同时中间层的特征图通道数控制为 2^k 个，这有助于硬件层面实现网络模型的加速。同时，为了提高 BCNN 的表达能力，将 1×1 的二元权值卷积核由单分支设计成并行分支结构，如图 3-4。每个分支都有不同的偏置、二元权值和批正则化参数。BCNN 为构建二元权值网络模型提供了结构基础。

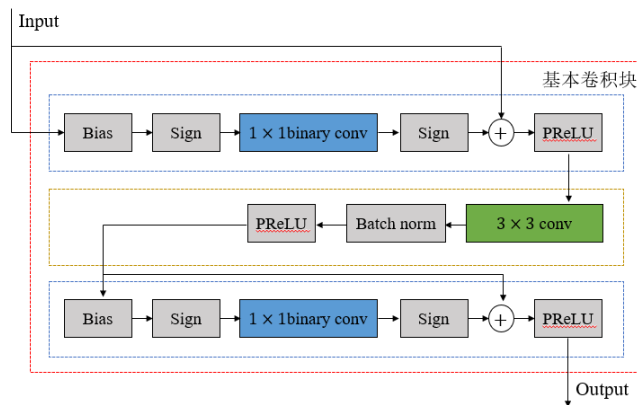


图 3-3 BCNN 的基本卷积块

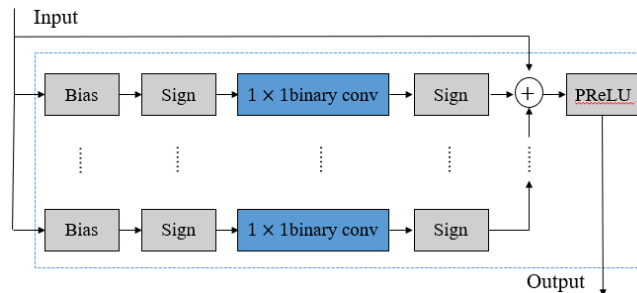


图 3-4 并行分支

三元权值网络 (Ternary Weight Network, TWN)^[37]是权值限制

为-1、0、+1的神经网络。相较于二值网络，表征能力得到加强，是二值网络 and 全精度网络之间的一个平衡。最常用的卷积核的大小为 3×3 。对于二进制精度，只有 $2^{3 \times 3} = 512$ 个模板。然而，同样大小的三值卷积核拥有 $3^{3 \times 3} = 19683$ 个模板，其表达能力比二进制卷积核增强38倍。在量化权值的策略中，不同于XNOR-Net引入比例因子那样近似权值，而是以此为基础计算出一个量化阈值，将数值大小处于阈值内的权值量化为0，在量化阈值之外的权值量化为-1和+1。对于阈值的计算，作者也给了论证，能够最小三值化误差所带来的精度损失，还能够使神经网络权重稀疏化，减小计算复杂度的同时也能得到更好的准确率和泛化能力。TWN将压缩问题转化为优化原始权值与三元权值之间欧式距离的问题，在运行效率上，TWN与BWN相当，但是准确率却有着明显的提升，在ImageNet验证数据集上的Top-1比BWN高11%，比TWN高10.6%。

二元权值量化与三元权值量化将神经网络的权值和激活量化位为-1、0、+1，这种量化方式对神经网络的性能造成严重损害。一种补救措施是使用一些全精度的比例因子来近似权值和激活。例如，研究人员从神经网络的参数中为每个通道上的卷积核参数学习一个全精度的比例因子[38]；文献[39]将二值化和三值化的比例因子作为可训练的参数。在文献[40]中，证明低秩矩阵与符号函数相结合，可以近似表示神经网络中的参数。在此基础上，将二值量化和三值量化拓展为 k -值量化。该方法是一个QAT方法，是在神经网络训练的过程中对权值和激活进行量化。因此，在训练的过程中需要根据权值和激活实时计算比例因子 v_i ，并且存储 v_i 以在神经网络推理时使用。在神经网络推理的过程中保持权值和激活的量化，可以加速神经网络推理。

3.2.3.2 定点量化

将神经网络中的权值和激活由32位浮点型转换较低比特的整数或定点小数即为神经网络量化，量化后的神经网络可以在硬件上部署

时成本更低。文献[41]表明，可以将神经网络的权值与激活量化为 8 位整数。而在最近的工作中[42]，实现了 2 位整数的量化。

文献[43]提出了一种新的增量网络量化（Incremental Network Quantization, INQ）方法，并没有特殊网络架构，而是旨在将预先训练好的全精度卷积神经网络（CNN）模型有效地转换为低精度模型，即一套训练方法，该模型的权值被限制为二次幂或零次幂。这种低精度模型的优点是，在专用硬件（如 Field Programmable Gate Array, FPGA）上，原始的浮点乘法运算可以被更方便的二进制位移位运算所取代。在以往的方法中，大多数的网络量化方法都是采取一种全局的策略，将网络模型中的所有权值都同时转换为低比特的权值。换言之，这些方法没有考虑到权值之间的不同重要性，因此导致性能下降明显。在此基础上，INQ 提出了权值划分、分组量化、再训练三个相互依赖的操作。权值划分受到剪枝（另一种网络压缩的思想）的启发，将预先训练的全精度网络模型的每一层中的权值划分为两个不相交的组，这两个组在 INQ 中起着互补作用。其中一组权值被量化，从而为原始模型形成一个低精度的基础。在保持量化权值固定的同时，对另一组中的权值进行重新训练，以补偿量化导致的精度损失。这项工作的不足之处在于只考虑了权值的量化而未考虑激活和梯度的量化。

DoReFa-Net^[44]首次尝试量化反向传播期间的梯度，是一种以低比特梯度训练网络模型的方法。针对网络模型不同层的权值、激活和梯度设置不同的量化位宽也是该方法的亮点之一，以此来权衡模型性能和量化误差。DoReFa-Net 作为一种训练方法能够很好地应用于多种经典的网络模型。虽然对梯度量化可以进一步加速网络，但是梯度对于量化更为敏感，所以又额外引入了一项随机噪声来弥补量化误差。参数化裁剪激活函数（Parameterized Clipping acTivation, PACT）^[45]提出的激活函数量化方案引入了可学习的裁剪参数。一般的神经网络

模型中采用的 ReLU 函数是无上界的，这种高动态的范围在量化时势必会引起巨大的量化误差，利用裁剪参数截断激活函数的输出来降低量化误差。由于层与层之间以及模型与模型之间的差异，无法找到一个裁剪参数的全局最优值，需要在模型训练时与其他参数一起训练。

还有工作[46]提出一种仅由定点 8 位乘法组成的新型量化框架 (Fixed-Point 8-bit Only Multiplication for Network, F8Net)。在这项工作中，研究人员首先讨论了不同格式的定点数的定点乘法的优点，并研究了相关的不动点数的统计性。其次，基于统计和算法分析，对不同层的权值和激活应用了不同的定点格式。还引入了一种在训练过程中自动确定每一层的定点格式的新算法。最后，还将提出的算法拓展到了之前的工作 PACT 上。与 F8Net 相似，文献[47]根据神经网络每层参数的分布来匹配定点格式，使用该方法量化的 ResNet18 在推理时消耗地能量仅为未量化的 17~30%。

3.2.3.3 混合精度量化

在以往的量化方法中，对神经网络中的参数都采取统一的量化位宽。尽管之前的工作[44]，为权重、偏置和激活选择了不同的量化位宽，但在每种类型的参数中，量化位宽仍然是一致的。首先，对于定点量化，在神经网络中存在一些对网络性能敏感的层，为了保持神经网络的性能，这些敏感层会被分配更多的量化位宽；那些相对不敏感的层也会因此被分配相同的量化位宽，这会导致次优的压缩效果。其次，如果将神经网络二值量化或三值量化，神经网络的参数被限制在 1 比特或 2 比特范围内，这会导致神经网络的性能严重下降。

混合精度量化试图将之前的量化方法组合在一起来解决这些问题。量化粒度从神经网络本身下降到了神经网络的层级别。混合精度量化首先识别出神经网络中哪些层的参数需要被分配更多的量化位宽，剩余层的参数则被分配较少的量化位宽。因此，在不严重损失网络性能的情况下实现了最优的压缩效果。

文献[48]提出了一种用于深度卷积神经网络的量化器。在没有模型微调的情况下，将浮点深度网络转换为定点深度网络，本质上是一个将量化噪声引入神经网络的过程。浮点数值到定点数值的表示有三个依赖的参数：位宽、步长、动态范围。这项工作首先分析了不同分布在特定位宽下的步长，不同卷积层中权值与激活的分布如图 3-5 所示。例如，假设输入是一个高斯分布，将输入量化到 2 个比特时，最好的方法是将量化值放置在 -1.494、-0.498、0.498 和 1.494，即步长是 0.996。这项工作通过分析信号量化噪声比（Signal Quantization Noise Ratio, SQNR）和位宽之间的近似线性关系，指出在预训练的深度卷积神经网络模型中 SQNR 的值在 2~4dB/bit 之间。值得注意的是，在网络模型中，权值和激活（应用激活函数之前）的分布近似于高斯分布。任何浮点数值深度卷积神经网络模型都可以通过三步转换为定点数值：

- (1) 首先以浮点数值运行前向传播过程并记录激活情况；
- (2) 收集网络模型中每层的权值、激活、偏置的统计信息；
- (3) 根据数值的分布范围确定小数点的位置，即确定小数的有效位数。

众所周知，在音频处理或数字通信等领域，随着量化噪声的增加，系统性能会下降。量化的效果可以在一个单独的量（SQNR）中准确捕获。这项工作通过构造 SQNR 与权值、激活之间的关系发现，深度卷积网络中一层输出的 SQNR 是所有前面量化步骤的 SQNR 的调和平均值。这意味着所有量化步骤对输出的整体 SQNR 都有相同的贡献，无论是权值量化还是激活量化，也不管发生在哪里（网络的顶部或底部）；由于输出 SQNR 是谐波平均值，网络性能将由最短的量化步长决定。例如，如果某一层的激活比其他层的比特宽度小得多，这将成为网络性能的瓶颈；此外，网络模型的深度也是量化的挑战之一。在给定条件下，即 SQNR 与权值、激活之间的关系，优化每一层的 SQNR 即可确定适用于每层的量化位宽。




图 3-5 ImageNet2012 数据集上 ResNet18 中权值和激活值的分布

在最近的工作中[49]，同样使用 SQNR 来测量神经网络每一层在不同量化位宽下对网络性能的影响，并依此建立一个灵敏度列表。该方法首先将神经网络的所有层量化到尽可能高的位宽，之后，基于创建的灵敏度列表，迭代地将最不敏感的层量化到较低的位宽，直到满足所要求的量化位宽。

变换量化（Transform Quantization, TQ）[50]提出通过变换量化对预训练的卷积神经网络的权值进行压缩，是一种 PTQ 方法。以往的量化工作往往忽略了权值和激活之间的统计信息，或者在网络模型训练时考虑它们的统计信息，导致次优的压缩性能。在网络模型中，权值往往存在冗余，这也是能实现网络压缩的原因之一。因此，作者引入一种去相关变换对权值进行解耦，这样可以更有效的量化权值，如图 3-6 所示。对权值使用最简单的均匀量化器，那么网络压缩问题就可以看成是最小化量化网络的输出与原始网络的输出之间的误差，即寻找最优比特分配和最小输出失真之间的权衡。在此基础上，通过计算对权值进行去相关变换的编码增益，确定了去相关变换的有效性。因为在网络模型中，层与层之间、通道与通道之间的权值对于网络模型的重要性不尽相同，考虑到这一点，文章还加入最优比特分配规则，即为每一层分配最优位宽，由此建立了率-失真理论，将最优量化问题转化为一个率-失真优化问题。这项工作应用于 ImageNet2012 数据集上的预训练分类网络模型 AlexNet、ResNet、DenseNet[51]，表现非

常出色。此外，该方法还应用于图像超分辨率网络，也取得了良好的效果。




图 3-6 卷积核的变换量化

Hardware-Aware Quantization (HAQ) [52]是一种 QAT 方法，从神经网络硬件模拟器上运行的延迟以及能量消耗的角度出发，在满足给定资源约束的条件下，利用强化学习找到最佳混合精度位宽的分配。比特稀疏量化 (Bit-level Sparsity Quantization, BSQ) [53]是另一种 QAT 方法。在这项工作中，分配于每个权值的比特被独立对待，将一些权值置为 0，促使产生稀疏且较低的量化位宽。与之前的混合精度量化方法相比，虽然 BSQ 将神经网络的第一层和最后一层的量化位宽固定在 8 比特，但是 BSQ 在实现更好压缩效果的同时保持了最优的网络性能。

3.2.3.4 其他

对于典型的网络，约 90%的存储被密集连接层占用，90%以上的运行时间由卷积层占用。因此，在矢量量化[54]中重点关注如何压缩密集连接层以减少神经网络的存储。文章分析对比了参数二值化、K-means 聚类和使用乘积量化或残差量化的结构化量化。作者发现简单地应用 K-means 聚类可以获得非常好的结果，且优于矩阵分解方法。结构化量化是探索矢量空间中的冗余的一种矢量量化方法。结构化量化方法可以通过探索参数中的冗余来获得额外的增益，特别是乘积量化明显优于其他方法。该工作是第一次系统地研究使用不同的矢量量化方法来压缩网络模型。对于网络模型中的密集连接层的压缩，文中首先介绍了矩阵分解的方法。矩阵分解已经被广泛应用于加速卷积神

神经网络，通常情况下使用的是奇异值分解（Singular Value Decomposition, SVD）来分解权值矩阵，这里不再赘述。下面介绍矢量量化的方法。第一种矢量量化的方法是二值化量化，同样是受到Dropconnect的启发，Dropconnect的策略是在网络模型训练期间根据概率将部分参数随机置为0，二值化根据权值的正负将权值强制置为+1和-1两个值。因为权值是由一位表示，所以二值化实现了32倍的压缩。第二种方法是K-means聚类。对于网络模型中的权值，一般是一个四维张量，而四维张量中的每一个元素是一个标量，可以将这些标量收集起来进行K-means聚类。在聚类后，每一个元素标量被分配一个聚类索引，并且可以由聚类中心形成码本。在网络模型推理期间，可以直接在聚类中心中查找每个标量元素的值。对于这种方法，只需要将索引和码本存储为参数。给定k个中心，只需要 $\log_2 k$ 位来编码聚类中心。例如，如果使用k=256个中心，则每个簇索引只需要8位，因此压缩率是 $\frac{\log_2 k}{32}$ 。虽然这种方法简单，但是在压缩参数方面取得了令人惊讶的良好效果。第三种是乘积量化（Product Quantization, PQ），乘积量化是一种结构化矢量量化方法。PQ的基本思想是将向量空间划分为许多不相交的子空间，并在每个子空间中执行量化。由于假设每个子空间中的向量都是冗余的并且通过在每个子空间中执行量化，因此能够更好地探索冗余结构。具体来说，给定权值矩阵，可以将其划分为若干子空间，在每个子空间内进行聚类。对于这种方法，需要为每个子向量存储索引和码本，并且与标量量化不同的是，这里的码本不可忽略。第四种是残差量化（Residual Quantization），RQ是结构化量化的另一种形式。基本思想是首先将矢量量化为k个中心，然后递归地量化残差。例如，给定一组向量 w_i ，在第一阶段，我们首先使用K-means聚类将它们量化为k个不同的向量，每个向量 w_z 将由其最近的中心 c_j^1 表示。接下来，我们计算所有数据点的 w_z 和 c_j^1 之间的残差 r_z^1 ，并将残差矢量 r_z^1 递归地量化为k个不同的码字 c_j^2 。最后，

可以通过在每个阶段添加相应的中心来重建矢量。上述 (KM, PQ 和 RQ) 是用于压缩矩阵的三种不同类型的矢量量化方法。KM 仅捕获每个神经元的冗余 (单个标量); PQ 探索了一些局部冗余结构; 并且 RQ 试图探索权重向量之间的全局冗余结构。这项工作不仅在图像分类的网络模型上取得了良好的效果, 还在图像检索等其他任务上进行了实验, 以验证压缩模式的泛化能力。

Song Han 等人^[26]的网络压缩工作结合了剪枝、量化、哈夫曼编码三种方法。其中的剪枝和哈夫曼编码部分不做过多介绍, 只介绍量化部分。网络量化和权值共享通过减少表示每个权值所需的比特数来进一步压缩修剪后的网络。通过让多个连接共享相同的权值来限制需要存储的有效权值的数量, 然后对这些共享权值进行微调。通过使用 K-means 聚类来确定训练后的网络各层的共享权值, 使得属于同一簇的所有权值共享相同的权值, 权值不会跨层共享。对于簇中心的初始化, 文中提出了三种初始化方法: Forgy (随机)、基于密度的初始化和线性初始化。网络模型中的大权值具有更重要的作用, 但是所占据的比例低。因此, 对于随机初始化和基于密度的初始化, 很少有质心具有较大的绝对值, 对于较大的权值表示并不友好, 线性初始化不受此问题的影响。作者通过实验对比了不同的初始化效果, 发现线性初始化效果最好。使用 K-means 聚类的方法来确定共享权值, K-means 聚类的好坏决定了量化的质量, 质心初始化影响聚类的质量, 进而影响网络的预测精度。对于删减的 AlexNet, 可以量化每个 CONV 层到 8 位 (256 个共享权重), 每个 FC 层量化为 5 位 (32 个共享权重), 而不会损失任何精度。

3.2.3.5 量化方法分析

(1) **训练时量化:** 在网络模型训练阶段设计针对权值、激活甚至输入数据的量化算法旨在加速网络模型。BNN 将权值和激活直接限制为 +1、-1 两个值, 在网络训练的反向传播阶段, 使用二值化的参数计

算梯度，并且将乘法运算替换为位运算，使网络模型在训练和推理时能大幅提速。但是简单的二值化方式也限制了 BNN 的性能，难以在大型数据集产生优秀的效果。XNOR-Net 针对二值化方式加以改进，通过引入一个比例因子对参数进行二值化近似，以同或运算和位计数运算替换卷积操作中的加乘运算，这种方法在加速网络模型的同时还能保证参数的精度。XNOR-Net 同时尝试改变卷积、批正则化、激活、池化的顺序，使得网络模型的性能显著提高。TWN 根据量化阈值将权值限制为 -1、0、+1 三个值，在网络模型的表征能力上相较于 BNN 和 XNOR-Net 增强 38 倍。同时 TWN 将网络模型压缩问题转化为了原始权值与三元权值之间欧式距离的优化问题。以上三种量化算法的优势在于，网络模型在训练时和推理时参数占用的内存减小 32 倍，位运算的应用使得训练和推理显著提速；但是缺点在于参数的精度严重丢失，这也是网络模型性能差的直接原因。基于 QAT 的混合精度量化的主要挑战在于，对于神经网络中每一层甚至每个参数，如何确定最优的量化位宽。因为量化位宽的搜索空间在层数上是指数的。穷举搜索这个空间是不切实际的，尤其是对于深度网络来说。因此，混合精度量化需要解决的问题是如何高效地搜索最优量化位宽。文献 [55] 提出使用小规模代理数据集来搜索神经网络的量化位宽分配策略，打破了在神经网络训练和搜索量化位宽时需要一致数据集的惯例。使用的代理数据集的规模，相较于训练神经网络使用的大规模数据集，仅为大规模数据集的 4%，将搜索效率提高了 300 倍。

(2) 训练后量化：不同于训练时量化网络模型，训练后量化旨在量化预训练好的模型中的参数以压缩网络模型。基于 PTQ 的定点量化^[24]虽然可以在没有模型微调的情况下将浮点参数转化为定点参数，但是需要让模型做一次推理，同时在网络模型推理时记录每层权值和激活的统计信息，以此确定小数的有效位数来实现浮点到定点的转换。INQ 通过迭代执行权值划分、分组量化和再训练三个操作，可以将预

训练的全精度网络模型有效的转换为低精度的网络模型。进行权值划分的原因是考虑到了权值的不同重要性，要优于全局量化的策略。在量化时将权值限制为二次幂，这样的好处在于可以将乘法运算替换为移位运算。INQ 的不足之处在于仅针对权值量化，未考虑激活和梯度的量化，并且需要花费额外的时间再训练。变换量化^[50]指出了权值存在统计相关性，在对权值量化之前引入类似于 SVD 的变换算法对权值矩阵进行解耦，同时引入比特分配算法针对不同层的权值分配最优的比特位宽来权衡最优比特分配和最小输出失真。将一个最优量化问题转化为了率-失真优化问题。同样的该方法只考虑了权值的量化，并未考虑激活和梯度的量化。矢量量化^[54]和 Song Han 等人^[26]的工作都使用了聚类算法对权值进行压缩，能够对网络模型的存储空间深度压缩。但是基于聚类算法的矢量量化方法依赖于簇中心的选取，在聚类算法中簇中心往往是随机选取的，簇中心选取的好坏直接决定了压缩后的网络模型的性能优劣。

研究人员在部署量化模型时，首先可以根据部署所需的时间成本以及训练集是否易获取来选择 QAT 或 PTQ。QAT 需要在模型量化的过程中重训练，时间成本上要高于 PTQ，并且 QAT 需要原始训练集，而 PTQ 无需训练集或仅需少量数据作为校准数据集。其次，研究人员还可依据模型大小、模型运行时的内存占用、模型的推理时间来选择量化方法。例如，在部署环境对存储空间有着严格限制的情况下，可以选择轻量型的 MobileNet 进行量化，尽管会牺牲一定的模型性能，但是在存储空间上获得了很大的收益；若考虑内存占用情况，诸如 INQ 这种没有对激活量化的方法并不是最佳的选择；相较于云端，在边端部署量化模型时更加注重推理时效，因此，二值量化中采用的位运算以及定点量化中的整数运算更具有优势，而混合精度量化由于模型参数的比特精度不统一，在推理时效上不具有优势。依据以上分析，研究人员可以根据部署环境来决定选择哪种量化方案。

3.3 深度学习模型中间层特征压缩

深度学习方法的兴起极大的提高了计算机视觉分析任务的效率。相较于传统的通过人工进行一步步设计的方法，深度学习模型能够直接从海量的数据中进行学习，并且提取所需要的特征信息。深度学习方法因此在各种基础的计算机视觉分析任务中取得了很好的应用，如图像分类任务，图像对象检测任务和图像检索任务等。随着网络基础服务设施的不断更新换代，越来越多基于深度学习的计算机视觉任务以边端-云端智能协同的方式进行快速部署，深度学习过程中需要的各种原始信号数据，如图像、视频等，在边端设备上采集和处理，并发送给云端服务器；云端服务器在接受到比特流后，对其进行进一步的计算处理与分析。这种边端-云端智能协同的方式广泛应用于如自动驾驶过程中的车牌检测、车辆识别；手机等智能设备的人脸识别、物体检测等等一系列计算机视觉任务中。然而边端设备采集到的图像或视频等信号级数据由于体积庞大，数据在边端设备和云端服务器之间的传输给带宽带来了很大的压力；信号级的视觉数据传递给云端服务器后，给云端服务器带来了很大的计算负担，同时也会带来巨大的能源消耗。为了将计算负担从云端服务器转移到边端设备上，一种被称为边缘计算的方法试图将深度学习网络模型部署在边端设备中而不是云端服务器上。在这种深度学习网络模型的部署方式下，边端设备采集到的原始信号级数据将在边端设备上进行全部的深度学习网络前向推理过程，并将推理得到的结果传递给云端服务器进行轻量级的计算处理与分析。然而深度学习网络模型往往是针对特定任务进行设计，因此经过推理得到的最终特征信息也是针对特定的任务，导致特征的泛化能力较差。通过边缘计算的方式进行网络模型的部署虽然可以将计算负担从云端转移到边端，在边端设备上推理得到体积足够小的特征进行压缩与传递，但是在越来越普遍的多任务分析场景下，往往只能采取在边端设备上部署多个深度学习网络模型对不同的视

觉任务进行计算与分析，极大的增加了边端设备的计算负担以及功耗，不符合边端设备低功耗低计算复杂度的自身特性以及设计需求，导致边缘计算方式难以被广泛应用。

基于上述传统云计算和边缘计算的利弊，一种新的深度学习网络模型中间层特征传输方式被提出，如图 3-7 所示



图 3-7 深度学习模型中间层特征传输流程

在这种特征传输方式下，深度学习网络模型将会拆分成两个部分，分别部署在边端设备和云端服务器上，网络模型的推理过程将以边端-云端智能协同的方式进行。图像或视频等信号级视觉数据在边端设备上采集与获取，经过部署在边端设备上前半部分网络模型的推理后提取得到中间层特征；推理得到的中间层特征在经过量化编码或其他形式的变换后进行压缩处理，并发送给云端服务器；云端服务器从接收到的比特流中提取数据，并且经过解压解码去量化等逆变换后得到重建的中间层特征，再将重建的中间层特征放入部署在云端的剩余部分网络模型中进行后半段推理过程，并对推理得到的结果进行计算处理与分析。这种新的特征传输方式可以在不限制云端服务器计算分析能力的前提下，在边端设备和云端服务器之间实现了计算负担和功率消耗的平衡。

通过传递深度学习网络模型的中间层特征，边端设备与云端服务器之间的数据传输成本将得到极大的降低，如 Lou 等人[56]的工作中，在一个实际监控系统中对 100000 台摄像头采集得到的紧凑特征和视觉信号之间的传输成本进行了比较。Chen 等人[57]的工作也同时提出，在深度学习网络模型中，随着网络结构层次的前移，中间层特征的数

据量也会出现大于原始输入的视觉信号的可能。因此，为了部署这种新的特征数据传输方式，并且满足边端设备与云端服务器智能协同中对传输带宽的要求，需要对在边端设备和云端服务器之间传递的中间层特征进行压缩编码或其他形式的变换。考虑到中间层特征可以表示为二维灰度图像或视频序列，因此中间层特征的压缩过程可以视为是二维图像或视频序列的去冗余过程，这与 JPEG/HEVC 等图像视频编码标准（Modrzyk 等人[58]、Flynn 等人[59]）处理二维图像或视频序列的过程极为相似。因此，深度学习网络模型中间层特征的编码压缩过程开始引入 JPEG/HEVC 等图像/视频编码器进行计算处理。Choi 等人[60]首次引入 HEVC 视频编解码器对中间层特征进行近似无损压缩，比较了中间层特征数据和自然图像数据之间的差异。在 Choi 等人[61]另一项工作中，使用图像/视频编解码器对物体检测的深度学习网络模型的中间层特征进行近似无损的压缩。Chen 等人[57][62]的工作将深度学习网络模型中间层特征的无损压缩结果与有损压缩结果进行对比，他们认为相比于中间层特征的无损压缩，采用有损的压缩方式进行压缩传输是一个更加合适的选择，为中间层特征压缩研究提供了一个更好的思路。由于特征编码是针对机器视觉服务而非人类的视觉，因此对特征编码后的结果应用任务性能指标（如 mAP）和人类感知指标（如 SSIM）并不合适。在 Chen 等人[63]的工作中，针对应用中间层特征有损压缩的三种主要的计算机视觉任务类型（即图像分类，图像检索和图像对象检测）分别提出了新的评价指标。在上述几项开创性工作之后，关于中间层特征的有损压缩技术，大多数工作采用基于图像/视频编解码的编码框架，该框架整合了传统的图像/视频编解码来进行中间层特征的压缩。Chen 等人[64]的工作开始着手中间层特征压缩的标准化工作，提出了基于视频编解码的中间层特征压缩技术的标准化流程，即 Quantization（量化），Repack（打包），和 VideoEncoder（视频编码器编码）三步流程。并且在三个计算机视觉

任务上对深度学习模型中间层特征进行压缩编码的实验。**Suzuki** 等人[65]则在 **Chen** 等人[64]工作提出的 **Repack** 模块基础上，精心设计了一个新的通道排序搜索算法，在中间层特征被送入视频编解码器进行压缩编码前，根据中间层特征不同通道间的时间空间冗余程度对特征通道进行重新排列来降低视频编解码器编解码过程造成的量化误差。除了基于图像/视频编解码框架的深度学习网络模型中间层特征压缩，近些年专家学者们也提出一些新的深度学习中间层特征编码压缩方式，如基于特征通道比特分配的中间层特征压缩，该方法试图通过计算速率-失真曲线等方式来探索特征通道最佳比特分配方式，在这一研究方向有着众多方法陆续提出：**Alvar** 等人[66]的工作中，通过引入新的损失函数，优化中间层特征的可压缩性，并且提高深度学习网络模型在多个任务上的性能；**Alvar** 等人[67][68]的工作中，提出类似于速率-失真的理论的概念，将任务失真建模为速率的函数，使用这样的模型为单任务系统和标量化多任务系统提供封闭式的比特分配解决方案。如基于设计新的网络架构实现中间层的特征编码压缩：**Li** 等人[69]的工作提出一种联合准确度和延迟感知的网络框架，该框架将深度学习网络模型解耦并分析最佳的分层位置以及最小化整体执行延迟；**Eshratifar** 等人[70]通过设计新的深度学习网络结构用于减少需要发送到云端服务器的特征大小，同时该项工作还提出了一种新的训练方式，用来补偿在将特征传送到云端之前，由于特征的有损压缩而造成的潜在的准确性损失；**Eshratifar** 等人[71]的工作则是设计了一个新的深度学习模型单元，通过该单元，可以更大程度上减少需要载入云端服务器的特征数据的大小；在他们的另一项工作 **Eshratifar** 等人[72]中提出了一种高效且自适应的架构，可以为深度神经网络在边缘设备和云服务器之间的推理和训练进行协作计算；**Matsubara** 等人[73]的工作则是采用知识蒸馏和图像压缩的思想来有效地压缩中间特征表示。本文综述了最近几年深度学习网络模型中间层特征压缩各个

研究方向上的经典方法和最新进展。重点关注中间层特征压缩编码的思路以及具体的实现过程。此外，对各类典型方法在公开数据集上的性能进行了综合比较以及简要总结。最后，本小节对当前研究中尚未解决的问题进行展望，并且对如何务实地解决这些问题进行了思考。

3.3.1 基于图像/视频编解码框架的中间层特征压缩

目前大多数深度学习网络模型的中间层特征压缩工作都是基于传统图像/视频编解码器。中间层特征在经过量化打包等变换后，送入图像/视频编解码器进行编码压缩。在这种方式中，图像/视频编解码器中成熟的编解码技术可以直接用于中间层特征的编码压缩中。尽管为压缩真实图像或视频序列而设计的图像/视频编解码器可能无法完美的适应中间层特征自身特性而进行压缩，但基于图像/视频编解码的编解码框架仍然是现阶段进行中间层特征编码压缩研究和标准化的最佳选择之一。

Choi 等人[61]提出了在边端设备和云端服务器之间应用边端-云端智能协同的方式部署深度学习网络模型，并在中间层特征上应用视频编解码器进行特征的量化编码压缩，用来减少边端-云端设备间传输数据的体积。这项工作在于物体检测任务的 YOLO9000 网络上进行了实验，并分析了 YOLO9000 网络不同层特征在应用视频编解码器进行量化编码压缩后对最终物体检测任务准确性的影响。作者首先对不同网络层特征的近似无损压缩进行了分析，近似无损即误差来源仅为特征量化过程中产生的量化误差，在高比特位量化过程中，该量化误差可以忽略不计。在边端设备上采集和获取信号级原始数据后，使用部署在边端设备上前半段深度学习网络模型对数据进行计算推理后，对得到的中间层特征进行量化在分析了 YOLO9000 不同层特征的近似无损压缩后，得到了如下结论：当深度学习网络模型的分割点越接近原始输入时（即深度学习网络的浅层），提取得到的中间层特征的数据量越大，并且难以在压缩率和模型性能之间取得一个好的

平衡 (trade-off)。随着分割点的后移 (即更深的网络层), 将会在特征的压缩率与模型性能之间取得较好的平衡。同时, 该项工作还通过调整 HEVC 高效视频编码器的量化参数对有损压缩编码的实验结果进行了统计分析。在有损压缩方式中, 该工作进行了压缩增强训练, 即针对不同的 HEVC 量化参数重新训练了网络模型分割点处的权重信息。实验结果表明, 有损压缩可以节省大量的比特, 而经过压缩增强训练后的权重信息也保持了可以接受的任务性能损失。

Chen 等人[90]的工作不同于 Choi 等人[61]仅专注于应用 YOLO9000 网络进行物体检测这个特定的计算机视觉分析任务, 他们提出以一种通用性更强的方式在深度学习网络模型中间层特征的计算负荷和泛化能力之间进行平衡。由于通用深度学习网络模型 (如 VGG-16, ResNet-50 等) 可以为特定任务的深度学习网络提供强大的视觉级信号表征, 大量的视觉任务可以在通用深度学习网络模型中提取得到的中间层特征的基础上, 应用针对特定计算机视觉任务的深度神经网络来解决。因此, 该项工作在 VGG 和 ResNet 两种通用的深度学习网络模型的中间层特征上进行量化编码压缩与传输的实验, 并对实验结果进行分析总结; 同时, 不同于 Choi 等人仅对中间层特征有损压缩进行了分析, 这项工作对中间层特征的无损压缩和有损压缩都进行了实验和对比分析。在无损压缩的实验中, 该项工作在压缩率和计算时间成本这两个评价指标上评估了 GZIP、ZLIB、BZIP2 和 LZMA 这四种传统无损数据压缩方法在压缩中间层特征上的性能表现。无损压缩方法的压缩率很大程度上受到待压缩中间层特征非零率的限制, 特征的统计冗余主要取决于特征中零值的数量。所以采用无损方式对中间层特征进行压缩并不能保证有很大的压缩空间。在实际应用中采用无损压缩方式的结果可能不会很理想。因此该工作接下来探讨了有损压缩在中间层特征上的应用。Chen 等人认为, 与针对网络模型的轻量化研究相似, 对中间层特征进行有损压缩造成的特征值微小变化

并不会严重影响最终输出的总体性能。同时经过卷积计算的特征是以特征向量的形式出现的，而特征向量则是由元素之间具有空间相关性的二维向量的排列组合，因此中间层特征的一个通道可以被视作为一个视频帧，而一个完整的特征向量可以视作为一个视频序列。因此已经趋于成熟的视频编解码技术可以无缝地借用到深度学习网络模型中间层特征的编码压缩当中。在中间层特征的编码阶段，由于视频编解码器的输入要求，需要先对特征进行量化处理，在信息损失这一方面，对原始特征和解码后的重建特征进行比较可以得知，重建特征的信息损失并没有明显受到有损压损的影响，整体任务性能仍在可以接受的范围之内。因此该项工作认为，相比较于对中间层特征向量应用传统无损压缩方法，应用视频编解码器的有损压缩方法在深度学习网络模型的中间层特征编码压缩上更有应用前景。

因为深度学习网络模型的中间层特征编码是针对机器视觉服务而非人类的视觉，同时深度学习网络模型的中间层特征往往具有高层次的语义信息，因此对中间层特征编解码后的推理结果应用任务性能指标（如 **mAP**）或人类感知指标（如 **SSIM**）可能并不合适。所以为了评估中间层特征有损压缩而造成的信息损失，应该考虑传输到云端服务器的中间层特征所需要执行的对应计算机视觉任务的输出结果去进行比较。**Chen** 等人[61]的工作说明了寻找新的针对中间层特征编码压缩的评价指标的原因：首先，任务性能指标的变化可能无法反映编码压缩前后中间层特征的信息损失水平，具体来说，就变化方向而言，压缩前后中间层特征的信息损失可能导致计算机视觉任务表现指标的正向或负向变化；而就变化量来说，任务性能指标的相同变化量可能是不同的信息损失水平造成的。任务性能指标可能不与信息的损失成线性相关。其次，用任务性能指标来评估信息损失并不是很规范。一方面，任务性能指标的取值范围并不相同；另一方面，原始特征上的任务性能的结果可能会因测试数据集的不同而产生不同，这使得很

难用任务性能指标来比较信息损失。接着该项工作针对不同的计算机视觉任务分别提出了新的性能评价指标来评估中间层特征由于编码压缩造成的信息损失。同样在这项工作中，他们还提出了基于视频编解码框架中间层特征编码压缩的标准化流程。具体流程如图 3-8 所示。该标准化流程的提出为之后基于图像/视频编解码框架的中间层特征压缩的研究奠定了基础。

在 Alvar 等人[66]的工作中，通过引入新的损失函数来进一步提高中间层特征的可压缩性，降低编码压缩造成的信息损失，并且提高深度学习网络模型在多任务场景上的性能。在该项工作中引入了 DCT 变换并将空间预测纳入了信息损失的计算。

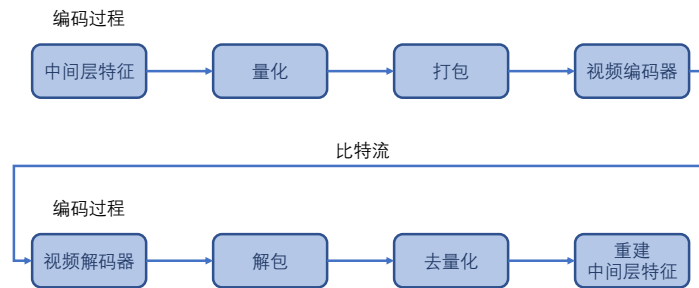


图 3-8 基于视频编解码的编码框架进行中间深度特征压缩的流程图

由于在基于图像/视频编解码框架的中间层特征编码压缩中，图像/视频编解码器针对自然图像或自然视频而开发的，因此编解码性能将在很大程度上取决于中间层特征数据的表示如何更好的适应图像/视频编解码器的输入要求，即如何更加贴近自然图像或自然视频序列。在 Chen 等人[64]的工作中因此提出了三种 Repack 方式，即 Naive Channel Concatenation (NCC)、Channel Concatenation by Distance (CCD) 和 Channel Tiling (CT) 三种方式，来探索特征图中的通道间冗余并重新表示中间层特征，使中间层特征数据更好的适应图像/视频编解码器的输入要求来提高编码器的编码性能。在 NCC 方式中，如图 3-9 所示，通过简单的连接所有通道来重新打包中间层特征向量。在这种方式下，中间层特征的每个通道被认为是一个灰度帧，而整个中间层特征向量可以看作是一个视频序列。由于每个通道的空

间相关性比较密切，特征通道内的冗余可以通过传统视频编解码器中的内部预测工具进行识别并最大程度消除。CCD 方式则通过重新组织中间层特征通道的排列顺序来减少相邻特征通道之间的残差，从而更好的消除特征通道之间的空间和时间冗余，达到提高压缩率的目的。在该方式中，通过使用 L2 准则来计算特征通道之间的距离。将该搜索找到的特征通道放置在锚点特征通道后并将其更新为新的锚点通道，重复上述过程直到计算完全部特征通道。在 CT 方式中，如图 3-10 所示，是将每个中间层特征通道视作为一个大图像帧的补丁，整个特征通道被重新组织成为一个大的灰度帧，然后送进图像/视频编解码器进行编解码操作，特征通道间的时间冗余和空间冗余将由图像/视频编解码器的内部编码工具进行探索。




图 3-9 特征通道串联




图 3-10 特征通道平铺

Suzuki 等人[65]在 Chen 等人[64]提出的 Repack 模块基础上，精心设计了一个新的通道排序搜索算法，在中间层特征被送入视频编解码器进行压缩编码前，根据中间层特征不同通道间的时间空间冗余程度对特征通道进行重新排列来降低视频编解码器编解码过程中产生

的误差。该 **Repack** 方法首先将中间层特征的通道个数 f 从原有的特征通道数 C 设置为 2 的幂数个, 例如 2, 4, 8。再根据 f 的数值确定重新排列后每个特征通道的尺寸大小, 在经过如上变换后, 重新排列组成的新的帧数量减少, 而每一帧上特征数量变多, 在增加了中间层特征的空间相关性的同时, 又保持有一定长度的视频帧序列, 从而保留了中间层特征通道之间的时间相关性, 使中间层特征的整体更符合自然视频序列的特性和状态。同时, 在该项工作中还提出了一个针对中间层特征通道的排序搜索算法。**Suzuki** 等人认为在一个自然的视频帧序列中, 相邻的两个帧之间的差异越小, 时间上的相关性就越高。因此该算法希望通过减少相邻帧之间的差异来增加时间上的关联性。

3.3.2 基于比特分配的中间层特征压缩

通过图像/视频编解码进行深度学习网络模型中间层特征编码压缩虽然高效便捷, 但是由于中间层特征向量不是自然图像/视频序列, 图像/视频编解码器并不是最适合压缩中间层特征的方式, 针对自然视频序列的内部预测工具无法完美并且高效地去除特征通道间和通道内的各种时间空间冗余。因此, 除了基于图像/视频编解码框架的中间层特征的编码压缩方式之外, 研究者开始探索根据中间层特征自身的特性来进行编码压缩和传输, 提出了基于比特分配的中间层特征编码压缩方式。在该研究领域, 算法的核心聚焦在如何为中间层特征的不同通道分配合适的量化比特位数。

Zhe 等人[82]的工作试图通过分析量化对神经网络的影响来探索不同网络层权重和不同层特征之间的关系, 并以这个关系建立编码压缩框架来最小化输出误差。在这项工作中首先定义了不同层权重的量化误差:

Alvar 等人[67]提出一个多流多任务的模型, 并在该模型中在总速率约束的条件下解决了率失真优化问题, 以获得待传输的中间层特征向量之间的最佳速率分配, 即中间层特征向量不同通道的最佳比特

分配。在该项工作中，设 \bar{A}_i 为模型在给定数据样本后，第 i 个任务不进行编码压缩的平均性能， A_i 为进行编码压缩后的平均性能，从而定义第 i 个任务的失真为相对于不对特征向量进行压缩的情况下性能下降的部分，

Hu 等人[83]的工作提出了一种基于通道敏感度的深度学习网络模型中间特征编码压缩比特分配算法。考虑到中间层特征不同的通道对网络模型最终推理结果的贡献不同，该项工作通过定义和评估特征的每个通道对编码压缩噪声的敏感性，并根据通道不同的敏感性，设计了一种以中间层特征通道为基础的比特分配机制，以保持任务精度，同时试图降低编码压缩的比特率。该比特分配机制包含了两个步骤，在第一步中，只有中间层特征一个被选定的通道进行编码压缩，而其他特征通道则保持不变，通过后续的计算推理过程来测试这个特征通道对编码压缩的敏感性。重复这个过程直到获得所有特征通道的敏感性。由于通过上述计算得到的原始中间层特征不同通道灵敏度的分布不一定具有相同规则，不同通道之间的灵敏度差距可能会很大，这使得中间层特征的所有通道之间的比特分配很难得到统一，因此需要对得到的中间层特征原始灵敏度进行归一化处理。

Alvar 等人[68]在之前的工作基础上进行了扩展。在该项工作中研究了多流智能协作系统中中间层特征编码压缩的比特分配问题，使用类似于速率-失真理论中的凸面将任务失真转换为速率的函数。使用这样的模型，为单任务系统和标量化多任务系统提供封闭式的中间层特征比特分配解决方案。此外在该项工作中，作者对 2 流 K 任务系统 Pareto 集的特征进行了分析，同时对 3 流 2 任务系统的 Pareto 集的分界线进行了研究。

Cohen 等人[84] [85]的工作则提出了一种轻量级的中间层特征编码压缩方法，该方法使用简单的标量化，经过剪切、二值化以及熵编码来压缩深度学习网络模型的中间层特征，并且不需要对网络的权

重进行重新训练，同时可以在广泛的比特率范围内进行编码压缩。该轻量化方法流程如图 3-11 所示：

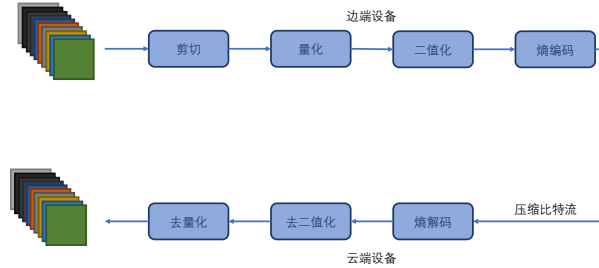


图 3-11 轻量化压缩流程

在该方法中主要涉及三个部分：裁剪、熵约束量化和二值化熵编码。在熵约束量化阶段，通过使用熵约束的设计过程，在速率范围内可以轻松获得均方意义上的最佳量化器。在量化阶段用表示 bin 的二进制码字的长度来代替用于表示 bin 数量的概率用以中间层特征通道的比特分配。

在 Ikusan 等人[86]的工作中提出一个整合速率-失真优化模块的层次化架构，用于压缩深度学习网络模型的中间层特征以及提高速率限制下基于深度学习的计算机视觉分析任务的质量。该工作从两个方面推进了现有的特征压缩解决方案。一方面，由于深度特征之间的相似性，传输一个特征子集不一定会降低计算机视觉任务的准确性，因此该工作中设计了一种基于分层聚类的特征选择策略，自下而上地建立一个树状图，从而大大减少压缩后的特征大小。在另一方面，该工作作为编码率和计算机视觉任务的质量建立了预测模型，并在预测模型的基础上设计了一个新的速率-失真组件。

3.3.3 基于深度学习网络架构的中间层特征压缩

通过设计一个新的网络结构减少待压缩中间层特征的元素数量进行特征的编码压缩也是一个值得研究的方向，不少研究团队在该方向上不断的提出新的方法。

在 Eshratifar 等人[70]的工作中提出一种新的名为 BottleNet 的深

度学习网络架构，用于减少发送到云端服务器的中间层特征体积。**BottleNet** 结构中包含有两个单元：通道缩减单元和空间缩减单元，分别如图 3-12、图 3-13 所示。其中通道缩减是指缩小中间层特征的通道数量，将一个大小为 (w, h, c) 的张量经过 1×1 卷积，压缩为一个大小为 (w, h, c^*) 的张量，其中 $c^* \ll c$ ；空间缩减是指缩小中间层特征的空间尺寸，将一个大小为 (w, h, c) 的张量经过卷积滤波器，输出一个大小为 (w^*, h^*, c) 的张量，其中 $w^* < w, h^* < h$ 。**BottleNet** 在边端移动设备上使用深度学习网络压缩单元来创建特征向量的压缩表示，然后将该张量传输到云端服务器。在云端服务器，**BottleNet** 通过对接收到的比特流应用解压器、应用通道恢复单元以及空间恢复单元，以恢复原始中间层特征向量的维度。**BottleNet** 的详细结构如图 3-14 所示，同时该项工作还提出了一种新的训练方法。该方法通过在反向传播过程中将压缩单元和解压单元定义为梯度，使模型能够端到端可分，用于补偿在将中间层特征传送到云端之前因有损压缩而造成的潜在任务性能准确性的损失。




图 3-12 通道缩减单元




图 3-13 空间缩减单元




图 3-14 Bottleneck 网络单元

在 Eshratifar 等人[70]的工作基础上, Shao 等人[87]提出一个名为 Bottleneck++的端到端的可训练架构用于边端-云端智能协同中的中间层特征编码压缩。Bottleneck++由一个编码器、一个通道层以及一个解码器组成。在训练阶段,该工作提出三步法来训练该端到端架构:第一步是训练深度学习网络模型,使其以达到任务的预期精度;第二步是选择合适的分割点来部署 Bottleneck++,训练并更新 Bottleneck++编码器和解码器的权重。同时需要在不同的信道条件,如 AWGN 信道、BEC 信道,进行训练,有利于端到端架构的泛化能力;在最后一步中对整个网络进行微调。Bottleneck++有效地利用了 DNN 的容错特性,以获得更高的压缩率。同时考虑到多种信道条件,进一步提高了架构的泛化能力。

Choi 等人[88]的工作提出了一种称为 Back-and-Forth 前后预(BaF)的预测方案,该方案是为中间层特征向量开发的,能够极大地减少向量的大小并提高其可压缩性。算处理与分析。




图 3-15 BaF 网络单元

3.3.4 中间层特征压缩三类方法的比较与分析

为了对近年来提出的深度学习网络模型中间层特征压缩技术进

行直观讨论,根据不同的中间层特征压缩方法用表格展示了中间层特征压缩的实验结果。同时考虑到评价各种方法的优劣需要在相同数据集条件以及相同深度学习网络模型下进行比较才有意义,因此在本文根据数据集的不同和网络模型的不同按时间顺序展示各种方法的比较结果。由于图像/视频编解码器的量化参数 QP 有着较大的动态范围,基于图像/视频编解码器的中间层特征压缩方法在压缩率上也会随着 QP 的变化而发生改变并保持在一个较低的范围,同时有着不错的任务性能,如 Choi 等人[61]和 Chen 等人[90]的工作在 mAP , $PSNR$ 以及 $Fidelity$ 等任务性能评价指标上均有着较为优秀的综合表现。基于比特分配的中间层特征压缩方法根据中间层特征自身的统计性质以及特征通道对网络输出误差的贡献程度计算不同通道的量化参数,理论上在无损压缩传输的场景中可以达到任务性能的理想值,即各项任务性能评价指标的最优。为了满足边端-云端智能协作对传输带宽的严格要求,基于比特分配的中间层特征压缩方法均采用有损压缩进行数据的传输,并且仍然保持了优秀的任务性能,如 Cohen 等人[85]的工作在 mAP 和 $Top-1 Accuracy$ 等评价指标上都达到相同数据集上的最优。基于深度学习网络架构的中间层特征压缩方法则通过减少待压缩中间层特征的通道数量以及通道的尺寸大小,极大的降低了待压缩特征的元素数量,并且通过重新训练的方式保证云端服务器恢复的重建特征与边端设备的原始中间层特征尽可能保持一致,因此,在保证任务性能的前提下,特征被压缩到一个很小的体积中,同时我们总结归纳了三类中间层特征压缩方式中的优缺点。基于图像/视频编解码器的中间层特征压缩方式的最大优势在于可以直接利用已经趋于成熟的图像/视频编解码器,如 $HEVC$, $JPEG$ 等,进行特征的压缩并且快速部署,只需将输入的待压缩特征以通道为单位重新排列成图像帧或者视频序列的形式,这对本身就通道排列的特征来说是容易实现的;基于图像/视频编解码器的特征压缩方式的另一个优势在于可以

进行模块化操作。在 Chen 等人[64]的工作中，中间层特征的压缩过程被拆分成量化、打包、编码三个模块，后续的很多研究工作都是对这些模块进行优化使待压缩特征能与图像或者视频更加接近，同时模块化的操作又推动着中间层特征压缩的标准化工作。基于图像/视频编解码器的特征压缩方式的缺点也十分明显，即中间层特征实际上并不是图像帧或者视频序列，中间层特征针对机器视觉而图像或者视频则是针对人类视觉，二者在空间冗余、时间冗余以及语义信息的分布等特性上有着明显的区别，HEVC 等编解码工具中用于消除图像/视频冗余的方法，如运动估计，帧内/帧间预测等技术手段并不能完美去除中间层特征的时间空间冗余，导致特征的压缩效果并不具有很大的优势。不少的研究工作试图在应用图像/视频编码器进行特征压缩前消除特征中的冗余信息来解决这个问题。基于比特分配的中间层特征压缩方式则是将待压缩特征适应编码方式的思路转变成编码方式适应带压缩特征，根据待压缩特征自身的统计性质以及特征通道对网络输出误差的敏感程度，通过建立速率-失真模型进行量化参数的分配，量化参数包括量化比特位数、量化区间个数、量化步长等。对特征不同的通道分配不同的量化参数，试图降低待压缩特征的编码误差。速率-失真模型一旦确定，量化参数分配的计算是十分迅速的。基于比特分配的压缩方式的另一个优势在于，速率-失真模型的建立并不局限在一个任务的特征上，而是可以在多个任务的特征上进行建模，以达到多任务联合优化的目的。基于比特分配的压缩方式面临的问题在于，速率模型和失真模型的建立并不容易，特别是在多任务联合优化的场景下，需要综合考虑多个任务的不同影响因素，给速率模型和失真模型的建立增加了难度。基于深度学习网络架构的中间层特征压缩方式，优点是改变待压缩中间层特征的维度以及尺寸大小，极大的减少了待压缩特征的元素数量，在保证任务性能损失在可接受范围的前提下，压缩率得到了降低。基于深度学习网络架构的压缩方式

的缺点在于，为了保持云端服务器恢复的重建特征与未压缩中间层特征尽可能一致，需要对网络架构中的权重等参数进行大量的训练，同时网络中部分推理的计算过程并不透明，很难在数学上进行分析。

3.3.5 思考与展望

从 2018 年 Choi 等人[60]首次将视频编解码器应用在深度学习网络模型中间层特征编码压缩开始，在之后的短短几年时间，该领域的研究工作已经取得了巨大的进展。但是在很多方面，中间层特征编码压缩仍然面临着各种各样的挑战（Lou 等人[56]、Bajic 等人[89]）。下面将从深度学习网络模型中间层特征编码压缩的可扩展性、互操作性、实用性和可行性这四个方面对当前研究所取得的成果、面临的问题以及可能的解决方案进行分析和讨论。

1、中间层特征压缩技术的可扩展性

深度学习网络模型中间层特征的可扩展性应当支持根据动态的网络条件，任务部署的环境情况以及边端-云端的编解码能力进行相适应的调整。在自然图像和自然视频序列的编解码器的应用中，可扩展性已经得到了广泛的研究与应用。由于中间层特征表示能够概括不同程度与维度的视觉特征，通过关注适当的中间层特征向量或网络层，可扩展性在中间层特征和深度学习网络模型表示中也自然可以得到支持。然而，由于深度学习网络模型的权重信息往往通过端到端的学习得到，为了实现中间层特征表示的可扩展性，有必要确定选定的中间层特征每个通道的重要性以及该层权重所包含的信息。只有这样才能在确定的约束条件下，最大限度的提高被编码压缩后的特征的信息表示能力，即降低编码压缩带来的信息损失以及提高任务性能。综上所述，对中间层特征编码压缩的可扩展性的探索是一个重要并且很有挑战的一项工作。

2、中间层特征压缩技术的互操作性

深度学习网络模型中间层特征编码压缩的互操作性将通过对中

中间层特征编码压缩的流程进行标准化来实现。经过标准化后，任何符合标准的比特流都能够被正确的去压缩和解码。在自然图像和自然视频序列的研究领域，有着一系列的编码标准化框架，如 H.264/AVC, H.265/HEVC。可以预见，随着深度学习相关领域技术的逐渐完善，中间层特征编码压缩的互操作性可以通过一个统一的标准化的流程来实现。但是，相比于已经趋于成熟的图像或视频信号，深度学习领域的快速发展导致网络模型结构和中间层特征表达方式的快速改变，这就给深度学习网络模型中间层特征编码压缩的标准化工作带来了一定的困难。目前可行的方式是，在目前的发展阶段，通过部署灵活并且实用的半标准化工作方案来进行过渡。例如只在原始中间层特征到编码压缩比特流的阶段进行标准化和规范化（Chen 等人[57]）。至于原始中间层特征是如何生成的则是开放的。综上所述，对深度学习网络模型中间层特征编码压缩的标准化工作的探索将是一个漫长而艰巨的任务。

3、 中间层特征压缩技术的实用性

深度学习网络模型中间层特征压缩编码的实用性体现在压缩后的比特率和任务性能之间的美好权衡。因此，越来越多的研究团队对使用基于速率-失真函数作为优化函数的兴趣越来越大。然而，由于速率-失真关系在理论上很难被清晰的描述，特别是，当有多个任务需要同时执行时，如何在这些任务之间实现良好的比特率和任务性能之间的平衡，是阻碍中间层特征编码压缩实用性探索的一个重要问题。因此，我们需要一个能够很好地描述中间层特征编码压缩的速率-失真关系的统一函数，能够大大促进中间层特征编码压缩在实际应用部署中的发展。

4、 中间层特征压缩技术的可行性

由于深度学习网络模型中间层特征是视觉信号的紧凑表示，要想从编码压缩后的比特流中恢复原始的中间层特征，并通过从重建的中

间层特征中恢复原始的信号级的视觉数据是十分困难的。而对信号级视觉数据的回溯困难就导致了人类视觉对信息追溯的困难，这就导致在计算机视觉分析任务中，基于中间层特征的生成模型是有一定缺陷的。但是，对原始信号级的视觉数据的回溯在一些问题中又是必须的，例如当机器的计算与处理无法理解一些特征并表示，或者计算推理的结果与事实有很大偏差时，通过人类视觉去分析图像或视频的纹理信息进行最终判断是一个必要的方式。在图像或视频编码压缩领域，对纹理信息重建与复原有着广泛的研究，然而在中间层特征编码压缩中加入图像或视频的纹理信息，必然导致比特率大幅增加，从而我们所预想的边云协同应用中的中间层特征编码压缩的优势将不复存在。另一种思路是将视觉信息与特征信息同时进行编码压缩。但是增加人类视觉信息也会在一定程度上增加从边端设备发送到云端服务器比特流的体积。因此如何在满足一定的速率的约束条件下将图像或视频的纹理信息加入编码压缩的范围内，是解决中间层特征编码压缩技术可行性的一个急切的问题。

3.4 本章小结

本章主要阐述了深度学习中的模型压缩以及模型中间层特征压缩技术的研究背景和意义，对当前的研究现状进行了归纳和总结。一方面，随着网络基础设施的不断更新换代，以及越来越多的深度学习计算机视觉任务将以云-边-端智能协作的方式快速部署，迫切需要深度学习模型中间层特征压缩的先进技术，实现智能终端与边云设备的低带宽、低延时传输；另一方面，终端设备的低功耗要求迫切需要轻量化的深度学习模型，以便能够大范围部署在计算能力有限的各种终端设备上，实现终端设备对采集信号初步的智能化处理。随着智能化技术的普及，深度学习的模型压缩和中间层特征压缩将会逐步走向标准化，且迎来激烈的市场竞争，将成为一个学术界和工业界备受关注的话题。

参考文献

- [1] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Advances in neural information processing systems, 2012, 25.
- [2] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv:1409.1556, 2014.
- [3] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.
- [4] HANSON S, PRATT L. Comparing biases for minimal network construction with back-propagation[J]. Advances in Neural Information Processing Systems, 1988, 1: 177-185.
- [5] HASSIBI B, STORK D. Second order derivatives for network pruning: Optimal brain surgeon[J]. Advances in Neural Information Processing Systems, 1992, 5: 164-171.
- [6] SRINIVAS S, BABU R V. Data-free parameter pruning for deep neural networks [C] //Proceedings of the British Machine Vision Conference 2015.
- [7] HAN Song, POOL J, TRAN J, et al. Learning both weights and connections for efficient neural network [J] . Advances in Neural Information Processing Systems, 2015, 28: 1135-1143.
- [8] CHEN Wenlin, WILSON J T, TYREE S, et al. Com- pressing neural networks with the hashing trick[J]. 32nd International Conference on Machine Learning, ICML 2015, 2015, 3: 2275-2284.
- [9] WEN Wei, WU Chunpeng, WANG Yandan, et al. Learning structured sparsity in deep neural networks[EB/ OL]. 2016: arXiv: 1608.03665[cs. NE]. <https://arxiv.org/abs/1608.03665>.
- [10] ZHOU Hao, ALVAREZ J M, PORIKLI F. Less is more: Towards compact CNNs [M] //Computer Vision-ECCV 2016. Cham: Springer International

- Publishing, 2016: 662-677.
- [11] LI Hao, KADAV A, DURDANOVIC I, et al. Pruning filters for efficient ConvNets [EB/OL] . <https://arxiv.org/abs/1608.08710>, 2016.
- [12] LIU Zhuang , LI Jianguo , SHEN Zhiqiang , et al. Learning efficient convolutional networks through network slimming [C] // 2017 IEEE International Conference on Computer Vision (ICCV) . Venice, Italy. IEEE, 2017: 2755-2763.
- [13] LUO Jianhao, WU Jianxin, LIN Weiyao. ThiNet: A filter level pruning method for deep neural network compression [C] // 2017 IEEE International Conference on Computer Vision (ICCV) . Venice, Italy. IEEE, 2017: 5068-5076.
- [14] HE Yihui, LIN Ji, LIU Zhijian, et al. AMC: AutoML for model compression and acceleration on mobile devices [C] // Computer Vision-ECCV 2018, 2018: 784-800. DOI: 10.1007/978-3-030-01234-2_48.
- [15] Yu Jiahui, Huang T. Autoslim: Towards one-shot architecture search for channel numbers [J] . ArXiv Preprint arXiv: 1903.11728, 2019.
- [16] LIU Ning, MA Xiaolong, XU Zhiyuan, et al. AutoCompress: an automatic DNN structured pruning framework for ultra-high compression rates [J] . Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34 (4): 4876-4883.
- [17] BUCILUĂ C, CARUANA R, NICULESCU-MIZIL A. Model compression [C] // Proceedings of the 12th ACM SIGKDD international conference on Knowledge discovery and data mining-KDD'06. Philadelphia, PA, USA. New York: ACM Press, 2006: 535-541.
- [18] HINTON G, VINYALS O, DEAN J. Distilling the knowledge in a neural network [EB/OL] . <https://arxiv.org/abs/1503.02531>, 2015: 38-39.
- [19] ROMERO A, BALLAS N, KAHOU S E, et al. Fitnets: Hints for thin deep

- nets [J] . ArXiv Preprint arXiv: 1412.6550, 2014.
- [20] ZAGORUYKO S, KOMODAKIS N. Paying more attention to attention: Improving the performance of convolutional neural networks via attention transfer [EB/OL] . <https://arxiv.org/abs/1612.03928>, 2016.
- [21] CHEN Tianqi, GOODFELLOW I, SHLENS J. Net2Net: accelerating learning via knowledge transfer [EB/OL] . <https://arxiv.org/abs/1511.05641>, 2015.
- [22] KORATTIKARA Balan A, RATHOD V, MURPHY K P, et al. Bayesian dark knowledge [J] . Advances in Neural Information Processing Systems, 2015, 28: 3438-3446.
- [23] LUO Ping, ZHU Zhenyao, LIU Ziwei, et al. Face Model Compression by Distilling Knowledge from Neurons [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2016: 3560-3566.
- [24] ZHANG Linfeng, SONG Jiebo, GAO Anni, et al. Be your own teacher: Improve the performance of convolutional neural networks via self distillation [C] // 2019 IEEE/CVF International Conference on Computer Vision (ICCV) . Seoul, Korea (South) . IEEE, 2019: 3712-3721.
- [25] CHEN Hanting, WANG Yunhe, XU Chang, et al. Data-free learning of student networks [EB/OL] . https://openaccess.thecvf.com/content_ICCV_2019/html/Chen_Data-Free_Learning_of_Student_Networks_ICCV_2019_paper.html, 2019.
- [26] HAN Song, MAO Huizi, DALLY W J. Deep compression: Compressing deep neural networks with pruning, trained quantization and Huffman coding [J] . ArXiv Preprint arXiv: 1510.00149, 2015.
- [27] HU Hengyuan, PENG Rui, TAI Y W, et al. Network trimming: A data-driven neuron pruning approach towards efficient deep architectures [EB/OL] . <https://arxiv.org/abs/1607.03250>, 2016.
- [28] ZHUANG Zhuangwei , TAN Minkui , ZHUANG Bohan , et al.

- Discrimination-aware channel pruning for deep neural networks [C] // Proceedings of the 32nd International Conference on Neural Information Processing Systems (NIPS' 18) . New York: Curran Associates Inc., 2018: 883-894.
- [29] LIN Mingbao, JI Rongrong, WANG Yan, et al. Hrank: Filter pruning using high-rank feature map [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1529-1538.
- [30] ZHANG Ying, XIANG Tao, HOSPEDALES T M, et al. Deep mutual learning [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA. IEEE. 2018: 4320-4328.
- [31] ZHANG, D., YANG, J., YE, D., HUA, G.: Lq-nets: Learned quantization for highly accurate and compact deep neural networks. In: Ferrari, V., Hebert, M., Sminchisescu, C., Weiss, Y. (eds.) Computer Vision - ECCV 2018 - 15th European Conference, Munich, Germany, September 8-14, 2018, Proceedings, Part VIII. Lecture Notes in Computer Science, vol. 11212, pp. 373– 390. Springer (2018).
- [32] BANNER, R., NAHSHAN, Y., SOUDRY, D.: Post training 4-bit quantization of convolutional networks for rapid-deployment. In: Wallach, H.M., Larochelle, H., Beygelzimer, A., d'Alch'e-Buc, F., Fox, E.B., Garnett, R. (eds.) Advances in Neural Information Processing Systems 32: Annual Conference on Neural Information Processing Systems 2019, NeurIPS 2019, December 8-14, 2019, Vancouver, BC, Canada. pp. 7948–7956 (2019).
- [33] COURBARIAUX M, BENGIO Y, DAVID J P. BinaryConnect: Training Deep Neural Networks with binary weights during propagations[C]// International Conference on Neural Information Processing Systems. MIT Press, 2015.
- [34] COURBARIAUX M, HUBARA I, SOUDRY D, et al. Binarized neural networks: Training deep neural networks with weights and activations

- constrained to +1 or -1[J]. arXiv preprint arXiv:1602.02830, 2016.
- [35] RASTEGARI M, ORDONEZ V, REDMON J, et al. Xnor-net: Imagenet classification using binary convolutional neural networks[C]//European conference on computer vision. Springer, Cham, 2016: 525-542.
- [36] Redfern A J, Zhu L, Newquist M K. BCNN: A binary CNN with all matrix Ops Quantized to 1 bit precision[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021: 4604-4612.
- [37] LI F, LIU B. Ternary weight networks[J]. arXiv preprint arXiv:1605.04711, 2016.
- [38] Hubara I, Courbariaux M, Soudry D, et al. Quantized neural networks: Training neural networks with low precision weights and activations[J]. The Journal of Machine Learning Research, 2017, 18(1): 6869-6898.
- [39] Razani R, Morin G, Sari E, et al. Adaptive binary-ternary quantization[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021: 4613-4618.
- [40] Pouransari H, Tu Z, Tuzel O. Least squares binary quantization of neural networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. 2020: 698-699.
- [41] Jacob B, Kligys S, Chen B, et al. Quantization and training of neural networks for efficient integer-arithmetic-only inference[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 2704-2713.
- [42] Fan A, Stock P, Graham B, et al. Training with quantization noise for extreme model compression[J]. arXiv preprint arXiv:2004.07320, 2020.
- [43] ZHOU A, YAO A, GUO Y, et al. Incremental network quantization: Towards lossless cnns with low-precision weights[J]. arXiv preprint arXiv:1702.03044, 2017.
- [44] ZHOU S, WU Y, NI Z, et al. Dorefa-net: Training low bitwidth convolutional

- neural networks with low bitwidth gradients[J]. arXiv preprint arXiv:1606.06160, 2016.
- [45] CHOI J, ZHUO W, VENKATARAMANI S, et al. Pact: Parameterized clipping activation for quantized neural networks[J]. arXiv preprint arXiv:1805.06085, 2018.
- [46] Jin Q, Ren J, Zhuang R, et al. F8net: Fixed-point 8-bit only multiplication for network quantization[J]. arXiv preprint arXiv:2202.05239, 2022.
- [47] Langroudi H F, Karia V, Pandit T, et al. Tent: Efficient quantization of neural networks on the tiny edge with tapered fixed point[J]. arXiv preprint arXiv:2104.02233, 2021.
- [48] LIN D D, TALATHI S S, ANNAPUREDDY V S. Fixed point quantization of deep convolutional networks[C]//International conference on machine learning. PMLR, 2016: 2849-2858.
- [49] Prasad Pandey N, Nagel M, van Baalen M, et al. A Practical Mixed Precision Algorithm for Post-Training Quantization[J]. arXiv e-prints, 2023: arXiv:2302.05397.
- [50] YOUNG S I, ZHE W, TAUBMAN D, et al. Transform Quantization for CNN Compression[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020.
- [51] HUANG G, LIU Z, LAURENS V, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 4700-4708.
- [52] Wang K, Liu Z, Lin Y, et al. Haq: Hardware-aware automated quantization with mixed precision[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 8612-8620.
- [53] Yang H, Duan L, Chen Y, et al. BSQ: Exploring bit-level sparsity for mixed-precision neural network quantization[J]. arXiv preprint arXiv: 2102.

10462, 2021.

- [54] GONG Y, LIU L, MING Y, et al. Compressing deep convolutional networks using vector quantization[J]. arXiv preprint arXiv:1412.6115, 2014.
- [55] Tang C, Ouyang K, Chai Z, et al. Searching Transferable Mixed-Precision Quantization Policy through Large Margin Regularization[J]. arXiv preprint arXiv:2302.06845, 2023.
- [56] Lou Y, Duan L Y, Wang S, et al. Front-end smart visual sensing and back-end intelligent analysis: A unified infrastructure for economizing the visual system of city brain[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(7): 1489-1503.
- [57] Chen Z, Fan K, Wang S, et al. Toward Intelligent Sensing: Intermediate Deep Feature Compression[J]. IEEE trans on image processing: a publication of the IEEE Signal Processing Society, 2019.
- [58] Modrzyk D, Staworko M. A high-performance architecture of JPEG2000 encoder[C]//Proc of the 19th European Signal Processing Conference. IEEE press, 2011: 569-573.
- [59] Flynn D, Marpe D, Naccari M, et al. Overview of the range extensions for the HEVC standard: Tools, profiles, and performance[J]. IEEE Trans on Circuits and Systems for Video Technology, 2015, 26(1): 4-19.
- [60] Choi H, Bajić I V. Near-lossless deep feature compression for collaborative intelligence[C]//Proc of IEEE 20th International Workshop on Multimedia Signal Processing (MMSP). IEEE press, 2018: 1-6.
- [61] Choi H, Bajić I V. Deep feature compression for collaborative object detection[C]//Proc of the 25th IEEE International Conference on Image Processing (ICIP). IEEE press, 2018: 3743-3747.
- [62] Chen Z, Lin W, Wang S, et al. Intermediate deep feature compression: the next battlefield of intelligent sensing [EB/OL]. (2018) [2022-9-11].

<https://arxiv.org/pdf/1809.06196.pdf>

- [63] Chen Z, Fan K, Wang S, et al. Lossy intermediate deep learning feature compression and evaluation[C]//Proc of the 27th ACM International Conference on Multimedia. ACM press 2019: 2414-2422.
- [64] Chen Z, Duan L Y, Wang S, et al. Data representation in hybrid coding framework for feature maps compression[C]//Proc of IEEE International Conference on Image Processing (ICIP). IEEE Press, 2020: 3094-3098.
- [65] Suzuki S, Takeda S, Takagi M, et al. Deep Feature Compression using Spatio-Temporal Arrangement toward Collaborative Intelligent World[J]. IEEE Trans on Circuits and Systems for Video Technology, 2021.
- [66] Alvar S R, Bajić I V. Multi-task learning with compressible features for collaborative intelligence[C]//Proc of IEEE International Conference on Image Processing (ICIP). IEEE press, 2019: 1705-1709.
- [67] Alvar S R, Bajić I V. Bit allocation for multi-task collaborative intelligence[C]//Proc of ICASSP IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE press, 2020: 4342-4346.
- [68] Alvar S R, Bajić I V. Pareto-optimal bit allocation for collaborative intelligence[J]. IEEE Trans on Image Processing, 2021, 30: 3348-3361.
- [69] Li H, Hu C, Jiang J, et al. Jalad: Joint accuracy-and latency-aware deep structure decoupling for edge-cloud execution[C]//Proc of IEEE 24th international conference on parallel and distributed systems (ICPADS). IEEE press, 2018: 671-678.
- [70] Eshratifar A E, Esmaili A, Pedram M. et al. deep learning architecture for intelligent mobile cloud computing services[C]//Proc of IEEE/ACM International Symposium on Low Power Electronics and Design (ISLPED). IEEE press, 2019: 1-6.
- [71] Eshratifar A E, Esmaili A, Pedram M. Towards collaborative intelligence

- friendly architectures for deep learning[C]//Proc of the 20th International Symposium on Quality Electronic Design (ISQED). IEEE press, 2019: 14-19.
- [72] Eshratifar A E, Abrishami M S, Pedram M. JointDNN: An efficient training and inference engine for intelligent mobile cloud computing services[J]. IEEE Trans on Mobile Computing, 2019, 20(2): 565-576.
- [73] Matsubara Y, Yang R, Levorato M, et al. Supervised compression for resource-constrained edge computing systems[C]//Proc of the IEEE/CVF Winter Conference on Applications of Computer Vision. IEEE press, 2022: 2685-2695.
- [74] Shao J, Zhang J. Communication-computation trade-off in resource-constrained edge inference[J]. IEEE Communications Magazine, 2020, 58(12): 20-26.
- [75] Ulhaq M, Bajić I V. Shared mobile-cloud inference for collaborative intelligence[EB/OL]. (2020)[2022-9-11]. <https://arxiv.org/pdf/2002.00157.pdf>
- [76] Chamain L D, Racapé F, Bégaint J, et al. End-to-end optimized image compression for machines, a study[C]//Proc of Data Compression Conference (DCC). IEEE press, 2021: 163-172.
- [77] Dhondea A, Cohen R A, Bajić I V. DFTS2: Simulating Deep Feature Transmission Over Packet Loss Channels[EB/OL]. (2021)[2022-9-11]. <https://arxiv.org/pdf/2112.00794.pdf>
- [78] Wang S, Wang Z, Wang S, et al. End-to-end compression towards machine vision: Network architecture design and optimization[J]. IEEE Open Journal of Circuits and Systems, 2021, 2: 675-685.
- [79] Chamain L D, Racapé F, Bégaint J, et al. End-to-end optimized image compression for multiple machine tasks[EB/OL]. (2021)[2022-9-11]. <https://arxiv.org/pdf/2103.04178.pdf>
- [80] Zhang Z, Wang M, Ma M, et al. Msfc: Deep feature compression in multi-task network[C]//Proc of IEEE International Conference on Multimedia and Expo

- (ICME). IEEE press, 2021: 1-6.
- [81] Yuan Z, Rawlekar S, Garg S, et al. Feature Compression for Rate Constrained Object Detection on the Edge[EB/OL].(2022) [2022-9-11]. <https://arxiv.org/pdf/2204.07314.pdf>
- [82] Zhe W, Lin J, Chandrasekhar V, et al. Optimizing the bit allocation for compression of weights and activations of deep neural networks[C]//Proc of IEEE International Conference on Image Processing (ICIP). IEEE press, 2019: 3826-3830.
- [83] Hu Y, Xia S, Yang W, et al. Sensitivity-Aware Bit Allocation for Intermediate Deep Feature Compression[C]//Proc of IEEE International Conference on Visual Communications and Image Processing (VCIP). IEEE press, 2020: 475-478.
- [84] Cohen R A, Choi H, Bajić I V. Lightweight compression of neural network feature tensors for collaborative intelligence[C]//Proc of IEEE International Conference on Multimedia and Expo (ICME). IEEE press, 2020: 1-6.
- [85] Cohen R A, Choi H, Bajić I V. Lightweight compression of intermediate neural network features for collaborative intelligence[J]. IEEE Open Journal of Circuits and Systems, 2021, 2: 350-362.
- [86] Ikusan A, Dai R. Rate-Distortion Optimized Hierarchical Deep Feature Compression[C]//Proc of IEEE International Conference on Multimedia and Expo (ICME). IEEE press, 2021: 1-6.
- [87] Shao J, Zhang J. Bottlenet++: An end-to-end approach for feature compression in device-edge co-inference systems[C]//Proc of IEEE International Conference on Communications Workshops (ICC Workshops). IEEE press, 2020: 1-6.
- [88] Choi H, Cohen R A, Bajić I V. Back-and-forth prediction for deep tensor compression[C]//Proc of ICASSP IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE press, 2020: 4467-4471.

- [89] Bajić I V, Lin W, Tian Y. Collaborative intelligence: Challenges and opportunities[C]//Proc of ICASSP IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE press, 2021: 8493-8497.
- [90] Chen Z, Fan K, Wang S, et al. Toward Intelligent Sensing: Intermediate Deep Feature Compression[J]. IEEE trans on image processing: a publication of the IEEE Signal Processing Society, 2019.

第 4 章 人工智能大模型

4.1 引言

人工智能 (AI) 的迅速发展已经引起了全球范围内的广泛关注和研究。随着大数据的不断积累、计算能力的提升和算法的创新, 人工智能正在改变我们生活和工作的方方面面。然而, 在实现人工智能的愿景和目标时, 一个重要的问题是如何构建更强大和高效的人工智能模型。伴随着近年来人工智能基础大模型逐渐在智慧城市、问答系统、无人驾驶等应用领域展示出巨大的应用潜力, 吸引了学术界与工业界的聚焦关注。以 CLIP[1]和悟道[2]为代表的图像或文本模态的人工智能基础大模型向下可带动基础软硬件发展, 向上可支撑智能应用百花齐放, 是新一代人工智能生态的核心技术。具体而言, 基础大模型一般基于超大规模数据, 在高算力服务器集群上训练, 并普遍拥有千万级至亿级参数量。例如, GPT-3[3]的 1750 亿参数需要在 500GB 数据训练 355 个 GPU 年。如何进一步利用多模态数据、多任务信息实现通用的基础大模型, 并在各类边缘场景部署, 近期已成为下一代人工智能技术的重要发展趋势。

人工智能大模型作为人工智能领域的重要组成部分, 近年来备受瞩目。大模型是一种具有巨大规模和复杂结构的神经网络, 它们可以通过大规模的预训练和微调过程来学习和推理。这些模型的出现和发展引发了人们对于人工智能能力的新的认识和期望。在过去, 人工智能模型的能力和性能受到计算资源和数据量的限制。然而, 随着云计算和大数据技术的迅猛发展, 我们现在能够处理和分析前所未有的规模和复杂度的数据。这使得人工智能大模型的训练和部署变得可行, 同时也推动了大模型的发展。人工智能大模型的兴起得益于深度学习算法和大规模数据集的共同作用。通过在海量数据上进行预训练, 模型能够学习到丰富的语义和知识表示。随后, 在特定任务上进行微调, 模型可以根据具体的需求进行优化, 进一步提升性能。人工智能大模

型的出现是为了应对复杂任务和领域中的挑战。在自然语言处理领域，大模型在机器翻译、问答系统和文本摘要等任务中取得了显著的突破。在计算机视觉领域，大模型在图像分类、目标检测和图像生成等方面展现出了强大的能力。此外，在语音识别、推荐系统和自动驾驶等领域，大模型也展现出了巨大的潜力。然而，人工智能大模型的发展仍然面临一些挑战。首先，大模型的训练和部署需要大量的计算资源和时间。这对于普通用户和研究机构来说可能是一个巨大的挑战，限制了大模型的普及和应用。其次，大模型通常被视为黑盒，难以解释其内部的决策和推理过程，这对于一些关键应用场景和行业来说可能是不可接受的。此外，模型中的潜在偏见和歧视也是一个需要解决的问题。为了克服这些挑战，研究人员和工程师们正在努力开发更高效、可解释和公平的人工智能大模型。他们致力于开发更加高效的训练算法和模型优化技术，以降低训练和部署大模型的成本和时间。同时，他们还研究可解释性和公平性技术，以解决大模型的黑盒问题和潜在的偏见。这些努力将推动人工智能大模型的发展，并为更广泛的应用和推广打开新的可能性。我国人工智能基础大模型在构建理论与训练部署技术上，仍然存在系列缺陷及卡脖子风险。此外，现有的超大规模模型训练框架大多数依赖于英伟达计算卡，对于人工智能硬件平台的自主可控带来巨大的卡脖子风险。2017年国务院发布《新一代人工智能发展规划》明确指出要求建立包括大数据智能以及多媒体感知计算的新时代理论体系，统筹布局国产自主人工智能开源软硬件基础平台。

本白皮书的目标是深入探讨人工智能大模型的发展趋势、技术挑战和应用前景，为读者提供关于该领域的最新研究成果和实践经验。我们的目标是促进人工智能大模型的发展和应用，推动人工智能技术的创新和应用在各个领域的广泛推广。为了实现这一目标，本白皮书将关注以下几个方面的内容：

1) 人工智能大模型概述：回顾人工智能大模型的起源和发展历程，探讨其从传统模型到大模型的演进过程。我们将介绍关键的技术突破、算法发展和应用案例，以展示人工智能大模型的发展动态和取得的成果。

2) 关键技术和算法：探讨人工智能大模型的关键技术和算法。我们将详细介绍预训练和微调的方法，模型架构和深度学习算法的进展，以及与大模型训练和部署相关的计算资源和优化技术。我们将探索这些技术在不同领域和任务中的应用和效果。

3) 应用领域和案例研究：探索人工智能大模型在各个领域的应用。我们将聚焦于自然语言处理、计算机视觉、语音识别、推荐系统和自主系统等领域，通过案例研究和实际应用来展示人工智能大模型的潜力和效果。我们将深入讨论大模型在这些领域中的关键应用和挑战。

4) 技术挑战和解决方案：探讨人工智能大模型面临的技术挑战，并提出相应的解决方案和研究方向。我们将讨论大模型的计算资源需求、可解释性和透明度问题，以及模型偏见和公平性等挑战。我们将探索新兴的技术和方法，以解决这些挑战并推动大模型的可持续发展。

5) 未来发展方向和展望：展望人工智能大模型的未来发展方向，并提出对该领域的展望。我们将讨论模型规模和性能的持续提升、可解释性和公平性研究的进展，以及模型训练和部署的高效化和可持续性。我们还将探讨人工智能大模型与其他技术的结合，以期在更广泛的领域中实现更多的创新和应用。

本白皮书的范围将涵盖人工智能大模型各个方面，包括理论研究、技术创新、应用案例和社会影响等。我们将综合各个领域的研究成果和实践经验，旨在为读者提供一个全面的视角，以深入理解和应用人工智能大模型的最新发展和趋势。本白皮书旨在全面探讨人工智能大模型的发展、应用和相关挑战，并提供相关领域的最新研究成果和发展趋势。我们希望这份白皮书能够为政策制定者、学术界和产业

界的决策者提供有价值的信息和见解，促进人工智能大模型的发展和
应用，推动人工智能技术的进一步创新和推广。

4.2 人工智能大模型概述

人工智能大模型是指具有庞大参数规模、复杂结构和强大学习能力
的人工智能模型。这些模型通常基于深度学习技术，由数十亿甚至数
万亿个参数组成，可以通过在大规模数据上进行预训练和微调来学习
和推理，人工智能大模型的主要特征有：

参数规模：人工智能大模型拥有庞大的参数规模，通常是以亿甚
至万亿级别的参数量进行定义。这使得模型能够包含大量的特征和表
示能力，以更好地捕捉数据中的复杂模式和关联。

深层结构：大模型通常由多个层次和模块组成，形成深度的网络
结构。这种深层结构能够通过层与层之间的信息传递和转换，提取数
据中的高级特征和抽象表示，从而实现更准确的预测和推理。

预训练和微调：人工智能大模型通常采用预训练和微调的方法。
预训练是指在大规模未标记数据上进行训练，学习到丰富的特征表示。
然后，通过在有标签的数据上进行微调，使模型适应特定的任务。

强大的学习和推理能力：大模型具有强大的学习和推理能力，能
够从海量数据中提取有用的信息并进行复杂的推理和决策。这使得它
们在自然语言处理、计算机视觉、语音识别等领域中展现出卓越的性能。

人工智能大模型的发展为各种复杂任务和领域的解决提供了强
有力的工具和方法。它们在自然语言理解、图像识别、语音生成、推
荐系统等方面取得了显著成果，并推动了人工智能技术的快速发展和
应用的广泛推广。人工智能大模型的发展历程可以追溯到深度学习的
兴起和神经网络的发展。以下是人工智能大模型的主要发展里程碑：

深度学习的兴起：在 2000 年前后，深度学习开始受到重视，并

被证明在处理复杂任务上具有优势。深度学习使用多层神经网络来学习数据的特征表示，通过反向传播算法进行训练。这为人工智能大模型的发展奠定了基础。

卷积神经网络 (CNN): 在计算机视觉领域，卷积神经网络的出现推动了图像识别和分类的发展。CNN 利用卷积层和池化层等结构，可以有效地提取图像中的特征，并实现准确的图像分类。

递归神经网络 (RNN) 和长短时记忆网络 (LSTM): 递归神经网络和长短时记忆网络的出现使得处理序列数据（如自然语言和时间序列数据）变得更加有效。RNN 可以处理具有时间依赖关系的序列数据，而 LSTM 则解决了 RNN 在长序列中出现的梯度消失问题。

预训练和微调: 为了解决数据稀缺的问题，预训练成为一种重要的技术。预训练是指在大规模未标记数据上训练模型，学习到丰富的表示。然后，使用有标签的数据对模型进行微调，以适应特定的任务。这种预训练和微调的方法为人工智能大模型的发展提供了重要的推动力。

大规模模型的出现: 随着计算能力的提升和大规模数据集的可用性，人工智能大模型开始出现。其中，Google 的 Transformer 模型和 OpenAI 的 GPT（生成式预训练）模型等引起了广泛的关注。这些大模型具有数十亿或数万亿个参数，能够处理更复杂和多样化的任务。

语言模型的突破: 2019 年，OpenAI 发布了 GPT-2 模型，它在自然语言处理领域引起了轰动。GPT-2 模型可以生成连贯的文本，具有出色的语言理解和生成能力。它开创了大模型在自然语言处理领域的新纪元，并为后续的研究和发展打下了基础。2020 年中，人工智能公司 OpenAI 发布了第三代语言预测模型 GPT-3，这是科学家们迄今创建的最先进也是最大的语言模型，由大约 1750 亿个“参数”组成，这些“参数”是机器用来处理语言的变量和数据点。众所周知，OpenAI 正在开发一个更强大的继任者 GPT-4。

视觉领域的进展：在计算机视觉领域，人工智能大模型也取得了重要进展。例如，OpenAI 的 CLIP 模型结合了图像和文本信息，可以实现图像搜索和图像分类等任务。Facebook 的 DETR 模型则通过端到端的方式实现了目标检测和图像分割。

模型规模和性能的持续提升：近年来，人工智能大模型不断迭代和演进，规模和性能不断提高。模型的参数量持续增长，计算能力和训练算法也在不断改进，使得大模型在各个领域中的表现越来越出色。

人工智能大模型的发展历程是一个不断演进和创新的过程。通过不断突破技术和算法的边界，人工智能大模型为实现更强大和智能的人工智能系统打下了坚实的基础。在 2023 世界人工智能大会上，“大模型”相关话题成为焦点，会上展示的国内外大模型多达 30 余款。从“作坊式”走向“工业化”，“大模型”已经成为 AI 开发的重要方向。

4.3 关键技术和算法

人工智能大模型的成功离不开一系列关键技术的支持。以下是人工智能大模型中的一些关键技术：

深度学习算法：深度学习算法是人工智能大模型的基础。这些算法使用多层神经网络来学习数据的特征表示和模式，通过反向传播算法进行训练和优化。深度学习算法的发展为大模型提供了强大的学习能力和表达能力。

预训练和微调：预训练和微调是人工智能大模型中的重要技术。预训练是指在大规模未标记数据上进行训练，通过学习丰富的特征表示。然后，通过在有标签的数据上进行微调，使模型适应特定的任务和领域。这种预训练和微调的方法提供了一种有效的方式来利用大规模数据和先验知识。

模型架构设计：人工智能大模型的成功与模型架构的设计密切相关。

关。设计合适的模型架构可以提高模型的学习能力和表达能力，使其能够更好地捕捉数据中的复杂模式和关联。例如，卷积神经网络(CNN)在图像处理任务中的成功，很大程度上归功于其专门设计的卷积和池化操作。

计算资源和分布式训练：人工智能大模型的训练过程需要大量的计算资源。为了加速训练过程，研究人员和工程师们利用分布式计算和并行计算技术，将计算任务分配给多个计算单元进行同时计算。这样可以大大缩短训练时间，并提高大模型的训练效率。

模型优化和加速：模型优化和加速技术对于大模型的训练和推理至关重要。研究人员不断探索各种优化算法和技术，如批量归一化、自适应学习率调整、权重剪枝等，以提高模型的训练速度和效果。同时，针对不同硬件平台的优化（如 GPU、TPU 等）也能够加速模型的推理过程。

可解释性和透明度：由于人工智能大模型的复杂性，其决策和推理过程通常被视为黑盒。然而，对于某些关键应用领域（如医疗、金融等），模型的可解释性和透明度非常重要。因此，研究人员正在努力开发技术和方法来解释和理解大模型的决策和推理过程。

模型评估和鲁棒性：人工智能大模型的评估和鲁棒性测试是确保模型性能和可靠性的关键。研究人员不仅需要设计合适的评估指标和测试集，还需要针对模型的弱点和偏差进行鲁棒性测试。这有助于提高大模型在实际应用中的性能和可靠性。

这些关键技术的不断进步和创新推动着人工智能大模型的发展和應用。研究人员和工程师们在这些技术上进行深入研究和探索，以提高大模型的性能、效率和可靠性，从而推动人工智能技术的不断进步和应用的广泛推广。

人工智能大模型的成功依赖于一系列关键算法的支持。以下是人工智能大模型中的一些关键算法：

反向传播算法 (Backpropagation): 反向传播算法是深度学习中的基本算法，用于训练多层神经网络。通过计算模型预测值与真实值之间的误差，并根据误差逐层反向传播更新网络中的权重，从而优化模型的预测能力。

梯度下降优化算法 (Gradient Descent Optimization): 梯度下降算法是一种优化算法，用于最小化损失函数。通过计算损失函数对模型参数的梯度，梯度下降算法沿着梯度的负方向更新参数，使损失函数逐步降低，以优化模型的性能。

卷积神经网络 (Convolutional Neural Networks, CNN): 卷积神经网络是一种广泛应用于计算机视觉任务的深度学习算法。它通过卷积层和池化层来提取图像中的局部特征，并通过全连接层进行分类或回归预测。CNN 在图像分类、目标检测和图像分割等领域取得了显著的成果。

递归神经网络 (Recurrent Neural Networks, RNN): 递归神经网络是一种用于处理序列数据的深度学习算法。它通过引入时间步和循环连接，在每个时间步上接收输入和隐藏状态，并使用门控单元(如长短时记忆网络)来处理序列数据中的时间依赖关系。RNN 在自然语言处理、语音识别和时序预测等任务中表现出色。

Transformer 模型: Transformer 模型是一种基于自注意力机制的深度学习算法，用于处理序列数据。它不依赖于递归结构，通过自注意力机制来捕捉序列中的依赖关系。Transformer 模型在机器翻译、语言建模和文本生成等任务中取得了重大突破，并成为人工智能大模型中的重要算法。

预训练和微调 (Pretraining and Fine-tuning): 预训练和微调是一种训练策略，常用于训练人工智能大模型。预训练阶段通过在大规模未标记数据上进行训练，学习到模型的初始参数和特征表示。然后，在有标签的数据上进行微调，使模型适应特定任务和领域，提高模型

的性能和泛化能力。

生成对抗网络 (Generative Adversarial Networks, GAN): 生成对抗网络是一种由生成器和判别器组成的深度学习模型。生成器负责生成逼真的数据样本，而判别器负责区分真实样本和生成样本。通过对抗训练的方式，生成对抗网络可以生成高质量的合成数据，如图像、文本和音频等。

这些关键算法是人工智能大模型中的重要组成部分，为模型的学习、推理和生成能力提供了关键支持。同时，这些算法也在不断发展和创新，以应对新的挑战 and 推动人工智能大模型的进一步发展。

4.4 应用领域和案例研究

人工智能大模型在各个领域中都有广泛的应用。以下是一些人工智能大模型的应用领域：

自然语言处理 (Natural Language Processing, NLP): 人工智能大模型在自然语言处理领域取得了显著的成果。它们能够理解和生成自然语言文本，包括机器翻译、文本摘要、情感分析、问答系统、对话生成等任务。

计算机视觉 (Computer Vision): 人工智能大模型在计算机视觉领域有广泛的应用。它们能够识别和理解图像和视频内容，包括图像分类、目标检测、图像生成、图像分割、人脸识别等任务。

语音识别和语音合成 (Speech Recognition and Speech Synthesis): 人工智能大模型在语音识别和语音合成领域也有重要的应用。它们能够将语音转换为文本，并生成逼真的语音输出。这些应用包括语音助手、语音转写、语音合成等。

推荐系统 (Recommendation Systems): 人工智能大模型在推荐系统中发挥着重要作用。它们能够根据用户的兴趣和行为数据，推荐个性化的产品、服务或内容，提供更好的用户体验。这包括电子商务、音乐和视频推荐等领域。

医疗健康 (Medical and Healthcare): 人工智能大模型在医疗和健康领域有着广泛的应用。它们能够辅助医生进行诊断、预测疾病风险、分析医疗影像、个性化治疗等。这些应用有助于提高医疗效率、准确性和个性化护理。

金融领域 (Finance): 人工智能大模型在金融领域也发挥着重要的作用。它们能够分析和预测金融市场、评估风险、进行欺诈检测、个性化金融推荐等。这些应用有助于提高金融决策的准确性和效率。

智能交通 (Intelligent Transportation): 人工智能大模型在智能交通领域有广泛应用。它们能够实现交通流预测、智能驾驶、路径规划、交通信号优化等，提高交通安全性、效率和环境友好性。

能源管理 (Energy Management): 人工智能大模型在能源管理领域也有应用。它们能够分析能源数据、优化能源分配和利用，实现能源效率的提升和节能减排。

这些仅是人工智能大模型应用领域的一部分，实际上，人工智能大模型在各个领域都有广泛的应用潜力。随着技术的不断进步和创新，人工智能大模型将进一步拓展其应用范围，并为各行业带来更多创新和改变。以下是一些实际应用的例子：

自然语言处理 (NLP): 谷歌的 BERT[4] 模型 (Bidirectional Encoder Representations from Transformers) 是一种预训练的语言模型，通过在大规模文本数据上进行训练，实现了在多项自然语言处理任务上的优秀性能，如问答、文本分类和命名实体识别等。

计算机视觉 (Computer Vision): Facebook 的 MAE 预训练模型是一个基于深度学习的计算机视觉框架，它在目标检测、实例分割和关键点检测等下游任务上表现出色，能够快速准确地识别图像中的物体和特征。

语音识别和语音合成 (Speech Recognition and Speech Synthesis): OpenAI 的 TTS (Text-to-Speech) 模型是一种基于深度学习的语音合

成模型，能够生成逼真的语音输出。这种技术被广泛应用于语音助手、自动语音系统等领域。

推荐系统 (Recommendation Systems): Netflix 的推荐系统利用人工智能大模型进行个性化推荐。通过分析用户的观看历史、评分和偏好，它能够推荐用户可能感兴趣的电影和电视节目，提供更好的用户体验和内容发现。

医疗健康 (Medical and Healthcare): 谷歌的 DeepMind 利用人工智能大模型开发了 AlphaFold，这是一种能够预测蛋白质三维结构的模型。这项技术对于理解蛋白质的功能和与疾病相关的变化具有重要意义。

金融领域 (Finance): Goldman Sachs 等金融机构利用人工智能大模型来进行交易策略分析和风险管理。通过分析大量的市场数据和模型的学习能力，这些模型能够预测市场趋势和风险，辅助金融决策。

智能交通 (Intelligent Transportation): Waymo 是谷歌旗下的自动驾驶技术公司，利用人工智能大模型来实现自动驾驶汽车。这些模型能够通过分析传感器数据、识别道路、预测行为，实现安全和高效的自动驾驶。

这些案例只是人工智能大模型在各个领域中的一小部分应用。实际上，人工智能大模型的应用已经渗透到各行各业，包括教育、农业、能源等领域。这些案例展示了人工智能大模型在提高效率、推动创新和改善用户体验方面的潜力。随着技术的不断发展，人工智能大模型将继续为各个行业带来更多的应用和变革。

4.5 人工智能多模态大模型

北京大学（深圳）和鹏城实验室陈杰团队在多模态大模型和大模型压缩方面的最新探索，我们在基于国产软硬件平台，系统性解决大模型构建训练与适配部署的系列关键问题，力图形成软硬件全国产的

紧致化多模态人工智能基础大模型，突破模型构建、规模训练、动态适配、自动压缩系列关键技术，遵照木兰协议开源多模态基础大模型全流程构建、训练、压缩代码框架，支持千节点国产芯片以及千亿参数的模型构建，在通用性、高效性、跨域迁移能力达到世界领先，并在儿童智能陪护机器人这一全新场景上形成应用示范。包括“多模态架构设计（高效训练（多任务子结构动态迁移学习（大模型自动化压缩加速（智能儿童机器人应用”五个方面

（1）多模态架构设计：多模态大模型的设计关键旨在利用多模态语义相关性优化模态表征能力。如表 4-1 所示，现有的多模态模型大多仅支持图像和文字，然而，图像、文本、声音、视频等多模态任务的需求跨度大，统一建模存在困难，同时不同模态的表征也无法精确匹配，上述困难在进行任务迁移时进一步放大，从而使得最终性能严重受限。为此，北京大学（深圳）和鹏城实验室陈杰团队研究了多模态统一建模编码机制，并在架构层实现模态对齐与特征匹配，打造基于国产软硬件的千亿级参数量多模态大模型。

表 4-1 多模态架构设计研究现状

国内外研究现状	关键研究挑战
<p>微软公司团队提出通过将视觉文本任务统一看作生成任务建立统一的预训练和微调范式，同时提高多个图文跨模态下游任务性能，并支持迁移至跨视频模态，然而其不支持声音等其他模态 [5]。</p>	<p>1.多模态统一建模需要对输入编码和生成特征匹配对齐 2.如何实现基于国产软硬件设备的千亿级参数的多模态大模型</p>
<p>谷歌公司团队利用对比和生成损失在超大规模图文跨模态预训练数据集上训练，提高了在零样本、少样本等新任务下的模型适配性能，但是其仅支持图文两个模态 [6]</p>	
<p>百度公司团队提出面向视觉-语言知识增强的预训练框架，首次在视觉-语言预训练中引入结构化知识，但是其采用非国产硬件设备 [7]。</p>	
<p>智源公司团队提出悟道大模型，融合生成语言框架和图文匹配框架，取得了良好的性能，然而其依旧采用了非国产深度学习框架来进行训练 [2]。</p>	

（2）大模型高效训练：大模型训练往往涉及巨量的开销，而现有的训练方法主要采用少量节点的单一并行训练方法，且要求大规模

的较难获取的标注数据。此外，如表 4-2 所示，当前方法多针对于单模态进行无监督与自监督学习，但对于精、弱、无标签数据的多元利用，以及多模态表征联合学习的探索存在明显局限。同时，现有方法多关注于小计算模块的加速，对于大规模的并行训练加速尚未探索。北京大学（深圳）和鹏城实验室陈杰团队利用不同程度的标记信息，学习多模态数据统一表征，并实现针对千亿级参数模型的高效训练加速架构。

表 4-2 弱监督自监督知识学习研究现状

国内外研究现状	关键研究挑战
<p>帝国理工学院与 Deepmind 团队提出构建不依赖于负样本的对比学习结构，采用模型滑动、梯度截断、线性投影层等技术进行自监督学习，但是其没有利用不同标记程度的信息，数据利用率低效 [8]。</p>	<p>1. 缺少充分利用不同标记程度信息以及联合学习多模态数据表征的数据增强方法。</p>
<p>清华大学与微软亚洲研究院提出构建基于掩码图像建模的自监督学习结构，采用 Transformer 与掩码恢复技术，然而其没有涉及跨多模态数据表征学习 [9]。</p>	<p>2. 缺少针对跨模态、千亿级参数大模型的高性能训练的计算框架。</p>
<p>中国科技大学与清华大学团队提出构建基于弱标签的弱监督对比学习技术，实现语义层面的自监督学习，但是其仅涉及图像模态，不支持其他模态 [10]。</p>	<p>3 缺乏多模态数据自监督、弱监督表征强化的统一算法，以及针对大规模多模态数据的高性能训练计算框架。</p>
<p>麻省理工大学设计针对 Attention 机制的高性能计算模块节约计算成本，提高计算效率，然而其不支持大规模神经网络模型 [11]。</p>	

(3)多任务子结构动态迁移学习:在基础模型的迁移应用阶段，当前研究多针对已知任务，在真实世界开放空间中存在明显的局限性。如表 1-3 所示，现有模型适配多采用预训练-迁移-微调的范式，面临真实场景任务对象动态扩增的情况，存在高效任务迁移的瓶颈。因此，面向开放任务环境的动态网络结构和多任务元知识是提升多任务适应性的先决条件之一，北京大学（深圳）和鹏城实验室陈杰团队探索了自适应的任务关系预测，以此为依据训练动态神经网络，并针对不

同任务进行结构和权重的预测，实现多任务高效迁移。

表 4-3 模型结构迁移研究现状

国内外研究现状	关键研究挑战
芝加哥大学、谷歌公司提出基于高效参数的多任务和迁移学习，允许同时（多任务）以及顺序迁移学习，然而并未能判别模型面对多任务场景下参数的重要性 [12]	1. 现有研究多面向有限环境单一静态任务，而真实环境中场景任务多样，且动态变换。 2. 不同场景中感知对象、感知任务存在差异，需要网络进行动态处理。 3. 缺乏开放多任务环境下，多源数据的精准感知高效微调方法。
约翰霍普金斯大学、英伟达公司提出多步任务的有效强化学习与模拟到真实的迁移学习，但是该方法与数据有较强的相关性，并且对于多任务场景其结构需要进一步优化 [13]。	
谷歌公司与 DeepMind 团队基于迁移学习的极端多任务扩展，然而该方法局限于 NLP 任务 [14]。	
中山大学与华为诺亚方舟实验室提出统一自动驾驶多任务协同训练，实现在自动驾驶系统中的多任务间的有效迁移学习，但是该方法没有考虑硬件资源偏好问题 [15]。	

(4) 大模型自动化压缩加速：智能机器人等多终端边缘部署场景，往往需要根据硬件限制要求对大模型进行加速与压缩。如表 4-4 所示，当前研究方法针对不同终端都需进行一次压缩与训练流程，带来了巨量的人工设计和计算开销。此外，当前方法采用单一策略进行压缩与加速，面向大规模基础模型的场景只能取得有限的效果，无法达到部署需求。针对上述挑战，北京大学（深圳）和鹏城实验室陈杰团队采用网络结构搜索对不同终端进行自动紧致化，进一步研究多种压缩技术组合方式，提升大模型在实际部署场景中的推理性能。

表 4-4 大模型自动化压缩研究现状

国内外研究现状	关键研究挑战
美国麻省理工学院与美国 IBM 公司团队提出基于多终端部署的自动化模型压缩，但是只考虑了单一任务场景下的模型压缩与加速，在多任务场景下无法实现通用性部署 [16]。	1. 现有研究多采用单一策略对大模型进行压缩与加速，无法满足大模型在实际场景下的部署需求。
美国佐治亚理工学院与美国谷歌公司等提出基于元学习的神经网络架构搜索方法，通过元学习学习到任务无关的	

高效网络结构，实现多任务协同部署，然而只采用了单一策略的网络压缩方法，压缩率有限 [17]。	2. 现有研究多研究单一任务下的压缩，在多任务场景下往往需要多次完整的预训练或压缩流程，增加了大模型的压缩开销。
瑞士苏黎世联邦理工学院团队提出利用元学习对神经网络进行可微分的自动化压缩，但是只考虑了单一任务下的压缩，且压缩过程较为耗时 [18]。	
百度公司团队提出统一特征优化范式，将单一的任务与大规模的预训练任务的进行联合训练，用于在现实世界和大规模场景下训练的深度学习部署，然而训练流程繁琐，需要完整的预训练流程，压缩开销较大 [19]。	

(5) **多模态基础大模型应用**：当前基础模型主要面向单一文本或图像模态进行研发，在金融、新闻传播、医疗等人工智能紧耦合行业实现了广泛应用。如表 4-5 所示，我国人工智能头部企业（百度、腾讯、字节等）已在多个领域实现了领跑或并跑。然而在非人工智能紧耦合场景中，基础模型所发挥效力仍旧有限。例如，涉及行为监控与智能交互陪护机器人场景鲜有研发与应用。诚如联合国秘书长古特雷斯在可持续发展高级别政治论坛中指出：“儿童心理健康服务长期以来一直受到忽视，获得所需服务的儿童少之又少”。因此，如何拓展传统人工智能应用至儿童认知陪护领域，实现基于多模态基础模型的儿童认知能力感知、快速预警、主动交互，并以此形成在边缘设备部署的基于主动对话的儿童认知创新应用，不仅是未来研究重点，也有望填补国内外研发与产品空白。

表 4-5 人工智能基础模型应用现状

国内外应用现状	国内外对比
自动驾驶 ：2021 Guidehouse Insights 排行榜报告，Waymo 名列第一获得 85.6 分，百度紧随其后，皆处于“领导者”等级。	国内外并跑
推荐系统 ：国外 Meta，Google 公司广告推荐系统是主要的利润来源，国内淘宝商品推荐，字节跳动凭借 TikTok 等产品成功登顶海外市场。	国内领先
智慧医疗 ：大约 1/3 的美国的医院已 通过 HIMSS EMRAM 级及以上的评审，表明它们已能够熟练使用电子健康智慧系统；腾讯公司医疗产品可提供多种购药方式，助力医院服务智慧升级，提升患者就医满意度。	国内外并跑

<p>儿童监护&陪护：国内儿童陪护机器人起步较晚，存在差距，大多仅具有日常交流；国外 Aeolus 公司的陪护机器人能够与儿童进行多轮对话交流，可根据儿童情绪变化调整交互内容，具有较强的人机交互能力；中国淘云公司实现覆盖 160 个国家 1000 万家庭，但在多模态感知上仍存在技术差距。</p>	<p>国外领先市场巨大 国内跟跑</p>
---	--------------------------

表 4-6 国外从事相关研究的主要机构

序号	机构名称	相关研究内容	相关研究成果	成果应用情况	评价
1	微软公司	将视觉文本任务统一看作生成任务建立统一的预训练和微调范式	同时提高多个图文跨模态下游任务性能，支持迁移至跨视频模态 [20]	微软 Seeing AI 产品	<input checked="" type="checkbox"/> 领跑 <input type="checkbox"/> 并跑 <input type="checkbox"/> 跟跑
2	Meta 公司	将视觉文本任务统一看作生成任务建立统一的预训练和微调范式	可更高效的训练大模型，同时提升模型泛化精度,下游任务的迁移取得了优于监督训练的性能。	Facebook 公司的 Facebook Shops, Instagram Reels 等产品	<input type="checkbox"/> 领跑 <input checked="" type="checkbox"/> 并跑 <input type="checkbox"/> 跟跑
3	麻省理工学院	将视觉文本任务统一看作生成任务建立统一的预训练和微调范式	提出基于跨模态对比学习的新训练框架，使用渐进蒸馏和软图像-文本对齐，更有效地从噪声数据学习鲁棒表示 [21]。	基础研究，未见有应用报道	<input type="checkbox"/> 领跑 <input checked="" type="checkbox"/> 并跑 <input type="checkbox"/> 跟跑
4	麻省理工大学	提出适用于 IoT 设备的设备上训练，能够执行 256KB 极低内存预算下的设备上训练	提高模型在边缘设备上的训练效率，甚至支持在单片机上的极低内存训练 [22]。	基础研究未见有应用报道	<input type="checkbox"/> 领跑 <input checked="" type="checkbox"/> 并跑 <input type="checkbox"/> 跟跑
5	华盛顿大学	研究具有高泛化能力的预训练模型	提出多任务自适应参数共享，将模型迁移优化到新任务上 [23]。	基础研究未见有应用报道	<input type="checkbox"/> 领跑 <input checked="" type="checkbox"/> 并跑 <input type="checkbox"/> 跟跑

表 4-7 国内从事相关研究的主要机构

序号	机构名称	相关研究内容	相关研究成果	成果应用情况	评价
1	百度公司	自然语言处理部门提出面向视觉-语言知识增强的预训练框架,首次在视觉-语言预训练引入结构化的知识	五项视觉-语言下游任务取得最好效果,视觉常识推理榜单取得第一 [24]。	ERNIE-ViL 产业级大模型	√领跑 □并跑 □跟跑
2	清华大学	提出使用滑动窗口 Transformer 的结构进行自监督学习	实现了使用少量数据,在参数量与计算量不增加的情况下取得了先进的下游任务微调性能 [9]。	基础研究,未见有应用报道	□领跑 √并跑 □跟跑
3	快手科技	研究使用降噪标签指导的高效单模态增强与跨模态集成学习	提出通过集成自信学习的降低噪声的影响,同时通过丰富非配对单模态数据增强模型的泛化能力 [25]。	用于快手短视频平台	□领跑 √并跑 □跟跑
4	清华大学	研究样本自适应、空间自适应和时空自适应三类典型的动态神经网络	黄高课题组提出了具有时间与空间自适应特性的动态深度神经网络 [26]。	基础研究,未见有应用报道	□领跑 √并跑 □跟跑
5	厦门大学	提出神经网络压缩与加速的标准框架相关技术	参与制定中华人民共和国关于网络压缩部分的技术标准。	已在国内领先企业如华为、百度、阿里巴巴等落地产品上应用。	□领跑 √并跑 □跟跑

表 4-8 领域内主要代表性成果

序号	类型	名称	机构	作者
1	文献	Language Models are Few-Shot Learners 发表于 arXiv 2020	OpenAI	Tom B. Brown, Benjamin Mann, Nick Ryder 等
2	文献	PanG- α : Large-scale Autoregressive Pretrained Chinese Language Models	Huawei Inc, Pengcheng Lab	Wei Zeng, Yonghong Tian

		with Auto-parallel Computation 发表于 arXiv 2021		
3	文献	Dynamic Neural Networks: A Survey 发表于 TPAMI 2021	Tsinghua University, Beijing Academy of Artificial Intelligence	Yizeng Han, Gao Huang, Shiji Song, Le Yang, Honghui Wang, Yulin Wang
4	文献	Once-for-all 发表于 ICLR, 2020	MIT, IBM	Cai han, Tianchuang Gan
5	国家标准	《信息技术：神经网络表示与模型压缩》标准编号：AI115.1—2021.	厦门大学, 华为技术有限公司	纪荣嵘, 郑侠武等

4.6 人工智能大模型在生命科学领域上的探索

北京大学（深圳）和鹏城实验室陈杰团队在生命科学领域上的探索，11月17日，美国计算机协会（ACM）公布2022年度戈登贝尔新冠特别奖评选结果。北京大学深圳研究生院信息工程学院与鹏城实验室、山东大学组成的联合研究团队在自行研发的鹏程·神农生物信息研究平台上完成的“领先于病毒的进化——通过人工智能模拟预测未来高风险新冠病毒变异株”研究项目成功入围2022年度“戈登贝尔新冠特别奖”，也是本次入围唯一来自中国团队的项目。北大主要参与者是来自信息工程学院的田永鸿教授、陈杰副教授和博士研究生聂志伟等。该成果由美国华盛顿大学医院院长 John Lynch 教授、捷克查尔斯大学 Martina Koziar Vasakova 教授、西湖大学周强教授提名推荐。入围该奖的其余2个团队为：美国阿贡国家实验室、英伟达、芝加哥大学、加州理工学院联合团队及美国橡树岭国家实验室团队。鹏程·神农团队于众多世界级顶尖强队中脱颖而出，名列前茅，足见中国人工智能在计算集群和科研创新领域已处于全球顶尖水平。

鹏程·神农是基于“鹏城云脑II”超大规模算力集群和昇思 MindSpore AI 框架联合打造的面向生物医学领域的新一代数据密集型生命科学精准计算平台。该平台依托生物大数据、计算生物学理论

和技术、人工智能算法和计算集群，实现新药创制和病毒演化预测。团队研发了首个面向新冠病毒 RBD 区域变异的全环节模拟流程，通过多层次优化的计算策略、国际领先的新冠病毒变异体精准评价筛选算法，实现了对高风险变异株的演化模拟及精准预测。




图 4-1 首个面向新冠病毒 RBD 区域变异的 AI 模拟工作

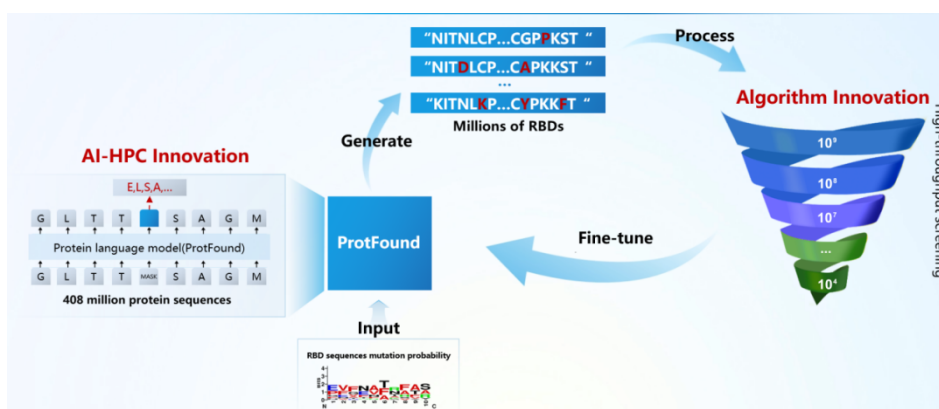


图 4-2 依托“鹏城云脑II”的大规模并行病毒变异模拟全流程

为了在高维变异空间中实现高性能预测，团队充分融合专家知识，复刻病毒在真实世界中的变异规律，构建基于神农的变异体生成器。生成的海量变异体通过多层次的精准病毒关键性质预测算法，进行高通量筛选，以模拟病毒在真实世界变异过程所面临的筛选压力，每秒可生成、筛选超百万条变异体，每天可生成、筛选超 10^{11} 条变异体。

同时通过递进循环微调的范式，逐步缩小病毒的变异空间，最终实现病毒的全流程变异模拟。团队在两天内实现了新冠病毒 Alpha、Beta、Gamma、Delta、Omicron BA.5 等主流毒株的变异模拟，且可以准确预测大多数的高风险监测变异株，包括 BF.7、BQ.1、BA.4.6 等。

病毒变异不断冲击着人类抗疫战线。在新冠病毒新变种不断出现的情况下，对潜在高风险变异株的预测有助于疫苗和药物研发的提前部署，为疫情防控决策提供有力支撑和可靠保障。

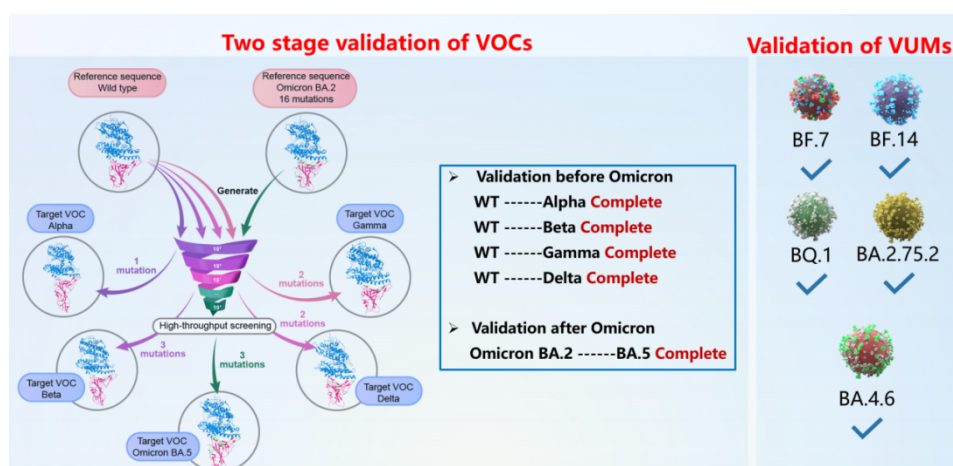


图 4-3 神农 AI 大模型在两天内实现了对高风险变异株的演化模拟和精准预测

设立于 1987 年的“戈登贝尔奖”是国际上高性能计算应用领域的最高学术奖项，主要颁发给高性能应用领域最杰出成就，被称为“超算领域的诺贝尔奖”。在 2016 年之前，美国、日本曾垄断该奖项长达近 30 年。该奖项由 ACM 每年评选和颁发。由于新冠疫情的暴发，ACM 于 2020 年首次设立了“戈登贝尔奖新冠特别奖（ACM Gordon Bell Special Prize for High Performance Computing-Based COVID-19 Research）”以表彰在“超算抗疫”领域取得杰出成就的研究成果。

4.7 技术挑战和解决方案

人工智能大模型在发展和应用过程中面临着一些技术挑战。以下是一些常见的技术挑战：

计算资源需求：人工智能大模型通常需要大量的计算资源，包括高性能的计算设备和大容量的存储空间。这对于许多组织和研究人员来说是一个挑战，因为它们需要投入大量的时间和资金来满足这些需求。

数据质量和标注：人工智能大模型的训练需要大量高质量的数据，并且通常需要对数据进行标注。数据质量和标注的准确性是一个挑战，因为错误或不一致的数据可能导致模型训练不稳定或性能下降。

模型泛化和过拟合：人工智能大模型在训练数据上表现出色，但在未见过的数据上可能泛化能力不足。过拟合是一个常见的问题，即模型在训练数据上过度拟合，而在新数据上的表现较差。

解释性和可解释性：人工智能大模型通常被视为黑盒，即很难理解模型的决策和推理过程。这在某些应用场景中是不可接受的，如医疗和金融领域，因为解释模型的决策对于决策的可信度和可解释性至关重要。

隐私和安全性：人工智能大模型处理大量的个人数据，隐私和安全性是一个重要关注点。保护数据的隐私，防止数据泄露和滥用是一个挑战，特别是在跨组织或跨边界数据共享的情况下。

算法和模型选择：在人工智能大模型的开发中，选择合适的算法和模型架构是关键。然而，从众多的算法和模型中选择最合适的一个可能是具有挑战性的，因为不同的任务和数据可能需要不同的模型来实现最佳性能。

可扩展性和效率：随着模型规模的增大，人工智能大模型的可扩展性和效率成为挑战。大模型需要更多的计算资源和存储空间，对于实时应用或边缘计算等资源受限的场景可能不够高效。

伦理和社会影响：人工智能大模型的发展和应用引发了许多伦理和社会问题。这包括公平性、透明度、责任和权益等方面的考虑，需要制定相应的政策和规范来确保模型的公正和可接受性。

这些技术挑战是人工智能大模型所面临的一些重要问题，研究人员和开发者正在努力寻找解决方案，推动人工智能大模型的发展和应用。针对人工智能大模型所面临的技术挑战，可以采取以下解决方案：

计算资源需求：利用云计算平台提供的弹性计算和存储资源，以满足模型训练和推理的需求。同时，优化算法和模型架构，减少计算资源的需求，如模型剪枝、量化和近似计算等方法。

数据质量和标注：建立高质量的数据集，进行数据清洗和预处理，确保数据的准确性和一致性。利用半监督学习和迁移学习等技术，最大限度地利用少量标注数据来提高模型性能。借助众包平台或自动化工具加速数据标注过程，并进行质量控制。

模型泛化和过拟合：采用正则化方法，如 L1/L2 正则化、Dropout 等，控制模型的复杂度，减少过拟合的风险。增加训练数据的多样性，使用数据增强技术如旋转、缩放、剪裁等，提高模型的泛化能力。使用集成学习方法如 Bagging、Boosting 等，结合多个模型的预测结果，提高模型的鲁棒性和性能。

解释性和可解释性：使用可解释的模型，如决策树、规则模型等，能够提供对模型决策过程的解释。利用可视化技术、注意力机制和解释生成方法，解释模型对输入数据的关注点和决策依据。研究模型的可解释性，并提供合理的解释和解决方案，增强模型的可信度和可解释性。

隐私和安全性：采用数据加密、差分隐私和安全多方计算等技术，确保个人数据的隐私和安全。实施访问控制和身份认证机制，限制对模型和数据的访问权限。进行安全审计和监控，及时发现和应对潜在的安全风险。

算法和模型选择：基于具体任务的特点和数据的特征，选择合适的算法和模型架构。进行模型评估和对比实验，选取在性能和效率方面均较优的模型。利用开源社区和研究机构的资源，了解最新的算法

和模型发展，选择适合的模型进行应用。

可扩展性和效率：优化模型的架构和参数，减少模型的计算和存储需求。采用模型压缩和量化技术，减小模型的规模，提高计算效率。使用分布式训练和模型并行化技术，提高模型训练和推理的速度和效率。

伦理和社会影响：制定合适的法律法规和伦理准则，确保人工智能大模型的使用符合道德和法律要求。开展公开和透明的讨论，促进社会对于人工智能技术的理解和参与。注重公平性和权益保护，进行数据脱敏和去偏倚处理，避免对特定群体的歧视和偏见。

这些解决方案可以帮助克服人工智能大模型所面临的技术挑战。然而，具体的解决方案需要根据具体的应用场景和问题进行定制化。随着技术的进步和实践的积累，将会出现更多的解决方案来应对新的挑战 and 推动人工智能大模型的可持续发展。

4.8 未来发展方向和展望

人工智能大模型的未来发展有着广阔的展望。人工智能大模型可能的发展方向有：

1) **模型的更大规模和复杂性：**人工智能大模型可能会继续增大规模和复杂性，拥有更多的参数和更深层次的结构。这将使模型能够更好地捕捉数据中的复杂模式和关联，并提高模型的性能和泛化能力。

2) **跨模态学习和多任务学习：**人工智能大模型将会更加注重跨模态学习，即利用多种类型的输入数据（如图像、文本、语音等）来提升模型的理解和推理能力。同时，人工智能大模型还将更多地应用于多任务学习，即在一个模型中同时学习和处理多个相关任务，提高模型的效率和智能性。

3) **模型的自学习和迁移学习：**人工智能大模型将越来越具备自学习和迁移学习的能力，能够从大规模的无监督数据中进行学习，并将

已学到的知识迁移到新任务或新领域中。这将减少对大量标注数据的依赖，并加速模型在新领域的应用和推广。

4) 长期记忆和时间建模：人工智能大模型将更加注重长期记忆和时间建模，能够对时间序列数据和动态环境进行更好地建模和预测。这将使模型能够处理更复杂的任务，如视频分析、自然语言理解和机器人控制等。

5) 模型的适应性和鲁棒性：人工智能大模型将更加注重模型的适应性和鲁棒性，能够在不同环境和数据分布下保持良好的性能和泛化能力。模型将更具灵活性，能够从少量的样本中进行学习和推理，并在面对新的任务和数据时快速适应。

6) 可解释性和可信度：人工智能大模型将致力于提高可解释性和可信度，使模型的决策和推理过程更可理解和透明。研究人员将进一步探索模型解释性的技术，以帮助用户和相关利益方理解和信任模型的决策。

7) 联邦学习和隐私保护：人工智能大模型将更加关注联邦学习和隐私保护的技术，实现在分布式环境下模型的训练和推理，同时保护用户数据的隐私和安全。这将促进跨组织和跨边界的合作，推动人工智能应用的发展。

总体而言，人工智能大模型未来的发展将更加注重模型的规模、复杂性、跨模态学习、自学习能力、长期记忆和时间建模、适应性和鲁棒性、可解释性和可信度、联邦学习和隐私保护等方面的进一步突破和创新。这将为各个领域的应用带来更高的性能、更广泛的应用场景和更好的用户体验。同时，也需要解决伦理、隐私、安全和社会影响等问题，确保人工智能大模型的可持续发展和社会价值。

参考文献

- [1] Radford, A., Kim, J.W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., Sastry, G., Askell, A., Mishkin, P., Clark, J. and Krueger, G. Learning transferable visual models from natural language supervision. In: International conference on machine learning, 2021: 8748-8763.
- [2] 悟道大模型介绍.
<https://www.baai.ac.cn/portal/article/index/cid/49/id/518.html>.
- [3] Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J.D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A. and Agarwal, S. Language models are few-shot learners. *Advances in neural information processing systems*, 33, 2020:1877-1901.
- [4] Devlin, J., Chang, M.W., Lee, K. and Toutanova, K. Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*, 2018.
- [5] Wang, J., Yang, Z., Hu, X., Li, L., Lin, K., Gan, Z., ... & Wang, L. (2022). GIT: A Generative Image-to-text Transformer for Vision and Language. *Transactions on Machine Learning Research*.
- [6] Yu, J., Wang, Z., Vasudevan, V., Yeung, L., Seyedhosseini, M., & Wu, Y. (2022). Coca: Contrastive captioners are image-text foundation models. *arXiv preprint arXiv:2205.01917*.
- [7] Yu, Fei, et al. "Ernie-vil: Knowledge enhanced vision-language representations through scene graphs." *Proceedings of the AAAI Conference on Artificial Intelligence*. Vol. 35. No. 4. 2021.
- [8] Grill, J.B., Strub, F., Altché, F., Tallec, C., Richemond, P., Buchatskaya, E., Doersch, C., Avila Pires, B., Guo, Z., Gheshlaghi Azar, M. and Piot, B., 2020. Bootstrap your own latent-a new approach to self-supervised learning. *Advances in neural information processing systems*, 33, pp.21271-21284.

- [9] Xie, Z., Zhang, Z., Cao, Y., Lin, Y., Bao, J., Yao, Z., Dai, Q. and Hu, H., 2022. Simmim: A simple framework for masked image modeling. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 9653-9663).
- [10] Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S. and Guo, B., 2021. Swin transformer: Hierarchical vision transformer using shifted windows. In Proceedings of the IEEE/CVF international conference on computer vision (pp. 10012-10022).
- [11] Wang, H., Zhang, Z. and Han, S., 2021, February. Spatten: Efficient sparse attention architecture with cascade token and head pruning. In 2021 IEEE International Symposium on High-Performance Computer Architecture (HPCA) (pp. 97-110). IEEE.
- [12] Sandler, M., Zhmoginov, A., Howard, A.G. and Mudrakarta, P.K., Google Llc, 2023. Parameter-efficient multi-task and transfer learning. U.S. Patent 11,676,008.
- [13] A. Hundt et al., "Good Robot!": Efficient Reinforcement Learning for Multi-Step Visual Tasks with Sim to Real Transfer, in IEEE Robotics and Automation Letters, vol. 5, no. 4, pp. 6724-6731, Oct. 2020, doi: 10.1109/LRA.2020.3015448.
- [14] Aribandi, V., Tay, Y., Schuster, T., Rao, J., Zheng, H.S., Mehta, S.V., Zhuang, H., Tran, V.Q., Bahri, D., Ni, J. and Gupta, J., 2021. Ext5: Towards extreme multi-task scaling for transfer learning. arXiv preprint arXiv:2111.10952.
- [15] Liang, X., Wu, Y., Han, J., Xu, H., Xu, C. and Liang, X., 2022. Effective adaptation in multi-task co-training for unified autonomous driving. Advances in Neural Information Processing Systems, 35, pp.19645-19658.

- [16] Cai, H., Gan, C., Wang, T., Zhang, Z. and Han, S., 2019. Once-for-all: Train one network and specialize it for efficient deployment. arXiv preprint arXiv:1908.09791.
- [17] Shaw, A., Wei, W., Liu, W., Song, L. and Dai, B., 2019. Meta architecture search. *Advances in Neural Information Processing Systems*, 32.
- [18] Li, Y., Gu, S., Zhang, K., Van Gool, L. and Timofte, R., 2020. Dhp: Differentiable meta pruning via hypernetworks. In *Computer Vision – ECCV 2020: 16th European Conference, Glasgow, UK, August 23 – 28, 2020, Proceedings, Part VIII 16* (pp. 608-624). Springer International Publishing.
- [19] Xi, T., Sun, Y., Yu, D., Li, B., Peng, N., Zhang, G., Zhang, X., Wang, Z., Chen, J., Wang, J. and Liu, L., 2022, October. UFO: unified feature optimization. In *European Conference on Computer Vision* (pp. 472-488). Cham: Springer Nature Switzerland.
- [20] Unify visual-text tasks as generative tasks to establish a unified pre-training and fine-tuning paradigm
- [21] Andonian, A., Chen, S. and Hamid, R., 2022. Robust cross-modal representation learning with progressive self-distillation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 16430-16441).
- [22] Lin, J., Zhu, L., Chen, W.M., Wang, W.C., Gan, C. and Han, S., 2022. On-device training under 256kb memory. *Advances in Neural Information Processing Systems*, 35, pp.22941-22954.
- [23] Wallingford, M., Li, H., Achille, A., Ravichandran, A., Fowlkes, C., Bhotika, R. and Soatto, S., 2022. Task adaptive parameter sharing for multi-task learning. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 7561-7570).
- [24] Sun, Y., Wang, S., Li, Y., Feng, S., Tian, H., Wu, H. and Wang, H., 2020, April. Ernie 2.0: A continual pre-training framework for language understanding. In

Proceedings of the AAAI conference on artificial intelligence (Vol. 34, No. 05, pp. 8968-8975).

- [25] Liu, S., Fan, H., Qian, S., Chen, Y., Ding, W. and Wang, Z., 2021. Hit: Hierarchical transformer with momentum contrast for video-text retrieval. In Proceedings of the IEEE/CVF International Conference on Computer Vision (pp. 11915-11925).
- [26] Han, Y., Huang, G., Song, S., Yang, L., Wang, H. and Wang, Y., 2021. Dynamic neural networks: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(11), pp.7436-7456.
- [27] Zeng, W., Ren, X., Su, T., Wang, H., Liao, Y., Wang, Z., Jiang, X., Yang, Z., Wang, K., Zhang, X. and Li, C., 2021. Pangu- α : Large-scale autoregressive pretrained Chinese language models with auto-parallel computation. arXiv preprint arXiv:2104.12369.

第 5 章 深度学习与图像描述生成及视觉定位

5.1 图像描述生成

随着互联网与信息技术的发展，多媒体数据呈现爆炸性增长的趋势。从各种信息源（如网络、新闻、相机等）上可获得的图像数据越来越多。由于图像数据具有海量特性和非结构化特性，如何快速有效地组织、存储和检索图像成为重要的研究课题，而完备的图像语义理解则是其中的关键问题。尽管从信息源上获取的大多数图像并没有对应的语义描述，但人类仍然能够在很大程度上理解它们。也就是说，人类很容易就能完成涉及复杂视觉识别以及场景理解的各种任务，涉及自然语言交流的各种任务以及两种模态之间的转换任务。例如，只需快速浏览图像就足以让人指出并描述关于视觉场景的大量细节，而这对于机器来说目前仍然是难以完成的任务。为了实现图像数据的结构化和半结构化，从语义上更完备地理解图像数据，从而进一步研究更符合人类感知的视觉智能，迫切需要机器能够为给定图像自动地生成自然语言描述。

计算机视觉研究如何理解图像和视频，而自然语言处理研究如何分析和生成文本。尽管这两个领域的研究都采用类似的人工智能和机器学习方法，但在很长一段时期里它们都是各自发展而很少交叉。近几年，结合视觉和语言的跨模态问题受到了广泛关注。事实上，许多日常生活中的任务都具有这种跨模态的特性。例如，看报纸时解释图片的上下文信息，听报告时为理解讲话而搭配的表，网页上提供大量结合视觉信息和自然语言的数据（带标签的照片、新闻里的图片视频、具有多模态性质的社交媒体）等。为完成结合视觉和语言的任务并充分利用多模态数据，计算机视觉和自然语言处理两个领域的联系越来越紧密。在这个新的视觉和语言交叉的研究领域中，图像描述生成是个重要的任务。该任务包括获取图像信息、分析其视觉内容、生成文本描述以说明图像中的显著物体和行为等步骤。

从计算机视觉角度来看，图像描述生成是个重大挑战。描述可能涉及图像各个方面，可能是关于物体及其属性，也可能是关于场景特性或人物交互行为。更具挑战性的是，描述可能指出图像中没有的物体（如等待中的火车）或提供不能直接从图像推出的背景知识（如画作中的蒙娜丽莎）。总之，好的图像描述不仅需要完备的图像理解，还需要综合而精炼的表达，因而图像描述生成对计算机视觉系统是个良好的测试。传统的视觉任务（如物体检测或图像自动标注）都是在有限类别上测试检测器或分类器的精确率，相比之下，图像描述生成任务更具综合性。从自然语言处理角度看，该任务是个自然语言生成的问题，需要将非语言的表示转换成可读的文本。一般来说，非语言表示可以是逻辑形式、数据库查询或数字串，而图像输入通常转换为中间表示向量（如深度特征表示），需要语言模型将其转换成语句。

图像描述生成任务结合了计算机视觉和自然语言处理两个研究领域，不仅要求完备的图像语义理解，还要求复杂的符合人类感知的自然语言表达，具备重要的理论意义和应用前景。在理论上，图像描述生成的研究将促进计算机视觉和自然语言处理领域的发展。通过构建新的计算模型与方法，提高计算机对非结构化信息的理解能力和对海量信息的处理效率，从而为人工智能和认知科学的发展作出贡献。此外，图像描述生成还具有广阔的应用前景。首先，图像描述生成技术可应用于自动图像索引，提升图像检索的效果和效率，适用于医疗、商业、军事、教育、数字图书馆等多个领域。其次，图像描述生成技术可帮助社交媒体平台（如 Facebook、Twitter 等）为图像生成自然语言描述，包括地点、穿着和活动等信息，直接帮助和指导日常生活。最后，图像描述生成技术还可在机器人交互、学前教育和视觉障碍辅助等领域发挥关键作用。

5.1.1 图像字幕关键技术

图像描述生成的目标是给定一幅图像，根据图像内容生成语法正

确、语义合理的语句。显然，图像描述生成涉及两个基本问题：视觉理解和语言处理。为了保证生成描述语句在语法和语义上的正确性和合理性，需要利用计算机视觉和自然语言处理技术分别处理不同模态的数据并做适当的集成。

近年来，深度学习技术得到迅速发展，并成功应用于计算机视觉和自然语言处理相关领域。图像描述生成的研究在经历了早期基于模板的方法和基于检索的方法之后，大多数方法都是基于深度学习技术构建，并在性能上取得了显著的提升。基于深度学习的图像描述生成方法涉及的关键技术主要包括整体架构、学习策略、特征映射、语言模型和注意力机制五个方面。

5.1.1.1 整体架构

从整体架构上看，当前主流的基于深度学习技术的图像描述生成方法大都基于编码器-解码器架构或复合架构来构建学习模型。

基于深度学习技术构建的图像描述生成方法大部分采用端到端的工作方式，这与基于编码器-解码器架构的神经机器翻译方法非常相似。受到这个思路的启发，可以将图像描述生成看作一个序列到序列的翻译问题，输入是图像，而输出是自然语言，并利用编码器-解码器架构完成图像理解和语言生成的任务。这种架构在性能上取得了重要进展，成为当前图像描述生成方法的主流通用架构。在编码器-解码器架构中，编码器通常采用卷积神经网络 (Convolutional Neural Network, CNN) 提取图像特征，而解码器通常采用循环神经网络 (Recurrent Neural Network, RNN) 生成自然语言描述。

基于复合架构的图像描述生成方法利用概念检测模型（如物体检测模型、图像自动标注模型等）获取图像中不同粒度的语义概念（包括物体名、标注、短语等形式），再利用并列语言模型或者分层语言模型代替解码器生成描述语句。这类方法通常由几个功能独立的部件组成，各个部件被集成到管道中，为输入图像生成自然语言描述。

5.1.1.2 学习策略

图像描述生成的学习策略包括有监督学习、无监督学习和强化学习。在有监督学习中，使用训练数据伴随着期望输出的标签，通常能够获得较高的精确率。

绝大多数图像描述生成方法采用有监督学习进行训练，其中应用特别广泛的包括各种基于深度神经网络模型：从 AlexNet、VGG16 到 ResNet，性能逐步提升；基于区域建议的物体检测模型从 R-CNN、Fast R-CNN 到 Faster R-CNN 和 R-FCN，在精确率和效率方面取得了显著进展；RNN 模型在自然语言生成方面取得成功，特别是经过改进的 LSTM 和 GRU 等。这些有监督学习方法都可以嵌入到当前主流的编码器-解码器架构中，作为编码器或解码器的组成部分，完成图像描述生成过程中的基本功能。然而，由于图像内容的复杂性，精确地标注图像数据常常是不切实际的，因此难以获得成对的图像-语句训练数据。随着无标签的图像数据不断增加，需要利用无监督学习与强化学习来辅助和改进图像描述生成方法。

无监督学习方法用于揭示数据的内在性质和规律，常用于图像或文本预处理，包括聚类、降维以及概率模型如概率潜在语义分析和潜在狄利克雷分布模型。此外，生成对抗网络（GAN）是图像描述生成中最广泛应用的无监督学习技术，可从无标签数据学习深度特征表示并扩充有限数据集，提升系统性能。然而，GAN 应用存在两个问题：首先，图像上像素值连续，GAN 可通过反向传播进行训练，但文本处理是基于离散数据，难以直接应用反向传播学习；其次，评估器在序列生成中面临梯度消失和误差传播问题，通常需借助强化学习方法进行梯度传导。

强化学习方法设计智能体、状态、动作、奖励函数、策略和值等参数。智能体选择动作，接收奖励值，并移动到新状态。策略由动作定义，值由奖励函数定义。智能体试图选择具有最大长期回报的动作，

需连续的状态和动作信息提供奖励函数保证。典型的基于强化学习的图像描述生成方法包含策略网络和价值网络，分别称为行动者和评论者。评论者（价值网络）用于估计预期奖励，训练行动者（策略网络）。现有图像描述生成方法存在“暴露偏差”和不可微评估指标问题。基于强化学习的训练方法一方面缓解“暴露偏差”，另一方面直接优化评估指标，保持训练目标和测试一致。因此，基于强化学习的模型优化是生成高质量图像描述的重要保证。

5.1.1.3 特征映射

对于图像描述生成任务而言，最基本的问题是将图像或文本内容映射到特征空间。常用的特征空间包括多模态空间、视觉空间和语义空间，然后再生成自然语言描述。图像描述生成方法中，将图像和文本内容映射到多模态空间需要使用隐式映射方法和语言模型，将图像内容映射到视觉空间通常基于显式映射方法，而将图像内容映射到语义空间通常需要加入概念检测部件构成复合映射方法。

在图像描述数据集中，图像和对应的描述文本可以同时被编码器学习得到公共的多模态空间，然后传递给语言解码器。多模态空间的学习方法多种多样，可以直接加权融合视觉和文本特征，或者在融合的基础上采用各种降维方法学习潜在的语义空间。

主流的图像描述生成方法是将图像内容映射到视觉空间。在这种方法中，图像特征和描述文本被分别传递给语言解码器。早期方法主要使用手工提取的图像特征，然后通过特征选择算法将多种特征融合为统一的视觉空间。而当前的方法则普遍采用预训练的 CNN 模型或物体检测模型提取图像特征来构造视觉空间。

然而，仅使用 CNN 模型提取图像特征构造视觉空间会限制图像内容的全面理解，因为它只能从某个特定角度描述图像。因此，另一种方法是在获取视觉空间表示的基础上构建语义空间，全面描述图像中的物体、属性关系等语义要素，并将各个要素融合成语义属性向量

输入解码器生成描述语句。

5.1.1.4 语言模型

一般来说，自然语言生成可以看作序列到序列的学习任务。为完成这个任务，研究者提出了多种神经语言模型，如 RNN 模型、神经概率语言模型和对数双线性模型等。

RNN 在各种序列学习任务中被广泛应用，但存在梯度消失和梯度爆炸的问题，且不能充分处理长期时序依赖问题。为此，LSTM 对 RNN 加以改进，可以解决 RNN 无法处理的长期时序依赖问题，也缓解了 RNN 容易出现的梯度消失问题。原始的 RNN 隐藏层只有 1 个单一的 \tanh 层，输出 1 个状态，对于短期的输入非常敏感。LSTM 在 RNN 的基础上增加了 1 个单元状态，可以保存长期的状态。LSTM 的关键在于穿越单元的数据传送线，它使得单元状态 c 的传输能够快速通过，从而实现长期的记忆保留。LSTM 使用的 3 个门（遗忘门、输入门和输出门）结构可以选择性地让信息通过，从而实现信息的保护和控制。

在图像描述生成的任务中，LSTM 占据压倒性的重要地位。它通常用作解码器，将编码器得到的中间向量解码为单词序列。单词由词嵌入向量表示，每个语句的开头用 1 个特殊的开始标记 $\langle \text{start} \rangle$ ，结尾用 1 个特殊的结束标记 $\langle \text{end} \rangle$ 。在模型解码过程中，上一时间步生成的单词会被反馈到 LSTM 中，结合注意力机制，生成当前时间步 LSTM 的隐状态 h ，然后根据 h 预测生成当前单词。

GRU 是与 LSTM 类似的语言模型，它不使用单独的存储单元，并且使用较少的门来控制信息流。从结构上看，GRU 只有更新门和重置门 2 个门，把 LSTM 中的遗忘门和输入门用更新门来替代，并把单元状态和隐状态进行合并，在计算当前时刻新信息的方法和 LSTM 有所不同。从某些任务的表现上看，GRU 与 LSTM 获得的性能大致相当，但计算效率更高。因此，GRU 既保持了 LSTM 的效果，又具

有更加简单的结构和更少的参数，也更容易收敛。但是，GRU 并不能取代 LSTM，因为 LSTM 在数据集很大的情况下表现效果更好。在图像描述生成的任务上，要处理的数据量日益增大，LSTM 的应用还是比 GRU 广泛得多。

此外，LSTM 忽略了语句潜在的层次结构，并需要大量的存储空间。相比之下，CNN 可以学习语句的内部层次结构，并且处理速度比 LSTM 快。因此，CNN 也被用于序列学习任务，如条件图像生成和机器翻译等。

5.1.1.5 注意力机制

视觉注意力机制是灵长类和人类视觉系统中的重要机制，本质上是一个反馈过程。它有选择地将视觉皮层的早期表达映射到更突出中心的非拓扑表达，其中只包含场景中特定区域或物体的属性。这种选择性映射允许大脑在低层图像属性的指导下，将计算资源集中在某个物体上。机器注意力机制也是模仿人类的这一能力，最初在计算机视觉领域提出，后来被应用于机器翻译等任务，主要与编码器-解码器架构相结合来使用，已经应用于人工智能的各个领域。

在最初应用于机器翻译的编码器-解码器架构中，编码器读取具有可变长度的序列输入，将其编码为隐状态，解码器根据编码器的最后 1 个隐状态来生成输出序列。但这个架构存在的潜在问题是大量的源信息可能无法通过固定长度的向量（即编码器最终的隐状态）来捕获，特别是在长语句的情况下，这个问题尤为严重。因此，通过将注意力机制与编码器-解码器架构结合，利用注意力机制来对齐源信息和目标输出，源信息中保留了来自编码器所有时间步的隐状态信息，通过注意力机制来计算目标输出当前所需要的源信息，这样可以使模型能够“关注”源信息的特定部分，并更好地建立源信息与目标信息之间的联系。注意力机制在图像描述生成的任务中也起着重要的作用。特别是，人们在描述图像的过程中并不需要一直关注整幅图像的所有

信息，而是更倾向于讨论图像中语义上更显著的区域和物体。因此，引入注意力机制可以将注意集中在图像的显著部分，同时生成相应的单词。

随着技术不断发展，出现了各种注意力机制，但其本质思想都是对信息进行加权整合，以获取更重要的信息组成，从而将有限的信息处理资源分配到重要的部分。注意力机制大致可以分为上下文注意力机制和自注意力机制。注意力机制计算的核心思想是在输入序列上引入注意权重系数 α ，以优先考虑与生成下一个输出相关的位置集。将源端的构成元素想象成由一系列数据对 $\langle K, V \rangle$ 构成，给定某个元素 Q ，通过计算 Q 和各个区的相似性或相关性，得到每个区对应 V 的权重系数，然后进行加权求和，得到最终输出。因此，注意力机制本质上是对源端中元素进行加权求和，其中 Q 和 K 表示信息的不同方面。在上下文注意力机制中， K 和 V 一般来自源端信息，而 Q 一般来自目标端信息（例如在图像描述生成任务中， K 和 V 表示编码端图像的空间特征，而 Q 表示解码端的上下文信息）。上下文注意力机制通过计算当前目标端信息 Q 和源端信息 K 的关系，来对源端信息进行整合得到输出。而在自注意力机制中， Q 、 K 和 V 都来自源端信息，自注意力机制计算了源端信息本身内部存在的依赖关系，从而可以提取信息中的重要部分，得到关系化的特征表示。

无论是理论上还是实践上，注意力机制在各种计算机视觉和自然语言处理任务中都起到了重要作用，并在图像描述生成任务中占据着重要地位，显著提升了系统性能。

5.1.2 图像描述生成方法

图像描述生成经过多年的发展，研究者提出了大量的方法，对这些方法进行分类也存在多种标准。按照图像描述生成发展过程的时间线对这些方法进行划分，大致可分为 4 大类：基于模板的方法、基于检索的方法和基于编码器-解码器架构的方法。基于模板的方法和基

于检索的方法是早期的方法。前者依赖于硬编码的语言结构，而后者则利用训练集中现成的描述语句，因此它们的共同缺点是不够灵活，在生成描述的表达上受到较大的限制。基于编码器-解码器架构的方法则是基于深度学习的方法。在深度神经网络中，CNN 等具有强大的图像特征提取能力，LSTM 等具有良好的时间序列数据处理能力，这使得基于深度神经网络的方法能够在性能上取得突破，成为当前图像描述生成的主流方法。

5.1.2.1 基于模版的方法

基于模板的方法通过对语法和语义的约束过程来生成图像描述。通常，该方法先检测出图像中特定的一系列视觉概念，然后通过语句模板、特定的语法规则或组合优化算法等将这些概念进行连接以生成描述语句。

Yang 等人[1]利用四元组〈名词-动词-场景-介词〉作为生成图像描述的语句模板。首先使用检测算法评估图像中的物体和场景，然后利用语言模型预测可能用于构成描述语句的动词、场景和介词，并利用隐马尔可夫模型推理得到最佳的四元组，最后通过填充四元组给出的语句结构生成图像描述。Kulkarni 等人[2]用图结点分别对应物体、属性及空间关系等，通过条件随机场确定需要呈现在图像描述中的图像内容，然后基于语句模板将推理的输出转换成图像描述。Li 等人[3]首先使用视觉模型检测图像并提取物体、属性和空间关系等语义信息，然后定义三元组〈〈形容词 1，物体 1〉，介词，〈形容词 2，物体 2〉〉对识别的结果进行编码，并执行短语选择和短语融合，最终得到优化的短语集合作为图像描述。

基于模板的方法能够生成语法正确的语句，且与图像内容的相关性强。然而，因为这类方法依赖于视觉模型识别图像内容的精确性，所以生成的语句在广泛性、创造性和复杂性上有缺陷。此外，与人工描述相比，使用严格的模板作为语句结构使得生成的描述不够自然。

5.1.2.2 基于检索的方法

给定一幅查询图像，基于检索的方法通过从预先定义的语句集中利用相似度匹配的方式检索出一个或一组语句作为该图像的描述语句。生成的描述语句可以是一个现有的语句，也可以是一个由检索结果得到的多个语句组合而成的语句。

Farhadi 等人[4]提出基于三元组〈物体，行为，场景〉构建语义空间以连接图像和语句。给定一幅查询图像，该方法通过求解马尔科夫随机场将给定图像映射到语义空间，并使用相应的相似度度量措施计算给定图像与现有语句的距离，将与给定图像最相似的语句作为相应的描述。Ordonez 等人[5]首先提取给定查询图像的全局特征表示，从带有描述语句的图像集中检索出一系列图像；然后对检索得到图像的语句进行重新排序，将排位最靠前的语句作为给定图像的描述。Hodosh 等人[6]利用核典型相关性分析技术将图像和文本投影到公共空间，使得训练图像与其相应的描述相关性最大。在这个公共空间中，通过计算图像和语句的余弦相似度来选择排位最靠前的语句作为给定图像的描述。以上方法直接使用检索得到的语句作为给定查询图像的描述，隐含的假设是总存在一个语句适合描述给定图像，然而现实中此假设未必正确。于是，另一些基于检索的方法利用检索得到的语句进行重新组合得到给定图像的新描述。

基于检索的方法能够为给定的查询图像传送格式良好的语句或短语，以生成图像描述。虽然生成的语句通常语法正确、流畅，但是将图像描述约束到已经存在的语句中并不能适应新的物体或场景的组合。在某些特殊情况下，生成的描述甚至可能与图像内容无关。此外，这类方法的性能依赖于大量带有描述语句的图像，也使其应用受到很大的限制。

5.1.2.3 基于编码器-解码器架构的方法

在编码器-解码器架构下，编码神经网络（通常采用 CNN）首先

将原始图像转换成中间表示(可以是多模态空间或视觉空间等表示形式),然后解码神经网络(通常采用 LSTM)将中间表示作为输入,在注意力机制的引导下,逐词生成描述语句。基于各种图像描述生成方法所重点关注的关键技术不同,基于编码器-解码器架构的方法可以进一步分为基于多模态空间的方法、基于视觉空间的方法、基于语义空间的方法和基于注意力机制的方法。

基于多模态空间的方法使用多个深度神经网络(如 CNN 和 LSTM)同时处理训练图像的视觉模态和文本模态数据,在生成公共空间的基础上得到训练图像的多模态空间表示,然后进行解码以生成相应的图像描述。Kiros 等人[7]最早采用编码器-解码器架构完成图像描述生成任务。首先将图像文本联合嵌入模型和多模态神经语言模型相结合,使用 CNN 和 LSTM 分别对视觉和文本数据进行编码;然后通过最小化对偶排位损失,将编码的视觉数据投影到由 LSTM 隐状态所覆盖的嵌入空间中,得到图像的多模态空间表示;最后利用内容结构化的神经语言模型对多模态空间表示进行解码,生成描述语句。Karpathy 等人[8]提出了一种架构更简单的深度视觉语义对齐模型,其基本思想是假设语句的某些部分对应的是图像中特定的未知区域。该模型利用图像区域 CNN、语句双向 RNN 和对齐两种模态的结构化目标来推断语句片段和图像区域之间的对齐。文本和图像区域被映射到公共的多模态嵌入空间中,然后利用多模态 RNN 推断出视觉和语义的对齐并生成新的描述语句。Mao 等人[9]提出了多模态循环神经网络(multimodal RNN, m-RNN),包含两个子网:一个 CNN 子网处理图像,一个 RNN 子网生成语句。两个子网在多模态层中相互作用构成整个 m-RNN 模型,以图像和语句片段作为输入,计算生成描述语句下一个词的概率分布。

基于视觉空间的方法通常在编码时使用 CNN 直接处理训练图像,得到图像的视觉空间表示,或者经过预处理融合多个区域特征得到视

觉空间表示，然后进行解码以生成相应的图像描述。Vinyals 等人[10]提出了神经图像描述生成 (Neural Image Caption Generator, NIC) 方法，使用 CNN 获取图像表示并使用 LSTM 生成图像描述。NIC 的编码器 CNN 使用新方法进行批量归一化，并将 CNN 最后的隐藏层输出作为解码器 LSTM 的输入，且 LSTM 能够记录已经使用文本描述过的物体。在生成图像描述时，图像信息包含在 LSTM 的初始状态中，下一个词根据当前时间步和上一个隐状态生成，这个过程一直持续到描述语句的结束标记为止。由于图像信息只在处理过程的开始时输入，因此 NIC 可能面临梯度消失问题，并且在生成长语句时仍然存在问题，开始产生的单词作用会越来越弱。为此，Donahue 等人[11]提出了长期循环卷积网络。与 NIC 的不同之处在于，该网络并不是只在初始阶段向系统输入图像特征，而是在 LSTM 的每个时间步都为序列模型同时提供图像特征和上下文词特征作为输入。此外，Jia 等人[12]提出了一种 LSTM 的变体称为 gLSTM，可以生成长语句。该方法将全局语义信息添加到 LSTM 的每个门和单元状态中，同时考虑了不同长度的规范化策略来控制描述语句的长度。由于单向 LSTM 是基于视觉上下文和所有之前生成的文本预测下一个单词，因而不能生成上下文构造良好的描述。

随着图像描述生成技术的不断进步，单纯使用视觉特征向量表示图像已经很难提升系统性能。因此，越来越多的研究工作尝试使用融合视觉特征和语义特征的方法来表示图像。**基于语义空间的方法**通常认为图像中的区域、物体和属性等包含丰富的语义信息，因此许多方法提出在视觉空间的基础上进一步获取复杂的语义空间表示，并利用高级语义信息来生成图像描述。You 等人[13]提出了一种基于图像语义概念表示的方法，分别使用 CNN 和一组视觉属性检测器从输入图像中提取全局特征和一组语义属性。每个属性对应于所用词典的一个条目，要生成的单词和要检测的属性共享相同的词典。因此，解码过

程可以在语义空间上进行，从而获得优越的性能。Wu 等人[14]将视觉概念引入编码器-解码器框架，首先从训练语句中挖掘出一组语义属性，然后在基于区域的多标签分类框架下，针对每个属性训练一个基于 CNN 的语义属性分类器。该分类器可以将图像表示为一个预测向量，并给出每个属性在图像中出现的概率，然后再使用 LSTM 作为解码器生成描述图像内容的语句。Wang 等人[15]提出了一种新型的解码器结构，由一个 Skel-LSTM 和一个 Attr-LSTM 联合构成。前者使用 CNN 提取图像特征生成主干语句及其属性，后者为每个主干语句的属性生成一系列的主干词，然后再将两部分内容合成最终的描述语句。

前面讨论的一些方法在为图像生成描述时无法随着时间的推移分析图像，且通常将场景作为一个整体来考虑，而不考虑与描述语句部分相关的图像局部层面。为了缓解这个问题，研究者提出了利用注意信号来引导图像描述生成的方法，**基于注意力机制的方法**通过将注意力机制引入到编码器-解码器框架中，语句生成将以基于注意力机制计算的隐状态为条件。这些方法中使用的注意信息大致可分为视觉注意和语义注意，其中视觉注意又可分为单词级注意和语句级注意等多个层级。若希望同时利用多级注意信息，还需要提供协同机制以结合不同的注意。注意力机制的重要性在于它可以在生成输出序列的同时动态聚焦于输入图像的各个局部层面，因而能够达成整体和局部的平衡。Xu 等人[16]最先在图像描述生成方法中引入注意力机制，提出了一种能够自动描述图像显著内容的方法。该方法首先用 CNN 将图像表示为 N 个向量，每个向量表示图像的部分区域，然后提出随机性硬注意力机制和确定性软注意力机制两种不同的方法来产生注意信号。在每个时间步中，随机性硬注意力机制从 N 个位置中选择 1 个视觉特征作为上下文向量生成 1 个单词，而确定性软注意力机制将所有 N 个位置的视觉特征结合起来，获取上下文向量生成 1 个单词。

Yang 等人[17]提出利用评论网络来强化编码器-解码器架构。该方法首先执行多个评论步骤，对编码器的隐状态应用注意力机制，并在每个评论步骤后都输出 1 个思维向量；然后将这些思维向量作为解码器中注意力机制的输入。由于注意信号主要集中在 RNN 每个时间步的图像上，但有些单词或短语存在不必要的注意视觉信号，这些不必要的视觉信号可能会影响生成描述的总体性能。因此，Lu 等人[18]提出了基于视觉哨兵的自适应注意方法，可以确定什么时候关注图像区域，什么时候关注语言生成模型。该方法引入了新的空间注意方法，可以从图像中计算出空间特征，然后在自适应注意方法中引入一个扩展的 LSTM，能够产生一个额外的视觉哨兵，为解码器提供一个回退选项。此外，还有一个哨兵门用以控制解码器从图像中获取信息的多少。

5.1.3 未来趋势展望

近年来，图像描述生成受到了研究者广泛关注，取得了许多重要成果。然而，尽管目前基于深度学习的主流方法获得了有效的结果和良好的性能，但仍然面临几个重大挑战，这也是未来的重点研究方向和发展趋势。

5.1.3.1 识别细粒度语义以生成区分性强的图像描述

基于深度学习的方法能够识别图像中的一些重要语义概念（如老虎、鸟等），但是对于细粒度语义概念（如东北虎、夜莺等）的识别仍然是个难题。需要在物体检测、语义分割和图像自动标注等课题的基础上寻求解决方案。图像细粒度语义识别的重大挑战主要体现在类间差异小和类内差异大，如何检测并学习图像中的物体及其关键部件成为关键问题。此外，细粒度语义标注的成本要高于传统语义标注，难于获得大规模训练集，这使得很多强监督方法难于实际应用，需要借助弱监督方法完成识别任务。在图像描述生成任务中，识别细粒度的图像语义对于生成更准确、更具区分性的描述语句具有重要意义。

5.1.3.2 改进语言模型以生成语法正确的图像描述

目前的图像描述生成方法大都采用类似 LSTM 等深度神经网络模型逐词生成描述语句，取得了重要的成功。但这类模型并没有完全解决长期依赖问题，并且本身的顺序特征阻止了并行化，使得计算较为耗时。Transformer 模型使用注意结构取代 LSTM，减少了计算量同时提高了并行效率，但这个思路在图像描述生成任务上还没有得到广泛应用。在图像描述生成过程中，引入新的有效的语言模型对于生成语句的语法和语义正确性无疑能起到重要作用。然而，改进语言模型本身是一个难题，需要自然语言处理领域的研究者通过长期的工作逐步解决问题。

5.1.3.3 探索学习架构生成完整细致的图像描述

目前图像描述生成采用通用的编码器-解码器架构，将图像描述生成过程视为从图像"翻译"到文本的过程。这种架构通常将图像编码为中间向量，再以此为依据进行解码。中间向量包含的信息至关重要，如果信息不足，将导致生成的语句信息不完整。因此，这种架构有改进的空间，可以考虑改进编码器端以获取更优的中间向量，或者改进解码器端以更充分地利用中间向量包含的信息。此外，编码器-解码器架构并不是唯一可行的学习架构，提出全新的学习架构也是改善图像描述质量的途径。基于复合架构的方法强调识别复杂图像中的细节，取得了一些进展，但仍需作出重大突破。因此，学习架构的探索仍然是图像描述生成领域的重要课题。

5.1.3.4 利用多级注意力机制生成语序合理的图像描述

注意力机制在许多计算机视觉任务中都得到了很好的应用，并已经证明能够显著提升图像描述生成的性能。然而，目前多数注意模型只关注图像中的局部实体特征，没有关注实体间的相互关系，导致生成的图像描述存在语义不够完整和语序不合理的问题。因此，需要进一步挖掘不同层级的注意并加以整合，例如协同单词级和语句级的注意、结合视觉注意与语义注意等方法，都是建立在整合不同层级注意

的基础上。如何设计整合不同层级注意并使它们协同工作的机制，以生成语义和语序更合理的图像描述，仍然是图像描述生成领域的重点研究方向。

5.1.3.5 集成外部知识推理生成新颖自然的图像描述

目前的方法存在生成的图像描述与原始描述过于相似的问题，且不具备像人类一样的推理能力，难于发现图像中隐含的新物体和新行为。然而，仅仅依靠图像的视觉内容本身，很难解决这个问题。一个可行的思路是在图像描述生成方法中引入外部知识并进行适当地推理，模仿人类自主学习新知识的方法和能力，使得生成的描述语向新颖自然，从而实现初步的视觉推理。如何引入外部知识，并通过知识图谱等方法集成到现有的学习框架，使其具备从局部到整体、从属性到语义的视觉推理能力，是图像描述生成未来研究面临的重大挑战。

5.1.3.6 基于模型优化生成准确多样的图像描述

现有的图像描述生成方法通常要依赖大量的图像-语句对样本进行训练，才能取得较高的性能。然而，人工标注费时费力，难以获得大量的有标签样本，这使得图像描述的性能容易出现瓶颈。因此，基于无监督学习的方法扩充训练集及基于强化学习的方法优化系统的评估指标成为突破性能瓶颈的重要思路。目前，生成的图像描述在各种评估指标上都取得了较高的分数，但这很大程度上是因为生成的图像描述可区分性不够强。一方面，对于视觉内容有差异的图像，生成的描述语句差异性不高，即生成语义的粒度不够细致、描述不够准确；另一方面，对于同一幅图像，生成的描述语句相似度很高，即难于生成多样化的描述语句。基于无监督学习的方法可以充分利用无标签图像扩充训练集，生成多样化的描述语句；而基于强化学习的方法则可以利用奖励函数指引图像描述生成的方向，使得系统生成更准确可靠的描述语句。

5.1.3.7 设计更符合人类感知的性能评估措施

目前图像描述生成领域有 BLEU、ROUGE、METEOR 等多种常用的性能评估措施，但这些措施有各自的适用范围，不能完全反映生成描述语句的质量。即使性能指标数值很高的系统生成的描述语句也仍然可能不符合人类感知，也就是说评估措施与人类判断之间仍然存在着鸿沟。为缓解这个问题，一方面可以利用强化学习技术缩减评估措施与人类感知之间的差距，另一方面则需要设计出更好更全面的评估措施，既能反映描述语义质量（如语义多样性度量），也能尽量与人类判断保持一致，从而能够更客观地反映图像描述生成系统的优劣。

5.2 视觉定位

视觉定位是根据输入的指代表达式在图像中定位目标对象的任务，其中输入表达式是关于目标对象的完整描述性句子。该任务成功地构建起人类语言、机器以及现实场景之间的沟通桥梁，实现了基于复杂文本的视觉定位。因此，视觉定位在新一代智能设备的视觉理解系统和对话系统中具有广泛的应用前景，例如导航、自动驾驶、视频监控、机器人和早期教育等。其中，在视频监控领域视觉定位的出现可以代替传统监控网络中的单模态目标定位方法，实现机器对人类复杂语言指令的响应。

随着社会中大规模多模态数据的产生，与视觉定位类似的利用视觉和文本两种模态的数据进行视觉语义理解的相关任务吸引了大量关注，图像和视频描述生成（Image and Video Description Generation）、视觉问答（Visual Question Answering, VQA）、视觉文本检索（Image-Text Retrieval）等。短语定位（Phrase Localization）可以看做是视觉定位的子任务。其关键区别在于：短语定位需要对查询语句中提及的所有对象进行定位，查询语句可以是单个的词、短语或短从句，甚至可以是完整的句子；而视觉定位的查询语句则是一个描述特定对象的表达式，其需要根据对象的类别、属性以及与其他对象之间的关系等信息唯一地在图像中定位目标对象。另外，与视觉定位任务

相似的还有指代表达分割任务（Referring Expression Segmentation, RES），即在图像中分割出指代表达式所描述的对象。

作为视觉定位任务的基石，目标检测（Object Detection）可以在预定义了固定类别的数据集上实现对所有目标对象的定位。在过去 20 多年中，目标检测作为计算机视觉领域的核心任务不断发展，目前在 COCO（Common Objects in Context）数据集上的性能可以达到平均精度均值（mAP）63.2%。与传统的目标检测任务不同，视觉定位的目标对象没有固定的类别，完全由输入表达式决定。因此，相较于目标检测，视觉定位任务更具有挑战性。它不仅需要理解输入表达式的语义信息，包括对象的属性和关系等，还要对包含多个对象的视觉数据进行推理，最终定位目标对象。

在视觉定位任务中，处理流程被划分成了 3 个模块：文本特征提取、视觉特征提取以及视觉—文本特征融合推理。研究表明，视觉—文本多模态特征交互融合是整个流程的关键。同时，关注点也放在了视觉特征提取模块的设计上，将该模块视为视觉定位模型的基础。因为相较于文本数据，视觉数据含有更丰富的信息，同时也存在更多冗余信息的干扰，因此提取出完整且有效的视觉特征是后续定位成功的基础。

5.2.1 视觉定位关键技术

视觉定位任务的处理流程可以划分为 3 个步骤：文本特征提取、视觉特征提取以及视觉—文本特征融合推理。文本和视觉特征提取器分别对文本和视觉输入数据进行单模态特征提取，然后通过视觉—文本特征融合模块进行模态交互。

5.2.1.1 文本特征提取

视觉定位任务的文本特征提取模块用于对输入的指代表达式进行语义理解，以获取目标对象的相关信息，并指导后续的目标定位。早期方法通常采用单个长短期记忆网络（LSTM）直接对整个表达式

进行编码，但这种方法处理简单，忽略了表达式各部分信息的重要程度，对于较长表达式难以提取关键特征。后来，出现了对表达式进行分解建模的方法，包括将表达式分解为三元组或利用外部解析器进行分解等，这在一定程度上提高了对文本中有效信息的关注。随着大规模预训练任务在自然语言处理领域的发展，许多视觉定位方法开始使用预训练的 BERT(双向编码器转换器)模型对表达式进行特征提取。

5.2.1.2 视觉特征提取

视觉定位任务的输入图像通常包含多个同类别以及不同类别的对象。面对复杂的输入表达式，例如"man on middle horse wearing black and red"，模型需要根据表达式的语义对图像中的对象“man”和“horse”进行关系推理，从而定位目标对象。因此，对图像进行高级语义理解是视觉定位任务的重要步骤。现有的视觉定位方法对图像的视觉特征提取存在多种方式，根据特征粒度的不同将其分为了三类：区域卷积粒度视觉表征、网格卷积粒度视觉表征和图像块粒度视觉表征。

区域卷积粒度视觉表征方法利用预训练的目标检测网络，例如 Faster R-CNN，得到一系列对象边界框。类似于二阶段目标检测模型中的区域提议方法，视觉特征提取模块会在这些对象中筛选出一部分作为对象提议，并将其对应的卷积特征作为输入图像的视觉特征输入到后续的视觉-文本融合模块中。区域卷积粒度视觉表征方法可以有效避免图像中无用背景的干扰，从而有利于最终目标对象的选择。

在目标检测领域，一阶段目标检测器最早提出利用图像的整层卷积特征来替代二阶段目标检测的区域提议特征。**网格卷积粒度视觉表征方法**将图像的整个卷积特征划分为 $S \times S$ 个网格(grid)，每个网格负责检测中心位于该网格内部的物体。通过一阶段目标检测器的成功，证明了网格卷积粒度的视觉特征可用于目标定位。因此，现有许多视觉定位方法直接使用卷积神经网络如 ResNet 输出的整个卷积特征作为图像的视觉表征。网格卷积粒度特征的使用有效地解决了基于区域

卷积粒度视觉表征方法使用目标检测网络生成对象提议导致推理速度缓慢的问题。

然而，上述两类视觉特征提取方法都依赖于复杂的视觉特征提取器，包括区域提议网络和卷积神经网络，导致视觉特征提取步骤需要消耗大量计算资源。为了解决这个问题，Dosovitskiy 等人在 ViT (vision Transformer) 中提出了一种新方法，即将输入图像在空间维度上划分为一个个图像块 (patch)，然后将这些图像块映射成 1 维序列，直接作为 Transformer 的视觉输入。ViT 在图像分类任务上取得了成功，证明了这种无需卷积计算的简单视觉表征作为 Transformer 的视觉输入是足够有效的。这种**图像块粒度表征方法**实现了更轻量化、更快速的视觉特征提取过程。

5.2.1.3 视觉—文本特征融合推理

视觉定位任务的核心模块是视觉—文本特征融合推理部分，它对文本特征和视觉特征进行融合处理，从中挑选出图像中有用的视觉特征。现有方法在该模块的设计上非常多样，包括视觉—文本特征匹配、基于注意力机制的视觉—文本特征融合、基于图网络的特征融合、基于滤波的特征融合以及基于 Transformer 的特征融合方法等。

5.2.2 视觉定位生成方法

视觉定位任务的处理流程可以划分为三个步骤：文本特征提取、视觉特征提取以及视觉与文本特征融合推理。文本和视觉特征提取器分别对文本和视觉输入数据进行单模态特征提取，而视觉与文本特征融合模块则进行模态交互。与以往直接根据是否对图像预生成对象候选框的分类方式不同，现有的视觉定位方法可以直接分类为一阶段方法和二阶段方法。根据视觉定位任务的处理流程，可以将视觉定位方法分为三类，关注视觉特征提取模块的设计，并根据视觉数据的表征粒度进行分类。

5.2.2.1 基于区域卷积粒度视觉表征的方法

基于区域卷积粒度视觉表征的视觉定位方法借鉴了二阶段目标检测思想，将任务分为对象提议和筛选两个步骤。使用图像的对象提议卷积特征作为视觉表征，后续的多模态融合模块通过文本输入对多个对象进行筛选，最终选取得分最高的对象边界框。

视觉定位任务最早直接采用简单的 CNN-LSTM 框架。首先，对每个对象区域提取卷积视觉特征，使用 LSTM 提取文本特征，然后将两种模态的特征嵌入到同一特征空间，计算每个对象区域提议与整个视觉定位表达式的匹配得分，最终选取匹配得分最高的区域作为目标定位结果。首次引入了 CNN-LSTM 框架到视觉定位任务中的 MMI (Maximum Mutual Information) 模型采用 VGGNet 提取的整体图像特征、单个区域提议特征以及区域提议的位置信息作为 LSTM 每个时刻步的视觉输入。利用最大互信息的思想设计损失函数用于训练，使得模型在除目标区域以外的区域提议上的匹配得分较低。在 MMI 之后，相继出现了一些改进区域提议卷积视觉表征的方法。Yu 等人[19]提出 Visdif 模型，通过在视觉特征中添加同类区域提议特征的差值来表示物体间的视觉差异。Nagaraija 等人[20]的 MIL 模型采用名实例学习思想，将 LSTM 的视觉输入组织成区域提议对的形式，模型最终输出目标边界框及其相关对象边界框。Hu 等人[21]设计了空间上下文网络 (SCRC)，将区域提议边界框的空间信息聚合到区域提议的视觉特征中。

5.2.2.2 基于网格卷积粒度视觉表征的方法

基于网格卷积粒度视觉表征的视觉定位方法利用图像的整层卷积特征作为后续多模态特征融合的视觉输入。与区域卷积粒度方法相比，这类方法无需预先生成图像的区域候选框，直接将多层卷积特征与文本特征进行融合，模型直接输出目标定位结果。在处理文本数据时，大多使用 BERT 或 LSTM 将指代表达式直接编码为一个向量。这类基于网格卷积粒度特征的方法在保持准确率的情况下有效提升了

模型推理速度。

Yang 等人[22]首次提出了基于区域卷积粒度视觉输入的方法。为了避免生成区域提议所需的大量计算，他们设计了一种端到端的方法，称为 FAOA (Fast and Accurate One-stage Approach)。该方法利用 Darknet 网络获取图像的多级卷积特征，并与 BERT 获取的文本特征进行融合。融合模块首先在通道维度上将视觉和文本特征进行拼接，然后使用 1×1 卷积核进行特征融合。最终的定位模块直接输出目标对象的边界框坐标。Jiang 等人[23]最早在 VQA 任务中提出了一种方法，将图像的网格卷积特征在空间维度上划分成多个块，并将每个块进行线性映射，得到 1 维特征作为 Transformer 编码器的输入。这样的方法可以有效避免区域提议边界框生成所消耗的时间，并提高推理性能的上限。Deng 等人[24]设计的 TransVG 采用了类似 ViL-BERT 的双流架构，不过不同的是 TransVG 的视觉分支的输入 tokens 为图像网格卷积特征的 1 维映射。视觉-文本特征的融合采用拼接融合方式，将视觉和文本 Transformer 的输入以及一个 REG token 直接进行拼接，作为多模态融合 Transformer 层的输入。REG Token 对应的输出用于回归计算目标对象的边界框坐标。

5.2.2.3 基于图像块粒度视觉表征的方法

前两类视觉定位方法在视觉特征提取模块的设计上都采用独立的预训练网络。以区域卷积粒度特征作为视觉输入的视觉定位方法大多采用在固定类别的数据集上预训练的目标检测器，例如 Faster R-CNN 等；而网格卷积特征粒度的视觉定位方法则广泛采用预训练的图像分类网络，如 ResNet 等。然而，这些预训练的视觉特征提取网络可能不适用于视觉定位任务。

ViT 模型的提出证明了简单地将图像块进行线性映射变为 1 维视觉向量作为 Transformer 的输入在图像分类任务中已经足够有效。受到这一启发，基于图像块粒度视觉表征的视觉定位方法的视觉文本融

合模块直接采用图像块的 1 维映射作为输入，实现了不依赖卷积网络和目标检测网络的视觉特征提取。并且，这类基于图像块粒度的视觉定位方法，其视觉文本融合模块都采用 Transformer 实现。

为了解决独立视觉特征处理模块导致的视觉特征与视觉定位任务不匹配的问题，Ye 等人[25]改进了原本独立的视觉特征提取模块，提出了 QRNet (query-modulated refinement network) 网络用于实现基于文本查询输入的视觉特征提取。QRNet 网络中的查询感知动态注意模块 (query-aware dynamic attention) 实现了基于文本特征指导的视觉特征细化提取。在视觉-文本特征融合模块，QRNet 采用了基于拼接融合注意力的 Transformer。这样的设计有效地避免了视觉特征提取与文本输入分离导致的视觉特征与视觉定位任务不匹配的问题。同年，Deng 等人[26]在之前 TransVG 模型的基础上，提出了 TransVG++ 模型用于改进 TransVG 训练困难的问题。TransVG++ 删除了 TransVG 中独立的多模态融合模块，对原有视觉编码器进行了改进，使其在实现视觉特征提取的同时进行多模态特征融合处理。该模型本质上是将基于图像块输入的视觉 Transformer 的最后一层修改为语言指导的视觉编码器。Deng 等人[26]对视觉—文本融合编码层设计了两种不同的注意力方案，分别为 language prompter 和 language adapter。实验结果表明，使用 language adapter 的效果相比简单拼接的方式更优。TransVG++ 相比基于网格卷积视觉输入的 TransVG 在 Refcoco、Retcoco+ 以及 Refcocog 的验证集上性能实现了大幅提升：分别在 Refcoco 上提升了 5.26%，在 Retcoco+ 上提升了 10.57%，在 Refcocog 上提升了 7.51%。

5.2.3 挑战及未来发展方向

视觉定位任务作为沟通自然语言处理与计算机视觉两大领域的桥梁，实现了利用人类文本表述在物理世界的视觉数据中定位目标。该任务近几年受到越来越多的关注，也涌现出了诸多相关算法。然而，

目前该领域的研究还面临一定的挑战以及困难，简单总结如下：

(1) 模型的推理速度：现有视觉定位领域的研究大多关注于提升模型的推理性能，但在实际应用中，推理速度也是模型的一个非常重要的衡量指标。现有基于区域卷积粒度视觉表征的方法因其需要预先生成图像的区域候选框，导致模型的推理速度非常慢。相比之下，基于网格卷积粒度视觉表征的方法则实现了实时检测的效果。然而，基于网格卷积特征粒度的方法的性能仍有待提高，因此未来视觉定位领域的发展需要在兼顾性能的同时尽可能地提升模型推理速度。

(2) 模型的可解释性：目前的研究主要着重于视觉和文本特征融合模块的设计，但忽略了模型的可解释性问题。模型对于视觉定位中的指代表达式，即目标对象的描述与图像中的多个对象进行筛选和匹配的过程，往往是一个无法可视化的黑盒过程。一些研究者开始关注模型的可解释性问题。例如，利用注意力模型来输出指代表达式中各个部分对推理过程的重要程度得分，或通过建立语法树和图像中对象关系图的节点关联，实现了表达式各部分与图像中对象的一一对应。未来的发展应继续努力使模型更具可解释性。

(3) 模型对表达式的推理能力：当前，许多视觉定位方法仅限于理解表达式中对象的属性层次，缺乏真正的推理能力，因此对于长且复杂的表达式处理的结果不尽如人意。此外，当前的主流数据集往往由于表达式较短且图像中的干扰对象较少，无法评估模型的推理能力。为了解决这个问题，已经提出了一些更复杂的数据集用于对模型的推理能力进行评估。例如，在新的数据集 **Cops-Rief** 上对当前最先进的视觉定位模型进行了实验评估，发现与传统视觉定位任务数据集相比，模型在新数据集上的性能显著下降。这表明以往的大多数模型只是在特定数据集上实现了过拟合，而没有真正学会推理。因此，开发出具有真正推理能力的视觉定位模型是研究人员面临的重要挑战。

通过综合现有研究和视觉定位任务当前面临的挑战，对该领域未

来的发展进行了如下展望：

(1) 建立大规模预训练通用多模态模型：随着社会中不同模态数据不断增多，多模态任务在计算机视觉和自然语言处理领域具有广阔的发展前景。传统的单一模态任务使用相关预训练模型参数进行初始化已成标准操作，能有效节省模型和训练时间，并提高性能。因此，未来趋势将发展向使用大规模视觉和语言数据对通用的视觉定位模型进行预训练，然后在多种下游任务中进行迁移学习。

(2) 优化基于 **Transformer** 的多模态特征融合方法：基于 **Transformer** 的多模态融合方法将成为主流。这些方法利用 **Transformer** 中的多个注意力层来实现两个模态之间的信息融合，如基于区域卷积粒度视觉表征和基于网格卷积粒度视觉表征的方法。实验证明，这些方法的效果优于以往手工设计的多模态融合方法。

(3) 采用多任务学习的方法提升性能：近期出现了一些将视觉定位与指代表达分割或指代表达生成任务联合学习的模型。例如，联合训练模型，将视觉定位和指代表达分割任务相结合，提升了视觉定位的性能。这种联合训练模型中，视觉定位能够更好地定位目标，而指代表达分割任务则为视觉定位提供更细粒度的像素级监督。同时，将视觉定位和指代表达生成任务合并成一个统一的模型，实现了两个任务之间的知识共享。这些方法的实现表明多任务学习可以有效提升单一任务的性能。

(4) 构建弱监督模型缓解对标注数据的依赖：全监督学习方式通常依赖于指代表达式和图像之间的精确标注信息，而这类数据的获取非常困难。为此，一种有效的弱监督模型被提出，它仅需要输入部分标注的指代表达式和图像，然后输出重建的表达式，并选择与原表达式最接近的对象作为最终结果。这种弱监督模型缓解了对复杂标注数据的依赖，同时避免了由于人工标注错误导致的模型效果不佳的问题。

(5) 深入研究视频领域和 3D 领域：研究人员已开始将视觉定位任务拓展至视频领域。然而，视频时空定位任务由于缺少相应的边界框注释，只能采用弱监督方法，导致模型性能不理想。因此，未来视频定位任务的研究需要完善相关的数据集，并探索在未对齐的视频片段与文本之间如何实现视觉-语言的对应关系。在 3D 空间中实现语言与视觉定位对机器来说是具有现实意义的任务。最近的一些工作已经将视觉定位任务拓展到 3D 场景，使得机器可以在 3D 场景中定位自然语言表达式所指的物体。尽管这些方法取得了一定的成果，但该领域的研究仍需要更深入的探究，并且 3D 场景下相关数据集也需要进一步完善。

参考文献

- [1] Yang Yezhou, Teo C L, Daume H, et al. Corpus-guided sentence generation of natural images[C] //Proc of the 2011 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2011: 444-454
- [2] Kulkarni G, Premraj V, Ordonez V, et al. BabyTalk: Understanding and generating simple image descriptions[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(12): 2891-2903
- [3] Li Siming, Kulkarni G, Berg T L, et al. Composing simple image descriptions using web-scale n-grams[C] //Proc of the 15th SIGNLL Conf on Computational Natural Language Learning. Stroudsburg, PA: ACL, 2011: 220-228
- [4] Farhadi A, Hejrati M, Sadeghi M A, et al. Every picture tells a story: Generating sentences from images[G] //LNCS 6314: Proc of the European Conf on Computer Vision. Berlin: Springer, 2010: 15-29
- [5] Ordonez V, Kulkarni G, Berg T L. Im2text: Describing images using 1 million captioned photographs[C] WAdvances in Neural Information Processing Systems. Cambridge, MA: MIT Press, 2011: 1143-1151

- [6] Hodosh M, Young P, Hockenmaier J. Framing image description as a ranking task: Data, models and evaluation metrics]. *Journal of Artificial Intelligence Research*, 2013, 47: 853-899
- [7] Kiros R, Salakhutdinov R, Zemel R S. Unifying visual-semantic embeddings with multimodal neural language models [OLJ. 2020-04-15]. <https://arxiv.org/abs/1411.2539>
- [8] Karpathy A, Li Feifei. Deep visual-semantic alignments for generating image descriptionsICl //Proc of the IEEE Conf on Computer Vision and Pattern Recognition. Los Alamitos, CA: IEEE Computer Society, 2015:3128-3137
- [9] Mao Junhua, Xu Wei, Yang Yi, et al. Deep captioning with multimodal recurrent neural networks (m-RNN)[CJ //Proc of the Int Conf on Learning Representations. La Jolla, CA:ICLR, 2015:1-15
- [10] Vinyals O, Toshev A, Bengio S, et al. Show and tell: A neural image caption generator[C] //Proc of the IEEE Conf on Computer Vision and Pattern Recognition. Los Alamitos, CA: IEEE Computer Society, 2015: 3156-3164
- [11] Donahue J, Hendricks L A, Guadarrama S, et al. Long-term recurrent convolutional networks for visual recognition and description[C] //Proc of the IEEE Conf on Computer Vision and Pattern Recognition. Los Alamitos, CA: IEEE Computer Society, 2015: 2625-2634
- [12] Jia Xu, Gavves E, Fernando B, et al. Guiding the long-short term memory model for image caption generation[C] //Proc of the IEEE Int Conf on Computer Vision. Piscataway, NJ: IEEE, 2015: 2407-2415
- [13] You Quanzeng, Jin Hailin, Wang Zhaowen, et al. Image captioning with semantic attention[C] //Proc of the IEEE Conf on Computer Vision and Pattern Recognition. Los Alamitos, CA: IEEE Computer Society, 2016: 4651-4659
- [14] Wu Qi, Shen Chunhua, Liu Lingqiao, et al. What value do explicit high level concepts have in vision to language problems[C] //Proc of the IEEE Conf on

- Computer Vision and Pattern Recognition. Los Alamitos, CA: IEEE Computer Society, 2016: 203-212
- [15] Wang Yufei, Lin Zhe, Shen Xiaohui, et al. Skeleton key: Image captioning by skeleton-attribute decomposition[C] //Proc of the IEEE Conf on Computer Vision and Pattern Recognition. Los Alamitos, CA: IEEE Computer Society, 2017: 7272-7281
- [16] Xu K, Ba J L, Kiros R, et al. Show, attend and tell: Neural image caption generation with visual attention[C] //Proc of the 32nd Int Conf on Machine Learning. Cambridge, MA: MIT Press, 2015: 2048-2057
- [17] Yang Zhilin, Yuan Ye, Wu Yuexin, et al. Review networks for caption generation[C] //Advances in Neural Information Processing Systems. Cambridge, MA: MIT Press, 2016: 2361-2369
- [18] Lu Jiasen, Xiong Caiming, Parikh D, et al. Knowing when to look: Adaptive attention via a visual sentinel for image captioning[C] //Proc of the IEEE Conf on Computer Vision and Pattern Recognition. Los Alamitos, CA: IEEE Computer Society, 2017: 3242-3250
- [19] Yu L C, Poirson P, Yang S, Berg A C and Berg T L. 2016. Modeling context in referring expressions//Proceedings of the 14th European Conference on Computer Vision. Amsterdam, the Netherlands : Springer : 69-85
- [20] Nagaraja V K, Morariu V I and Davis L S. 2016. Modeling context between objects for referring expression understanding//Proceedings of the 14th European Conference on Computer Vision. Amsterdam, the Netherlands : Springer : 792-807
- [21] Hu R H, Rohrbach M and Darrell T. 2016a. Segmentation from natural language expressions//Proceedings of the 14th European Conference on Computer Vision. Amsterdam, the Netherlands : Springer : 108-124

- [22] Yang S B, Li G B and Yu Y Z. 2019a. Dynamic graph attention for referring expression comprehension//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision. Seoul, Korea (South) : IEEE : 4643-4652
- [23] Jiang H Z, Misra I, Rohrbach M, Learned-Miller E and Chen X L. 2020. In defense of grid features for visual question answering//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA : IEEE : 10264-10273
- [24] Deng J J, Yang Z Y, Chen T L, Zhou W G and Li H Q. 2021. TransVG : end-to-end visual grounding with transformers//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada : IEEE : 1749-1759
- [25] Ye J B, Tian J F, Yan M, Yang X S, Wang X W, Zhang J, He L and Lin X. 2022. Shifting more attention to visual backbone : query-modulated refinement networks for end-to-end visual grounding// Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA : IEEE : 15481-15491
- [26] Deng J J, Yang Z Y, Liu D Q, Chen T L, Zhou W G, Zhang Y Y, Li H Q and Ouyang W L. 2022. TransVG++ : end-to-end visual grounding with language conditioned vision transformer [EB/OL] . [2023- 03-06] . [https : //arxiv.org/pdf/2206.06619.pdf](https://arxiv.org/pdf/2206.06619.pdf)

第 6 章 深度学习在编码中的应用

6.1 引言

随着 5G 和 AI 技术的发展，视频行业商业模式重构，新型视频应用场景应时而生，广泛应用于人们的生产、生活之中。视频应用不再局限于娱乐场景，而是向工业制造、安防领域、生产办公等场景拓展。在娱乐应用场景中，短视频、云游戏等作为软件应用在人们手机、平板等终端设备中随处可见；受过去几年疫情的影响，远程办公成为强需求，云桌面和远程会议等作为新型视频应用是远程办公的重要模式；在工业、安防等领域，机器视觉和视频监控对视频形式提出了新的要求。未来随着产业整合泛化和元宇宙布局趋势加强，广电超高清、VR/AR 等场景持续涌现，人们需求和视频类型将会更趋多元。

由于超高清视频、虚拟现实视频、全景视频、智能化应用视频等领域的快速发展以及面向机器视觉的视频编码和处理需求的爆发增长，传统编码工具的性能已趋于极限，难以满足通用化、智能化的视频应用需求。基于神经网络技术的智能图像/视频编码将成为下一代视频编码技术发展的重要突破口。全新的神经图像/视频压缩技术需要在节省存储与传输宽带成本、降低时延、保障视觉质量的基础上满足对视频感知、分析、理解等智能应用方面的需求。

本章将分别介绍智能图像编码压缩、智能视频编码压缩等核心技术的研究现状，并围绕该领域当下挑战及未来趋势展开讨论。

6.2 智能图像编码压缩

2017 年 Ballé 等人[1]提出了基于均匀噪声的近似可微量化器，以支持有损图像压缩模型的端到端训练。2018 年，他们又提出使用超先验结构来更高效地捕捉潜在空间上的空间依赖性[2]。此后，许多用来改进熵模型和网络主干（编码器和解码器）的方法不断涌现，如自回归上下文先验模型[3]和基于混合高斯分布的熵模型[4]。最近，分析/

合成变换模块中的主干网络引入了可避免重建信息丢失的可逆神经网络（Invertible Neural Networks, INNs）[5]架构，以及可充分利用全局或局部信息的 Transformer[6]-[8]架构等。以下将从编解码器架构设计和编解码器优化技术两个方面具体展开介绍：

6.2.1 编解码器框架设计

与传统图像编解码系统类似，智能图像编解码系统亦是由编码器和解码器构成，区别主要在于编码器/解码器中，各子模块包含可学习参数，可通过端到端训练，实现针对数据集特性的学习。如图 6-1 所示，智能图像编码器一般由分析变换、量化和熵编码模块组成；对应的解码器则是由合成变换、反量化和熵解码模块组成。分析变换/合成变换本质是自编码器架构。值得注意的是，在编解码器端到端训练阶段，深度学习图像压缩模型中并不需要实际调用熵编（解）码模块，而是通过熵模型实现量化后特征张量的码率估计。以下将从基础架构设计、分析/合成变换、自适应熵模型和损失函数设计四个角度分别展开介绍：

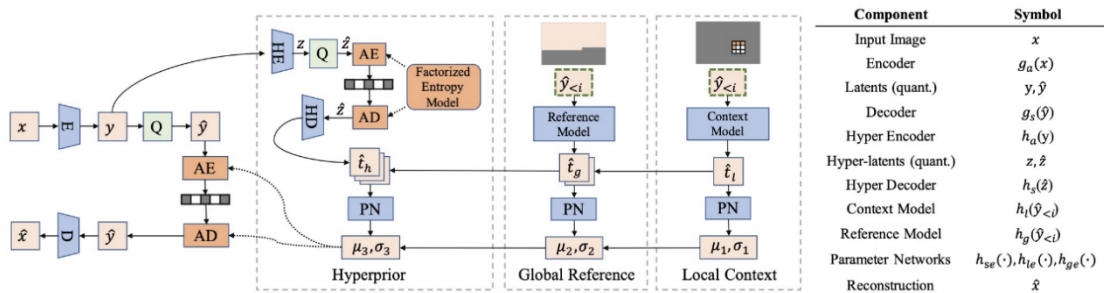


图 6-1 典型的智能图像编解码系统架构示意图（图来源于文献[16]）

1) 基础架构设计

无损/有损神经数据压缩的研究在很大程度上受到了深度生成模型研究的启发。如自回归（Autoregressive, AR）模型、归一化流（Normalizing Flows）、对抗生成网络（Generative Adversarial Networks,

GAN)、变分自编码器 (Variational Autoencoder, VAE) 和扩散模型 (Diffusion Model) 等深度生成模型, 能够从样本中捕捉复杂的数据分布, 进而消除数据中存在的各类冗余, 实现高效数据压缩的目标。根据所采用的深度生成模型的不同和层数多少, 主要可分为基于自编码器的架构、基于可逆网络的架构、基于 GAN 模型的架构和多层结构图像压缩框架。目前的代表性工作大部分为自编码器的架构, 不再赘述。以下具体介绍:

基于可逆网络的架构: Xie[5]等人提出的架构使用INNs作为编码网络的主体, 相比自动编码器架构可以减少编码过程中的信息丢失, 基于小波变换的端到端优化图像压缩框架 iWave++[36]将小波变换与深度自适应熵编码及反量化模块有机结合, 能够同时支持无损和有损压缩, 实现了多种比特率的自适应调控。上述架构在高分辨率/高码率图像压缩场景下的性能较佳。

基于 GAN 模型的架构: 针对极低比特图像压缩应用场景, Agustsson[13]等人基于 GAN 模型以解决极低比特率图像压缩中存在的严重压缩失真, 视觉质量较差的问题。该方法首先编码器将图像编码为压缩表示; 接着解码器/生成器从压缩表示解码并合成图像细节; 最后鉴别器对解码图像进行判别。三者组成一个 GAN 框架进行端到端训练。损失函数包含 GAN 损失、重建误差和熵编码约束。关键是在极低比特率下, 生成器可以合成无法编码的图像细节, 获得更优的视觉效果。另外, 如果有图像语义标签, 可以选择只编码重要区域, 其余部分完全生成, 以进一步减少比特率。该方法可以在极低比特率下获得更好的主观视觉质量, 明显优于 BPG 等方法。生成式压缩方法 [15]可以在高分辨率图像上获得视觉效果接近原图的高保真重建图像。总体而言, 该类方法为极低比特率图像压缩提供了有效途径, 但缺点是模型较复杂和计算量大。

多层结构图像压缩框架: 多层框架相比单层框架, 可以更有效地

捕捉图像的长程空间依赖性。具有多层结构的图像压缩框架[14]逐层学习图像的超表示，逐层消除图像中的空间冗余；同时设计了信号保护超变换，通过扩展维度和空间深度操作，使超表示可以保留更多信息。最内层超表示直接采用因子分解的高斯分布熵模型。其他层则基于超表示进行条件概率建模。此外，还利用超表示进行图像重建的信息聚合子网络，提升重建质量。双流图像压缩框架[19]包含图像内容流和模型流，其中模型流提取的神经语法可生成解码器的变换参数，实现数据依赖的变换。具体来说，编码器输出内容流和模型流。内容流进行熵编码压缩。模型流先提取神经语法进行压缩，然后解码后输入权重生成器，生成解码器最后一层的卷积核参数。解码时，内容流解码得到特征，模型流解码得到卷积核参数，进行数据依赖的逆变换，重建图像。此外，该框架提出了基于模型流的在线编码优化策略。即针对每个图像，优化模型流的编码，采用更优的变换参数，以获得更好的速率失真性能。相比固定的变换，数据依赖的变换可以更好地适应不同图像，提升性能。该框架的提出为神经网络压缩引入了新的思路，但也增加了计算和存储成本，模型流本身也可进一步优化。

RDONet网络架构[20]包含多个潜在空间层，可以实现图像块的可变深度压缩。具体来说，网络主干包含多个下采样和上采样模块，提取并重建图像特征。每个潜在空间层接收不同分辨率的特征，包含混合高斯模型进行熵编码。在编码时，可以选择每个位置的特征是否在当前层传输，未传输的特征会在下一层传输，以控制码率。相比在网络训练后确定的单一压缩方案，这种结构可以灵活地在编码时适应不同内容，进行率失真优化。借鉴于HEVC中自适应分块的方法，在优化过程中，该方法先使用图像随机分割，然后使用方差预测的分割，使网络对各类内容更加鲁棒。在测试时，使用零次优化，根据特征方差直接预测分割，避免多次测试。

2) 分析/合成变换

根据分析/合成变换模块中隐表示学习方法的不同，现有的神经图像压缩模型可以分为基于 RNN 架构的方法、基于 CNN 架构的方法、基于 Transformer 架构的方法和基于混合架构的方法。目前的代表性工作大部分为基于 CNN 架构的方法，不再赘述。以下具体介绍：

基于 RNN 架构的方法：Toderici [29]等人提出的框架中的自动编码器由编码器、二值化和解码器模块串联而成。每次迭代时，自动编码器都以前一次编码的残差图像作为输入，输出当前编码的残差图像。残差图像随着迭代次数的增加而减小，因此可以通过设置迭代次数来控制压缩率。在此基础上，基于循环神经网络的全分辨率无损图像压缩架构 [33]，可以更好地处理不同内容图像残差的衰减速率差异。并设计了单次迭代和渐进式两种熵编码方法，可以捕捉图像不同部分之间的长程依赖关系，进一步提高压缩率。Johnston [31] 等人提出用感知加权训练损失、隐藏状态预热和自适应比特率分配三种技术来改进该类架构。总体上，上述方法通过创新的框架设计，在低比特率图像压缩任务上获得了进步，为该领域提供了有价值的参考。

基于 Transformer 架构的方法：相较于 CNN 架构，Transformer 架构具备更好的空间解相关性、更灵活的感受野、更局部化的潜变量响应等特性。同时 Transformer 架构可以并行化编码和解码，相比序列模型更快，更实用。目前，Swin Transformer[8]已被应用于图像压缩的编码器和解码器中，构建了 SwinT-Hyperprior 和 SwinT-ChARM 两个模型。与 CNN 架构相比，Swin Transformer 在图像压缩任务中性能更优，复杂度更低。SwinT-ChARM 甚至超过了 VTM 的性能，在相同解码速度下可提升 3.68% 的 BD-rate。

基于混合架构的方法：图像压缩任务在特征表示学习上表现出非常强的局部性。相比全局注意力，基于局部窗口的注意力更适合用于图像压缩，可以更合理地分配比特。Cheng [4]在网络架构中引入了一个简化的注意力模块，可以让模型更加聚焦在复杂区域，提高编码性能。

Zou[22]等人提出的基于窗口注意力机制和对称 Transformer 框架的方法，可以增强 CNN 和 Transformer 架构对局部纹理的建模能力。




图 6-2 熵模型演进示意图（图来源于文献[16]）从左到右：因子分解先验模型[1]，超先验模型[2]，上下文模型[3]和全局参考熵模型[16]。

3) 自适应熵模型

熵编码依赖于熵模型来估计潜在表示的先验概率。如图 6-2 所示，因子分解先验模型[1]结构简单，但量化后的离散潜在表示的先验概率估计是独立于图像内容的。超先验模型[2]将潜在表示建模为零均值高斯分布，以消除量化后潜在特征表示中存在的空间相关性。为了更好的近似估计量化后潜在表示特征的信息熵，Theis[9]采用高斯尺度混合（Gaussian Scale Mixture, GSM）模型。

为了进一步量化后潜在特征表示中存在的空间/通道相关性，Minnen[3]等人在熵模型中引入自回归分量。所提出的熵模型包含上下文模型和超先验网络两部分，其中上下文模型对量化特征做自回归预测，超先验网络学习提升熵模型的先验信息，最后将两者联合作为条件高斯混合熵模型，对量化特征建模。Mentzer[10]中的上下文模型采用 3D 卷积架构以学习量化后特征的条件概率分布，用于熵编码和码率估计。该方法还通过引入重要性图以实现图像空间域的码率动态分配。Lee[11]等人提出了一种新的上下文自适应熵模型，用于端到端优化的图像压缩。该模型利用两种类型的上下文，即消耗位数的上下文和无需位分配的上下文，来更准确地估计每种潜在表示的分布。

为了解决同时利用局部和全局上下文信息，Qian [16]等人提出了

一种全局参考熵模型。具体是首先定义目标潜在变量和参考潜在变量之间的相似度矩阵。然后根据相似度选择已解码的最相关的参考潜在变量，将相关潜在变量的特征通过卷积提取为参考特征。最后将参考特征与局部上下文特征和超先验特征级联，生成高斯熵模型的参数。该方法可以捕捉全局信息，与局部上下文信息互补。相比仅用局部上下文的方法，该方法提供了全局参考信息，使熵模型更强大。基于分离熵编码[21]的神经图像压缩方法则将潜在变量分成两个组，第一个组使用标准上下文模型，第二个组使用改进的上下文模型，整合相邻与自身分量作为上下文，提高熵估计的准确性。而因果全局预测模型是通过第一个组构建全局相关矩阵，为第二个组选择全局参考点进行预测，无需额外传输开销但可以利用全局上下文。上述方法的缺点是解码复杂度增加，需做进一步优化。

4) 损失函数设计

图像压缩方法的性能评测一般使用 FID、KID、NIQE、LPIPS 等多种感知指标，以及 PSNR、MS-SSIM 等经典失真指标。但 Mentzer [15] 等人指出现有的大部分指标都无法完美地对任意方法进行排序，但 FID 和 KID 可以作为有价值的工具来指导模型架构和其他设计选择的探索。Cheng [18] 等人提出了一种结合相对平均最小二乘生成对抗网络 (RaLSGAN) 的率失真优化方法，以提高重建图像的主观质量。传统方法通常优化评价指标如 PSNR、SSIM 等，这会导致一些视觉伪影。于是，此方法提出加入判别器网络，与编码器解码器一起训练。判别器试图区分重建图像和原始图像，压缩的潜在变量作为条件信息输入判别器。其中损失函数包含比特率损失、误差损失和对抗损失。实验证明，RaLSGAN 方法的可以稳定地融合对抗训练，取得主观质量提升。

6.2.2 编解码器优化技术

1) 低复杂度解码优化

架构轻量化：为了解决神经解码器计算复杂度较高，内存占用大的问题，现有的低复杂度解码优化技术主要考虑优化解码器的架构，包括A) 轻量化算子设计，如简化通用标准化（Generalized Divisive Normalization, GDN）激活函数，删除平方和平方根运算，用基本的算术运算取代，减少运行时间而不损失性能；分析不同损失函数（MSE 和 MS-SSIM）优化的网络在计算效率和率失真上的区别[27]；使用深度残差网络来代替大卷积核，通过堆叠多个小卷积核来达到同样的感受野，以减少参数量[28]；在解码器中使用子像素卷积作为上采样操作，与转置卷积相比，能够以更低的计算复杂度可以提供更好的重建质量[28]。B) 自动架构搜索，如应用基于 Group Lasso 的正则化技术，实现最优网络结构的自动搜索[27]等。上述方法的缺点是训练时间较长且搜索到的网络结构可能不是全局最优，还需要人工调整保证网络结构的有效性。而且目前只考虑了解码器的计算复杂度优化，没有考虑编码器。C) 蒸馏学习，如EVC[26]可减少编解码过程中产生特征的通道数，虽然略微降低率失真性能，但也进一步加快了编解码速度。

架构并行化：A) 基于CNN架构的并行上下文模型：尽管自适应上下文先验信息[3]能够改善神经图像压缩的性能，但是其在解码过程中需要串行处理，不能够有效地利用GPU的并行性能。He等人[23]提出采用棋盘卷积作为来替换序列自回归模型，并行化的棋盘格形上下文模型具有更好的并行度和恒定的复杂性。比串行上下文模型，该方法可以将解码时间降低40多倍，仅引入很小的率失真性能损失。Minnen [24] 等人以通道维度的上下文模型来替代空间维度的上下文模型，将压缩的特征图按通道分成多片，每片的熵模型都基于之前片的解码结果进行条件化，以实现每片中的所有像素的并行解码。提高了并行性。ELIC[25]则使用堆叠的残差块来代替GDN层，使得编码器和解码器更容易进行

推理的加速，同时使用非均匀分组空间-通道上下文自适应编码来提高模型的并行度。

B) 基于Transformer架构的并行上下文加速: Entroformer [7]使用自注意力机制建模特征之间的全局依赖关系,以更准确地估计压缩时的概率分布。该模型应用双向上下文模型和两阶段解码框架,使Entroformer支持并行解码加速而不损失性能。**Informer[6]**可以同时利用全局和局部两个层次先验信息。全局先验使用固定查询数量的交叉注意力提取整幅图像的内容相关信息,局部先验使用 1×1 卷积提取空间相关信息。**Informer**相比只用局部上下文的方法具有更好的率失真性能,并且能够避免了计算复杂度呈二次增长的问题。上述方法的缺点是训练较为困难,需要特定的优化策略。

2) 单次训练多码率推理

基于深度学习的图像压缩方法一般需要训练多个固定码率模型来实现码率自适应,其中每个模型对应一种码率。因此,训练成本和内存需求随着所需码率范围的增长和细化而急剧增加。条件自动编码器架构[32]将全连接层合并到卷积单元中以实现离散速率自适应,但是增加网络的计算复杂性和内存需求。**Thesis**等人[9]首先以高比特率训练自动编码器网络,然后固定预训练的自动编码器并与比例参数结合以实现码率自适应。**AG-VAE[33]**通过使用配对的增益单元以及指数插值的方法,实现了图像压缩的连续码率自适应。根据优化的方式不同,现有方法主要可分为架构设计改进和训练技巧优化两类。以下具体展开介绍:

架构设计改进:渐进式编码架构仅需要一次训练,可支持比特的渐进式编码与传输[29],发送的比特越多,图像重建就越准确。其中,基于LSTM的方案被广泛采用,并利用残差尺度重建、熵编码和空间自适应比特率[30][31]等新技术提升率失真性能。高效单模型可变比特率编解码器EVC框架[28]由三个复杂度不同的模型组成:大型、中型和小型。大型模型的速率失真性能最好,但复杂度很高,而小型模型的复杂度最

低，但性能最差。该架构通过掩码衰减和残差表示学习等技术实现渐进式压缩。

训练技巧优化：由于条件卷积可以根据Lagrange乘数改变卷积层输出，Choi [34]等人在训练中同时使用多个Lagrange乘数，以学习对不同压缩率优化的编码器。接着同时使用不同的量化步长训练，使模型适应不同的量化。在测试时，根据需要的压缩率选择Lagrange乘数和量化步长，进行图像压缩。基于质量缩放因子的架构Chen [35]对自动编码器的编码器输出特征图进行缩放和偏移。在解码器部分加入对应的逆缩放因子，将特征图还原。其中缩放因子在不同的比特率下训练，其余网络参数固定。最后在测试时，根据需要的比特率选择相应的缩放因子，不需要重新训练网络。基于在线元学习的图像压缩方法[37]，将图像压缩建模为条件变分自动编码器结构，并从元学习的角度进行在线学习，以解决可变比特率问题。不更新模型参数，而是直接通过SGD优化重构过程中的条件超参数，以适应当前图像，从而弥补训练软量化和测试硬量化的误差。

相比单独训练多个网络，上述方法只需要训练一个网络即可适应不同压缩率，计算效率更高。缺点是需要存储额外的条件变量，增加了开销。而且搜索最优条件增加了训练时间。

3) 码率分配优化技术

针对低比特率下的视觉质量不够理想的问题，Li[12]等人提出的内容自适应图像压缩框架包含卷积编码器、重要性图网络、二值化器和卷积解码器四个部分。其中编码器输出特征图，重要性图网络根据图像内容学习每个位置的比特分配情况，二值化器将编码器输出量化为二值码，解码器复原图像。关键是提出了基于内容的重要性图，用于指导各位置的比特率分配，重要区域分配更多比特，不重要区域分配较少比特，以此提高重构质量。此外，该框架使用了直通估计器近似二值化操作的梯度，使框架可端到端训练。训练时，以重要性图的和作为码率约束，而

不是离散熵。最后，设计了卷积熵编码器进一步无损压缩输出码字。相比 JPEG 和 JPEG2000 等方法，该框架可显著减少模糊、振铃等压缩失真，尤其在低比特率下质量更好，边缘和纹理细节都得以良好保留。其缺点是搜索到的网络结构可能不是全局最优，还需人工调整。总体上，该框架对低比特率情况下的神经网络图像压缩性能有明显提升。

针对当前的神经网络图像压缩方法无法进行内容自适应的压缩，难以实现局部匹配不同复杂度图像区域的压缩率的问题，Brand[17]等人提出了一种分层自动编码器结构，可以进行自适应的压缩率选择。具体来说，该结构提出分层的潜在空间单元，可以提取不同分辨率的特征映射。使用定义掩码来选择是否传输每个潜在空间中的信息。而在编码时，通过改变掩码，可以自适应地选择每个区域的压缩深度。最后在训练网络时，随机生成掩码，测试时，进行多遍掩码优化以最小化率失真损失。相比单一压缩率的网络，该结构可以自适应选择局部压缩率，相当于传统编解码器中的块分割，可以根据图像内容分配比特率，在相同质量下节省约 20%的比特率。该方法的创新点在于将传统编解码器的率失真优化概念引入到神经网络图像压缩中，以实现内容自适应压缩，但需要存储和传输额外的掩码信息。

6.3 智能视频编码压缩

智能图像编解码器的成功也推动了智能视频编解码器的发展。传统的视频压缩方法依靠预测编码对运动信息和残差信息分别进行编码。开创性工作端到端深度视频压缩框架（Deep Video Compression, DVC）[38]将经典架构与神经网络的非线性表示能力相结合，实现了整个流程端到端的联合优化。根据时-空域冗余消除方式和阶段不同，现有相关方法可分为基于残差编码的框架、基于条件编码的框架、基于3D自编码器的框架和其他架构。

6.3.1 基于残差编码的框架

基于残差编码的框架，首先基于已解码参考帧，生成当前待编码帧的运动信息，然后生成运动补偿预测帧，最后对残差进行编码。所有模块通过一个损失函数进行联合学习[42]-[49]。值得注意的是，运动补偿过程可在图像空间域或特征空间域完成。运动估计的关键是基于学习的光流估计模块，以建立起视频序列中连续帧之间的关系。以下具体展开介绍：

尺度空间流估计：为了提高模型对不确定性运动模式的预测能力，基于广义扭曲算子的框架[39]引入尺度空间流估计技术，并集成尺度参数，增强了模型的预测能力。尺度空间流模块通过增加尺度参数作为第三维，将传统的两通道流扩展为三通道流。该尺度参数允许扭曲操作更好地处理复杂情况。本质上，尺度参数作为一个连续可微分的选项，可以在扭曲操作前自适应源图像的清晰度，因此可以很好的预测下一帧。为了实现尺度空间流，该方法从源图像构建了一个固定分辨率的尺度空间体，而不是像双线性扭曲那样直接从二维源图像中采样。使用三通道位移和尺度场在尺度空间扭曲中采用三线性采样，如果扭曲操作不能很好地预测目标图像，则允许模型在扭曲期间自适应地模糊源内容。通常，光流和双线性扭曲被用于视频压缩中的运动补偿模块，但其依赖于复杂的模型架构和训练的方法，该框架所提出的方法不需要任何预训练的光流网络，使用简单的方式进行训练就可以优于类似的基于学习的视频压缩模型。

多尺度光流估计：为了有效降低像素级光流图的码流，分辨率自适应流编码（Resolution-adaptive Flow Coding, RaFC）架构[40]，以实现运动矢量编码器的输入流图和输出运动特征的多分辨率表示。具体的，通过RaFC-frame模块根据当前帧的运动模式的复杂度，自适应最佳流分辨率；而RaFC-block模块为每个局部运动特征块选择最佳分辨率，以局部处理不同类型的运动模式。在两种方案中通过率失真优化技术以选择

最优的运动编码方式。

特征空间光流估计：特征空间视频编码（Feature-Space Video Coding, FVC）[41]架构在特征空间中执行包括运动估计、运动压缩、运动补偿和残差压缩在内的所有操作。首先，通过特征提取网络从两个连续帧中提取特征表示并估计运动信息。然后使用自编码器对偏移映射进行压缩，重构后的偏移映射将用于后续的可变形卷积运算，用于生成预测特征，从而实现更精确的运动补偿。最后，将残差特征进行压缩，并使用多帧特征融合组合多个参考特征，实现更好的帧重建。

时空一致性光流估计：基于学习的视频压缩方法通常将解码的前一帧作为参考帧进行运动估计，但是使用解码帧作为参考可能会对运动信息的空间结构造成损坏，并导致各帧在时间上的运动不一致。为了克服这些问题，保持结构的运动估计方法（Structure-Preserving Motion Estimation, SPME）[46]利用原始的和解码参考帧来估计一个既具有空间结构保持性又具有时间一致性的运动场。该方法在特征域完成主要运动场、辅助运动场和运动场融合等操作，进而减少误差传导带来的率失真性能损失。

运动分解模型：视频中的运动模式可以分解为内在运动和补偿运动两个组成部分。其中，内在运动可以捕捉历史序列中隐藏的时空上下文信息，而补偿运动则起到了提升纹理细化和结构优化的辅助作用。运动分解模型[50]的引入使得帧间预测可以在特征空间中进行条件建模，使用运动分解结果作为条件来进行预测。与传统的只能使用后向变形的运动矢量不同，该方法能够更紧凑和高效地表示运动，同时保持了优化的编码效率。

高阶光流估计：视频帧中存在两种层次冗余：一阶冗余和二阶冗余。其中，一阶冗余指的是相邻帧之间的像素值相似性，在运动和残差补偿中可以有效地捕捉到。而二阶冗余指的是由于自然视频中的平滑运动而导致的运动和残差图中的冗余。现有的神经视频编解码器解决了一阶冗

余的问题，但却没有解决二阶冗余的问题。为了进一步消除光流中的时间冗余，Liu等人[44]采用了一阶光流和二阶流预测来捕捉帧间的时间相关性。类似的，Pourreza等人[52]提出了用于捕捉第二层冗余的通用运动和残差预测器。这些预测器通过学习从先前解码的数据中外推，改善了神经视频编解码器的率失真性能。。

像素到特征的运动预测方法：为了提高帧间预测的准确性而不增加解码器的复杂性，AlphaVC[48]引入了一种像素到特征的运动预测方法，该方法通过生成预测的运动向量来改进帧间预测，生成的特征经过变形对齐得到预测特征，进而计算残差，并通过残差压缩模型进行压缩。

Rippel 等人[51]针对低延迟模式提出了一种新的视频编解码器 ELF-VC。该方法旨在解决现有神经视频压缩架构中的三个关键弱点，即比特率灵活性、压缩效率和速度。该框架包括多级损失设置，动态损失调制和级别嵌入模块。多级损失设置包括比特率和失真，以及一些额外的条件项。通过该设置，模型可以针对不同级别的比特率进行优化，并使用不同的正则化权重来实现多个点在率失真曲线上的选择。动态损失调制根据每帧图像的特性和不同级别进行编码，动态调整分配给不同部分的损失权重。在训练过程中，对于每个帧和每个级别，利用动态变化的权重来调整重建损失，以便在P帧的峰值信噪比与I帧的之间有更好的性能。通过根据帧的特性动态调整损失权重，可以加速高比特率级别的训练过程，并提高编码质量。此外，还提出了一种新的环路流量预测器，将之前的流和帧重构作为输入，产生基本预测流。然后，流自编码器生成稀疏的流增量，将其添加到掩码预测流中以生成最终流。

6.3.2 基于条件熵编码的框架

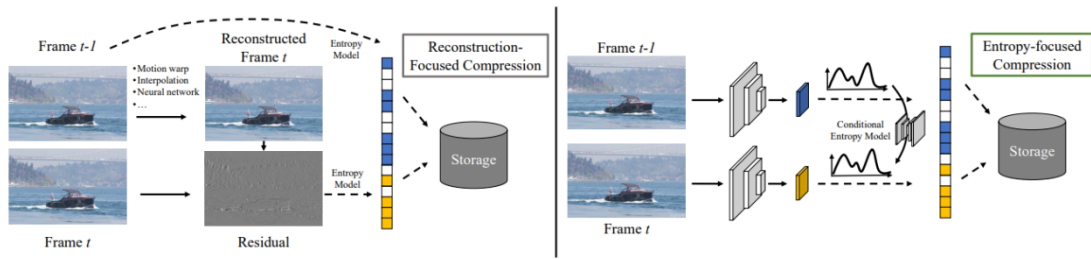


图 6-3 时域冗余的消除方式对比示意图（图来源于文献[52]）。

左图：基于残差编码的显式时域冗余消除框架；右图：基于条件熵编码的隐式时域冗余消除框架。

基于残差编码的神经视频压缩方法采用预测编码生成预测帧，对当前帧和预测帧之间的残差进行编码。然而，这种方法只使用简单的减法操作来消除帧间冗余，导致压缩比不理想。Liu等人[52]提出了一种基于条件熵编码的视频压缩方法，支持从基于预测残差编码的显式时域冗余消除到基于条件熵编码的隐式时域冗余消除的范式转换。具体来说，该方法的架构包含了单帧图像编码器/解码器、条件熵模型等模块。条件熵模型部分用于捕捉图像编码之间的时序关系，近似估计视频序列的联合熵。但由于该方法未考虑运动估计与运动补偿，率失真性能未能超过基于残差编码的DVC模型。

深度上下文视频压缩方法（Deep Contextual Video Compression, DCVC）框架[53]由编解码器、上下文生成器和熵模型组成。为了采集更富丰富的条件，上下文处于高维度的特征域中。上下文的学习过程使用特征提取网络将参考帧从像素域转换到特征域，还结合使用光流估计来学习参考帧和当前帧之间的运动向量，从而通过流操作提取上下文。最终上下文通过上下文细化网络得到。通过不同的上下文特征，DCVC可以实现更好的重建质量，特别是对于具有大量高频复杂纹理的图像。在处理新内容时，残差可能会很大，而DCVC可以自动学习当前帧和上下文之间的相关性并去除冗余。同时期，Ho等人[54]利用条件增强归一化流（Conditional Augmented Normalizing Flows, CANF）来用于条件帧间编码和运动编码，实现了更好的表示能力。

在DCVC的基础上,TCMVC[55]通过引入特征传播和多尺度时间上下文进一步提高了压缩率。首先,为了挖掘时间上下文,将先前重构的帧以及特征存储到广义解码图像缓冲区中;然后,从存储的传播特征中提出了学习多尺度时间上下文的方法,并将学习到的时间上下文重新填充到所提框架的模块中,包括上下文编码器-解码器、帧生成器和时间上下文编码器。尽管为了加快解码速度,该方法放弃了不利于并行化的自回归熵模型,在相同PSNR下该模型相比H.265-HM,可以节省14.4%的比特率;在相同MS-SSIM下该模型相比H.266-VTM节省了21.1%的比特率。

Li等人[56]提出了一种高效的混合时间空间熵模型,旨在准确预测量化潜在表示的概率分布,以提高视频数据的压缩效率。与现有的编码器主要依赖于图像编码器的现成熵模型不同,该模型引入了一个综合的熵模型,能够捕捉视频中的空间和时间依赖关系。该模型包括一个潜在先验,利用帧间潜在表示之间的相关性来减少时间冗余,并且还包括一个双重空间先验,以并行友好的方式减少空间冗余。此外,这个熵模型具有灵活性,还可以在空间-通道级别生成量化步骤,实现单一模型中的平滑的码率调整。为了实现这种熵模型,该方法使用了基于条件编码的框架,并将整个编码过程分为时域上下文生成、上下文编码/解码和重建三个步骤。在时域上下文生成阶段,通过使用轻量级的SPyNet进行运动估计和生成多尺度的上下文来充分利用视频数据的时域相关性。在上下文编码/解码阶段,使用改进后的核心模块对上下文信息进行编码和解码。在重建阶段,使用基于W-Net结构的帧生成器生成高质量的重建帧。此外,在获得高分辨率特征的情况下,该模块还使用时域特征代替前一个解码帧作为输入,以获得更丰富的信息。最终的目标是通过帧生成器生成高质量的重建帧。最终,通过准确预测量化潜在表示的概率分布,并实现空间和时间冗余的消除,该编码器超过了传统编码器H.266。

类似的, Mentzer 等人[57]将transformer架构应用在视频压缩网络

中，极大的简化了网络的复杂性。基于Transformer的框架使用transformer来建模输入帧之间的依赖关系，并预测未来表示的分布。它在标准视频压缩数据集上优于先前的方法，并且可以处理复杂的运动模式，而不依赖于手工设计的组件。该方法首先采用有损变换编码将输入帧映射为一个量化表示。接着利用transformer利用时间冗余对表示的分布进行建模，使用这些预测分布无损压缩量化表示。它的核心模块包括帧编码和解码、高效的编码方案和基于transformers的条件分布建模。在帧的编解码中使用基于CNN的图像编码器独立地对每一帧进行编码，得到量化表示。编码器通过空间降采样和通道增加将输入图像的分辨率缩小为输入图像分辨率的1/16。根据量化表示可以通过解码器恢复出重建帧。通过标准的神经图像压缩技术，使用损失变换的进行训练，以达到几乎任意所需失真。条件分布建模中，使用transformer模型来建模已传输块的时间信息，并预测量化表示的条件分布。transformer模型通过对块序列进行操作，从已传输的块中提取时序信息。通过这种方式，transformer模型能够利用帧间的时序冗余和帧内的空间一致性。这样，就可以预测未来表示的分布，并最大化编码效率。

视频编解码器的编码效率都取决于被编码的信号能否从已压缩重建的信号中找到相关的上下文。然而，现有的神经视频压缩方法上下文有限，导致压缩比低。为了解决这个问题，Li等人[58]提出增加时域和空域两个维度的上下文多样性。具体来说，该方法包括以下三个关键模块：1) 为了增加时域上下文多样性，方法提出了引导模型学习层次化质量模式的方法，以丰富长期时域上下文。通过在训练过程中引导模型学习这种模式，在特征传播过程中隐式地学习出对重建后续帧至关重要的长期高质量上下文特征。此外，为了进一步挖掘光流码流中的上下文信息，还采用了基于组的偏移多样性，其中跨组交互用于更好地挖掘时域上下文。2) 为了增加空间上下文多样性，采用了基于四叉树的分割方法，用于在并行编码潜在表示时增加空间上下文的多样性。与之前的

方法相比，这种分割方法的相关建模类型更多样化，因此模型有更大的机会找到更多相关的上下文。

6.3.3 其它类型的架构

1) 基于3D自动编码器的框架

3D自动编码器通过扩展输入维度，支持对多帧视频序列同时进行编码。Habibian等人[59]提出了一种使用率失真自编码器进行有损视频压缩的深度生成模型。该方法中的自编码器使用了一种三维自编码器，用于视频压缩。自编码器由编码器和解码器组成，通过将视频序列压缩为离散潜变量，然后再进行解压缩来实现视频的有损压缩。特别的是，该自编码器结合了一个自回归先验，用于熵编码，从而实现了压缩比和失真之间的平衡。整个模型通过最小化压缩损失来进行训练，即编码后的视频与原视频之间的差异。此外，为了进一步改进基本方法，引入了几个扩展。语义压缩方法是训练模型为感兴趣的对象（如人）分配更多的位。它利用学习的视频编解码器可以整合视频内容的语义理解，以优先对重要区域进行压缩，从而在较低的比特率下提供更好的视觉质量。其次，自适应压缩使模型被微调到具有有限可变性的特定域，例如从自动驾驶汽车上拍摄的视频。这种适应可以在特定的域上获得优越的压缩性能。最后，多模态压缩使得该模型能够联合压缩由非标准成像传感器（如四摄像头）捕获的多个模态，利用存在于不同模式之间的冗余来实现更好的压缩性能。

Pessoa等人[60]提出的基于时空自动编码器的视频压缩的端到端学习方法，避免了显式的运动估计和预测，并利用潜空间投影变换和合成变换进行低比特率视频压缩。压缩网络的损失函数结合了重构失真、熵编码的量化潜在表示和时间一致性损失。该方法使用了一种四舍五入方案和熵估计技术的量化器来实现信息瓶颈。该方法在低比特率下优于MPEG-4标准，并且与H.264/AVC竞争力相当。该方法中包括以下几个

部分。编码器使用三维卷积和非线性操作来生成视频的潜在空间表示，解码器则使用相反的操作将潜在空间表示重构成视频。编码器和解码器之间的处理块分为两个不同尺度，用于捕捉视频数据中的不同空间和时间尺度上的依赖关系。超先验网络用于估计视频数据中剩余空间和时间冗余的方差，通过结构化为时空自编码器的形式实现。超先验网络由编码器和解码器组成，其中编码器通过三个序列处理块（三维卷积）和ReLU非线性操作来生成超先验网络的潜在空间表示，解码器反转编码器的操作。为了解决梯度无法通过量化器传播的问题，文中采用了一种近似量化方法，即将量化器替换为在量化间隔 $[-1/2, 1/2]$ 上服从均匀分布的加性噪声。这样，训练过程中的量化过程就可以被梯度传播所参与，从而优化网络的参数。最后，提出了一种综合考虑重构失真、熵编码量化潜在表示和时间一致性的损失函数。该损失函数综合了各种损失项的权重，并用于优化网络参数。然而，这种框架会带来很大的编码延迟，不适合实时场景。

2) 基于循环自编码器的框架

现有视频压缩方法仅利用少量参考帧来压缩视频，没有充分使用视频帧之间的时间相关性方面。循环学习视频压缩（Recurrent Learned Video Compression, RLVC）模型[61]采用（Recurrent AutoEncoder, RAE）和循环概率模型（Recurrent Probability Model, RPM）来分别改进运动向量和残差压缩。RAE是一个使用循环单元的编解码器，利用当前帧和之前帧的信息来生成潜在表示和重构压缩输出。具体来说，在编码器中使用了四个二倍下采样的卷积层，并插入了一个Conv-LSTM单元来实现循环结构。这样，前一帧的信息通过Conv-LSTM的隐藏状态流入当前帧的编码器网络。在解码器中，同样有一个Conv-LSTM单元嵌入在四个二倍上采样的卷积层中，使用IGDN进行重构。因此，RAE从当前和之前的潜在表示中重构输出。RPM以潜在表征的分布为条件，循环估计潜在表征的概率质量函数。由于连续帧之间的相关性，条件交叉熵

要低于独立交叉熵，从而降低比特率。

3) 基于深度生成模型的框架

与传统的基于块的混合编码方法相比，基于深度生成模型的方法可通过学习将原始视频序列转换为低维表示以及将该表示进行离散化和熵编码来实现视频压缩。Han等人[62]提出的基于深度生成模型的视频压缩方法结合了序列数据的变分自动编码器模型。类似于传统方法中的关键帧，该方法中全局状态模块可以有效地压缩静态信息。全局状态可以从多个帧中推断出来，这样可以更好地捕捉视频序列的长期信息。

为了更好地合成细节，Mentzer等人[63]提出了基于GAN的神经视频压缩方法。由于GAN损失对于获得高视觉质量至关重要，因此使用两个组件来使GAN损失有效。首先，通过将生成器与从扭曲的先前重构中提取的潜在特征进行相互作用来合成细节；然后，通过高质量的流传播这些细节。实验证明，在通过用于研究来确定的主观视觉质量上，所提方法能够优于标准编解码器H.264和HEVC以及该方法提出之前的神经压缩系统。

Shukor等人[64]提出了一种基于学习的潜在GAN压缩模型方法SGANC。该方法利用GAN的生成能力对人脸视频进行压缩，包括帧内和帧间压缩。与传统的图像和视频编码技术不同，SGANC的重点是压缩后的人脸图像感知质量，而不是图像的保真度。该方法利用StyleGAN生成器的强大生成能力生成高质量逼真的图像，在极低的比特率下产生具有高质量的图像。与当前最先进的编解码器（包括VTM、AV1和最新的深度学习技术）相比，SGANC实现了更好的图像和视频编码结果，并在低比特率下显著减少了感知失真。

Zhao等人[65]提出了一种名为联合深度压缩和增强（Jointly Optimized Compression and Enhancement, JCEVC）的视频编码方法。JCEVC的主要目标是在保持视频质量的同时实现高压缩效率。该方法利用双通路生成对抗网络（Dual-path Generative Adversarial Network,

DPEG) 在压缩后进行视频重建。 α 通路专注于结构特征, 而 β 通路则专注于纹理细节。DPEG 网络在JCEVC框架的运动补偿和质量增强模块中被重复使用。框架还包括其他必要的模块, 如基于CNN的光流和残差网络。JCEVC框架采用联合训练的方式, 对深度视频压缩和增强进行优化, 以优化压缩的速率失真性能。

6.3.4 编码配置优化技术

前述视频编码架构主要是针对低延时P帧编码配置。实际上, 为了提升压缩效率, 传统视频编码器中的层次化分层B帧配置亦可以结合到基于学习的视频编码方案中。基于层次学习的高效视频压缩方法 (Hierarchical Learned Video Compression, HLVC) 通过将视频序列分成三个质量层以提高视频压缩性能。第一层, 第二层和第三层的质量分别以最高, 中等和最低的质量进行压缩。高质量的帧提供了高质量的参考, 在解码时可以利用高质量帧中的有利信息对低质量帧进行增强。第一层采用图像压缩方法进行编码, 消耗最高的比特率, 具有最高的压缩质量。可以有效的阻止视频编解码过程中错误的传播, 有利于相邻帧的压缩和增强。第二层使用双向深度压缩 (Bi-Directional Deep Compression, BDDC) 网络进行相对高质量的压缩, 该网络利用第一层的帧作为参考, 并且为第三层的低质量帧压缩和增强提供信息。该网络包括一个运动估计子网络, 用于捕捉参考帧和目标帧之间的时间运动, 并且采用金字塔网络来获得更大的感受野, 以处理较大的运动。第三层使用单运动深度压缩 (Single Motion Deep Compression, SMDC) 网络进行最低质量的压缩。通过使用压缩帧之间的运动作为参考, SMDC消除了对每帧单独的运动图进行编码的需要, 降低了运动信息的比特率, 提高了压缩效率。与现有方法相比, SMDC可以准确的从单个运动图中估计多帧运动, 获得更高质量的压缩帧。加权循环质量增强 (Weighted Recurrent Quality Enhancement, WRQE) 网络使用质量门控单元以利用多帧相关性。WRQE网络将压缩后的帧和码流中编码的质量信息作为输

入,根据帧的相对质量来提高帧的质量,有助于改善由于低比特率而导致严重失真的帧。

针对低延迟场景,多帧预测视频压缩(Multiple Frames Prediction for Learned Video Compression, M-LVC) [67]方法通过使用已解码重建的多帧信息作为参考帧,增强当前帧的预测准确性,从而减少残差。为了处理残差和运动向量的压缩误差,该方法使用了两个深度自编码器进行压缩。为了进一步补偿自编码器的压缩误差,该模型设计了一个运动向量优化网络和一个残差优化网络,这两个网络也使用了多个参考帧和对应的多个运动向量。通过引入基于多个帧的运动向量预测、基于多个帧的运动补偿、运动向量优化和残差优化等四个模块。首先进行运动估计和预测。将当前帧和参考帧输入到运动估计网络中,提取出运动信息。为了减少运动向量的时间冗余,采用多尺度对齐运动向量预测网络(Multi-scale Aligned MV Prediction Network, MAMVP-Net)来预测当前的运动向量。然后对运动进行压缩和细化,使用运动向量残差编解码网络对原始运动向量和预测运动向量的插值进行编码,并使用运动向量细化网络来减少压缩误差,提高重构运动向量的精度。接着对多个参考帧计算运动补偿。该方法使用之前三个重建的运动向量和参考帧来优化当前的运动向量,这样可以更准确地预测当前的运动向量。最后对残差进行压缩和细化。该方法引入了运动向量和残差优化模块,用于补偿压缩误差并提高重构质量。这些模块也使用了多个参考帧和对应的多个运动向量,并且采用速率失真损失函数共同优化各个部分,以达到最佳的编码比特数和失真。该方法在低延迟模式下比现有的学习视频压缩方法表现更好,并且在PSNR和MS-SSIM方面都优于H.265。

Pourreza等人[68]提出的B-EPIC方法专注于B帧编码。即通过同时利用过去和未来的参考帧预测当前帧。该方法的基本思想是将两个参考帧插值生成单一的参考帧,并将其与现有的P帧编解码器一起使用,对输入的B帧进行编码。相比于只使用P帧编解码器,该方法在UVG数据集

上实现了28.5%的比特率节省，同时保持相同的视频质量。其次，该方法可以很容易地添加到现有的神经编解码器中，因为同一个网络可以学习P帧编码并为B帧压缩做出贡献。

6.4 视觉数据压缩新趋势

目前，视觉数据的智能编码压缩技术仍处于快速发展阶段，其主要发展趋势反映在新架构、新内容和新场景三个维度。以下具体将从隐式神经表示、多模态视觉数据压缩和面向人机混合智能的编码三个方面展开介绍：

6.4.1 隐式神经表示

前述的神经压缩方法的核心技术是通过训练自动编码器实现图像/视频中的空间域像素信息到特征变换域量化潜在表示的可逆映射。而最近的研究显示了基于坐标映射的隐式神经表示（Implicit Neural Representation, INR）在图像压缩方面的潜力[71]-[72]。根据待编码压缩视觉数据的时域信息有无，可分为基于静态隐式神经表示的图像压缩和基于动态隐式神经表示的视频压缩。以下具体展开介绍：

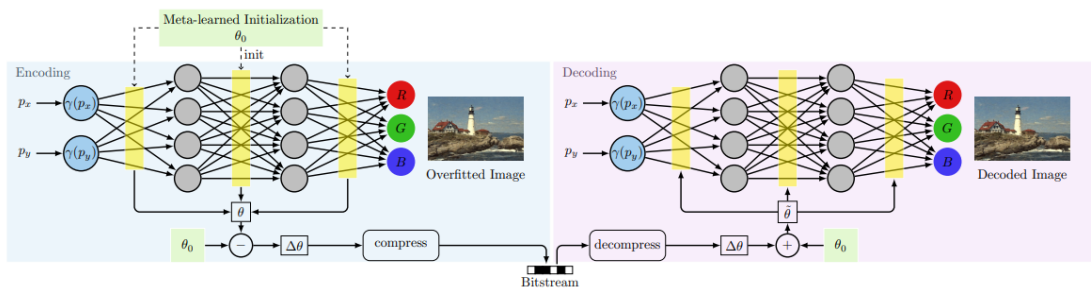


图 6-4 基于 INR 的图像编解码器架构示意图（图来自于文献[72]）

1) 静态隐式神经表示的图像压缩

基于隐式神经表示的图像压缩方法 COIN[69] 通过多层感知机（Multi-Layer Perceptron, MLP）拟合图像像素坐标与像素 RGB 值之间的关系函数，其中 MLP 的量化权重参数作为码流信息以重建图像。即

使不使用熵编码，这种简单的方法在低比特率下也能优于JPEG。为了加速训练速度，COIN++[70]采用元学习的方法进行模型训练，即首先使用SIREN网络学习一个基网络，然后对新的数据样本，通过梯度下降学习一组调制参数，以调制基网络来重构该样本，对调制参数进行量化和熵编码，得到压缩后的码流。

COIN方法需要对网络架构进行耗时的搜索，以在重构质量和压缩率之间取得平衡。Ramirez等人[79]提出的称为 L_0 onie的稀疏框架，使用 L_0 正则化技术引入稀疏性，在快速收敛的同时得到较好的压缩率。Strumpler等人[81]提出了两个改进点，一是基于元学习的初始化方法，可以利用数据分布的先验知识，提高INRs的压缩性能和收敛速度；二是基于SIREN网络和位置编码的INR架构，可以提高INRs的表达能力和对量化的鲁棒性。在Kodak和CelebA数据集上，该方法在不同比特率下都显著优于前述基于INR的图像压缩方法，并且可以与传统的图像压缩算法如JPEG和JPEG2000竞争。

2) 基于动态隐式神经表示的视频压缩

传统的视频表示方法将视频视为帧序列，而动态隐式表示将视频表示为神经网络，以帧索引作为输入。编码过程将神经网络拟合到视频帧上，解码过程则是一个简单的前馈操作。相比于基于像素的隐式表示方法，动态隐式神经表示框架NeRV[73]的编码速度提高了25-70倍，解码速度提高了38-132倍，同时实现了更好的视频质量。

NeRV方法直接从帧索引输入输出视频帧的时空信息，导致模型尺寸较大。E-NeRV[74]通过解耦空间和时间表示以及引入时间嵌入，通过去除时空背景的耦合和减少冗余模型参数提出了E-NeRV，加速了收敛速度的同时提高了视频的代表能力。

然而，上述方法存在内容不可知的嵌入问题，混合神经表示方法HNeRV[75]结合显式和隐式方法的特点，设计了内容自适应的可学习编

码器以生成内容自适应的嵌入表示，来进一步提高视频重建的质量。HNeRV通过模型压缩方法，如权重修剪和权重量化，可以进一步减小模型的大小，降低带宽。

针对长视频或者大量不同类型的视频，D-NeRV[76]将视频片段特定的视觉内容与动作信息进行分离，并引入时间推理和任务导向的流，以减少空间冗余，并提高视频压缩和重构任务的性能。

6.4.2 多模态视觉数据压缩

1) 双目立体图像/视频压缩

Deng 等人[77]将左图像通过单应矩阵估计得到右图像的估计，然后通过自动编码器来压缩左图像和右图像与估计图像的残差，从而提高了立体图像压缩效率。Wodlinger等人[78]在解码器中引入立体注意力机制，来进一步利用左右视图的相关性来降低比特率。Zhai等人[79]联合训练立体匹配和压缩网络，通过三支编码右图像、左右图像的视差、残差来提高压缩质量。Lei等人[80]设计双向上下文变换模块，实现双向编码利用视差信息，进一步提高了压缩性能。Chen 等人[81]提出基于学习的立体视频压缩框架LSVC，使用运动和视差补偿降低时间和视差冗余。

2) 跨模态图像/视频压缩

针对RGB-D数据，Peng等人[82]利用纹理特征作为上下文信息，提出纹理引导的变换模块和条件熵模型，提高了深度图的压缩效率。Chen 等人[86]提出了RGB引导的深度图压缩框架，通过提取RGB图像的跨模态结构先验来提高深度图的压缩性能。Lan等人[85]使用了3D-HEVC编解码器对彩色和深度视频进行压缩，然后利用使用RGB图像来辅助深度图进行超分辨率，对压缩后的深度视频进行重构，提高了压缩效率。

针对RGB-T数据，Lu等人[83]则使用通道和空间对齐模块，将不同模态的特征进行转换，从而更好地去除跨模态间的冗余性。Jiang等人[84]利用文本描述作为先验信息，提出了文本引导的图像压缩方法，在极低

比特率下也能获得好的性能。

6.4.3 面向人机混合的智能编码

Yang等人[87]提出了一个面向人机协同的面部图像编码框架。该方法提取边缘和对应的颜色信息作为紧凑表示,并利用生成模型从这些表示重构图像。具体来说,利用边缘检测获得图像边缘,再转化为矢量图形进行编码,作为结构信息;同时沿着边缘采样颜色像素作为颜色信息,并按去除该像素解码器所给反馈确定的优先级选择关键像素实现可缩放编码。解码端使用GAN从编码的结构和颜色表示重建图像。实验结果表明,该方法在类似比特率下重建图像质量超过JPEG,在机器视觉任务上也有明显提升。

Choi等人[88]提出了一种可扩展的视频编码框架,该框架支持人类和机器视觉任务。该框架包括来自传统和基于DNN的视频编码的组件。该框架通过使用用于机器视觉(特别是物体检测)的基础层比特流和用于人类视觉的增强层比特流来实现这一目标。该框架还将基于DNN仿射帧预测集成到编码管道中,通过估计两个输入帧和所需输出帧之间的运动以及自适应滤波,网络会生成估计的帧,从而最大限度地减少代码中的残留信号。与其他最先进的视频编解码器相比,该框架在物体检测方面取得了更好的结果,同时在人类视觉任务的MS-SSIM方面保持了竞争力。

Marie等人[89]评估了在机器视频编码(Video Coding for Machines, VCM)背景下压缩伪影对基于深度的语义分割算法的影响。为了减少通过机器到机器(Machine-to-Machine, M2M)连接传输的信息量,必须丢弃视觉内容中的冗余信息。然而,在高比特率下,DNN模型对视频编解码器伪像(例如循环内滤波)的泛化能力很差,这使得它们在码率精度权衡方面不如JPEG等更简单的编解码器。

Huang等人[90]提出了一种名为人机友好的视频压缩方法

(Human-Machine Friendly Video Compression Scheme, HMFVC), 可以同时优化人类感知的视觉质量、机器分析的准确性以及压缩效率。HMFVC可以以较低的比特率实现与原始视频类似的行为识别准确率, 相比x265可节省77%的比特率; 重建视觉质量也与x265相当。类似的, 任务驱动的视频压缩框架[91] [92]均通过设计相应的模块, 以实现信号保真度和语义保真度之间的权衡。

6.5 本章小结

基于神经网络技术的智能图像/视频编码成为下一代视频编码技术发展的重要突破口, 具有非常重要的学术研究与产业应用价值。全新的智能图像/视频编码技术将在节省存储与传输宽带成本、降低时延、保障视觉质量的基础上满足对视频感知、分析、理解等智能应用方面的需求。为了进一步提升产业落地的可行性, 需要结合应用和场景需求, 在新型架构设计、轻量化模型设计和自适应码率分配等方向展开研究, 需要在新的方法和技术上形成突破。

参考文献

- [1] Johannes Balle, Valero Laparra, and Eero P. Simoncelli. End-to-end optimized image compression. In *5th International Conference on Learning Representations, ICLR, Toulon, France, 2017*.
- [2] Johannes Balle, David Minnen, Saurabh Singh, Sung Jin Hwang, and Nick Johnston. Variational image compression with a scale hyperprior. In *6th International Conference on Learning Representations, ICLR 2018*.
- [3] David Minnen, Johannes Balle, and George Toderici. Joint autoregressive and hierarchical priors for learned image compression. In *Advances in Neural Information Processing Systems*, pages 10771–10780, Montreal, QC, Canada, 2018.
- [4] Zhengxue Cheng, Heming Sun, Masaru Takeuchi, and Jiro Katto. Learned image

- compression with discretized gaussian mixture likelihoods and attention modules. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 7936–7945, Virtual, Online, United states, 2020.
- [5] Yueqi Xie, Ka Leong Cheng, and Qifeng Chen. Enhanced invertible encoding for learned image compression. In *Proceedings of the 29th ACM International Conference on Multimedia*, pages 162–170, Virtual, Online, China, 2021.
- [6] Jun-Hyuk Kim, Byeongho Heo, and Jong-Seok Lee. Joint global and local hierarchical priors for learned image compression. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, volume 2022-June, pages 5982–5991, New Orleans, LA, United states, 2022.
- [7] Yichen Qian, Ming Lin, Xiuyu Sun, Zhiyu Tan, and Rong Jin. Entroformer: A transformer- based entropy model for learned image compression. In *10th International Conference on Learning Representations*, Virtual, Online, 2022.
- [8] Yin hao Zhu, Yang Yang, and Taco Cohen. Transformer-based transform coding. In *10th International Conference on Learning Representations*, Virtual, Online, 2022.
- [9] Lucas Theis, Wenzhe Shi, Andrew Cunningham, and Ferenc Huszar. Lossy image compression with compressive autoencoders. In *5th International Conference on Learning Representations*, Toulon, France, 2017.
- [10] Fabian Mentzer, Eirikur Agustsson, Michael Tschannen, Radu Timofte, and Luc Van Gool. Conditional probability models for deep image compression. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 4394–4402, Salt Lake City, UT, United states, 2018.
- [11] Jooyoung Lee, Seunghyun Cho, and Seung-Kwon Beack. Context-adaptive entropy model for end-to-end optimized image compression. In *7th International Conference on Learning Representations*, New Orleans, LA,

United states, 2019.

- [12] Mu Li, Wangmeng Zuo, Shuhang Gu, Debin Zhao, and David Zhang. Learning convolutional networks for content-weighted image compression. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 3214–3223, Salt Lake City, UT, United states, 2018.
- [13] Eirikur Agustsson, Michael Tschannen, Fabian Mentzer, Radu Timofte, and Luc Van Gool. Generative adversarial networks for extreme learned image compression. In *Proceedings of the IEEE International Conference on Computer Vision*, pages 221–231, Seoul, Korea, Republic of, 2019.
- [14] Yueyu Hu, Wenhan Yang, and Jiaying Liu. Coarse-to-fine hyper-prior modeling for learned image compression. In *34th AAAI Conference on Artificial Intelligence*, pages 11013–11020, New York, NY, United states, 2020.
- [15] Fabian Mentzer, George Toderici, Michael Tschannen, and Eirikur Agustsson. High-fidelity generative image compression. In *Advances in Neural Information Processing Systems*, pages 11913–11924, Virtual, Online, 2020.
- [16] Yichen Qian, Zhiyu Tan, Xiuyu Sun, Ming Lin, Dongyang Li, Zhenhong Sun, Hao Li, and Rong Jin. Learning accurate entropy model with global reference for image compression. In *9th International Conference on Learning Representations*, Virtual, Online, 2021. ICLR.
- [17] Fabian Brand, Kristian Fischer, and Andre Kaup. Rate-distortion optimized learning-based image compression using an adaptive hierarchical autoencoder with conditional hyperprior. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, pages 1885–1889, Virtual, Online, TN, United states, 2021.
- [18] Zhengxue Cheng, Ting Fu, Jiapeng Hu, Li Guo, Shihao Wang, Xiongxin Zhao, Dajiang Zhou, and Yang Song. Perceptual image compression using relativistic average least squares gans. In *IEEE Computer Society Conference on Computer*

- Vision and Pattern Recognition Workshops*, pages 1895–1900, Virtual, Online, TN, United states, 2021.
- [19] Dezhao Wang, Wenhan Yang, Yueyu Hu, and Jiaying Liu. Neural data-dependent transform for learned image compression. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 17358–17367, New Orleans, LA, United states, 2022.
- [20] Fabian Brand, Kristian Fischer, Alexander Kopte, Marc Windsheimer, and Andre Kaup. Rdonet: Rate-distortion optimized learned image compression with variable depth. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, pages 1758–1762, New Orleans, LA, United states, 2022.
- [21] Zongyu Guo, Zhizheng Zhang, Runsen Feng, and Zhibo Chen. Causal contextual prediction for learned image compression. *IEEE Transactions on Circuits and Systems for Video Technology*, 32(4):2329–2341, 2021.
- [22] Renjie Zou, Chunfeng Song, and Zhaoxiang Zhang. The devil is in the details: Window-based attention for image compression. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 17471–17480, New Orleans, LA, United states, 2022.
- [23] Dailan He, Yaoyan Zheng, Baocheng Sun, Yan Wang, and Hongwei Qin. Checkerboard context model for efficient learned image compression. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 14766–14775, Virtual, Online, United states, 2021..
- [24] David Minnen and Saurabh Singh. Channel-wise autoregressive entropy models for learned image compression. In *International Conference on Image Processing*, pages 3339–3343, Virtual, Abu Dhabi, United arab emirates, 2020.
- [25] Dailan He, Ziming Yang, Weikun Peng, Rui Ma, Hongwei Qin, and Yan Wang. Elic: Efficient learned image compression with unevenly grouped space-channel

- contextual adaptive coding. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 5708–5717, New Orleans, LA, United states, 2022.
- [26] Guo-Hua Wang, Jiahao Li, Bin Li, and Yan Lu. EVC: Towards real-time neural image compression with mask decay. *ICLR2023*.
- [27] Nick Johnston, Elad Eban, Ariel Gordon, and Johannes Balle. Computationally efficient neural image compression. *arXiv preprint arXiv:1912.08771*, 2019.
- [28] Zhengxue Cheng, Heming Sun, Masaru Takeuchi, and Jiro Katto. Deep residual learning for image compression. In *CVPR Workshops*, 2019.
- [29] George Toderici, Sean M. OMalley, Sung Jin Hwang, Damien Vincent, David Minnen, Shumeet Baluja, Michele Covell, and Rahul Sukthankar. Variable rate image compression with recurrent neural networks. In *4th International Conference on Learning Representations*, San Juan, Puerto rico, 2016.
- [30] George Toderici, Damien Vincent, Nick Johnston, Sung Jin Hwang, David Minnen, Joel Shor, and Michele Covell. Full resolution image compression with recurrent neural networks. In *30th IEEE Conference on Computer Vision and Pattern Recognition*, pages 5435–5443, Honolulu, HI, United states, 2017.
- [31] Nick Johnston, Damien Vincent, David Minnen, Michele Covell, Saurabh Singh, Troy Chinen, Sung Jin Hwang, Joel Shor, and George Toderici. Improved lossy image compression with priming and spatially adaptive bit rates for recurrent networks. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 4385–4393, Salt Lake City, UT, United states, 2018.
- [32] Fei Yang, Luis Herranz, Joost van de Weijer, Jos A. Iglesias Guitin, Antonio Lpez, and Mikhail Mozerov. Variable rate deep image compression with modulated autoencoder. *IEEE Signal Processing Letters*, 27:331–335, 2019.
- [33] Ze Cui, Jing Wang, Shangyin Gao, Tiansheng Guo, Yihui Feng, and Bo Bai.

- Asymmetric gained deep image compression with continuous rate adaptation. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 10527–10536, Virtual, Online, United states, 2021.
- [34] Yoojin Choi, Mostafa El-Khamy, and Jungwon Lee. Variable rate deep image compression with a conditional autoencoder. In *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2019.
- [35] Tong Chen and Zhan Ma. Variable bitrate image compression with quality scaling factors. In *IEEE International Conference on Acoustics, Speech and Signal Processing*, pages 2163–2167, Barcelona, Spain, 2020.
- [36] Haichuan Ma, Dong Liu, Ning Yan, Houqiang Li, and Feng Wu. End-to-end optimized versatile image compression with wavelet-like transform. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(3):1247–1263, 2022.
- [37] Wei Jiang, Wei Wang, Songnan Li, and Shan Liu. Online meta adaptation for variable-rate learned image compression. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, pages 497–505, New Orleans, LA, United states, 2022.
- [38] Guo Lu, Wanli Ouyang, Dong Xu, Xiaoyun Zhang, Chunlei Cai, and Zhiyong Gao. DVC: An end-to-end deep video compression framework. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 10998–11007, Long Beach, CA, United states, 2019.
- [39] Eirikur Agustsson, David Minnen, Nick Johnston, Johannes Balle, Sung Jin Hwang, and George Toderici. Scale-space flow for end-to-end optimized video compression. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 8500–8509, Virtual, Online, United states, 2020.
- [40] Zhihao Hu, Zhenghao Chen, Dong Xu, Guo Lu, Wanli Ouyang, and Shuhang

- Gu. Improving deep video compression by resolution-adaptive flow coding. In *European Conference on Computer Vision*, pages 193–209, Glasgow, United Kingdom, 2020.
- [41] Zhihao Hu, Guo Lu, and Dong Xu. FVC: A new framework towards deep video compression in feature space. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 1502–1511, Virtual, Online, United states, 2021.
- [42] Chao-Yuan Wu, Nayan Singhal, and Philipp Krahenbuhl. Video compression through image interpolation. In *European Conference on Computer Vision*, pages 425–440, Munich, Germany, 2018.
- [43] Oren Rippel, Sanjay Nair, Carissa Lew, Steve Branson, Alexander Anderson, and Lubomir Bourdev. Learned video compression. In *Proceedings of the IEEE International Conference on Computer Vision*, pages 3453–3462, Seoul, Korea, Republic of, 2019.
- [44] Haojie Liu, Han Shen, Lichao Huang, Ming Lu, Tong Chen, and Zhan Ma. Learned video compression via joint spatial-temporal correlation exploration. In *34th AAAI Conference on Artificial Intelligence*, pages 11580–11587, New York, NY, United states, 2020.
- [45] Theo Ladune, Pierrick Philippe, Wassim Hamidouche, Lu Zhang, and Olivier Deforges. Conditional coding for flexible learned video compression. *Neural Compression Workshop @ ICLR 2021*.
- [46] Han Gao, Jinzhong Cui, Mao Ye, Shuai Li, Yu Zhao, and Xiatian Zhu. Structure-preserving motion estimation for learned video compression. In *Proceedings of the 30th ACM International Conference on Multimedia*, pages 3055–3063, Lisboa, Portugal, 2022.
- [47] Jiayu Yang, Chunhui Yang, Fei Xiong, Feng Wang, Ronggang Wang. Learned low bitrate video compression with space-time super-resolution. In *IEEE*

- Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, pages 1785–1789, New Orleans, LA, United states, 2022.
- [48] Yibo Shi, Yunying Ge, Jing Wang, and Jue Mao. AlphAVC: High-performance and efficient learned video compression. In *European Conference on Computer Vision*, pages 616–631, Tel Aviv, Israel, 2022.
- [49] Zhaobin Zhang, Yue Li, Kai Zhang, Li Zhang, and Yuwen He. Optimized bit allocation for learning-based video compression. In *Proceedings - IEEE International Symposium on Circuits and Systems*, pages 1938–1942, Austin, TX, United states, 2022.
- [50] Kai Lin, Chuanmin Jia, Xinfeng Zhang, Shanshe Wang, Siwei Ma, Wen Gao. DMVC: Decomposed motion modeling for learned video compression. *IEEE Transactions on Circuits and Systems for Video Technology*, 33(7): 3502–3515, 2023.
- [51] Oren Rippel, Alexander G. Anderson, Kedar Tatwawadi, Sanjay Nair, Craig Lytle, and Lubomir Bourdev. ELF-VC: Efficient learned flexible-rate video coding. In *Proceedings of the IEEE International Conference on Computer Vision*, pages 14459–14468, Virtual, Online, Canada, 2021.
- [52] Jerry Liu, Shenlong Wang, Wei-Chiu Ma, Meet Shah, Rui Hu, Pranaab Dhawan, and Raquel Urtasun. Conditional entropy coding for efficient video compression. In *European Conference on Computer Vision*, pages 453–468, Glasgow, United kingdom, 2020.
- [53] Jiahao Li, Bin Li, and Yan Lu. Deep contextual video compression. In *Advances in Neural Information Processing Systems*, volume 22, pages 18114–18125, Virtual, Online, 2021.
- [54] Yung-Han Ho, Chih-Peng Chang, Peng-Yu Chen, Alessandro Gnutti, and Wen-Hsiao Peng. CANF-VC: Conditional augmented normalizing flows for video compression. In *European Conference on Computer Vision*, pages 207–223, Tel

- Aviv, Israel, 2022.
- [55] Xihua Sheng, Jiahao Li, Bin Li, Li Li, Dong Liu, and Yan Lu. Temporal context mining for learned video compression. *IEEE Transactions on Multimedia*, DOI: 10.1109/TMM.2022.3220421.
- [56] Jiahao Li, Bin Li, and Yan Lu. Hybrid spatial-temporal entropy modeling for neural video compression. In *Proceedings of the 30th ACM International Conference on Multimedia*, pages 1503–1511, Lisboa, Portugal, 2022.
- [57] Fabian Mentzer, George Toderici, David Minnen, Sung Jin Hwang, Sergi Caelles, Mario Lucic, and Eirikur Agustsson. VCT: A video compression transformer. In *Advances in Neural Information Processing Systems*, volume 35, New Orleans, LA, United states, 2022.
- [58] Jiahao Li, Bin Li, and Yan Lu. Neural video compression with diverse contexts. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 22616–22626. 2023.
- [59] Amirhossein Habibian, Ties Van Rozendaal, Jakub Tomczak, and Taco Cohen. Video compression with rate-distortion autoencoders. In *Proceedings of the IEEE International Conference on Computer Vision*, pages 7032–7041, Seoul, Korea, 2019.
- [60] Jorge Pessoa, Helena Aidos, Pedro Tomas, and Mario A. T. Figueiredo. End-to-end learning of video compression using spatio-temporal autoencoders. In *IEEE Workshop on Signal Processing Systems*, pages 1–6, Virtual, Coimbra, Portugal, 2020.
- [61] Ren Yang, Fabian Mentzer, Luc Van Gool, and Radu Timofte. Learning for video compression with recurrent auto-encoder and recurrent probability model. *IEEE Journal on Selected Topics in Signal Processing*, 15(2):388–401, 2021.
- [62] Jun Han, Salvator Lombardo, Christopher Schroers, and Stephan Mandt. Deep generative video compression. In *Advances in Neural Information Processing*

Systems, volume 32, Vancouver, BC, Canada, 2019.

- [63] Fabian Mentzer, Eirikur Agustsson, Johannes Balle, David Minnen, Nick Johnston, and George Toderici. Neural video compression using gans for detail synthesis and propagation. In *ECCV*, pages 562–578, Tel Aviv, Israel, 2022.
- [64] Mustafa Shukor, Bharath Bhushan Damodaran, Xu Yao, and Pierre Hellier. Video coding using learned latent GAN compression. In *Proceedings of the 30th ACM International Conference on Multimedia*, pages 2239–2248, Lisboa, Portugal, 2022.
- [65] Tiesong Zhao, Weize Feng, Hongji Zeng, Yiwen Xu, Yuzhen Niu, and Jiaying Liu. Learning-based video coding with joint deep compression and enhancement. In *Proceedings of the 30th ACM International Conference on Multimedia*, pages 3045–3054, Lisboa, Portugal, 2022.
- [66] Ren Yang, Fabian Mentzer, Luc Van Gool, and Radu Timofte. Learning for video compression with hierarchical quality and recurrent enhancement. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 6627– 6636, Virtual, Online, United states, 2020.
- [67] Jianping Lin, Dong Liu, Houqiang Li, and Feng Wu. M-LVC: Multiple frames prediction for learned video compression. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 3543–3551, Virtual, Online, United states, 2020.
- [68] Reza Pourreza and Taco Cohen. Extending neural p-frame codecs for b-frame coding. In *Proceedings of the IEEE International Conference on Computer Vision*, pages 6660–6669, Virtual, Online, Canada, 2021.
- [69] Emilien Dupont, Adam Goliski, Milad Alizadeh, Yee Whye The, and Arnaud Doucet. Coin: Compression with implicit neural representations. *ICRL Neural Compression Workshop*, 2021.
- [70] Emilien Dupont, Hrushikesh Loya, Milad Alizadeh, Adam Goliski, Yee Whye

- Teh, and Arnaud Doucet. Coin++: Neural compression across modalities. *Transactions on Machine Learning Research*, 2022.
- [71] Juan Ramirez and Jose Gallego-Posada. L_0 onie: Compressing coins with L_0 -constraints. *Neural Networks (SNN) Workshop*, 2022.
- [72] Yannick Strumpler, Janis Postels, Ren Yang, Luc Van Gool, and Federico Tombari. Implicit neural representations for image compression. In *ECCV*, pages 74–91, Tel Aviv, Israel, 2022.
- [73] Hao Chen, Bo He, Hanyu Wang, Yixuan Ren, Ser-Nam Lim, and Abhinav Shrivastava. NeRV: Neural representations for videos. In *Advances in Neural Information Processing Systems*, volume 26, pages 21557–21568, Virtual, Online, 2021.
- [74] Zizhang Li, Mengmeng Wang, Huaijin Pi, Kechun Xu, Jianbiao Mei, and Yong Liu. E-NeRV: Expedite neural video representation with disentangled spatial-temporal context. In *ECCV*, pages 267–284, Tel Aviv, Israel, 2022.
- [75] Hao Chen, Matthew Gwilliam, Ser-Nam Lim, and Abhinav Shrivastava. Hnerv: A hybrid neural representation for videos. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 10270–10279., 2023.
- [76] Bo He, Xitong Yang, Hanyu Wang, Zuxuan Wu, Hao Chen, Shuaiyi Huang, Yixuan Ren, Ser-Nam Lim, and Abhinav Shrivastava. Towards scalable neural representation for diverse videos. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 6132–6142, 2023.
- [77] Xin Deng, Wenzhe Yang, Ren Yang, Mai Xu, Enpeng Liu, Qianhan Feng, and Radu Timofte. Deep homography for efficient stereo image compression. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 1492–1501, Virtual, Online, United states, 2021.
- [78] Matthias Wodlinger, Jan Kotera, Jan Xu, and Robert Sablatnig. Sasic: Stereo

- image compression with latent shifts and stereo attention. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, volume 2022-June, pages 651–660, New Orleans, LA, United states, 2022. IEEE.
- [79] Yongqi Zhai, Luyang Tang, Yi Ma, Rui Peng, and Ronggang Wang. Disparity-based stereo image compression with aligned cross-view priors. In *MM 2022 - Proceedings of the 30th ACM International Conference on Multimedia*, pages 2351–2360, Lisboa, Portugal, 2022. ACM.
- [80] Jianjun Lei, Xiangrui Liu, Bo Peng, Dengchao Jin, Wanqing Li, and Jingxiao Gu. Deep stereo image compression via bi-directional coding. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, volume 2022-June, pages 19637–19646, New Orleans, LA, United states, 2022. IEEE.
- [81] Zhenghao Chen, Guo Lu, Zhihao Hu, Shan Liu, Wei Jiang, and Dong Xu. Lsvc: A learning-based stereo video compression framework. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, volume 2022-June, pages 6063–6072, New Orleans, LA, United states, 2022.
- [82] Bo Peng, Yuying Jing, Dengchao Jin, Xiangrui Liu, Zhaoqing Pan, and Jianjun Lei. Texture-guided end-to-end depth map compression. In *Proceedings - International Conference on Image Processing, ICIP*, pages 2386–2390, Bordeaux, France, 2022. IEEE.
- [83] Guo Lu, Tianxiong Zhong, Jing Geng, Qiang Hu, and Dong Xu. Learning based multi- modality image and video compression. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 6073– 6082, New Orleans, LA, United states, 2022.
- [84] Xuhao Jiang, Weimin Tan, Tian Tan, Bo Yan, and Liquan Shen. Multi-modality

- deep network for extreme learned image compression. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 37, pages 1033–1041, 2023.
- [85] Hui Lan, Zhe Ji, Cheolkon Jung, Dan Zou, and Ming Li. Multisensor collaboration network for video compression based on wavelet decomposition. *IEEE Transactions on Circuits and Systems for Video Technology*, 33(1):434–444, 2023.
- [86] Minghui Chen, Pingping Zhang, Zhuo Chen, Yun Zhang, Xu Wang, and Sam Kwong. End-to-end depth map compression framework via rgb-to-depth structure priors learning. In *Proceedings - International Conference on Image Processing, ICIP*, pages 3206–3210, Bordeaux, France, 2022.
- [87] Shuai Yang, Yueyu Hu, Wenhan Yang, Ling-Yu Duan, and Jiaying Liu. Towards coding for human and machine vision: Scalable face image coding. *IEEE Transactions on Multimedia*, 23:2957–2971, 2021.
- [88] Hyomin Choi and Ivan V. Bajic. Scalable video coding for humans and machines. In *2022 IEEE 24th International Workshop on Multimedia Signal Processing, MMSP 2022*, Shanghai, China, 2022.
- [89] Alban Marie, Karol Desnos, Luce Morin, and Lu Zhang. Video coding for machines: Large-scale evaluation of deep neural networks robustness to compression artifacts for semantic segmentation. In *2022 IEEE 24th International Workshop on Multimedia Signal Processing, MMSP 2022*, Shanghai, China, 2022.
- [90] Zhimeng Huang, Chuanmin Jia, Shanshe Wang, and Siwei Ma. Hmfvc: A human-machine friendly video compression scheme. *IEEE Transactions on Circuits and Systems for Video Technology*, pages 1–1, 2022.
- [91] Xiaokai Yi, Hanli Wang, Sam Kwong, and C.-C. Jay Kuo. Task-driven video compression for humans and machines: Framework design and optimization. *IEEE Transactions on Multimedia*, pages 1–12, 2022.

- [92] Wei Jiang, Hyomin Choi, and Fabien Racadé. Adaptive human-centric video compression for humans and machines. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 1121–1129, Vancouver, Canada, 2023.

第 7 章 深度学习在天文学研究中的应用

过去十年间,深度学习得到了广泛发展。它被认为是人工智能(AI)最有前景的方法,引发了整个计算机科学领域的革命。其中最成功的例子包括图像分类、物体检测、识别、跟踪、分割,自然语言处理(NLP)、机器翻译等。最近,我们目睹了深度学习在科学领域的快速发展,例如蛋白质结构预测的 **AlphaFold**、材料科学、医学、农业和能源等领域,催生了一个热门的词汇——**AI for Science (AI4S)**,吸引了一大批科学家和计算机领域的学者们开展交叉学科研究。

深度学习作为一种强大的人工智能技术,已经在各个领域展示出巨大的潜力。本章将重点介绍深度学习在天文学研究中的应用,并展示一些具体的应用示例。天文学作为一门探索宇宙奥秘的学科,面临着海量的观测数据和复杂的数据处理任务。深度学习通过直接学习海量原始数据中的特征,不依赖于先验知识,为天文学研究提供了全新的方法和工具,其主要涉及大数据处理,包括对海量观测数据的过滤和存档、探测/识别物体/事件、预测天文事件、成像观测数据和图像恢复。

深度学习直接从海量原始数据中学习紧凑/压缩特征,无需先验知识,这在先验知识不可用或不可靠的情况下优于手工设计的特征。这种情况在天文学中非常常见,因为大部分物理过程都是未知的。需要指出的是,从原始数据中提取特征在机器学习中是不可或缺的,因为原始数据维度非常高,无法在如此高维数据上建立分类/回归模型。同时,深度学习模型是端到端的优化过程,自动学习数据的特征而无需提取手工特征,降低了物理建模中对先验知识的依赖。此外,深度学习通过使用预训练模型的技术,可以大大降低深度学习训练对于海量数据的需求,降低了深度学习模型在天文领域的应用门槛。另外,通过增加物理约束,能够同时从数据中挖掘出隐含的数据知识和利用已有的先验知识,得到数据加知识联合驱动的模式,相比单纯的数据

和知识驱动，模型更具有适应性和鲁棒性。近期出现的物理启发深度学习模型，把神经网络作为一种微分方程的求解器，可以求解物理中复杂的流体动力学、特别是电磁场方程，进一步提升了深度学习在科学领域的应用层次。

在海量数据基础上的人工智能建模被称为数据驱动的建模，深度学习已经被反复验证为数据驱动建模的最有效技术。经典的深度学习模型，如 AlexNet、VGG、ResNet 和 DenseNet 等，已经在大规模数据库上进行了充分的预训练。对于特定的应用，基于预训练模型，只需要少量样本对预训练模型进行微调就可以了，极大地降低了深度学习在天文数据上的应用门槛。最近，我们看到深度学习在同时利用先验知识和数据驱动方面的流行应用，例如将图像的某种先验作为一个轻量级子网络，嵌入到主干网络中，以实现比单独使用它们中的任何一个更高的效率。

深度学习应用于天文学研究，主要涉及以下几大类的研究：

目标检测：天文学中存在许多需要自动化检测的目标，例如太阳黑子、日珥、活动区和冕洞等。深度学习可以通过训练模型来识别并定位这些目标，极大地提高了目标检测的准确性和效率

时间序列分析：天文学中的时间序列数据包含丰富的信息，例如太阳耀斑、太阳射电流量和日冕物质抛射等。深度学习可以通过对时间序列数据的建模和预测，帮助科学家更好地理解 and 预测这些天文事件。

图像生成：天文学中的图像处理是一项重要任务，包括图像去卷积、去模糊、去饱和、超分辨率和磁场图生成等。深度学习可以通过学习大量的天文图像的数据分布，生成高质量的图像，并提供更清晰、更详细的观测结果。图像生成任务也包括为了消除各种噪声而进行的图像去干扰、去噪和重建任务，特别是在射电观测数据成像中，各种复杂的电磁干扰下图像的重建。

深度学习在天文学研究中的应用带来了许多优势和挑战。其优势在于可以从海量数据中提取特征，无需先验知识，并能够进行端到端的自动化处理。然而，深度学习也面临着数据稀缺和过拟合等问题，需要更多的样本和改进的算法来克服这些挑战。

7.1 深度学习在射电天文成像中的应用

深度学习在射电天文学中具有广泛的应用前景。射电天文学通过观测和分析射电波段的信号来研究宇宙中的物理过程和结构。深度学习在射电天文学中可以应用于以下方面：

信号处理和数据降噪：射电观测数据往往包含噪声和干扰，降低了信号的质量和分辨率。深度学习可以通过学习大量的观测数据，提供高效的降噪算法，从而提高信号的清晰度和可靠性。

信号分类和识别：射电天文学中存在着各种不同的信号源，例如脉冲星、星系、射电晕等。深度学习可以通过训练模型，自动识别和分类不同的信号源，有助于天文学家更准确地理解和研究宇宙中的各种天体现象。

数据分析和特征提取：深度学习可以通过学习射电观测数据，提取其中的关键特征和模式。这些特征和模式可以帮助天文学家发现隐藏在数据中的重要信息，从而推动对宇宙演化和天体物理等方面的研究。

信号重建和成像：射电干涉阵列观测得到的数据通常是不完整和非均匀采样的，需要进行信号重建和成像。深度学习可以通过训练神经网络，实现高质量的信号重建和成像，提高观测结果的准确性和清晰度。

总之，深度学习在射电天文学中的应用为我们更好地理解宇宙提供了强有力的工具。通过利用深度学习算法对射电观测数据进行处理和分析，我们可以揭示更多关于宇宙起源、星系演化和天体物理现象的重要信息，推动射电天文学领域的进一步发展。

7.2 深度学习在恒星观测中的应用

1) 恒星光谱分类:

深度学习在恒星光谱分析中的应用已经取得了显著的成果。恒星光谱是研究恒星物理特性和化学成分的重要工具，而深度学习技术则能够从大规模的光谱数据中提取有价值的信息。

首先，深度学习可以用于恒星光谱的分类和识别。传统的光谱分类方法通常依赖于手工设计的特征提取和模式识别算法，但随着深度学习的发展，可以直接从光谱数据中学习到更具有判别力的特征表示。通过使用卷积神经网络（CNN）递归神经网络（RNN）等深度学习模型，可以有效地对光谱数据进行分类和识别，例如确定恒星的光谱类型、光谱线特征等。

其次，深度学习可用于恒星参数的估计和预测。恒星参数如有效温度、表面重力、金属丰度等对于了解恒星的物理性质和演化过程非常重要。深度学习模型可以通过对大量恒星光谱数据进行训练，学习到恒星参数与光谱之间的复杂映射关系，并能够对未知恒星的参数进行准确预测。

此外，深度学习还可应用于恒星谱线的分析和特征提取。恒星光谱中的吸收线和发射线包含了丰富的信息，反映了恒星的化学组成和动力学过程。深度学习模型可以自动学习到光谱线的特征表示，对光谱进行降噪、去除连续谱背景、检测和量化线强度等处理，从而提高光谱分析的精度和效率。

综上所述，深度学习在恒星光谱分析中具有广泛的应用前景。通过深度学习模型对光谱数据进行学习和建模，可以实现更精确的光谱分类、恒星参数估计和谱线分析，推动恒星物理学和天体化学的研究进展。

2) 深度学习寻找宽距离双星

双星系统在天文学中扮演着重要角色，对于理解恒星形成、演化

和动力学等过程具有重要意义。传统的双星检测方法通常基于观测数据和模型假设，但随着深度学习技术的快速发展，利用深度学习模型对双星进行自动检测成为一种新的研究方向。国家天文台吴优等人 [111] 论述了深度学习在双星检测中的应用，探讨了其在提高检测准确性和效率方面的潜力和优势。

双星系统由两颗相互绕绕旋转的恒星组成，对于了解恒星的物理性质、轨道参数和动力学特征具有重要意义。传统的双星检测方法依赖于特定的观测数据和建模假设，例如径向速度变化、光度变化等。然而，这些方法可能受到噪声、数据限制和复杂性的影响，且需要耗费大量的人力和时间。深度学习作为一种数据驱动的方法，具有从大规模数据中学习特征表示和自动分类的能力，为双星检测提供了新的可能性。[111] 采用深度卷积神经网络 (CNN) 作为深度学习模型，利用双星系统的光度曲线数据进行训练和检测。首先，将光度曲线数据进行预处理和标准化，以确保数据的一致性和可比性。然后，构建一个多层的 CNN 模型，通过卷积和池化操作提取光度曲线中的特征，并通过全连接层进行二分类（双星或单星）决策。在训练过程中，使用已知的双星和单星样本作为监督信号，通过反向传播算法优化网络参数。作者从观测数据库中获取了大量的双星和单星样本，将其分为训练集和测试集。通过对 CNN 模型进行训练和验证，我们得到了在双星检测任务上的良好性能。与传统方法相比，深度学习模型能够更准确地区分双星和单星，并具有较强的鲁棒性和泛化能力。该方法充分利用了空间望远镜的点扩散函数 (PSF)，可以很好的分辨 0.1-2 个像素内的双星。他们考虑了不同的噪声分布，使模型具有较好的鲁棒性和泛化能力。将该方法应用到未来 CSST 空间巡天中，可以极大的增加宽双星的观测样本，使科学家能够高效的利用统计方法研究它们的分布与物理参数。

在 [110] 中，作者通过深度卷积网络寻找经典的 Be 星，利用

ResNet-18 层网络在 LAM-OST 中分辨率光谱数据中寻找经典 Be 星。首先根据 $H\alpha$ 的特征构建了 Be 星和非 Be 星光谱的训练样本,挑选了 1042 个 Be 星候选光谱和 1042 个非 Be 星候选光谱,并在 6530-6590Å 范围内生成相应的光谱图,送入到网络中训练。然后,通过文献比对等筛选过程确认了新发现的经典 Be 星。最后根据 Gaia EDR3 的天测数据计算它们的切向速度来确认是否是超高速星。

3) 中国空间站 CSST 望远镜

CSST 是 2 米口径的多功能光学设施,成像分辨率高、天区覆盖面积大、波长覆盖范围广。兼具多色成像与无缝光谱观测,拥有极强的发现暗弱天体、新天体、新现象的能力。CSST 预计 2024 年前后发射,而针对 CSST 的数据及科学任务已经开展,[111]针对 CSST 的成像及成像处理任务、双星系统检测做了充分的准备。

CSST 是我国空间站巡天空间望远镜,其具有如下特定:

1) CSST 的巡天中会获得大量的测光图像,包含数十亿的天体,也会有许多 "异常 "(Anomaly)。其中有些是由于数据本身的缺陷,有些是由于目标本身的特殊性。找到这些数据 "异常 "对于改进数据处理和发现稀有天体非常重要。可以使用对抗生成神经网络 (GAN) 进行学习重构测光图像,而无法复原的天体就会作为 "异常 "被检测出来。

2) CSST 的巡天中还会获得大量的光谱数据,光谱观测每个物体都有不同的测量特征和目标变量,可以通过人工智能中的分类算法对光谱进行特征提取并分类,再应用回归算法分析目标天体的物理参数,最后可以利用这个模型来预测未知的天体的物理参数。

3) CSST 所携带的系外行星成像星冕仪具有在可见光至近红外波段对系外行星进行高对比度成像观测的能力,通过直接成像探测类太阳光谱型恒星周围的成熟系外行星。在寻找 "可能宜居 "的系外行星时,需要先找到类太阳恒星(F, G, K 光谱型) 这样恒星活动稳定的恒星。

可以通过深度学习技术的目标检测和分类等算法在大量数据中筛选和识别中找到类太阳恒星，再通过区分行星引起的信号和由恒星活动引起的信号，发现系外行星，加深我们对恒星周围的行星系统的理解。

4) 通过深度学习模拟 CSST 的星系图像，可以作为数据库并完善数据处理过程。

5) 红移是一个关键的宇宙学参数，通过深度学习方法，利用 CSST 所观测的星系的宽带或中带测光来估计它们的红移。

CSST 是天基望远镜，尽管最大程度减少了大气扰动的影响，但观测质量还是受仪器噪声、处理过程的人为因素或其他天文现象（如宇宙线）的影响，掩盖了我们所观测的目标信号，造成信息缺失，此时需要建立具有不改变信号本身的生成和重构模型对观测数据恢复，因此深度学习强大的生成能力能够用于 CSST 成像及成像处理。

7.3 深度学习探究天文事件的物理机制

太阳爆发先兆及触发机制的因果推理：太阳爆发活动的先兆及触发机理的研究至关重要，从应用角度来讲，该研究是太阳爆发预报建模的基础，从科学探索方面来讲，该研究是揭示太阳爆发机理的关键。

传统太阳物理研究从物理机制出发研究太阳爆发机理，提出了耀斑模型、日冕物质抛射模型等，主要是基于太阳大气加热、磁场模型、磁重联、磁能输运和转换等。物理模型应用于太阳爆发活动预报，在时间提前量、普适性方面不足。随着机器学习技术的进步以及太阳活动大数据的积累，大数据基础上的统计预报成为当前的主流，但统计预报关注事物之间的相关关系而不能正确刻画事物之间的因果关联，存在解释性差、确定性难以保障等问题。因此，从因果推理出发，寻求太阳爆发的先兆因子和触发机理，有望从根本上揭示太阳爆发之谜。

目前，因果推理在深度学习建模领域并不常用，而更多的是统计学的一个分支。Pearl 在《The Book of Why: The New Science of Cause

and Effect》一书中将因果关系分为三个层次（他称之为“因果关系之梯”）。自底到顶分别是：关联、干预、反事实推理。最底层的是关联（Association），也就是我们通常意义下所认识的深度学习在做的事情，通过观察到的数据找出变量之间的关联性。这无法得出事件互相影响的方向，只知道两者相关，比如我们知道事件 A 发生时，事件 B 也发生，但我们并不能挖掘出，是不是因为事件 A 的发生导致了事件 B 的发生。第二层级是干预（Intervention），也就是我们希望知道，当我们改变事件 A 时，事件 B 是否会跟着随之改变。最高层级是反事实（Counterfactuals），也可以理解为“执果索因”，也就是我们希望知道，如果我们想让事件 B 发生某种变化时，我们能否通过改变事件 A 来实现。

因果推理是根据一个结果发生的条件对因果关系得出结论的过程。研究因果关系最大的一个目标，就是找出事物之间真正的因果关系，去掉那些混杂的伪因果关系。在深度学习的框架里，已有相关工作研究了混杂因素的分离和因果推理的工作。

7.4 深度学习在太阳物理研究中的应用

天文学是一个庞大的学科，研究的目标包含各个尺度、距离、大小的天体，其中太阳是离我们人类最近的一颗恒星，也是能够被我们直接成像的一颗恒星，对于太阳的研究可以类比到其他恒星的研究。由于作者更多的工作是关于太阳观测数据的处理、太阳观测数据成像和太阳活动预报建模等方面，因此下文将着重就这些方面展开论述。

太阳活动的短时标变化，可能会引起日地空间环境的剧烈扰动，引发灾害性的空间天气，进而影响到高度依赖于高技术系统的现代人类。太阳质量占整个太阳系质量的 99.8%，处于绝对的主导地位，被认为是空间天气的源头；同时，太阳的观测数据和太阳活动预报的结果是其他空间天气预报模式的输入。因此，太阳活动预报无论是在太

阳物理研究还是空间天气应用领域都变得非常重要。

目前，国际上已经实现了太阳多波段常规监测，并积累了海量的太阳观测数据；同时，计算算力大幅提升和算法改进为太阳大气的建模提供了更有力的条件。海量观测数据为太阳活动预报提供了前所未有的机遇，同时也对我们的模型和算法提出了巨大的挑战——如何高效地利用海量太阳观测数据提高太阳活动预报模型的性能。令人振奋的是，当前在人工智能领域发展出了一系列大数据处理和数据驱动的建模方法，特别是 2006 年兴起的深度学习方法，为海量数据的信息提取、知识发现以及建模提供了强大的工具。因此，以太阳观测大数据为基础，利用人工智能技术进行数值化预报建模或数值驱动的预报模型成为现阶段的研究热点。人工智能作为处理大数据的一个强大的工具，已经被成功地应用于视觉、语音处理、自然语言处理[49]等技术领域。其在太阳活动预报领域也越来越受到人们的关注，但还远未达到系统的、成熟的阶段。

目前，太阳探测手段已经发生了很大的变化，国内外大型地面太阳观测设备和众多空间卫星计划推动太阳观测进入了一个全时段、全频段、高时间/空间分辨率和高频谱分辨率观测的新时代，我们已经从过去的的数据缺乏时代进入了现在的数据过剩时代。在这种情况下，从海量数据中高效地挖掘有价值的信息，并充分利用这些信息，改造和开发新的数据驱动的太阳活动预报模型成为当务之急。

国家天文台太阳活动预报中心（SAPC）是国内从事太阳活动预报研究的领头羊，主要从事太阳活动短期（太阳耀斑、太阳 F10.7 射电流量、质子事件和地磁活动）、中期（太阳黑子相对数平滑月均值、太阳 X 射线耀斑活动水平）和长期（太阳活动周的黑子相对数及 F10.7 平滑月均值）预报，为国家空间安全、卫星运行、航空航天等重大空间任务提供空间环境保障服务。同时，该中心也是国际空间环境服务组织（ISES）最早加入（1990 年）的成员之一，作为中国区域警报

中心 (RWC-China) 的总部, 肩负着为国际同行提供数据交换和预报模型服务的使命。

在人工智能技术应用领域, 国家天文台王家龙等人早在 2000 年前就利用神经网络模型预报质子事件。国家天文台李蓉、王华宁等人采用支持向量机、神经网络构建了短期耀斑预报、质子事件和 F10.7cm 射电流量预报模型。国家天文台黄鑫等人采用卷积神经网络构建了基于活动区磁图和多波段图像的太阳耀斑预报模型, 实现滚动的太阳 M 级及以上耀斑有无预报。国家天文台徐龙等人在基于深度学习的太阳射电频谱图分类方面进行了广泛、深入的研究, 尝试了若干深度学习模型; 采用深度学习完成了 STEREO EUV 图生成磁图、综合孔径成像去卷积以及色球 H α 和 HMI 磁图的相互转换; 采用深度学习开展了太阳活动信息的挖掘, 提取日面活动区、黑子、暗条、冕洞等重要信息, 构建了大型太阳活动数据库。国家天文台郭晶晶等人使用深度学习开展了磁场定标的工作。

基于 McIntosh 分类, NOAA 空间环境实验室和 Colorado 大学联合开发了一个专家系统 Theo 来预报太阳耀斑。利用与 Theo 相同的预报因子, Bradshaw 等人使用人工神经网络技术建立了耀斑预报模型, 可与 Theo 达到相同的预报精度。英国 Bradford 大学的 Qahwaji 和 Colak[61]应用神经网络和支持向量机, 以 McIntosh 分型和太阳黑子数为预报因子, 建立了混合耀斑短期预报系统。Baena 和 Morales 应用行为模式学习方法挖掘耀斑产生和活动区数据之间的关系。Leka 和 Barnes 对从光球磁场提取的特征参量进行了研究, 并应用 Fishers 线性判别预报耀斑发生。Song 等人选取总磁通、强梯度中心线长度和总磁场能量分布参量, 应用 logistic 回归预报耀斑。基于同样数据, Yuan 等人结合了 logistic 回归和支持向量机相建立耀斑预报模型。Ahmed 等人选取了多个和耀斑相关性强的光球磁场参量, 由特征选择算法挑出有效因子, 应用神经网络方法预报耀斑。谢菲尔德大学 Jiajia

Liu、Robertus 等人基于 182 个对地有影响的部分或全晕 CME，采用 SVM 算法估计 CME 到达时间，预测误差约为 5.9 小时，优于传统业务预报模型。

日冕物质抛射是一种剧烈的太阳爆发活动，其产生的高速等离子体云到达地球附近，会对地球磁场、等离子层和运行在其中的卫星造成极大的危害。近年来，对于 CME 日地空间传播、到达地球时间以及对地影响效应评估的关注越来越高。由于 CME 的光学薄特征，其中的自由电子与太阳光之间的汤姆逊散射投影到日冕仪的 CCD 上，得到的是二维投影积分图形。为了预报 CME 的对地有效性，需要首先将二维图形进行三维重建，然后将三维重建 CME 作为磁流体动力学（MHD）模拟的输入，来模拟 CME 在日冕和日地空间传播的情况。对于 CME 到达时间和对地影响预报，则可以通过 MHD 模拟的动态演化过程或基于历史数据建模的机器学习方法来研究。国家天文台戴幸华等人研究了 CME 三维重建，提出了一种使用 GL98 解析模型拟合 CME 观测数据，重构 CME 内部磁场及等离子体分布的三维重构算法（简称 GLF），并将其与 PRM、GRM 算法进行正、反演结合，获得比单一方法更好的重构效果；同时，以重构的三维 CME 作为 SWMF（Space Weather Modeling Framework）输入，实现 CME 行星际传播的 MHD 模拟。该工作相对于经典的 Cone+ENLIL 模型，不但包含了 CME 内部磁场及等离子体分布，而且更真实地模拟 CME 在日地空间的传播过程。NASA 的空间天气研究中心（SWRC）维护着一个 CME 到达时间预报的 scoreboard，世界各地的空间天气预报组织和研究者将其算法上传到指定的网站，等待未来 CME 发生时来验证。

海量的太阳观测数据为我们提供了丰富的资料，但是天文领域中数据本身的价值密度很小，非常需要开展数据挖掘以提取重要的研究资料。国家天文台徐龙等人使用深度学习方法，开展了如下太阳海量

观测数据挖掘和预报建模的研究。

自动化的海量观测数据的分类、归档和筛选。太阳观测设备每天采集到大量的观测数据，对于这些数据的校准、筛选、成像等初步分析通常需要人工干预。在天文大数据时代，这种方式不仅消耗了大量的人力，而且数据处理的效率低，严重阻碍了数据的快速归档和后期的深入分析。如何实现观测数据快速、高效的自动分类和归档是太阳观测大数据急需解决的首要问题。国家天文台徐龙等人针对太阳射电频谱图分类，讨论深度学习在大数据分类、归档任务中的应用，提出了基于深度置信网络 (Deep Belief Network, DBN)、多模态网络 (Multimodal Network) 和深度多模态网络 (Deep Multimodal Network, DMN)、卷积神经网络 (Convolutional Neural Network, CNN) 和长短时记忆网络 (Long-Short Time Memory, LSTM) 的太阳射电频谱图分类模型。相比传统的浅层分类模型，例如 SVM，深度学习能够根据具体任务目标从训练数据中自动提取特征，是一种端到端的模型，从模型优化角度讲可以获得最优的效果。

使用深度学习方法挖掘海量观测数据中的有价值信息及关联分析：传统的天文学研究着眼于基础理论分析和研究，借助于数学物理方法进行物理过程的推演。进入大数据时代之后，数据本身就是模型，即从数据本身出发、利用大数据处理的算法和工具，对数据进行分析研究，从中获得新的认识、新的发现。特别是对海量太阳多波段频谱成像观测数据的分析，可能获得有关太阳大气活动现象的本质性规律。

数据挖掘涉及的任务通常包括异常检测、关联规则学习、聚类、分类、回归和汇总等。国家天文台徐龙等人，借助数据挖掘技术，进行太阳多波段频谱成像观测数据的分析，从中获取数据之间内在的、隐含的关联关系，发现数据中蕴含的太阳活动规律。他们借助于深度学习模型，从太阳的紫外、极紫外观测生成光球的磁图，探索二者之间的关联，并用于太阳远端图像的生成，即从 STEREO 卫星的 EUVI

观测生成磁图，成果发表在 *ApJS* (2022) 期刊上。由于太阳多波段数据代表的太阳表面不同的高度，因此对于多波段数据的关联分析，可以较全面地获得一些太阳活动的起源、发展和演化过程，更好地揭示其背后的物理机制。通过对多波段数据的信息挖掘，获得太阳爆发活动在各个波段的联动性、因果关系等，为太阳活动预报提供可能的依据。

数据驱动的太阳爆发活动预报建模：使用太阳观测多波段的、海量的观测数据，借助深度学习模型，能够摆脱现有物理机制认识对预报建模的限制，获得更加稳定、适应性更强的预报模型。我们使用深度学习方法，从海量的观测数据中挖掘有效的预报模式，把从数据中学习到的预报模式与专家提取的物理预报模型进行比较融合，形成预报模式的自动提取机制，提高了太阳爆发预报模型的准确性。

建立了首个太阳耀斑深度学习预报模型 (*ApJ*, 2018)，首次实现了数据驱动的太阳耀斑先兆模式挖掘，该成果被 SDO 科学掘金栏目收录，获得美国天文学会与英国物理学会出版社 2021 年“中国高被引论文奖”。进一步，探索了磁图分辨率对基于深度学习的太阳耀斑预测模型的影响，取得了磁图分辨率对于深度神经网络不敏感的重要结论，该成果发表在 *ApJ* (2022) 上；并从 SDO/AIA 的多波段图像出发，采用深度学习模型挖掘多波段图像与太阳耀斑的关联，构建了新的耀斑预报模型，结果已投稿 *ApJ*。发布了大型的太阳耀斑数据库(覆盖第 23, 24 太阳活动周，长达 20 年)，该数据支持了 2020 年“第一届空间环境人工智能预警挑战赛”中的太阳耀斑预报赛道。

7.5 深度学习在太阳耀斑预报建模中的应用

7.5.1 太阳耀斑

太阳耀斑(solar flare)是太阳大气中剧烈的活动现象之一，通常指用 $H\alpha$ 单色光看到的太阳色球层中的突然增亮现象，也称为色球爆发。早在 1859 年 9 月 1 日，英国学者 Carrington 和 Hodgson 第

一次用肉眼在日冕的大黑子群附近观测 到一个白光耀斑。Carrington 手绘的 1859 年 9 月 1 日大耀斑的白光观测图像如图所示。这种耀斑起源于太阳光的连续谱，属于太阳大气中最强烈的耀斑。这次剧烈的耀斑爆发在地球上引起了强烈地磁暴和大范围的极光，对地球电力系统 造成严重危害。对耀斑观测和研究的全面展开是基于 1930 年 Lyot 发明了干涉偏振滤光器，通过太阳色球的 $H\alpha$ 谱线(6562.8 埃)对太阳进行观测，发现色球结构非常复杂，且在活动区中常有强烈的闪光出现。Babcock 的磁像仪和一些重要的太阳望远镜的创造和制造为太阳耀斑研究提供了大量的数据基础，这促进了耀斑研究的快速发展。在 20 世纪 70 年代之前，虽然已经积累了一些观测数据，但与太阳耀斑有关的研究主要集中在光学波段，即研究“低温耀斑”现象。研究工作主要是通过单色光观测，研究太阳耀斑的形态和运动，通过与磁图的对比来研 究太阳耀斑和磁场之间的关系，通过光谱观测来研究太阳耀斑谱线的加宽机制，确定太阳耀斑的物理参数等。

耀斑的分类：光学耀斑(色球耀斑)的强度评判基于耀斑面积的大小，国际上采用耀斑亮度达到极大值时的面积作为耀斑级别的主要依据，同时定性的描述耀斑的极大亮度。根据耀斑的 $H\alpha$ 单色光面积大小，光学耀斑分为 5 级，分别以 S、1、2、3、4 表示。在级别后加 F、N、B 分别表示该光学耀斑在 $H\alpha$ 线中极大亮度是由弱到强。例如 3B 表示面积在 1850 到 3650 百万平方公里之间的很明亮的耀斑。所以最大最亮的耀斑是 4B，最小最暗的是 SF。随着对耀斑进行 X 射线的观测，国际天文联合会决定按地球附近测量到的 1-8，分为 A、B、C、M、X 五级，所释放能量依次增大，分别对应流量为小于 10^{-8} ， 10^{-7} ， 10^{-6} ， 10^{-5} ， $10^{-4}J/(m^2 \cdot s)$ 。耀斑等级划分标准如表 7-1 所示，其中平方度等于太阳表面 $1.473 \times 10^8 km^2$ 。各等级后面的数值表示 X 射线峰值流量的具体数值，例如 X3.4 表示耀斑 X 射线流量为 $3.4 \times 10^{-4}J/(m^2 \cdot s)$ 。

7.5.2 耀斑的性质

耀斑是一种很复杂的动力学过程，耀斑爆发的往往同时伴随一系列的高能辐射。不同的耀斑具有不同的形态、辐射和演化历程。耀斑是由高能粒子(脉冲部分)和加热等离子体(渐进部分)的光谱特征组成的混合。软 X 射线发射是由等离子体的热分布引起的，因此会逐渐形成，而 X 射线光谱的非热尾部(>10keV)是由高能粒子减慢时的韧致辐射造成的。通常存在 3 个基本阶段：(1) 前相，持续几分钟至几十分钟，此时，软 X 射线，EUV 和射电辐射开始增强， $H\alpha$ 增亮；(2) 闪相，阶段通常持续 5 分钟(但有时为 1 小时)，它的特点是软 X 射线和 $H\alpha$ 发射的强度和面积迅速增加，太阳色球耀斑从开始变亮迅速发展至极大亮度，而日珥迅速爆发，快速粒子的加速继续进行，日冕等离子体被加热到数千万度。此时，会出现脉冲相，即硬 X 射线和微波爆发常表现为脉冲型的突然增强并在几分钟后迅速衰减。有些耀斑没有脉冲相，属于缓变型耀斑；(3) 缓变相 (主相)，主相期间耀斑附近的等离子体被迅速加热到上千万摄氏度，各波段峰值时间接近，持续几十分钟至两个小时，伴随 $H\alpha$ 和软 X 射线强度缓慢减弱。

表 7-1 耀斑等级分类

经投影改正后的面积长度单位/($10^{-6} R_{\odot}$)	平方度	级别	软 X 射线分类
<100	<0.26	S	C ₂
100-250	2.07-5.15	1	M3
250-600	5.16-12.4	2	X1
600-1200	12.5-24.7	3	X5
>1200	24.8	4	X9

耀斑中释放的能量从亚耀斑中的 $10^{22}J$ 到 $6 \times 10^{25}J$ 或更多。对于一个大的爆发耀斑，来自耀斑的辐射和伴随的日冕物质抛射的动能是相似的，总辐射的大部分出现在主相，其中少数($3 \times 10^{24}J$)出现在脉冲阶段。大部分是可见和紫外波段连续谱，在 $H\alpha$ 处特别明显；在软 X 射线中通常只有($2 \times 10^{24}J$)。额外的快速粒子能量和热传导有

助于光辐射和紫外线辐射。太阳高能粒子在日冕物质抛射驱动的激波下也会被有效地加速，并且可能拥有日冕物质抛射能量的 15% ($3 \times 10^{24}J$)。

7.5.3 耀斑预报建模

太阳耀斑是发生在太阳大气局部区域的一种最剧烈的爆发现象，在短时间内释放大量能量，引起局部区域瞬时加热，向外发射各种电磁辐射，并伴随粒子辐射突然增强。它是引起灾害性空间天气事件的罪魁祸首，特别是对于高技术系统具有巨大的破坏作用，例如导致磁暴、电离层暴，破坏卫星、无线电通讯干扰等。因此，对于太阳耀斑的预报尤为重要。在以往的研究中，大多数采用物理模型和浅层的机器学习方法，取得了一定的成果但局限较大，随着深度学习技术的进步，被广泛应用于耀斑预报，获得了巨大的成功。

太阳爆发活动是空间天气事件的源头，由太阳爆发产生的电磁辐射、高能粒子、高速等离子体云对地球磁层、电离层和中高层大气产生强烈影响。在空间天气事件中，太阳大气、行星际空间、地球磁层、电离层和中高层大气形成一个因果链。

太阳的空间观测不受地球自转和大气的影 响，可以实现太阳的连续、多波段观测。对太阳进行连续的多波段观测是太阳活动预报的基础。太阳的空间观测始于上个世纪四五十年代，美国海军实验室(NRL)利用 V-2 火箭携带的仪器对太阳紫外和 X 光辐射进行观测。60 年代中后期，美国航天局 NASA 发射了多颗“轨道太阳观测台”(OSO 系列卫星)，对太阳进行紫外和极紫外观测。进入 20 世纪 70 年代，空间科学技术的发展极大的促进了太阳领域的研究，例如 YOHKOH 卫星和 Skylab 卫星都取得了丰富的观测结果。到目前为止，国际上已经发射多颗太阳观测卫星（如 SOHO，SDO 等）对太阳进行连续的多波段观测。这些高时间分辨率、高空间分辨率的观测设备积累了海量的太阳观测数据，例如 SDO 卫星从 2010 年发射以来，每天在

10 个波段观测到超过 70,000 张连续的太阳图像，每天产生的数据超过 1.5 TB。海量的太阳监测数据为太阳活动预报提供了前所未有的机遇。如何利用海量的太阳观测数据提高太阳活动预报模型的性能成为一个重要的问题。

深度学习在诸多应用领域取得巨大成功[68]。在图像识别方面，基于卷积神经网络（Convolutional Neural Network, CNN）的深度学习方法取得了一系列的成功。从 2012 年 Krizhevsky 等人[113]首次将卷积神经网络应用于 ImageNet 挑战赛就取得第一的佳绩，到 ILSVRC2014 挑战赛中几乎所有的参赛队伍都采用了 CNN 及其变形方法，并将图像分类识错率降低到 6.7%，这说明 CNN 在图像识别领域具有巨大优势。在动态行为识别方面，Baccouche 等人[115]提出一种时序的深度学习模型，可在没有任何先验知识的前提下学习分类人体行为，该模型的测试精度达到 94.39% 优于其他已知模型。长短期记忆模型（Long Short-Term Memory, LSTM）是目前最为成功的一种递归神经网络模型，它解决了梯度消失和梯度爆炸问题，在处理时序问题,如机器翻译[116]、语音识别[117]以及视频识别与分类[118]等方面取得了显著突破。深度学习通过对海量数据进行学习，来自动挖掘和提取文本、语音和图像等数据中蕴含的本质特征，进而有效的实现模式识别，这是人工智能发展中的突破性进展。因此，从人工智能领域发展出的深度学习方法为我们提供了自动提取海量太阳多波段观测图像的特征、发现太阳爆发活动的规律，进而改善太阳活动预报性能的机会。

随着人工智能技术的迅速发展，越来越多的智能方法被应用到太阳活动预报中。英国 Bradford 大学的 Qahwaji 和 Colak[119]应用神经网络和支持向量机算法建立了混合耀斑短期预报系统，以 McIntosh 分型和太阳黑子数为预报因子，首先利用支持向量机预报是否有耀斑发生，如果有耀斑发生，再利用神经网络预报发生耀斑的级别是多大。

Baena 等人[120]应用行为模式学习方法挖掘耀斑产生和活动区数据之间的关系，这个关系以规则的形式表示出来，比较容易理解。Song 等人[121]选取总磁通、强梯度中心线长度和总磁场能量分布参量，应用 logistic 回归预报耀斑。基于同样数据，Yuan 等人[122]采用 logistic 回归和支持向量机相结合建立耀斑预报模型，首先使用 logistic 回归预报耀斑发生级别的概率，再将输出的概率作为输入，应用支持向量机预报耀斑级别。Ahmed 等人[123]选取了多个和耀斑相关性强的光球磁场参量，由特征选择算法挑出有效因子，应用神经网络方法预报耀斑的发生。

在国内，很早就开始利用人工智能方法进行太阳爆发事件预报建模的研究工作。王家龙[124]等人利用神经网络模型预报质子事件。李蓉等人[125][126][127]应用支持向量机方法建立了一个耀斑短期预报系统，并得到良好的预报精度。王华宁等人[128]利用从光球磁图中提取的纵向磁场最大水平梯度、中性线长度和孤立奇点个数，使用多层感知器建立了一个耀斑短期预报系统，预报精度能够达到有长期预报经验的预报人员的水平。于达仁、黄鑫等人[129][130][131]采用平滑窗技术建立了耀斑动态模型，并详细地比较了静态模型和动态模型的预报性能。结果表明，采用动态模型对耀斑发生的报准率和耀斑未发生的报准率都有大幅度显著提高。黄鑫等人[132][135][133][134]应用几种机器学习方法建立了耀斑预报模型，结果显示了磁场数据时间序列演化信息在耀斑预报中的有效性。

上述预报建模方法（多层感知机、支持向量机、决策树等）在人工智能方法中统称为“浅层学习”，这是为了与 2006 年发展起来的深度学习方法做区分。浅层学习方法在有限计算单元的情况下对复杂函数的表示能力有限，因此在复杂的预报建模问题中，其建模能力受到一定的制约。深度学习通过将输入数据进行分布式表示，并通过一种深层非线性网络结构扩展模型对复杂问题的逼近能力，在海量训练数

据的支持下,自动学习对象的特征表示,从而最终提升预测的准确性。在大数据时代,更加强大的深度模型能深刻揭示海量数据里所承载的复杂而丰富的信息,进而做出更精准的预报。

黄鑫等[136]在收集 SOHO/MDI 和 SDO/HMI 大部分活动区磁图数据的基础上,训练出首个太阳耀斑预报的深度学习模型,实现了太阳活动区磁图预报模式的自动提取,并给出预报模式的物理解释。该工作显示出深度学习方法在太阳爆发事件预报建模中蕴含着巨大的潜力。通过长期积累,作者及其团队成员已经在基于深度学习的大数据分析研究中积累了充分的研究经验,并且收集了研究所需的大量观测数据。[136]搜集了 SOHO/MDI 卫星从 1996 年至 2010 年所有太阳活动区视向磁场观测数据以及 SDO/HMI 卫星从 2010 年至 2015 年所有太阳活动区视向磁场数据,并对两颗卫星的观测数据进行同化,形成一个时间跨度接近 20 年的太阳活动区观测数据集。利用深度学习方法中的卷积神经网络模型,从磁图数据中自动抽取太阳耀斑预报模式,并建立预报模型。该模型在预报窗口分别为 6 小时、12 小时、24 小时、48 小时和耀斑阈值分别设为 C 级、M 级、X 级时,都取得了良好的预报效果。该项工作验证了深度学习方法的预报模式抽取能力。

7.5.4 提取耀斑先兆特征揭示耀斑发生的触发机理

活动区光球磁图物理特征:太阳是一个剧烈活动的天体,太阳的剧烈活动与太阳磁场密切相关,太阳的爆发现象如太阳耀斑和日冕物质抛射受到太阳磁场的支配。起初的研究主要针对太阳黑子的形态学特征,McIntosh[137]提出黑子群的 McIntosh 分型,用以刻画太阳黑子的复杂性。在统计黑子 McIntosh 分型与太阳耀斑产率间关系的基础上,建立了太阳耀斑预报的专家系统,实现了太阳耀斑的短期预报。之后,Atac [138]对黑子形态学分型(McIntosh 分型)和黑子的磁场分型(Wilson 山分型)进行了比较研究,并指出在 McIntosh 分型中

具有 Dki 或 Eki 分类的黑子, 在 Wilson 山分型中具有 δ 分类的黑子更容易产生大耀斑。太阳大气中等离子体的稳定性很大程度上受到太阳磁场的制约和影响。太阳耀斑和日冕物质抛射等爆发现象, 直接受太阳磁场的支配。因此, 太阳活动区的磁场特性得到广泛地研究 [139][140][141][142][143]。利用太阳活动区光球矢量磁场观测, Leka 和 Barnes[144][145]研究了太阳活动区磁场水平梯度, 垂直电流, 电流螺度等多个物理特征量与耀斑间的关系, 并指出单一的物理参量不足以有效地预测太阳耀斑的发生。因此, 我们一方面需要进一步分析活动区的磁场特性, 另一方面需要提取活动区日冕极紫外波段成像观测特性。综合考虑活动区的多波段观测特性, 形成一组有效的预报因子。

活动区日冕多波段图像特征提取: 传统耀斑预报都是在光球磁图上提取磁场参数或深度特征, 然后构建耀斑预报的分类模型。而耀斑真正发生在日冕区域, 真正与耀斑相关的应该是日冕磁图, 然而日冕磁场无法直接测量, 因而没有被使用来构建耀斑预报模型。

虽然没有日冕磁场测量, 但是 SDO/AIA 等空间卫星却提供了海量的高质量的日冕紫外极紫外观测图像, 很有可能这些观测数据中隐含着潜在的有价值的信息, 包括耀斑预报的信息。之前人们之所以忽略了这些宝贵的观测资料来构建耀斑预报模型, 可能是由于缺乏一种有效的大数据信息挖掘的工具, 而现在有了深度学习这个强大工具的加持, 非常有可能直接从日冕观测出发, 探测耀斑爆发的前兆, 进而构建其预报模型, 且发现真正的耀斑爆发的触发机理。

Sun 等人[146]研究在多个模型下, 分析和验证了各个波段与耀斑关联关系, 并且使用 voting 方法得出多波段联合的建模能够获得更佳的性能。从可视化结果来分析, 发现网络更加关注活动区磁绳和磁绳足点, 这也跟人们的常识相符。

为了模型的训练, [146]收集和整理 SDO/AIA 从 2010-2016 活动

区的多波段图像，并参考活动区定义的坐标，从全日面图像中提取了相应的活动区图像，构建了大型的数据库，数据分布情况如表 7-2。

表 7-2 多波段活动区数据的分布 (94、131、171、193、211、335 波段)

年代	负样本	正样本
2010	2545	41
2011	4424	633
2012	4578	699
2013	2930	840
2014	4203	1106
2015	4166	759
2016	4226	31

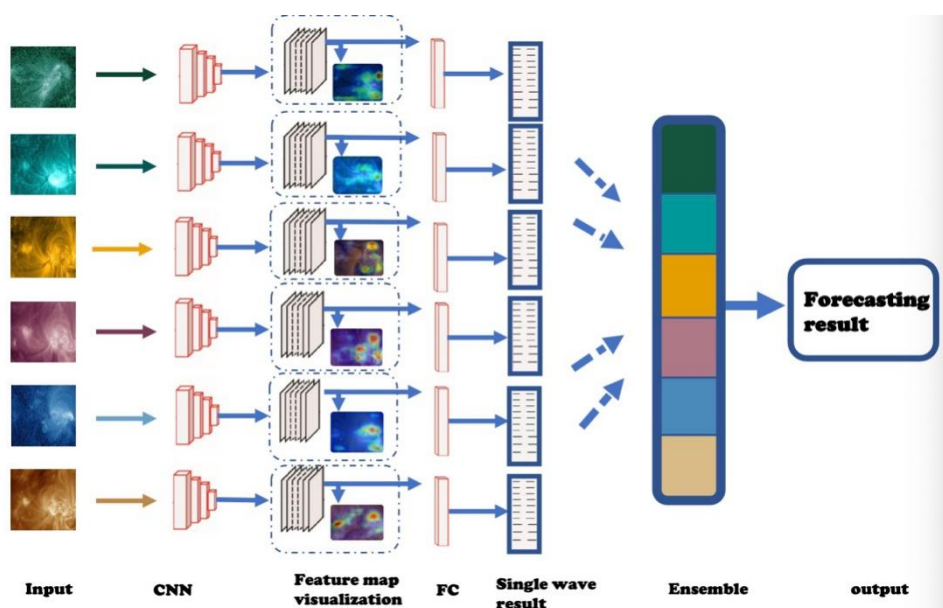


图 7-1 基于多波段日冕观测图像的耀斑预报算法框架 (日冕紫外极紫外多波段输入，采用深度学习模型提取深度特征，并综合在一起作为分类器输入)




图 7-2 神经网络的热力图（展示了模型的关注点为磁绳及磁绳足点）

太阳耀斑和日冕物质抛射发生于日冕中，因此，日冕的直接测量对于理解耀斑和日冕物质抛射的产生具有重要作用。活动区极紫外观测是对活动区上方日冕的直接观测。良好的特征表达对于太阳耀斑和日冕物质抛射预报具有重要的作用。目前，活动区的极紫外特征研究较少，手工选取特征比较困难，而采用深度学习技术从大量观测数据中自动抽取爆发的前兆特征，并利用深度学习技术进行耀斑预报建模具有极大的优势。

7.5.5 磁图分辨率对耀斑预报的影响

随着太阳观测数据的积累和数据驱动算法的发展，深度学习方法被广泛应用于构建太阳耀斑预测模型。大多数工作都集中在如何为预测任务设计或选择合适的深度网络。然而，图像分辨率对基于学习的太阳耀斑预测模型的影响尚未进行分析和讨论。

工作[147]研究了磁图分辨率对太阳耀斑预测准确性的影响。搜集 2010 年至 2019 年的活动区 SDO/HMI 磁图进行下采样以获得包含具有多种分辨率的活动区域的数据库。运用 AlexNet、ResNet-18 和 SqueezeNet 三个常见的深度神经网络来评估太阳耀斑预测在不同分辨率磁图下的性能。在实验中，作者不仅在自己的模拟数据库上做了不同分辨率的对比实验，还搜集了和 HMI 磁图有时间重叠的较高分辨率 Hinode 磁图和较低分辨率 MDI 磁图上进行了对比实验。实验结

果表明，深度学习网络都在一定程度上对分辨率不敏感（适当的降低分辨率不会对耀斑预报的结果造成影响）。该工作从可解释的角度可视化了网络的感兴趣区域，发现深度学习网络更加关注从活动区提取的全局特征而对局部的细节特征不敏感。

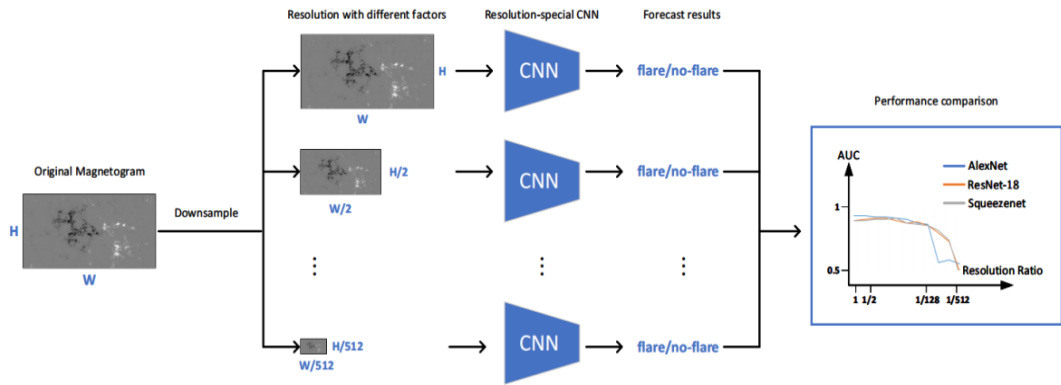


图 7-3 耀斑预报总流程图

图 7-3 展示了实验的总流程图。其中输入磁图被下采样到不同的分辨率然后使用不同的卷积神经网络（Convolutional Neural network, CNN）进行预报。每个 CNN 的输入是不同分辨率的磁图，输出是该磁图在未来 48 小时内是否会有耀斑爆发。我们通过综合这些不同网络在不同分辨率下的预报结果来进行对比分析。




图 7-4 不同分辨率下的 AUC 和 TSS 曲线

模拟实验结果如图 7-4 所示，从 AUC 和 TSS 指标的结果图中可以看出这三个网络的性能相当，AlexNet 略优于其他两个网络。刚开始，随着分辨率的降低，AUC 和 TSS 指标都保持在高位，直到分辨率降低到 1/64，指标开始显著下降。说明适当的降低磁图的分辨率

不会影响网络预报的性能。

为了进一步验证分辨率对深度学习预测模型的影响，我们搜集了不同分辨率的实际数据进行实验。选择相对 HMI 分辨率较高的 Hinode 磁图、相对 HMI 分辨率较低的 MDI 磁图和相对 Hinode 和 MDI 数据来说处于中间分辨率的 HMI 磁图。筛选出在时间和空间重叠的部分，准备 Hinode-HMI 和 HMI-MDI 两个对比数据库。然后利用深度学习模型在两个实际数据库上研究了分辨率变化带来的影响。利用 Hinode 和 MDI 的数据进行的实验表明，对具有更高分辨率的 Hinode 磁图进行训练并没有得到比用 HMI 训练更好的模型。同时，我们可以利用较低分辨率的 MDI 磁图得到与 HMI 相当的预报性能。使用这些实际数据库的结果再次证实了我们的结论，即三种选择的深度学习网络对 Hinode、HMI 和 MDI 磁图分辨率的变化不敏感。

可视化结果如图 7-5 所示，选择 2016 年 2 月 12 日的 NOAA 12497 活动区样本作为示例展示。显著性方法可以帮助理解深度神经网络，它将深度神经网络的预测与对预测影响最大的输入联系起来。可视化结果的显著性图指示了网络在预测时更关注输入图像的哪些区域。使用 Grad-CAM++ 基于梯度的方法来绘制显著性地图。可以得出结论：当分辨率没有下降太多时，网络所关注的区域就不会变化太大。当图像太模糊时，网络无法提取关键区域。这一结果也可以解释为什么当分辨率降低得很少时，网络性能不会下降可能是因为网络会根据一个区域来预测一个样本，略微模糊的磁图不会影响网络提取整个区域的特征。

Liu 等人[147]构建了一个大型的数据库，可供研究者使用。该数据库包含了从 2010 至 2019 年所有活动区磁图，数据分布如表 7-3 所示。

表 7-3 数据库数据分布(按年份统计)

Year	Positive number	Negative number
2010	51	3637
2011	377	9209

2012	475	9752
2013	615	12684
2014	791	10862
2015	528	10715
2016	67	6769
2017	84	5133
2018	0	1964
2019	0	87

为了研究分辨率对耀斑预报模型的影响,[147]在模拟数据和真实数据上分别进行实验和验证。模拟数据库通过降采样 HMI 活动区磁图得到,真实数据库选择比 HMI 具有更高分辨率的 Hinode 活动区磁图和较低分辨率的 MDI 活动区磁图,如图 7-6 所示,展示了 Hinode-HMI 数据库样例




图 7-5 网络热力图 (高亮的部分是网络关注的与爆发有关的区域)

1) HMI 模拟数据集

耀斑预报模型的输入是一个活动区的磁图,其输出是耀斑是否会发生耀斑。SDO/HMI 的常规观察始于 2010 年 4 月 30 日,活动区域的磁图可以从联合科学行动中心 (JSOC) 数据库下载 (<http://jsoc.stanford.edu/ajax/lookdata.html>)。下载的活动区磁图时间间隔为 96 分钟,其空间分辨率为 0.5 角秒/像素。

为了研究分辨率变化对耀斑预测的影响。将分辨率下采样到原始

分辨率的 $1/2$ 、 $1/4$ 、 $1/8$ 、 $1/32$ 、 $1/64$ 、 $1/128$ 、 $1/256$ 、 $1/384$ 、 $1/512$ 。然后，分别训练不同深度模型进行不同分辨率的太阳耀斑预测。随着分辨率的变化，一个活动区示例如图 6-1 所示。分辨率的比例标注在图像的右上角。“ $1/1$ ”表示原始磁图，“ $1/n$ ”表示图像的下采样到原始磁图的 n 分之一。

实验中使用的太阳耀斑数据下载自 NOAA 国家环境信息中心 (NCEI) 网站。对于正负样本的定义，从观测到磁图开始，在一个给定的预测时间窗口内，如果至少有一次耀斑爆发，则将这个观测的磁图定义为耀斑预报的正样本；如果在预测时间窗口内没有耀斑爆发，它就被认为是负样本。实验中设置预测时间窗口为 48 小时。选择 HMI 活动区数据跨度为 2010 年 5 月 4 日至 2019 年 1 月 26 日。该数据库包含 2988 张正样本图像和 70822 张负样本图像。按照年份统计的数据分布如表 7-3 所示，正负样本具有强不平衡性，负样本数远大于正样本数。网络优化按照年份划分训练集和测试集。选择 2011 和 2015 年的数据进行训练，其他年份的数据进行测试。

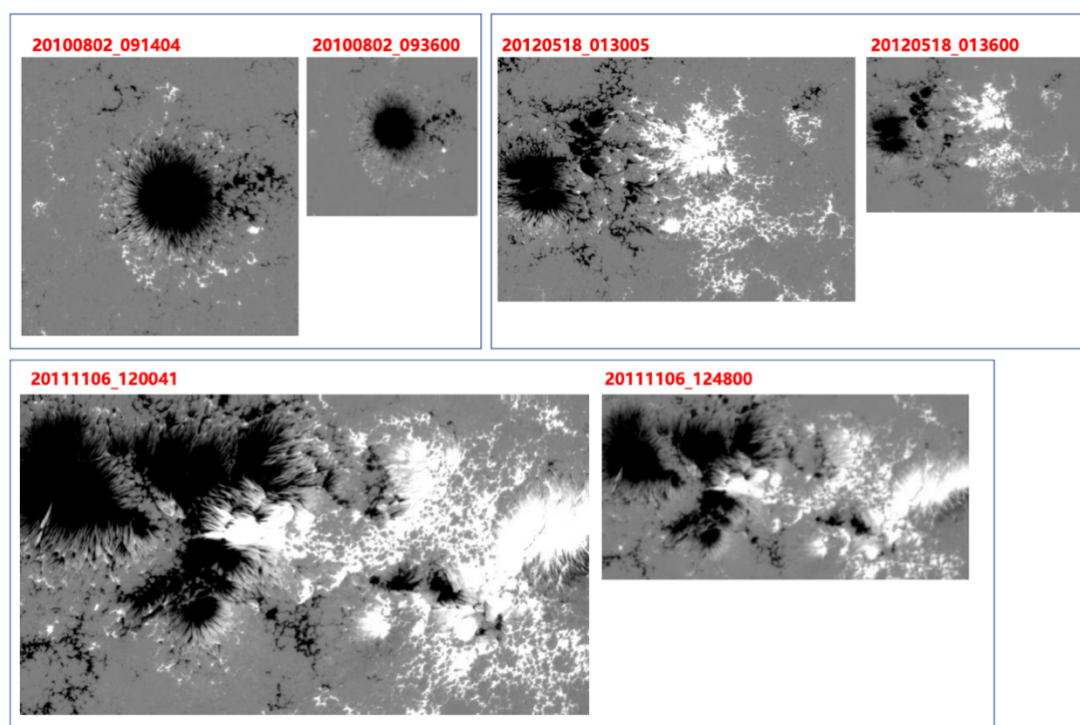


图 7-6 Hinode-HMI 数据库样例

三个网络的参数比较如表 7-4 所示，AlexNet 虽然层数低，但是由于全连接层的使用，浮点运算量最高。SqueezeNet 引入了 Fire 模块大大降低了网络参数量。

表 7-4 AlexNet, ResNet-18 和 SqueezeNet 参数比较

网络	网络层数	全连接层	浮点运算量	参数量
AlexNet	8	3	1.82G	11.69M
ResNet-18	18	1	714.69M	61.10M
SqueezeNet	10	0	351.91M	1.24M

7.6 从紫外、极紫外图像生成磁图的动态深度学习模型

太阳高层大气存在着非常剧烈的爆发活动，如太阳耀斑，日冕物质抛射等。这些剧烈的太阳活动都是由光球磁场来控制的。充分挖掘光球磁场与日冕高层大气层之间的关系，对太阳活动的触发机制以及太阳活动的预报有非常重要的意义。

韩国学者 Kim 等人 (ApJ, 2019) 将 Pix2pix 深度学习生成模型用于从 SDO/AIA 304Å 图像生成磁图，HMI 磁图作为输出标签。得到的模型用于太阳远端的磁图生成，即以 STEREO EUVI 304Å 图像作为输入，得到太阳远端的磁图数据。然而，当我们将生成出来的磁图按照时间顺序连续播放的时候，磁场会出现正负极的跳变或者强磁场区域的瞬时闪现。这种生成磁图的演化规律与观测磁图的演化规律并不符合。如图 7-7 所示，我们分别展示了三张观测磁图与生成磁图，时间分辨率为 12 分钟，并给出了区域(a)和区域(b)的颜色图。我们会发现，区域(a)中，观测磁图一直是平静区，而在生成磁图中，却出现了强磁场区域的忽然出现或者突然消失；在区域(b)是一个暗条结构，中性线非常的明确，然而在生成磁图中，正负极的边界并不明确，完全不符合暗条结构的磁场结构。

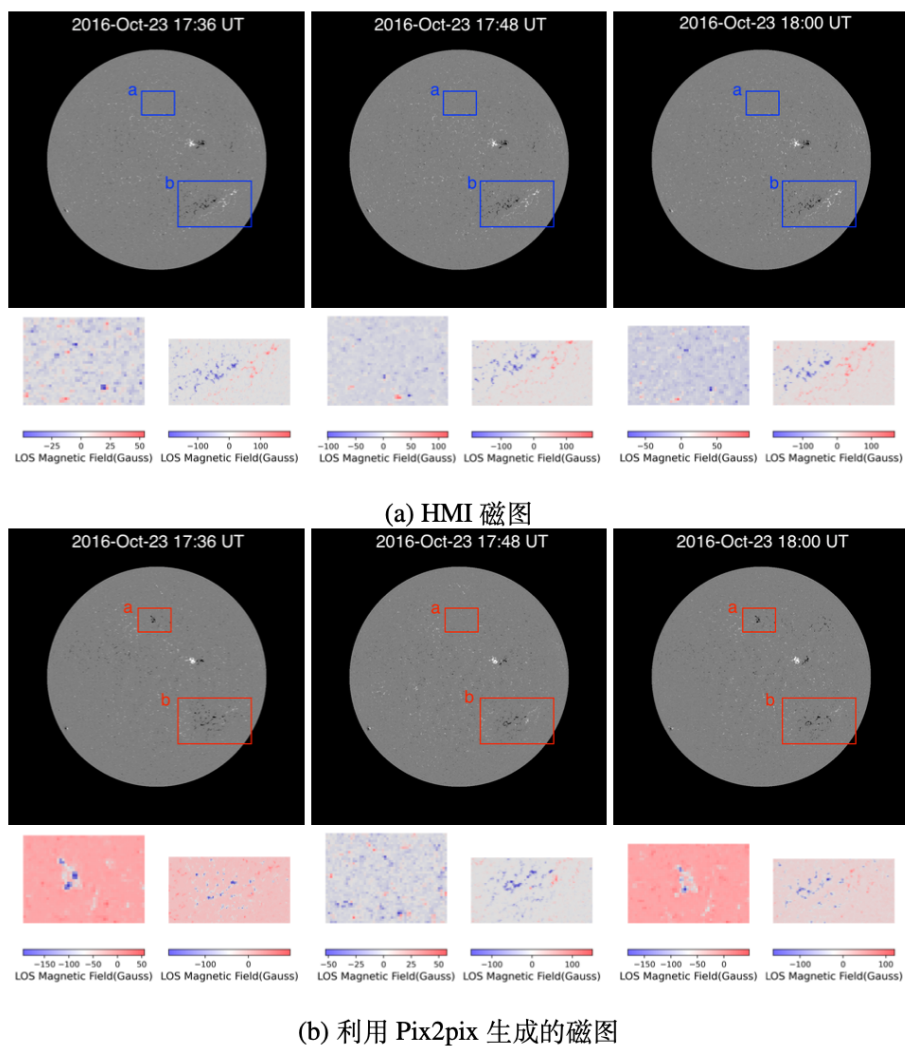


图 7-7 Pix2pix 模型问题描述:第一行和第三行分别展示的是 HMI 的观测磁图和 Pix2pix 模型生成的磁图;第二行和第四行分别展示了局部区域颜色图。

HMI 观测的是不同的物理参量, HMI 测量光谱线中的偏振以研究光层磁场, 而 AIA 提供 EUV 和 UV 带通的窄带成像, 以研究日冕和过渡区。这两者显然分布在不同的图像域中。当把源域中的 AIA 304 Å 图像翻译成目标域中的磁图时, 这两者之间存在非常大的域间隔。其次, AIA 观测记录了太阳高空活动的源区, 如太阳耀斑和日冕物质抛射(CME), 而 HMI 观测光球的磁场。虽然 AIA 304 Å 图像和 HMI 磁图在理论上存在映射关系, 但它们有完全不同的特点, 表现出不同步的演化节奏和不同的变化规律。一旦有太阳耀斑或者日冕物质抛射发生, 太阳耀斑或者日冕物质抛射的源区会在短时间内出现亮度和物质抛射的瞬时变化, 而相应的光球区域的磁场仍在小范围内演变。基

于上述两个观察,[148]提出了加入时序演化约束的动态深度学习模型 (convGRU-pix2pix) 来生成磁图, 该模型的基准网络仍然为 Pix2Pix 模型, 但增加了时序模型对图像序列进行分析。结果表明[148]提出的模型可以挖掘时序 EUV 图像中稳定的结构来生成磁图, 从而使得生成的磁图具备更加稳定的磁场结构并且其演化更加符合观测磁图的规律。

具体地, [148]提出了一个基于卷积门控递归单元(Convolutional Gated Recurrent Units)的生成对抗网络, 通过用卷积门控递归单元(Gated Recurrent Units)来赋予 GAN 处理时间序列的能力。GRU 是一种轻型的递归神经网络(RNN), 在某些任务中优于 LSTM。

convGRU-pix2pix 模型通过整合条件 GRU 到 pix2pix 中, 如图 7-8 所示。该模型总体上是一个编码器-解码器系统, 其中编码器提取输入 AIA 图像的压缩特征/表示, 解码器解压缩特征以生成类似 HMI 的磁图, 而中间的卷积 GRU 单元将图像特征序列作为输入, 从输入中提取长期稳定的结构, 将其与短时精细变化分开。

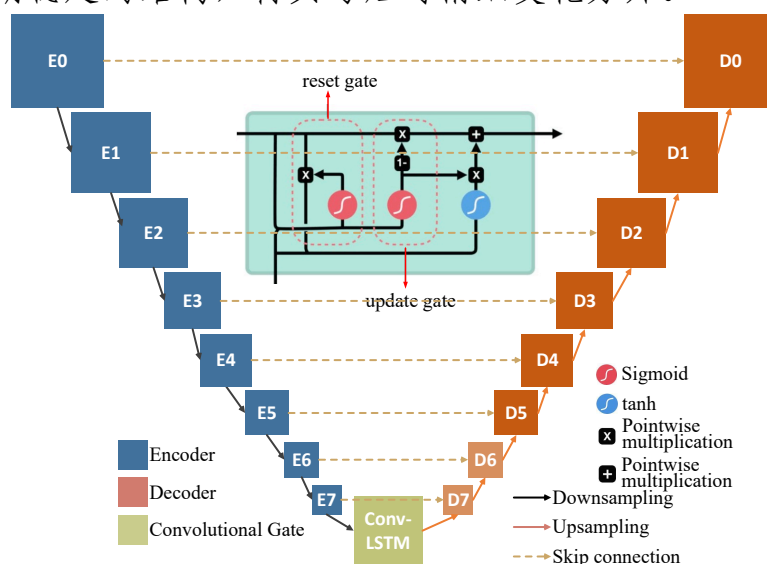
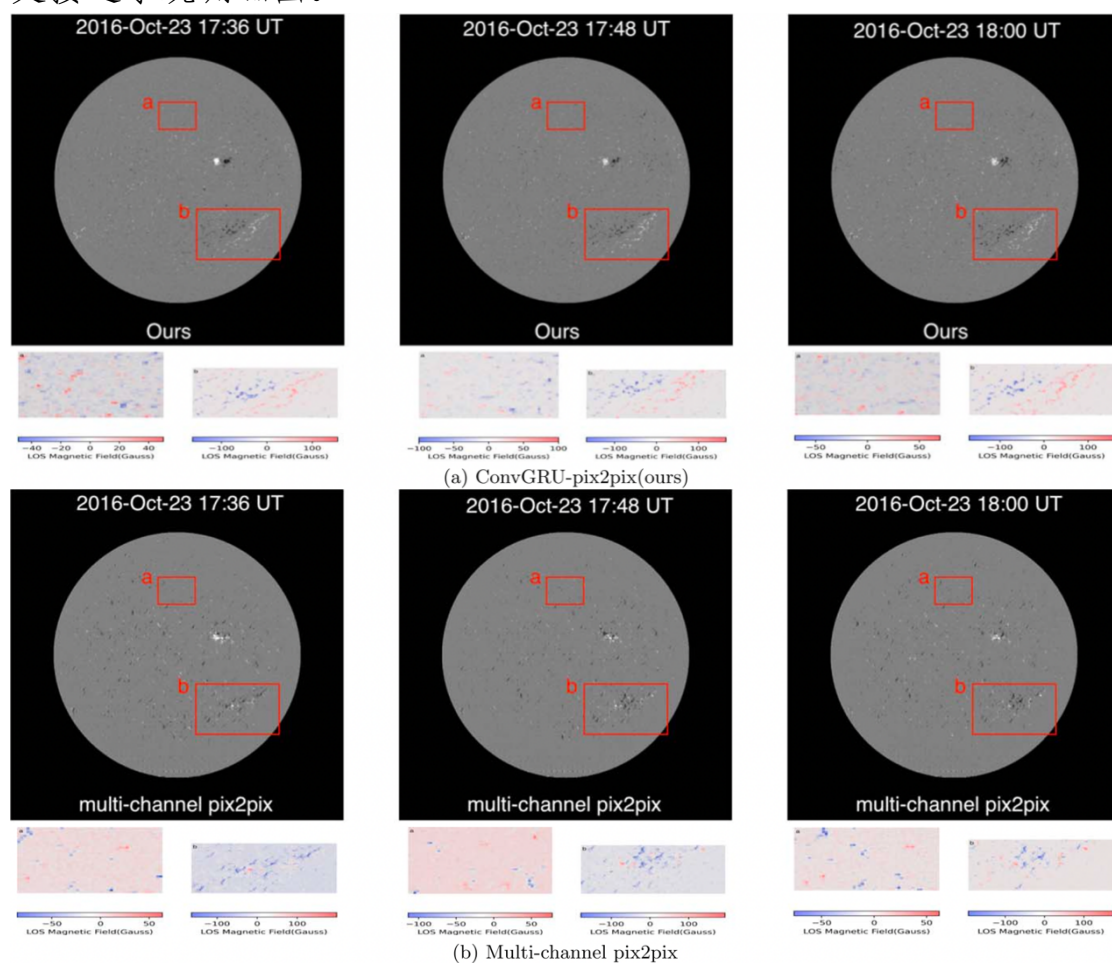


图 7-8 生成器的网络结构图

图 7-9 展示了不同模型生成的磁图与 HMI 观测磁图进行了比较。可以发现我们提出的 convGRU-pix2pix 模型的磁极和结构的波动比其他的的小。例如, 图 7-9 中, 区域(a)为宁静区域, 而从 pix2pix 生成

的第三列可以观察到明显的磁场出现；虽然多通道 `pix2pix` 也接受图像序列的输入，但它缺乏从序列中学习序列特征的机制，导致磁极性的波动。实验表明 `convGRU` 模块对于捕捉输入序列的时序特征确实有意义。客观指标表明模型达到了最佳的 SSIM 和 PSNR(最小的 MSE)，此外，我们的模型的总无符号通量相关系数、正通量相关系数和负通量相关系数分别达到了 0.88、0.87 和 0.89。它们都比其他模型大得多，表明我们的模型与观测磁图高度一致。

在图 7-10 中，展示了磁图生成在活动区 AR 上的结果，其中第一列是观测磁图(HMI 磁图)，其他列分别是我们的模型、多通道 `pix2pix` 和 `pix2pix`。为了便于检查 AR 序列的演变，我们计算了两个连续磁图之间的差异，并在每个 AR 序列旁边的一行用颜色图示出来。从图 7-9 中可以看出，通过比较它们的颜色图，我们的方法在形态上更接近于观测磁图。



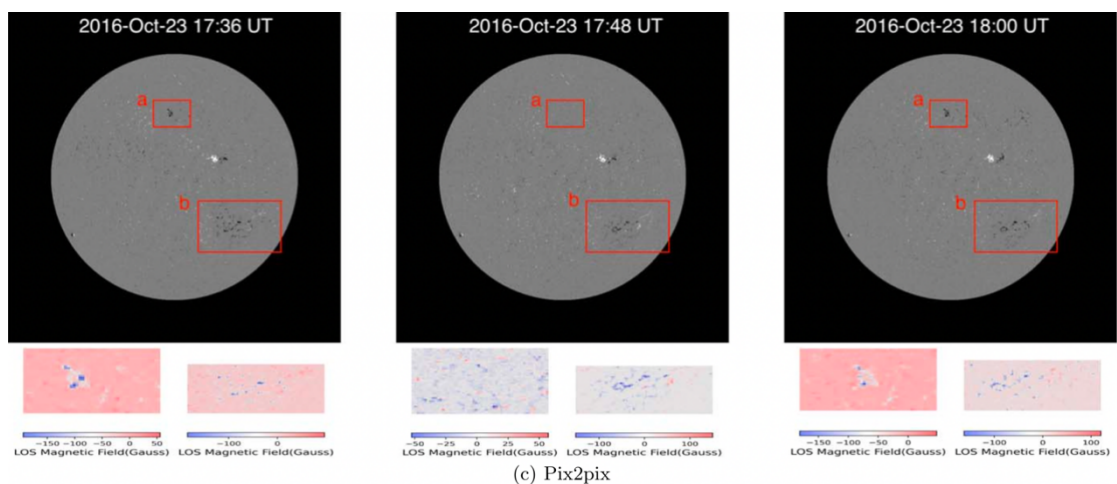


图 7-9 全日面磁图生成的可视化比较

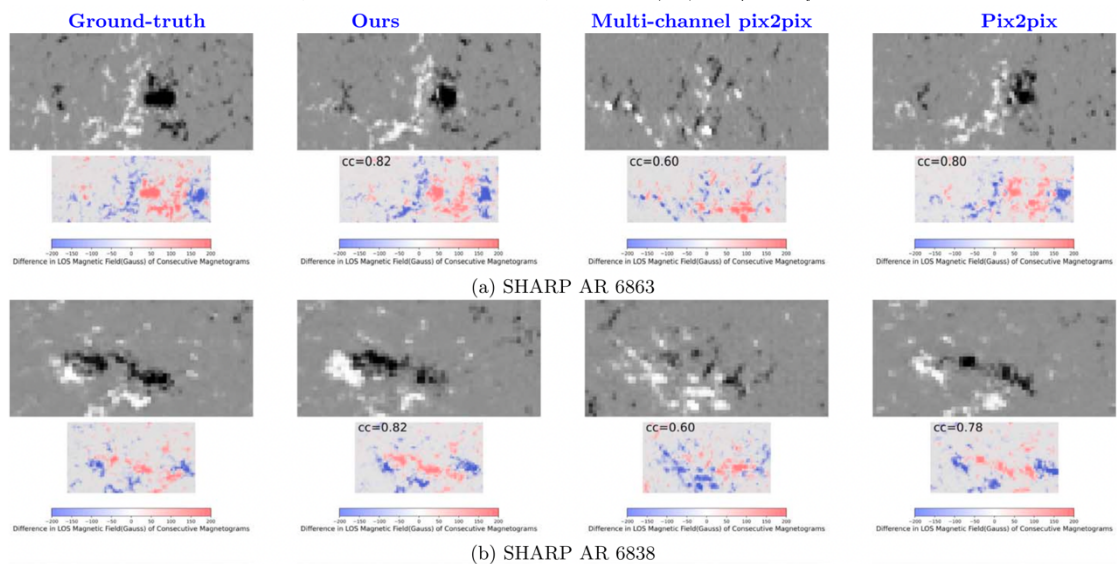


图 7-10 生成的活动区磁图可视化比较

7.7 深度学习用于太阳活动区磁图超分辨

不同的观测设备获得的图像分辨率不同，为了获取长时间的观测数据，特别是用于人工智能模型训练的大数据，需要对各种设备采集的图像归一化到一个统一的分辨率。SOHO/MDI 磁图分辨率为 2 角秒，SDO/HMI 磁图分辨率为 0.5 角秒，[149]采用深度学习模型对 MDI 活动区磁图进行 4 倍的超分辨率 (SR)，以达到与 HMI 活动区磁图相同的空间分辨率，这样可以构造一个几乎跨越 2 个太阳活动周的太阳磁图大数据库。

[149]采用深度学习算法，设计了一个无监督的生成对抗网络

DSGAN, 得到 LR-HMI 的活动区磁图, 与 LR-MDI 具有几乎相同的域。为了能够更好的保留活动区磁图的物理特性, [149]采用了有监督的 SPSR 超分模型, 该模型采用了一个额外的梯度分支网络, 生成高分辨率梯度图作为额外的结构先验。并引入了新的梯度损失, 对超分辨率图像施加了二次约束。DSGAN 网络和 SPSR 网络如下图所示。

为了模型训练, 建立了数据集, 收集了从 2010-2017 年的 HMI 的活动区磁图 (分辨率为 0.5 角秒, 时间分辨率为 12min)、1996-2010 年的 MDI 的全日面磁图 (分辨率为 2 角秒, 时间分辨率为 96min)。从中筛选出 2011 年到 2014 年中的活动区比较剧烈的 HMI 磁图当做训练集。训练集数据包含 500 张 HMI 活动区磁图, 将每张 HMI 活动区磁图裁剪成 128×128 的 HR 图像 patch, 并作为神经网络的标签数据, 得到大约 7 万多张图像块。采用双三次降采样的方法得到 HMI 低分辨率的 patch 块, 其大小为 32×32 。2014-2017 年的 HMI 图像和 1996-2010 年的 MDI 的磁图作为测试集。表 7-5 提供了训练、验证和测试数据集的细节。

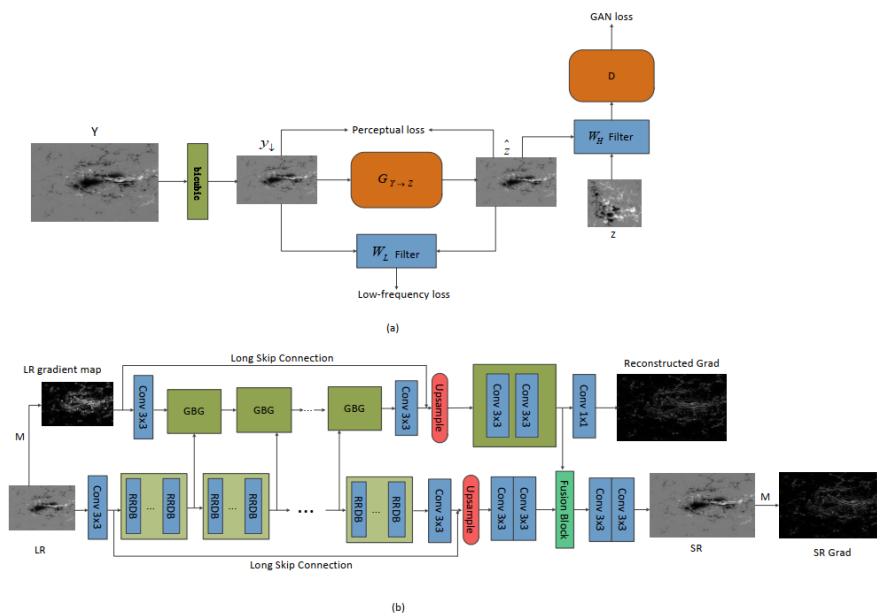


图 7-11 DSGAN 网络 (a) 和 SPSR (b) 网络结构

表 7-5 MDI 和 HMI 数据集

	Train set	Validation set	Test set
Time	2010/05-2014/05	2014/05-2014/11	HMI:2015-2017 MDI:1996-2010
Number	70064(patch)	8509(patch)	HMI:107 MDI(2010):58 MDI(1996-2010):145
Size	LR:32*32 HR:128*128	LR:32*32 HR:128*128	Random

实验结果如表 7-6 表明，SPSR 的模型与其他两种方法进行比较（双三次插值和 HighRes-Net），取得了最好的 PSNR、LPIPS、RMSE，以及相当的 SSIM 和 CC 值。其中 LPIPS 得益于梯度的引导，更好的保留了磁图的物理结构。尽管 HighRes-Net 获得了最好的 SSIM 值，但它获得了最差的 RMSE 和 PSNR 值。这是由于在强磁场中生成的磁通量与观察到的磁通量存在较大偏差。双三次上采样方法获得了较好的 PSNR 值，它更像是一个面向 PSNR 的插值方法。此外，SPSR 模型的 CC 值几乎等于 HighRes-Net 方法的 CC 值，而 RMSE 值却大大超过了 HighRes-Net，这表明 SPSR 方法具有良好的稳定性，同时产生的磁通量的值更接近于观察到的磁通量值。

表 7-6 超分辨结果定理比较

Method	PSNR	SSIM	LPIPS	CC	RMSE
Bicubic	36.3236	0.9489	0.3501	0.9844	17.9401
HighRes-Net	27.783	0.9606	0.1758	0.9867	48.3778
SPSR-GAN	36.4567	0.9595	0.0818	0.9863	17.6419

图 7-12 展示了 SPSR 模型，HighRes-Net 模型以及双三次上采样的方法的视觉效果，图中展示了 SPSR 模型生成的图像具有更多的细节信息，而且也更加清晰，也更加真实。从第一行中的活动区磁图（2015 年 1 月 3 日）来看，SPSR 方法能够恢复一些小的磁场结构，而且产生较少的伪影。此外，SPSR 模型可以生成清晰的极性反转线和更清晰的边缘。双三次上采样和 HighRes-Net 方法生成的活动区磁图较为模糊，而且很多细节信息也不能够恢复。




图 7-12 磁图超分辨的视觉效果比较

MDI 和 HMI 磁图在 2010 年是有重叠图像的，但是拍摄图像的时间是有一些差异的，这会导致 MDI 和 HMI 在同一位置上会出现一些轻微的偏差，所以 SPSR 将 2010 年的 MDI 和 HMI 的磁图做了对齐的操作，将对齐后的 MDI 的活动区磁图的超分结果进行了的定量和定性的比较。定量指标的结果值在表 7-7 所示，从中看到 SPSR 方法在 MDI 数据集上几乎所有的指标都是最好的。相关系数（CC）和均方根误差（RMSE）指标是根据总磁通量计算的，这表明 SPSR 的方法对真实的 MDI 磁图是有效的。

表 7-7 MDI 磁图数据集超分辨的结果比较

Method	PSNR	SSIM	LPIPS	CC	RMSE
Bicubic	34.7284	0.9070	0.5197	0.8669	21.1758
HighRes-Net	27.501	0.9171	0.3927	0.8723	49.4365
SPSR-GAN	35.4178	0.9240	0.3607	0.8721	19.5870

图 7-13 显示了在真实 MDI 低分辨率磁图上的实验结果，从图中可以看到，SPSR 方法可以生成一些小规模的磁场结构，其边缘比 HighRes-Net 和 Bicubic 方法更清晰，在正负极磁区更接近于目标磁图。HighRes-Net 和 Bicubic 方法的结果要比 SPSR 方法要模糊的多。




图 7-13 磁图超分辨在真实 MDI 观测数据上的视觉效果比较

7.8 深度学习用于太阳极紫外图像过曝光修复

当光强超过了一定的阈值，光学望远镜或者照相机总会发生过曝光，过曝光会造成图像区域的信息完全丢失，这类事件发生在空间卫星上，将会是难以弥补的，因此针对 SDO/AIA 多波段图像过曝光问题，[151][152][153]提出了使用深度学习网络进行过曝光修复，分别称为称为 PCGAN, MCNet 和 AANet。我们以 PCGAN 为基准模型为例，来说明采用深度学习如何进行图像过曝光修复。

AANet 模型采用图像生成领域经典的生成对抗网络 GAN，其中生成器采用 UNET 网络，能够较好地保持图像细节，网络框架如图 7-15。AANet 使用耀斑发生时，记录的短曝光（未发生过曝光）的图

像作为 **Ground-truth**，并对其进行曝光时间归一化处理，得到包含理想图像和过曝光图像的图片对，最终构建了大型的用于深度学习模型训练的数据库。数据库中的每个样本由图 7-14 展示的一组图像组成， I_{sat_fd} 为长曝光图像，提供了过曝光的区域及 **mask**（表示为 I_m ）， I_{unsat_fd} 表示与 I_{sat_fd} 相邻的未过曝光的、短曝光图像，其提供了 **Ground-truth**，而与 GT 相对的 degraded 图像由 GT 与 mask 相乘得到，用 I_d 表示。图 7-16 展示了 AANet 模型获得的过曝光修复的效果。




图 7-14 过曝光修复数据库例子

说明：图 7-14 (c) Recovered 是指使用 AANet 提出的深度学习网络去过饱和后的图像，相比图 7-14(a)，可以提供更多的爆发细节。

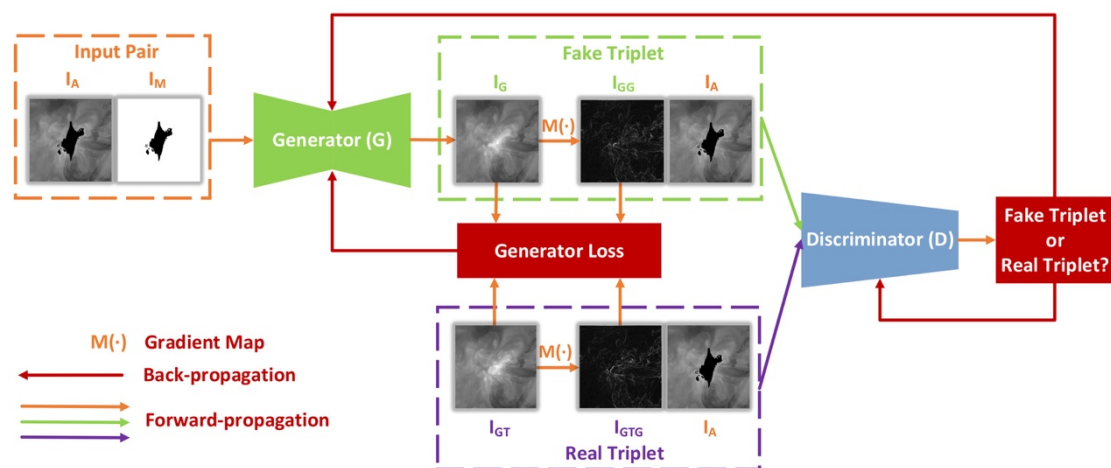


图 7-15 太阳图像去过曝光算法的框架图（主干网络为一个 CGAN，针对太阳图像去过曝光，Loss 函数综合考虑了图像保真度和纹理细节的恢复，使用了 L1 范数 Loss、对抗 Loss 及 Perceptual Loss）

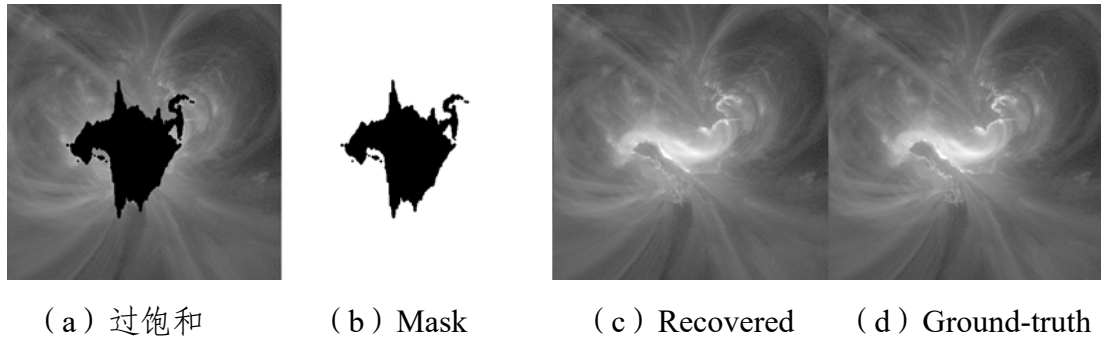


图 7-16 去过饱数据库样本示例

7.9 基于深度学习的日冕物质抛射预报

7.9.1 日冕物质抛射

每一颗主序星都在失去质量，这是由于大气中的动态现象加速等离子体或粒子超过逃逸速度。太阳上观察到两种形式的质量损失：稳定的太阳风外流和大型等离子体结构的不定时抛射，称为日冕物质抛射(Coronal Mass Ejection, CME)。日冕物质抛射(CME)是日冕中大规模物质快速抛射现象。用于描述白光日冕仪观测到的运动着的独立的亮结构。物质抛射的形态为环状或云状，抛出质量能达到 10^{12} - $10^{13}kg$ 。物质抛射运动的动能比大耀斑辐射出的能量大一倍多，抛出物质总质量不到太阳风总质量损失的 1%。日冕物质抛射现象与耀斑或爆发日珥相联系，这些爆发现象很大概率是由同一个不稳定磁场演化过程中的不同形式。日冕物质抛射是一种动态演化的等离子体结构，从太阳向外传播到行星际空间，携带着冻结的磁通量并不断膨胀。日冕物质抛射加速的高能粒子很有可能到达地球，因为它们沿着弯曲的帕克螺旋行星际磁场传播，从而对行星际空间产生潜在威胁。地球磁层中的相关地磁风暴可能导致全球通信和导航网络的中断、卫星和商业电力系统的故障，成为造成灾害性空间天气的主要原因之一。

7.9.2 日冕物质抛射的多波段观测

关于日冕物质抛射(CME)的第一次确切观测可以追溯到 1971 年 12 月 14 日，美国 OSO-7 卫星观测到日冕的结构瞬间变化，一些物质抛射出来。后续天空实验室、太阳极大使命、SOHO 等卫

星的发射，结合地面设备长期观测，积累了大量 CME 的观测数据。图 7-17 展示了 STEREO 卫星日冕仪拍摄的日冕爆发时的图像。右侧是真实的日冕图像观测结果，左侧是作差后的结果。Time_Diff 表示图像之间的时间差。图像上的蓝色表示 CME 前缘的位置。红色表示使用分割技术创建的前缘的近似轮廓。PAs 表示位置角检测，代表 CME 的起始和结束位置角。高度为当前帧中每对位置角对应的 CME 检测的高度。




图 7-17 日冕图像（由 STEREO Ahead 天文台的 SECCHI 外日冕仪 (COR2) 拍摄）

(1)白光观测：通常使用白光日冕仪对 CME 进行观测，外部环状结构由日冕中稀薄的高温物质组成，温度高达 $2 \times 10^6 K$ ，白光辐射强度与等离子体的密度成正比，白光连续辐射来源为自由电子对光球辐射的汤姆逊散射。

(2)X 射线：CME 在日冕中的 X 射线辐射与等离子体密度的平方成正比，且与温度有关。由于这种光学薄的特性，对 CME 的 X 射线观测只在低日冕中有效。Klimchuk 等人从 29 个 X 射线耀斑爆发事件中分析出 X 射线下 CME 的性质和白光 CME 相似。Gopalswamy 等人在 X 射线波段观测到了完整的 CME 三分量结构。Hudson 等人发现 CME 在 X 射线波段最好的观测区域为暗区 (dimming)，类似于白光观测中的日冕亏缺现象。

(3) 紫外线：在低日冕处，CME 的高温物质会产生较强的紫外辐射，如极紫外波段观测到的 EIT 波可能是 CME 的物质抛射结果。因此在卫星上搭载 $Ly\alpha$ 日冕仪来通过 $Ly\alpha$ 谱线观测 CME。

(4) 射电观测：由于 CME 的外环温度较高，因此将产生米波和更长波长的射电辐射。在 CME 爆发过程中会导致磁场发生巨大变化，伴随激波现象，在低频射电波段产生强烈的辐射，因此可以在射电波段观测 CME。射电观测具有很高的时间分辨率，且可以在不同频段进行观测，因此可以更好的监视 CME 的整个演化过程。

7.9.3 日冕物质抛射的性质

CME 的形态：CME 有很多不同的结构和形态，如环状、泡状、晕状和扇形等。CME 的形状不是固定的，在不同波段观测的形状不同，且随着时间的变化，形态结构也会发生变化。并且观测到的结构不能代表真实的结构，仅代表观测面的投影。CME 在白光日冕仪中通常表现出日冕中典型的三部分结构，即明亮的前缘、暗腔和明亮的核心，对应密度为高、低和高。图 7-17 展示了一个 2011 年 10 月 4 日的 CME 图像，(a) 中红色箭头指示了明显的空腔，后续 (b)-(d) 展示了由于前沿和膨胀的 MFR 之间的压缩，空腔逐渐变得模糊。




图 7-18 日冕三分量结构观测图像

CME 的质量: 对于 CME 质量的估计, 主要是基于 CME 和太阳物质的组成一致性假设, 其中包括 10% 氦和 90% 完全电离的氢。可以利用日冕仪观测 CME 的辐射, 该辐射主要来自自由电子对光球辐射的汤姆逊散射, 通过估计 CME 体积和电子数目来计算质量。或者, 可以根据热等离子体的辐射特征, 通过不同波段的观测特征来确定 CME 的质量。使用这两种方法可以得到基本一致的结果。但需要注意的是, 日冕仪观测对应较高的区域, 而射电和 X 射线等波段的观测对应较低的区域。Gopalswamy 和 Kundu 首次使用射电方法测定了 1986 年 2 月 16 日的 CME 的电子密度。需要指出的是, 这两种方法都需要考虑视宽度的大小, 但对于特别重要的晕状 CME 来说, 视宽度的测定并不是一件容易的事情。因此, 给出的晕状 CME 质量估计可能会有较大误差。一般认为只有视宽度超过 5 度的日冕运动结构才能被认定为 CME。CME 的质量范围一般为 $1 \times 10^{11} - 4 \times 10^{13} \text{kg}$, 平均为 $3.5 \times 10^{12} \text{kg}$, 大约 15% 的 CME 质量不足 10^{11}kg 。Gopalswamy 等人 (Gopalswamy 等, 1998) 发现 CME 的外环和爆发的暗条质量接近, 不过在 CME 的传播演化过程中, 部分暗条的物质会掉落到色球中, 使得 CME 的亮核结构质量低于爆发前的暗条。

CME 的速度: 根据不同时刻 CME 亮环顶点的位置可以推算出 CME 的爆发速度, 由于 CME 的观测是投影平面的, 因此计算出的速度是投影速度或成为视速度。Hundhausen 等人 (Hundhausen, 1998) 曾统计了 SMM 观测到的 673 个 CME 并计算其速度范围为 $35 \sim 911 \text{km/s}$, 平均速度为 349km/s , 中值速度为 285km/s 。Gopalswamy 等人 (Gopalswamy 等, 2003) 对 SOHO 从 1996 至 2002 年观测到的 CME 进行了详尽的分析, 图 7-18 展示了 CME 平均速度和中值速度的变化曲线, 可见平均速度从太阳活动极小年到极大年变化达一倍, 且平均速度极大值产生自 2002 年, 比黑子数极大要迟。

CME 的角宽度: 日冕物质抛射 (CME) 是造成地球空间非重现性地磁暴的主要来源, 但并非所有的正面(朝向地球面)CME 事件都能传播到地球空间。CME 角宽度定义为 CME 相对日心的张角, 是影响它能否传播到地球的重要因素之一。已有研究表明, CME 角宽度和其源区的某些太阳活动参数之间具有一定的相关性, 如活动区面积、磁通量、中性线长度、伴随耀斑参数等。角宽度较小的 CME 可以称之为窄 CME。LASCO 日冕仪发现每天至少有 3 个喷流状抛射物, 在极小年其角宽度为 2-4 度, 在极大年角宽度为 3-7 度。喷流状窄 CME 通常和位于冕洞的极紫外喷流对应, 速度分布和通常的 CME 相似, 且数目随着太阳活动增强而增大。角宽度大于 120 度的 CME 称为晕状 CME, 其中角宽为 360 度的称为全晕 CME。

7.9.4 日冕物质抛射预报

日冕物质抛射会造成严重的灾害性空间天气事件, 造成地球磁层扰动产生磁暴、电离层暴等, 日冕物质抛射还会带来空间高能粒子事件, 对航天器、卫星造成损害。针对其的预报是太阳物理领域的研究热点之一, 包括 CME 对地有效性、CME 到达时间及太阳风参数的预报。

表 7-8 CME 对地有效性预报

Model	reference	algorithm	accuracy
physics-based	[15]	WEC	0.83
	[16]	WEC	0.85
	[14]	SSEF	0.90
deep learning	[34]	support vector machine	0.66
	[35]	neural network	0.86
	[36]	logistic regression	1.00
	[38]	logistic regression	0.98

	[39]	recommenda tion system	1.00
	[40]	machine learning	0.99

7.9.4.1 CME 对地有效性预测

为了准确预测 CME 的到达时间，预报员必须对 CME 图像中观察到的事件能否对地球产生影响，即是否能够到达地球进行判断。在过去的几年中，一些论文 [14, 15, 16] 对到达/未到达地球的 CME 进行了详细的统计研究，并制定了提高命中率的方法。[14] 检查了使用 HI 观测来确定 CME 到达时间的可靠性，并评估了命中与未命中预测的精度。他们的方法采用了 CME 前沿的自相似扩展模型，考虑了 60° 的纵向宽度，一致的速度和不变的传播方向，反映了解析或数值建模技术的特点。[15] 提出了 WSA-ENLIL+Cone 集合模型，提供了一个包含不确定性评估的概率性预测，用于预测不同预测结果的到达时间不确定性，并对 CME 到达概率的预测准确性进行评估。[16] 验证了 WSA-ENLIL+Cone 模型，并对解释验证结果时需要仔细考虑的因素进行了全面分析。这些因素涉及基于实时日冕仪数据确定 CME 输入参数时出现的不确定性，识别 ICME 的原位到达所面临的挑战，以及涉及多个 ICME 到达的情况。

支持向量机(SVM)首次被用于预测地磁效应的全日冕 CME[34]。他们利用 SOHO/LASCO CME 目录的数据，该目录包含了从 1996 年 1 月至 2010 年 4 月的全日冕和部分日冕 CME。此外，他们利用相关耀斑的 X 射线级别，识别了大于 B1 级的前侧全日冕 CME，并利用 Dst 指数检测了强于 -50 nT 的地磁效应全日冕 CME。SVM 分类的输入特征是 CME 的角宽度、速度和相应的 X 射线级别的所有可能组合。利用 CME 的速度和 X 射线耀斑级别作为 SVM 的输入特征，他们可以确定最佳模型的统计参数，准确率达到 0.66。

[35] 提出了一种基于神经网络的模型，用于估计全日冕 CME

及其相关的星际事件之后地磁暴发生的概率。该模型结合了定义地磁效应全日冕 CME 的太阳和星际参数。太阳输入包括定量变量，如全日冕 CME 角宽度 (AW)、CME 速度 (V_{cme}) 和耀斑指数，该指数衡量与全日冕 CME 相关的耀斑活动量。星际参数包括星际磁场的南向 Z 分量和太阳风速的峰值 (V_{sw})。在假设存在全日冕 CME 的情况下，该模型准确预测了所有导致 Dst 小于或等于 -100 nT 的地磁暴。对于 Dst 在 -100 到 -50 nT 之间的中等级地磁暴，该模型的准确率为 75

[36] 旨在使用修改版 [37] 的逻辑回归模型来预测给定 CME 的地磁效应，该模型使用 CME 的初始参数。在 CME 爆发后，其传播路径与其在太阳上的起源点、速度、太阳日冕环境等因素密切相关，这些因素决定了它是否能够到达地球。该模型试图通过最小 Dst 值为 -30 nT 来判断 CME 是否会伴随地磁暴。他们使用了 2010 年 4 月 1 日至 2011 年 6 月 30 日（太阳第 24 个太阳活动周期的上升期）的数据，并利用修改后的逻辑回归模型来研究 SOHO LASCO 探测到的 CME，这与 [37] 的研究不同。在他们的研究中，CME 数据库仅包括与较长时期（1996-2002 年）的强烈和超强地磁暴相关联的 CME。

[38] 对基于 [37] 的逻辑回归模型进行了修订，以预测 CME 是否会响地球以及是否伴随最小 Dst 值小于 -30 nT 的地磁暴。在太阳第 24 个太阳活动周期中，该模型对 SOHO LASCO CME 目录中列出的几个 CME 进行了执行。模拟 CME 在星际空间的传播和演化需要一个或多个独立变量。因此，该模型需要五个独立变量（CME 在 20 倍太阳半径处的速度、角宽度、观测位置角度和加速度）。[38] 发现太阳风有时会在 20 倍太阳半径之前加速。因此，通过在 20 倍太阳半径处的速度更准确地揭示 CME 在离开太阳日冕环境后的状态。此外，他们选择了一个二进制变量，用于与 [36] 使用的变量相同的

目的。该变量的定义如下：如果 Dst_{min} 大于 30 nT（表示未检测到地磁暴），则为 0；如果 Dst_{min} 小于等于 30 nT（表示检测到地磁暴），则为 1。

为了提高预测准确性，[39] 采用了机器学习方法和经验丰富的预测者混合的方式，以确定预测 CME 地磁效应的最佳方法。预测者必须依赖过去的太阳活动事件来评估当前或未来的事件，而逻辑回归和推荐算法可以为预测者提供改进预测的选择。因此，[39] 首先使用逻辑回归分析了不同 CME 参数（例如中心位置角、角宽度和线速度）之间的相关系数，这些参数来自 CME 的观测图像。然后，他们开发了一个逻辑回归模型来预测 CME 是否会对地球产生影响。该模型的 F1 得分为 30%，召回率为 53%。此外，他们还使用推荐算法来识别最能代表每个 CME 的历史事件。所有这些信息都用作比较和预测 CME 地磁效应的基准。

[40] 专注于评估机器学习方法是否能够确定新爆发的 CME 是否有可能引起地磁活动。他们对太阳的白光日冕图像数据进行了多种方法的训练，包括逻辑回归模型、k 最近邻算法、支持向量机、前馈神经网络和集成模型。为确保较长的提前预报时间，[40] 仅将预测限制在太阳参数中，尽管有证据表明星际因素会影响 CME 的地磁效应。他们讨论了 CME 地磁效应的主要困难，包括地磁效应和非地磁效应事件数量和相似性的显著不平衡，以及相关变量的不足。尽管在这种情况下，[40] 证明了这些模型仍然可以达到足够的预测准确性。

7.9.4.2 CME 到达时间预报

在这一部分中，首先对基于物理理论的经典模型进行简要概述。如已有的论文中所提到的（[19, 20]），这些模型可以大致分为以下几类：经验模型、膨胀速度模型、基于阻力的模型、基于物理的模型和磁流体力学（MHD）数值模型。经验模型（[21, 22, 23]）采用简单的方程式来建立 CME 扰动到达地球的到达时间与太阳附近检测到的

相应观测值之间的相关性，包括初始速度。CME 受到远离太阳特定距离处的环绕太阳风的显著影响。为了解决这个问题，基于阻力的模型 ([24, 25, 26]) 应用运动方程式对 CME 进行建模，考虑到 CME 与周围太阳风的相对速度，集成二次阻力加速和减速效应。基于物理的模型 ([27, 28]) 利用特定的理论或概念进行准确预测，这些理论或概念建立在 CME-IP 扰动事件的框架之上。磁流体力学 (MHD) 模型 ([29, 30, 16]) 可以模拟太阳扰动在背景太阳风中的运动方程。这些模型包含近太阳处的时变边界条件，以提供太阳扰动在地球上预期到达时间的预测。

接下来，我们描述了几种应用于 CME 到达时间预测的深度学习技术。[37] 首次尝试使用神经网络等机器学习算法来探索 CME 的中央子午线距离和初始速度对其到达时间的影响。他们发现，基于 CME 的初始速度评估到达时间时，在太阳风中存在典型的阻力模式。此外，[41] 发现，与太阳的西侧爆发有关的 CME 的传输时间比起源于东侧的 CME 更短。神经网络预测和观测之间的平均时间差与先前的研究一致，为 12 小时。与基于物理的方法相比，使用神经网络的最大优势是无需指定将输入和输出参数连接起来的经验函数或超曲面。然而，使用更多输入参数使得获得最佳函数变得困难。

[38] 提出了一种新的方法，称为 CAT-PUMA，采用支持向量机 (SVM) 算法来预测部分或全日冕 CME 的到达时间。为了开发预测引擎，他们对 CME 的特性和太阳风因素进行了深入研究，并使用了 182 个先前报道的地磁效应部分和全日冕 CME。通过使用特征选择方法，[42] 确定了在确定 CME 到达时间方面至关重要的可观测特征。实验结果显示，CME 的平均速度、最终速度、角宽度和质量是在星际空间确定传输时间的最重要因素。他们还发现，阿尔法粒子与质子数密度比率、磁场 B_z 和 B_x 、质子温度、流速、流压和流经度等太阳风因素也是显著的。该模型在不需要任何先验假设或基

本物理理论的情况下，提供了约 6 小时的平均绝对预测误差。尽管 CAT-PUMA 获得了积极的结果，但其平均性能不能由 10 万次实验中的最佳结果来证明。

前面提到的模型依赖于手动选择的参数作为输入。然而，从原始观测中收集参数通常很繁琐，并可能忽视关键因素，导致偏见。此外，手动特征选择需要在 CME 方面具有专业知识。为了解决这些问题，[43]利用来自 SOHO LASCO C2 ([8]) 探测到的 223 个事件的 1122 个 CME 的图像作为输入数据，训练了一个卷积神经网络 (CNN) 回归模型，准确地预测了 CME 的到达时间。所有样本的平均绝对误差 (MAE) 约为 12.4 小时，与之前的研究在相同主题上的平均性能相当。具有固有特性的 CNN 在具有更多训练样本的情况下可以产生更好的结果。不幸的是，1122 个图像的数据集在实验中仍被认为是较小的。

由于观测图像的结构和形状并不能准确反映 CME 在 3D 空间中的实际形状，这是由于在 2D 平面上的投影效应和观测角度的限制，极大地限制了对 CME 物理机制和预测的研究。为了估计 CME 的地磁效应和到达时间，[44] 认为，预测者的经验可以辅助 CME 模型。因此，他们创建了一个基于机器学习的推荐系统，有效地分析历史 CME 事件的影响，并为当前预测工作识别出可比较的事件。此外，他们还构建了一个包含 215 个不同观测和 18 个标准的关联列表，例如 CME 特性、喷发区域坐标和太阳风参数。最后，他们使用推荐算法创建了一个模型，并基于这些列表预测了 CME 的到达时间。测试集的平均绝对误差和均方根误差分别为 11.78 小时和 13.77 小时。这些值与 CME 数据库中发布的其他 CME 模型一致，证明了推荐算法的有效性。基于创新的推荐算法的方法可能在空间天气预测中有许多潜在的应用。

之前的方法存在一些缺点，主要是它们无法在一个综合框架中同

时预测日冕物质抛射的地磁效应和到达时间。因此, [45] 提出了一个新的深度学习框架, 基于卫星的光学观测来预测日冕物质抛射的地磁效应和到达时间。该框架首次将这两个需求整合在一起, 消除了手动特征选择的需求。此外, 深度学习框架仅采用一系列太阳白光和极紫外观测作为唯一输入。[45] 收集了 1996 年至 2018 年间的 2400 个部分或全日冕物质抛射事件及相关图像用于训练和测试。到达时间预测的平均绝对误差仅为 5.8 小时。此外, 地磁效应预测的 F1 得分为 0.27%, 准确率为 75.1%, 与传统方法的最佳结果相当甚至更优。

参考文献:

- [1] Hundhausen A J, Sawyer C B, House L, et al. Coronal mass ejections observed during the Solar Maximum Mission: Latitude distribution and rate of occurrence[J]. *Journal of Geophysical Research: Space Physics*, 1984, 89(A5): 2639-2646. Zhao, X. and Dryer, M., *Space Weather* 12, 7 (2014).
- [2] Sheeley Jr N R, Howard R A, Koomen M J, et al. Coronal mass ejections and interplanetary shocks[J]. *Journal of Geophysical Research: Space Physics*, 1985, 90(A1): 163-175.
- [3] Gosling J T, McComas D J, Phillips J L, et al. Geomagnetic activity associated with Earth passage of interplanetary shock disturbances and coronal mass ejections[J]. *Journal of Geophysical Research: Space Physics*, 1991, 96(A5): 7831-7839.
- [4] Gopalswamy N, Yashiro S, Lara A, et al. Large solar energetic particle events of cycle 23: A global view[J]. *Geophysical research letters*, 2003, 30(12). Boteler, D. H., Pirjola, R. J., and Nevanlinna, H., *Advances in Space Research* 22, 1 (1998).
- [5] Richardson I G, Cane H V. Near-Earth interplanetary coronal mass ejections during solar cycle 23 (1996–2009): Catalog and summary of properties[J]. *Solar*

- Physics, 2010, 264: 189-237.
- [6] Brueckner, G. E., Howard, R. A., Koomen, M. J., Korendyke, C., Michels, D. J., Socker, D. G., and, ..., Coronal Streamers, Coronal Loops, and Coronal and Solar Wind Composition 348, 27, (1992).
- [7] Domingo V, Fleck B, Poland A I. The SOHO mission: an overview[J]. Solar Physics, 1995, 162: 1-37.
- [8] Howard R A, Moses J D, Vourlidas A, et al. Sun Earth connection coronal and heliospheric investigation (SECCHI)[J]. Space Science Reviews, 2008, 136: 67-115.
- [9] Socker, D. G., Howard, R. A., Korendyke, C. M., Simnett, G. M., and Webb, D. F., Instrumentation for UV/EUV Astronomy and Solar Missions 4139, 284 (2000).
- [10] Lemen J R, Title A M, Akin D J, et al. The atmospheric imaging assembly (AIA) on the solar dynamics observatory (SDO)[J]. Solar Physics, 2012, 275: 17-40.
- [11] Pesnell W D, Thompson B J, Chamberlin P C. The solar dynamics observatory (SDO)[M]. Springer US, 2012.
- [12] Möstl C, Isavnin A, Boakes P D, et al. Modeling observations of solar coronal mass ejections with heliospheric imagers verified with the Heliophysics System Observatory[J]. Space Weather, 2017, 15(7): 955-970.
- [13] Mays M L, Taktakishvili A, Pulkkinen A, et al. Ensemble modeling of CMEs using the WSA–ENLIL+ Cone model[J]. Solar Physics, 2015, 290: 1775-1814.
- [14] Wold A M, Mays M L, Taktakishvili A, et al. Verification of real-time WSA–ENLIL+ Cone simulations of CME arrival-time at the CCMC from 2010 to 2016[J]. Journal of Space Weather and Space Climate, 2018, 8: A17.
- [15] Kay C, Gopalswamy N, Reinard A, et al. Predicting the magnetic field of Earth-impacting CMEs[J]. The Astrophysical Journal, 2017, 835(2): 117.
- [16] Kay C, Gopalswamy N, Reinard A, et al. Predicting the magnetic field of

- Earth-impacting CMEs[J]. *The Astrophysical Journal*, 2017, 835(2): 117.
- [17] Zhao X, Dryer M. Current status of CME/shock arrival time prediction[J]. *Space Weather*, 2014, 12(7): 448-469.
- [18] Verbeke, C., Mays, M. L., Temmer, M., Bingham, S., Steenburgh, R., Dumbović, M., and, ..., *Space Weather* 17, 6 (2019).
- [19] Gopalswamy N, Lara A, Yashiro S, et al. Predicting the 1-AU arrival times of coronal mass ejections[J]. *Journal of Geophysical Research: Space Physics*, 2001, 106(A12): 29207-29217.
- [20] Kilpua E K J, Mierla M, Rodriguez L, et al. Estimating travel times of coronal mass ejections to 1 AU using multi-spacecraft coronagraph data[J]. *Solar Physics*, 2012, 279: 477-496.
- [21] Wood, B. E., Wu, C. -C., Lepping, R. P., Nieves-Chinchilla, T., Howard,
- [22] R. A., Linton, M. G., and, ..., *The Astrophysical Journal Supplement Series* 229, 29 (2017).
- [23] Vršnak B, Temmer M, Žic T, et al. Heliospheric propagation of coronal mass ejections: comparison of numerical WSA-ENLIL+ Cone model and analytical drag-based model[J]. *The Astrophysical Journal Supplement Series*, 2014, 213(2): 21.
- [24] Dumbović M, Čalogović J, Vršnak B, et al. The drag-based ensemble model (DBEM) for coronal mass ejection propagation[J]. *The Astrophysical Journal*, 2018, 854(2): 180.
- [25] Shi T, Wang Y, Wan L, et al. Predicting the arrival time of coronal mass ejections with the graduated cylindrical shell and drag force model[J]. *The Astrophysical Journal*, 2015, 806(2): 271.
- [26] Corona-Romero P, Gonzalez-Esparza J A, Aguilar-Rodriguez E, et al. Kinematics of ICMEs/shocks: blast wave reconstruction using type-II emissions[J]. *Solar Physics*, 2015, 290: 2439-2454.

- [27] Millward G, Biesecker D, Pizzo V, et al. An operational software tool for the analysis of coronagraph images: Determining CME parameters for input into the WSA-Enlil heliospheric model[J]. *Space Weather*, 2013, 11(2): 57-68.
- [28] Riley P, Mays M L, Andries J, et al. Forecasting the arrival time of coronal mass ejections: Analysis of the CCMC CME scoreboard[J]. *Space Weather*, 2018, 16(9): 1245-1260.
- [29] Delaboudinière, J. -P., Artzner, G. E., Brunaud, J., Gabriel, A. H., Hochedez, J. F., Millier, F., and, ..., *Solar Physics* 162, 291 (1995).
- [30] Liu Y, Hoeksema J T, Scherrer P H, et al. Comparison of line-of-sight magnetograms taken by the solar dynamics observatory/helioseismic and magnetic imager and solar and heliospheric observatory/Michelson Doppler imager[J]. *Solar Physics*, 2012, 279: 295-316.
- [31] Woods T N, Eparvier F G, Hock R, et al. Extreme Ultraviolet Variability Experiment (EVE) on the Solar Dynamics Observatory (SDO): Overview of science objectives, instrument design, data products, and model developments[J]. *The solar dynamics observatory*, 2012: 115-143.
- [32] Woods T N, Eparvier F G, Hock R, et al. Extreme Ultraviolet Variability Experiment (EVE) on the Solar Dynamics Observatory (SDO): Overview of science objectives, instrument design, data products, and model developments[J]. *The solar dynamics observatory*, 2012: 115-143
- [33] Srivastava N. A logistic regression model for predicting the occurrence of intense geomagnetic storms[C]//*Annales geophysicae*. Göttingen, Germany: Copernicus Publications, 2005, 23(9): 2969-2974.
- [34] Shi Y, Wang J, Chen Y, et al. Impacts of CMEs on Earth Based on Logistic Regression and Recommendation Algorithm[J]. *Space: Science & Technology*, 2022.
- [35] Pricopi, A. -C., Paraschiv, A. R., Besliu-Ionescu, D., and Marginean,

- [36] A. -N., *The Astrophysical Journal* 934, 176 (2022).
- [37] Sudar, D., Vršnak, B., and Dumbović, M., *Monthly Notices of the Royal Astronomical Society* 456, 1542 (2016).
- [38] Liu, J., Ye, Y., Shen, C., Wang, Y., and Erdélyi, R., *The Astrophysical Journal* 855, 109 (2018).
- [39] Korsós M B, Georgoulis M K, Gyenge N, et al. Solar flare prediction using magnetic field diagnostics above the photosphere[J]. *The Astrophysical Journal*, 2020, 896(2): 119.
- [40] Shi, Y. -R., Chen, Y. -H., Liu, S. -Q., Liu, Z., Wang, J. -J., Cui, Y.-M., and, ..., *Research in Astronomy and Astrophysics* 21, 190 (2021).
- [41] Fu H, Zheng Y, Ye Y, et al. Joint Geoeffectiveness and Arrival Time Prediction of CMEs by a Unified Deep Learning Framework[J]. *Remote Sensing*, 2021, 13(9): 1738.
- [42] Hinton, G.E., Osindero, S. & Teh, Y.-W., A fast learning algorithm for deep belief nets, *Neural Comp.* 18, 1527–1554 (2006).
- [43] Bengio, Y., Lamblin, P., Popovici, D. & Larochelle, H., Greedy layer-wise training of deep networks. In *Proc. Advances in Neural Information Processing Systems* 19 153–160 (2006).
- [44] Hinton, G. E., Salakhutdinov, R., Reducing the dimensionality of data with neural networks. *Science*, (2006), 313, 504
- [45] Krizhevsky, Alex , I. Sutskever, and G. Hinton, *ImageNet Classification with Deep Convolutional Neural Networks*, NIPS Curran Associates Inc. 2012.
- [46] Hochreiter, S. & Schmidhuber, J. Long short-term memory. *Neural Comput.* 9, 1735–1780 (1997).
- [47] LeCun, Y., Bengio, Y., Hinton, G., Deep learning. *Nature*, 2015, 521, 436
- [48] H. Purwins, B. Li, T. Virtanen, J. Schlüter, S. Chang, T. Sainath, "Deep learning for audio signal processing", arXiv:1905.00078, 2019.

- [49] <https://www.zhihu.com/question/40873677/answer/682588487>
- [50] <https://sdo.gsfc.nasa.gov>
- [51] <https://sohowww.nascom.nasa.gov>
- [52] https://www.nasa.gov/mission_pages/stereo/main/index.html
- [53] <https://www.spaceweatherlive.com>
- [54] <http://www.sepc.ac.cn>
- [55] <http://www.nsmc.org.cn/NSMC/Home/Index.html>
- [56] <http://rwcc.bao.ac.cn>
- [57] <http://www.spaceweather.org>
- [58] Zharkova V, Ipson S, Benkhalil A, et al., Feature recognition in solar images, *Artificial intelligence review*, 2005, 23(3): 209-266.
- [59] Zharkova V, Schetin V, Filament recognition in solar images with the neural network techniques, *Solar Physics*, 2005, V228(1): 137-148. McIntosh P S. The classification of sunspot groups. *Solar Phys*, 1990, 125: 251–267
- [60] Bradshaw G, Fozzard R, Ceci L. A connectionist expert system that actually works. *Adv Neu Inform Proc Sys*, 1989, 1: 248–255
- [61] Qahwaji R, Colak T. Automatic short-term solar flare prediction using machine learning and sunspot associations. *Solar phys*, 2007, 241:195–211
- [62] Baena M, Morales R. The influence of active region information on the prediction of solar flares: An empirical model using data mining. *Annales Geophys*, 2005, 3129–3138
- [63] Leka K D, Branes G. Photospheric magnetic field properties of flaring versus flare-quiet active regions. IV. A statistically significant sample. *Astrophys J*, 2007, 656: 1173–1186
- [64] Song H, Tan C, Jing J, et al. Statistical assessment of photospheric magnetic features in imminent solar flare predictions. *Solar Phys*, 2008, 254: 101–125
- [65] Yuan Y, Shih F Y, Jing J, et al. Automated flare forecasting using a statistical

- learning technique. *Res Astron Astrophys*, 2010, 10: 785–796
- [66] Ahmed O W, Qahwaji R, Colak T, et al. Solar flare prediction using advanced feature extraction, machine learning, and feature selection. *Solar Phys*, 2013, 283: 157–175
- [67] Liu, Jiajia, Ye, Yudong, Shen, Chenglong, et al. A New Tool for CME Arrival Time Prediction using Machine Learning Algorithms: CAT-PUMA[J]. *ASTROPHYSICAL JOURNAL*, 2018, 855(2):109.
- [68] 王家龙, 张训械, 黄泽荣, 神经网络方法用于太阳质子事件警报, *天体物理学报*, 1999, 19:318
- [69] Li R, He H, Cui Y M, et al. Support vector machine combined with K-nearest neighbors for solar flare forecast. *Chin J Astron Astrophys*, 2007, 7: 441
- [70] Li R, Wang H N, Huang X, et al. Solar flare forecasting using learning vector quantity and unsupervised clustering techniques. *Sci China Phy Mech Astron*, 2011, 54: 1367
- [71] 李蓉, 朱杰, 黄鑫, 崔延美, 基于自动特征提取方法的太阳耀斑预报模型, *科学通报*, 2016, 61:3958
- [72] 李蓉, 崔延美. 结合支持向量机和近邻法的太阳耀斑预报方法[J]. *计算机工程与设计*, 2009, 30(15):3605-3607.
- [73] 李蓉, 崔延美, 贺晗, 等. 基于支持向量机和k近邻的太阳质子事件预报模型[J]. *科学技术与工程*, 2007, 7(15):3649-3654.
- [74] J. D. Jackson. *Classical electrodynamics*. 1975.
- [75] M. Temmer, S. Preiss, and A. M. Veronig. CME Projection Effects Studied with STEREO/COR and SOHO/LASCO. *Sol. Phys.*, 256:183–199, May 2009.
- [76] Cone+ENLIL: D. Odstrcil, P. Riley, X. P. Zhao. Numerical simulation of the 12 May 1997 interplanetary CME event. *Journal of Geophysical Research : Space Physics*, Volume 109, Issue A2, CiteID A02116, 2004.
- [77] <https://swrc.gsfc.nasa.gov/main/cmemodels>

- [78] GL98: Gibson, S. E., & Low, B. C. A Time-Dependent Three-Dimensional Magnetohydrodynamic Model of the Coronal Mass Ejection, 1998, ApJ, 493, 460
- [79] PRM:T. G. Moran and J. M. Davila. Three-Dimensional Polarimetric Imaging of Coronal Mass Ejections. Science, 305:66–71, July 2004. doi: 10.1126/science.1098937.
- [80] Moran, T. G., Davila, J. M., & Thompson, W. T. 2010, ApJ, 712, 453
- [81] GRM:Dai, X., & Wang, H., Electron Density Reconstruction of Solar Coronal Mass Ejections Based on Genetic Algorithm: Method and Application, 2019, arXiv:1902.06953v1
- [82] 戴幸华 . 日冕物质抛射三维重构研究【中科院博士学位论文】. 2015.
- [83] <https://ccmc.gsfc.nasa.gov/models/modelinfo.php?model=BATS-R-US>
- [84] Yu D R, Huang X, Wang H N, et al. Short-term solar flare prediction using a sequential supervised learning method. Solar Phys, 2009, 255: 91–105
- [85] Yu D, Huang X, Wang H N, et al. Short-term solar flare level prediction using a Bayesian network approach. Astrophys J, 2010, 710: 869–877
- [86] Long Xu, et. al., LSTM Neural Network for solar radio spectrum classification, RAA, 2019.
- [87] Lin Ma, Zhuo Chen, Long Xu*, Multimodal Deep Learning for Solar Radio Burst Classification, Pattern Recognition, 2017 (SCI, Top).
- [88] [32] Zhuo Chen, Lin Ma, Long Xu*, Imaging and Representation Learning of Solar Radio Spectrums for Classification, MTAA, 2015
- [89] Teng, F., Deng, Y.Y.: Some tests and improvements to the VFISV: Very Fast Inversion of the Stokes Vector, 2014, RAA, 14(11), 1469.
- [90] Yan Y., Sakurai T. (2001) New Boundary Integral Equation Representation for Finite Energy Force-Free Magnetic Fields in Open Space above the Sun. In: Engvold O., Harvey J.W. (eds) Physics of the Solar Corona and Transition

Region. Springer, Dordrecht.

- [91] Yan Yihua, Li Z.H., Direct Boundary Integral Formulation for Solar Nonconstant alpha Force-free Magnetic Fields, *ApJ*, 2006, 638, 1162.
- [92] Xiaoshuai Zhu, Huaning Wang, Zhanle Du, Han He, Forced field extrapolation of the magnetic structure of the Halpha fibrils in solar chromosphere, April 2016, *ApJ*, 826(1).
- [93] Xueshang Feng, Current Status of MHD Simulations for Space Weather, Magnetohydrodynamic Modeling of the Solar Corona and Heliosphere, 10.1007/978-981-13-9081-4_1, (1-123), (2019).
- [94] A. Glocer, G.Toth, Y. Ma, et. al., Multifluid Block-Adaptive-Tree Solar wind Roe-type Upwind Scheme: Magnetospheric composition and dynamics during geomagnetic storms—Initial results, *Journal of Geophysical Research, Space Physics*, 114(A12), Dec. 2009.
- [95] Sokolov, I. V., Roussev, I. I., Gombosi, T. I., et al. 2004, *ApJL*, 616, L171
- [96] Borovikov, D., Sokolov, I. V., Roussev, I. I., Taktakishvili, A., & Gombosi, T. I. 2018, *ApJ*, 864, 88
- [97] <https://kubernetes.io>
- [98] <https://docs.docker.com/swarm/>
- [99] Hindman, Benjamin, et al. "Mesos: A Platform for Fine-Grained Resource Sharing in the Data Center." *NSDI*. Vol. 11. No. 2011. 2011.
- [100] <http://mesos.apache.org>
- [101] Borthakur, Dhruba. "HDFS architecture guide." *Hadoop Apache Project 53* (2008): 1-13.
- [102] <https://github.com/douban/tfmesos>
- [103] Mitchell, Christopher, Yifeng Geng, and Jinyang Li. "Using One-Sided RDMA Reads to Build a Fast, CPU-Efficient Key-Value Store." *USENIX Annual Technical Conference*. 2013.

- [104] L. Xu, Y. Yan, X. Yu, LSTM Neural Network for solar radio spectrum classification, *Research in Astronomy and Astrophysics (RAA)*, 2019.
- [105] L. Ma, Z. Chen, **L. Xu***, Multimodal Deep Learning for Solar Radio Burst Classification, *Pattern Recognition*, vol. 61, 2017.
- [106] Z. Chen, L. Ma, **L. Xu***, Imaging and Representation Learning of Solar Radio Spectrums for Classification, Springer: *Multimed Tools Appl.*, 2015.
- [107] Zhuo Chen, Lin Ma, Long Xu, Yihua Yan, Multimodal Learning for Classification of Solar Radio Spectrum, SMC2015, Sept. 2015.
- [108] X. Yu, **L. Xu***, Solar Radio Spectrum Classification with LSTM, ICME workshop, 2017.
- [109] S. Chen, **L. Xu***, Convolutional Neural Network for Solar Radio Spectrum Classification, ICME workshop, 2017
- [110] Wang L, Li J, Wu Y, et al. 2022, Identification of New Classical Be Stars from the LAMOST Medium Resolution Survey , *APJS*, 260 35
- [111] Wu, Y., Li, J., Liu, C., Hu, Y., Xu, L., Li, T., Chen, X., Han, Z. 2022, Deep learning for detecting wide binaries. I. The PSF-based method, submitted to *APJS*
- [112] LeCun, Y., Bengio, Y., Hinton, G., Deep learning. *Nature*, 2015, 521, 436
- [113] Krizhevsky A, Sutskever I, Hinton G E. ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 2012, 25
- [114] Taigman Y, Yang M, Ranzato M, et al. DeepFace: Closing the Gap to Human-Level Performance in Face Verification, 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE Computer Society, 2014, 1701

- [115] Baccouche M, Mamalet F, Wolf C, et al. Sequential Deep Learning for Human Action Recognition, Human Behavior Understanding. Springer Berlin Heidelberg, 2011, 29
- [116] Jean S, Cho K, Memisevic R, et al. On Using Very Large Target Vocabulary for Neural Machine Translation. Eprint Arxiv, 2014.
- [117] Graves A, Jaitly N, Mohamed A R. Hybrid speech recognition with Deep Bidirectional LSTM, Automatic Speech Recognition and Understanding (ASRU), 2013 IEEE Workshop on. IEEE, 2013, 273
- [118] Wu Z, Wang X, Jiang Y G, et al. Modeling spatial-temporal clues in a hybrid deep learning framework for video classification[C]//Proceedings of the 23rd ACM international conference on Multimedia. ACM, 2015: 461-470
- [119] Qahwaji R, Colak T. Automatic short-term solar flare prediction using machine learning and sunspot associations. Solar phys, 2007, 241: 195
- [120] Baena M, Morales R. The influence of active region information on the prediction of solar flares: An empirical model using data mining. Annales Geophys, 2005, 3129
- [121] Song H, Tan C, Jing J, et al. Statistical assessment of photospheric magnetic features in imminent solar flare predictions. Solar Phys, 2008, 254: 101
- [122] Yuan Y, Shih F Y, Jing J, et al. Automated flare forecasting using a statistical learning technique. Res Astron Astrophys, 2010, 10: 785
- [123] Ahmed O W, Qahwaji R, Colak T, et al. Solar flare prediction using advanced feature extraction, machine learning, and feature selection. Solar Phys, 2013, 283: 157
- [124] 王家龙, 张训械, 黄泽荣, 神经网络方法用于太阳质子事件警报, 天体物理学报, 1999,19:318
- [125] Li R, He H, Cui Y M, et al. Support vector machine combined with K-nearest neighbors for solar flare forecast. Chin J Astron Astrophys, 2007, 7: 441

- [126] Li R, Wang H N, Huang X, et al. Solar flare forecasting using learning vector quantity and unsupervised clustering techniques. *Sci China Phy Mech Astron*, 2011, 54: 1367
- [127] 李蓉, 朱杰, 黄鑫, 崔延美, 基于自动特征提取方法的太阳耀斑预报模型, *科学通报*, 2016,61:3958
- [128] Wang H N, Cui Y M, Li R, et al. Solar flare forecasting model supported with artificial neural network techniques. *Adv Space Res*, 2007, 42: 1464
- [129] Yu D R, Huang X, Wang H N, et al. Short-term solar flare prediction using a sequential supervised learning method. *Solar Phys*, 2009, 255: 91
- [130] Yu D R, Huang X, Wang H N, et al. Short-term solar flare prediction using multi-resolution predictors. *Astrophys J*, 2010, 709: 321
- [131] Yu D, Huang X, Wang H N, et al. Short-term solar flare level prediction using a bayesian network approach. *Astrophys J*, 2010, 710: 869
- [132] Huang X, Wang H N. Solar flare prediction using highly stressed longitudinal magnetic field parameters. *Res Astron Astrophys*, 2013, 13: 351
- [133] Huang X, Zhang L Y, Wang H N. Improving the performance of solar flare prediction using active longitudes information. *Astron Astrophys*, 2012, 549: A127
- [134] Huang X, Wang H N, Dai X H. Influences of misprediction costs on solar flare prediction. *Sci China-Phys Mech Astron*, 2012, 55: 1956
- [135] Huang X, Yu D, Hu Q, Wang H, Cui Y. Short-Term Solar Flare Prediction Using Predictor Teams. *Solar Phy.*, 2010, 263: 175
- [136] Huang X, Wang H, Xu L, Liu J, Li R, Dai X. Deep Learning Based Solar Flare Forecasting Model. I. Results for Line-of-sight Magnetograms, *The Astrophysical Journal*, 2018 in press
- [137] McIntosh P S. The classification of sunspot groups. *Solar Physics*, 1990, 125(2): 251-267

- [138] Atac, T., Statistical Relationship between Sunspots and Major Flares.
Astrophysics and Space Science, 1987, 129, 203
- [139] Wang, H., Evolution of vector magnetic fields and the August 27 1990 X-3 flare,
Sol. Phys., 1992, 140, 85
- [140] Wang, T.J., Xu, A., Zhang, H.Q., Evolution of vector magnetic fields and
vertical currents and their relationship with solar flares in AR 5747, Sol. Phys.,
1994, 155, 99
- [141] Wang, J., Shi, Z., Wang, H., Lu, Y., Flares and the magnetic nonpotentiality,
Astrophys. J., 1996, 456, 861
- [142] Bao, S.D., Zhang, H.Q., Ai, G.X., Zhang, M., A survey of flares and current
helicity in active regions, Astron. Astrophys. Suppl. Ser., 1999, 139, 311
- [143] Cui, Y., Li, R., Zhang, L., et al. Correlation between Solar Flare Productivity
and Photospheric Magnetic Field Properties. Solar Physics, 2006, 237, 45
- [144] Leka, K.D., Barnes, G., Photospheric magnetic field properties of flaring versus
flare-quiet active regions. I. Data general approach and sample results,
Astrophys.J. , 2003, 595, 1277
- [145] Leka, K.D., Barnes, G., Photospheric magnetic field properties of flaring versus
flare-quiet active regions. II. Discriminant analysis, Astrophys.J. , 2003,585,1296
- [146] Dezhi Sun, Xin Huang, Zhongrui Zhao, Long Xu, Deep-learning-based Solar
Flare Forecasting Model. III. Extracting Precursors From EUV Images, Major
revision, under second round of review, ApJS.
- [147] Liu S, Xu L, et al., Deep Learning Based Solar Flare Forecasting Model. II.
Influence of Image Resolution, ApJ, Nov. 2022.
- [148] W Sun, L Xu, S Ma, Y Yan, T Liu, W Zhang, A Dynamic Deep-learning Model
for Generating a Magnetogram Sequence from an SDO/AIA EUV Image
Sequence, The Astrophysical Journal Supplement Series 262 (2), 45.

- [149] F Dou, L Xu, Z Ren, D Zhao, X Zhang, Super-resolution of Solar Magnetograms Using Deep Learning, *Research in Astronomy and Astrophysics* 22 (8), 085018.
- [150] F. Gao, T. Liu, W. Sun, Long Xu*, Generating Space-based SDO/HMI-like Solar Magnetogram from Ground-based Ha Image by Deep Learning, *ApJS*, 2023.
- [151] X Yu, L Xu*, Y Yan, Image Desaturation for SDO/AIA Using Deep Learning, *Solar Physics* 296 (3), 1-14, 2021.
- [152] X Yu, L Xu, Z Ren, D Zhao, W Sun, Image Desaturation for SDO/AIA Using Mixed Convolution Network, *Research in Astronomy and Astrophysics* 22 (6), 2022.
- [153] Xinze Zhang, Long Xu, Zhixiang Ren, Xuexin Yu, Jia Li, Attention-Based Deep Learning Model for Image Desaturation of SDO/AIA, *RAA*, Vol. 23, no. 8, 2023.

第 8 章 雷达智能信息处理

8.1 引言

随着雷达探测技术和体制的不断提高,对探测距离、探测精度、目标精细化描述能力、信息处理的智能化水平的要求也越来越高。雷达对海探测能力的提升,需根据探测环境的变化,精准地实现杂波抑制、目标特性匹配及特征描述,才能有效提升目标的检测和快速识别能力。传统雷达目标探测主要基于模型假设,即需要假设背景的分布类型和分布特性等信息。例如,基于统计模型的检测方法将雷达回波建模为随机过程,建立相应的统计模型构造检测统计量。然而,当模型与实际环境或目标不匹配,则会导致性能下降,普适性较差,通用性不强。近年来,以深度学习为代表的人工智能方法在图像识别等计算机视觉领域的巨大成功极大促进了其在各个领域的应用。深度学习通过构建深度卷积神经网络(CNN)在海量数据样本中逐层抽象挖掘有用信息,极大减轻了对模型假设的依赖。本章将分别从雷达信号处理、雷达图像处理两个方面,介绍深度学习在雷达智能信息处理中的主要技术和应用,并对未来的发展趋势进行展望。

8.2 基于深度学习的雷达信号处理

8.2.1 噪声与杂波抑制

当对接收到的雷达图像进行图像处理和分析,提取目标信息时,去除噪声和杂波是首要任务。杂波是目标所在背景环境的散射信号。杂波和热噪声类似,其相位和幅度是随机的。对于背景环境的不同,比如地形地貌、表层复介电常数不均匀、海平面的风速、海面的海水蒸发等都会影响杂波。杂波一般是通过概率模型来建立的,杂波统计特性包含包络的概率分布及正交分量的相关性。经典杂波抑制及目标检测算法通常基于目标与杂波之间的能量或多普勒频谱差别。常用的方法包括非相参积累和恒虚警检测,这些方法基于统计模型假设,对

环境的适应能力不强，容易受到杂波非高斯分布特性的影响，而且频谱展宽会影响到滤波器凹口的实现。针对传统方法在海杂波抑制中出现的问题，需要结合雷达回波信号特征提出新的方法进行改进。

近年来，机器学习得到了飞速发展，特别是深度学习模型，在数据特征提取方面体现出强大的能力。近年来基于深度学习的处理海杂波的方法不断被提出，多集中在 SAR 雷达图像检测、目标或干扰源识别等领域。不同的应用场景下的杂波分布不同，因此基于深度学习的杂波抑制方法种类繁多。在 CNN 的卷积滤波过程中，深度学习分类器在训练过程中可以学习杂波和噪声模式。杂波对其他分类器的性能有重大影响，而深度学习架构拥有着自动消除杂波的能力。陈小龙等人利用传统的机器学习提出基于概率无向图模型的杂波抑制方法，但模型存在无向图权重无法自适应、模型参数需要人为调节的问题。针对概率无向图模型中存在的问题，将无向图的构建交由图卷积神经网络进行学习，如图 8-1 所示，提取特征，从而实现了对雷达接收回波中杂波的抑制^[1]。

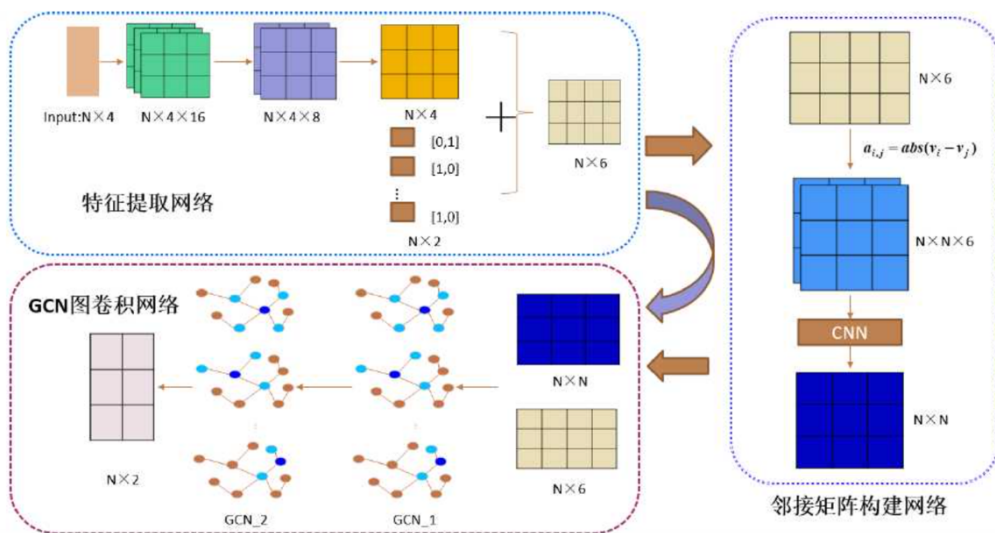


图 8-1 基于图卷积神经网络的杂波抑制方法框架

针对雷达回波数据庞大，处理需要较长的时间的问题。韩冰鑫提出一种基于遗传算法 (Genetic Algorithm, GA) 优化反向传播 (Back Propagation, BP) 神经网络的雷达杂波抑制方法^[1]，在数据输入时，

利用遗传算法对神经网络的输入自变量进行优化选择，降低输入数据维度，缩短建模时间。针对多特征、多目标的杂波抑制问题，施端阳等人提出基于学习向量量化(Learning Vector Quantization, LVQ)神经网络的雷达杂波抑制方法，如图 8-2，根据特征数量和点迹类别数量构建 LVQ 神经网络分类模型，并对模型进行训练，该方法能够有效区分目标点迹和杂波点迹，杂波抑制能力比 BP 神经网络算法更好 [4]。

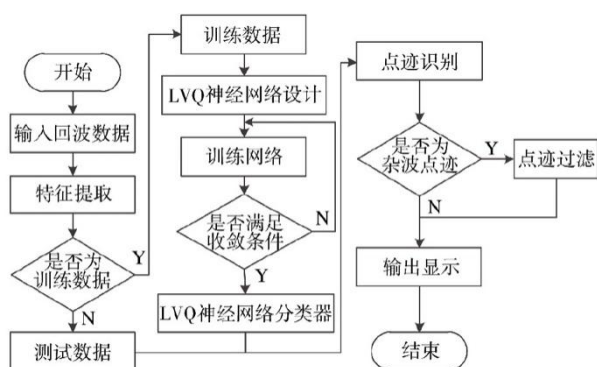


图 8-2 LVQ 神经网络雷达杂波抑制流程图

文献 [5] 利用接收回波信号的多维域互补特征，提出了一种基于深度学习并利用时频特性的海杂波抑制方法，采用离散小波变换(DWT)将回波信号分解为不同的子带。与现有的海杂波抑制方法相比，该方法利用了时频信息，有利于目标识别，如图 8-3。

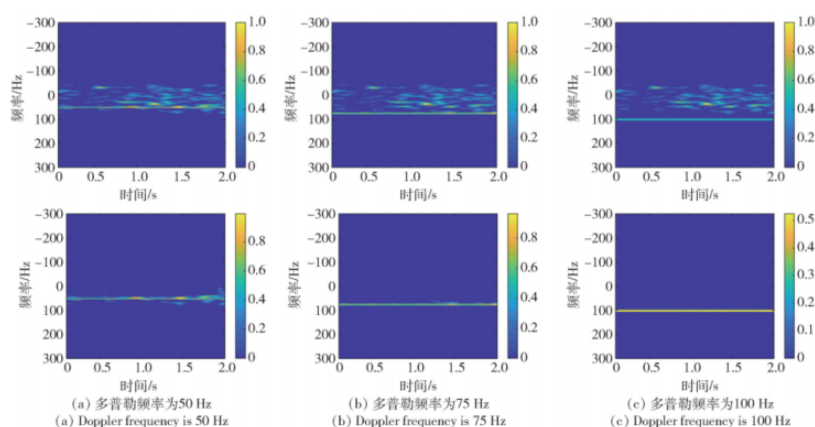


图 8-3 基于卷积神经网络的海杂波抑制前后时率谱

一些场景下杂波具有非均匀性，传统空时自适应处理(STAP)方法无法直接应用。X. Tang 等人提出了基于复值 U-Net(CV-UNet)的杂波

抑制方法^[6]。首先,通过开发复值卷积块来提取雷达回波序列的复杂信号特征。其次,通过采用上下采样结构和跳跃连接来融合复杂的多级特征,以抑制非均匀海杂波。段克清等人分析了天基预警雷达非均匀杂波分布特性,构建了基于卷积神经网络(CNN)超分辨谱估计的STAP处理框架^[7]。针对海尖峰等强海杂波问题可能会导致信杂波比(SCR)较低,对雷达海洋目标检测造成较大干扰,海军航空大学陈小龙等人设计了一种新型海杂波抑制生成对抗网络(SCS-GAN),并将其用于海洋雷达平面位置指示器(PPI)图像检测^[8]。

深度学习的网络模型繁多,针对不同环境的杂波特性,利用不同的网络均有良好的杂波抑制效果。雷达噪声抑制是一种旨在减少或消除雷达系统中的噪声干扰,从而提高雷达的性能和可靠性的技术。对于雷达系统的噪声抑制的研究,各国很早就已经进行了深入的研究。常见而有效的噪声抑制方法,比如门限法,平均对消法,小波变换法等。这些方法在其特定的条件下,都可以取得很好的耦合抑制效果,它们都可以有效的抑制了直接反射的回波耦合噪声以及环境噪声。对于连续波体制的雷达,发射天线与接收天线之间的耦合噪声是最重要的噪声干扰。对于这部分干扰需要进行信号预处理工作,现在常见的抑制方法有回波域去噪方法以及图像域信号增强技术。

传统的噪声抑制算法依赖于环境、系统特性,需要特定的条件下才取得较好的耦合抑制效果。小目标、集群目标等微弱信号很容易被噪声影响,深度学习技术能改善这一现状,在不同环境、系统下都有良好的抑制效果。杨宏宇等人提出一种基于深度卷积神经网络(DCNN)的气象雷达噪声图像语义分割方法。实验结果表明,该文方法对气象雷达图像的去噪效果较好^[9]。Z. Cui 等人提出了一种通过 CenterNet 在大规模 SAR 图像中进行船舶检测的方法。CenterNet 中引入了空间洗牌组增强(SSE)注意力模块,在抑制部分噪声的同时,提取更强的语义特征,以减少近海和内陆干扰造成的误报^[10]。X. Ye 等人结合生

成对抗网络(GAN)来抑制 ISAR 检测到的微簇目标的噪声^[11]。自适应滤波是根据噪声统计特性和信号特征,动态调整滤波器参数,以最大程度地抑制噪声的干扰。Zhou 等人噪卷积神经网络(CNN)框架应用于 500MHz LPR 数据的噪声抑制和微弱信号提取。与经典的带通滤波器和均值滤波器相比,CNN 滤波器在处理噪声干扰和微弱信号提取时具有更好的性能^[12]。

8.2.2 目标信号增强

信号增强工作在本质上和信号降噪工作相同,典型的传统降噪技术主要包括短时傅里叶变换(Short-Time Fourier Transform, STFT)、基于小波变换(Wavelet Transform, WT)算法、基于希尔伯特-黄变换(Hilbert-Huang Transformer, HHT)的经验模式分解算法(Empirical Mode Decomposition, EMD)等,随着深度学习的广泛应用,也有部分研究学者提出了一些深度学习方法对信号进行增强并取得了较好的效果。

深度学习技术在目标信号增强中得到广泛应用。通过使用卷积神经网络(CNN)、生成对抗网络(GAN)和自编码器等深度学习模型,可以学习目标信号的特征表示和噪声模型,从而实现目标信号的增强和去噪。针对雷达信号侦察领域中微弱信号检测困难的问题,耿常青等人提出了一种利用卷积神经网络算法增强微弱信号的方法^[13]。在 TensorFlow 框架下,首先对信号做短时傅里叶变换,通过监督学习训练,在含噪频谱和纯净频谱之间建立关系,最后将训练成熟的网络用于提高微弱信号的信噪比,实现了信号增强的目的,实验结果如图 8-4,左到右对应分别是纯净信号、输入(-3dB)和(0dB)。




图 8-4 常规信号、线性调频信号和二相编码混合信号的增强过程

曹鹏宇等人构建噪声增强网络与信号增强网络进行对抗训练，如图 8-5 所示，在对抗训练的过程中，噪声增强网络生成复杂高维噪声的能力和信号增强网络降噪的能力都得到了提升^[14]。

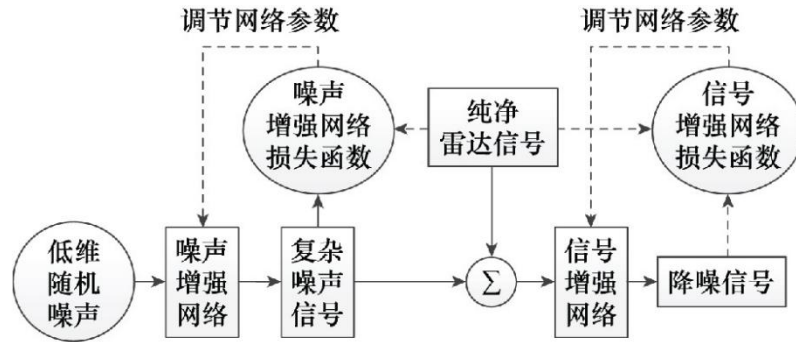


图 8-5 DAE-GAN 系统框图

苏琮智等人设计嵌入层对信号进行分块处理，结合多头注意力机制 (MSA) 建立 RSETransformer 增强模型，如图 8-6。根据信号增强评价指标对损失函数进行设计，通过网络训练隐式地挖掘出带噪雷达信号和纯净雷达信号之间的非线性映射关系，得到包含最优参数的模型实现对信号的增强^[15]。

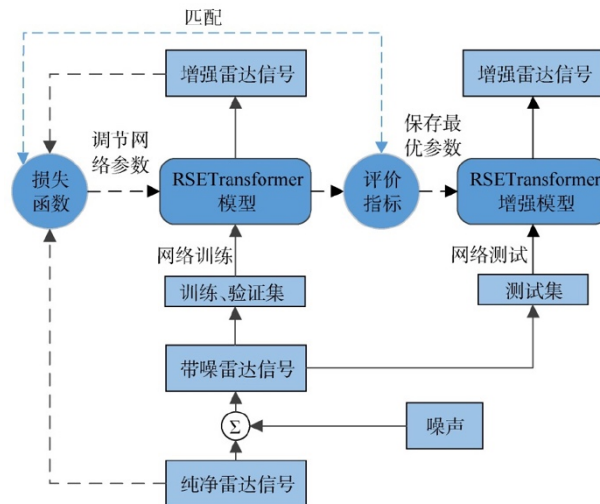


图 8-6 基于 RSETransformer 的信号增强算法系统框图

未来，随着深度学习、传感器技术和算法优化的进一步发展，目标信号增强将继续取得突破。这将为各个领域的目标检测、跟踪和识别任务提供更好的性能和效果。

8.2.3 雷达目标检测

雷达目标检测和分类是雷达信号处理的重要分支,对于目标的搜索、监视、跟踪和识别起着至关重要的作用,在国防战略安全和日常生活中应用广泛。可靠和稳健的目标检测和分类技术的难点主要体现在目标回波微弱、目标运动类型复杂多样、机动导致多普勒时变等。雷达在探测动目标时不仅受到目标机动性的影响,还受杂波和噪声等干扰,在实际的复杂背景下检测难度大。

传统雷达目标检测方法主要是基于统计特性的方法,可分为似然比检测(Likelihood Ratio Test, LRT)技术、检测前跟踪(Track Before Detect, TBD)技术和恒虚警率检测技术。似然比检测是基于统计特性的检测方法中最基础的检测理论,目前主要对其改进技术进行研究。检测前跟踪技术是将连续的多帧数据进行能量积累后与门限进行判决,实现目标检测,再通过航迹回溯,实现目标跟踪。TBD同时利用了单次扫描脉冲串积累和多次扫描间积累,对微弱目标具有较好的检测能力。恒虚警率检测技术按背景环境分为杂波中的CFAR检测和噪声中的CFAR检测,分别对应背景快起伏和慢起伏两种状态。杂波的统计特性比噪声的更复杂。因此,目前的研究对象主要是杂波中的CFAR检测。

现代雷达的空间分辨率和多普勒分辨率显著提升,回波信号更加复杂,承载的信息量更多。回波信号的复杂性导致对其统计建模的难度增加,传统的基于统计特性的检测方法应用受限。但回波信号中包含的丰富信息为基于特征的检测技术提供了有利条件。特征检测方法从模式分类的角度出发,提取回波信息中有用的特征,利用目标和干扰的特征差异性对两者予以区分,实现目标检测功能,如图8-7。深度学习目标检测方法是一种特征检测方法,也属于现代雷达目标检测方法。与机器学习方法相比,深度学习方法具有特征自动提取、分类准确度高、鲁棒性和泛化性强等优势。




图 8-7 雷达目标检测结构示意图

传统的特征提取算法和分类器采用的浅层结构无法充分利用雷达目标的原始测量数据，并且很容易忽略数据中的隐藏信息。针对这一问题，Y. Kong 等人将自动编码器和卷积神经网络相结合，提出了一种基于复合深度网络的目标识别方法^[16]。T. Tang 等人则将循环神经网络应用于基于微多普勒效应的雷达目标识别。使用四种类型的 RNN 来捕获时频分布矩阵的潜在序列相关性，实验结果显示出良好的性能^[17]。

受复杂海洋环境影响，基于统计理论的海面目标检测方法由于假设条件不成立，在实际应用中难以实现高性能检测；此外，由于目标的运动特性多种多样，仅使用单一特征进行检测是不可靠的。海军航空大学陈小龙等人从特征提取分类角度，通过深度学习分类方法对目标和杂波的雷达回波信号进行二元分类，提出了一种基于双通道卷积神经网络 (DCCNN) 的雷达海上目标智能检测方法^{[18][19]}。测试结果表明：与传统的单通道 CNN 以及无虚警控制 Hog-SVM 分类算法相比，基于二维卷积核 VGG16 和一维卷积核 LeNet 的 DCCNN 特征提取模型和 Softmax 分类器可实现更高的检测性能，并可以实现虚警率控制，为复杂海杂波背景下目标智能检测提供了新的技术途径。

为了提高检测的成功率，有学者提出基于深度学习的融合多域、多维特征检测方法。文献^[20]提出了一种新的基于目标帧间多维特征的目标检测方法及相应的神经网络模型 RDF-ResNet，如图 8-8。通过在解模糊过程中提取疑似目标帧间多维特征并输入到 RDF-ResNet 中，实现在特征空间上对虚警的抑制，结合低阈值检测，实现检测率的有效提升。文献^[21]提取 HRRP 序列内部的时间依赖性和多域特征，提出

了一种用于 RATR 的端到端多输入卷积门控循环单元神经网络，称为 MIConvGRU，通过利用多域和时间信息来提高 HRRP 目标的识别性能。



图 8-8 基于多帧联合目标检测流程概览

深度学习进行雷达目标识别效果取决于雷达图像的质量和训练样本的数量。雷达回波数据通常很庞大，人工标注的样本较少。针对训练样本有限且质量较差，普通深度学习的方法会导致严重的过拟合的问题，文献^[22]提出了一种物理模型与深度学习相结合的新方法。施端阳等人引入迁移学习思想，使用预训练过的卷积神经网络自动提取图像中的深层特征，以达到减少雷达图像训练样本量的目的，如图 8-9。实测数据的实验结果表明：与传统的恒虚警率检测方法相比，该方法提高了雷达目标检测率，降低了虚警率，解决了检测率与虚警率的矛盾^[23]。

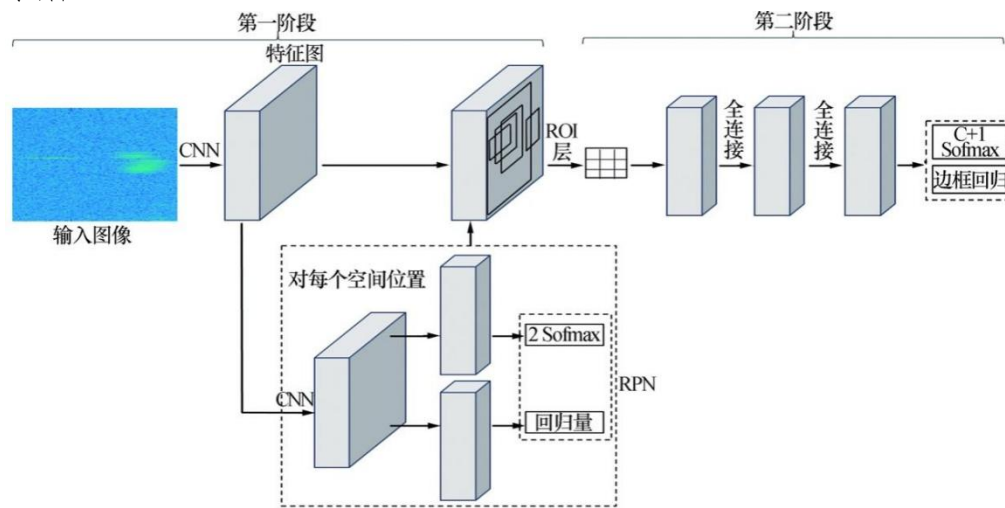


图 8-9 Faster R-CNN 雷达目标检测流程

受知识驱动模型思想的启发，T. Chen 等人提出了一种基于卷积神经网络 (ADAM-CNN) 的自适应领域知识与注意力机制相结合的新模型^[24]。在提出的模型中，将领域知识作为边信息 (SI) 引入到卷积模块中，引导模型充分利用领域知识引入的目标的先验信息，构建训练和测试阶段之间的数据分布映射，以克服小样本问题和低信噪比问题。

然后,通过卷积块注意力模块(CBAM)引入注意力机制,通过捕获 HRRP 的全局信息来引导模型聚焦于具有更多目标散射信息的距离单元,从而进一步减少所提出的模型对数量的依赖。实验结果证明 ADAM-CNN 模型具有良好的防止小样本过拟合的能力,并且具有良好的抗噪声性能。J. Qin 等人则提出了一种新颖的端到端扩展方法,称为带有梯度惩罚条件的深度卷积生成对抗网络(CWDCGAN),以实现指定类别的 SAR 图像扩展^[25]。此外,典型 ATR 系统中的特征提取和分类器设计往往严重依赖主观专家知识,这严重影响了其泛化性能。因此,采用 Resnet18 和支持向量机(Resnet18-SVM)的联合识别方法来提高泛化能力和识别性能。

随着深度学习技术的逐渐成熟,对雷达回波图像数据进行深度学习目标检测取得了较好的效果,但是深度学习技术也面临着理论和工程上的挑战。在理论方面,深度学习检测技术的可分析性和可解释性较差。目前,深度神经网络中参数的确定无法进行定量的分析,只能通过实验结果的好坏来确定,各参数的设置依据和原理尚不知晓。在工程方面,深度学习技术依赖于大量的训练样本和大规模的并行计算。目前,带标签的雷达图像数据集的质量和数量有限,大多都是研究者自行采集、制作的数据集,通用性较差。

8.2.4 阵列雷达信号处理

阵列信号处理是指将一组传感器按一定的方式布置在空间不同位置上,形成传感器阵列,用传感器阵列接收空间信号,相当于对空间分布的场信号采样,得到信号源的空间离散观测数据。其任务是从噪声和干扰中检测有用信号,估计信号波形,对接受的信号与噪声场进行时空谱估计,估计信号到达方向,对信号源定位,主要包括波束形成、参数估计和目标检测。

波束形成是提高系统中接收信号质量的有效手段。现有的和速率最大化(SRM)问题技术只能获得局部最优解,且由于复杂的矩阵运算

和迭代，需要大量的计算量。传统上，寻找最优波束形成解决方案依赖于迭代算法，这会引入较高的计算延迟，因此不适合实时实现。H. Huang 等人提出了一种基于深度学习的快速波束成形设计方法，无需复杂的操作和迭代^[26]，仿真结果表明，此方法速度很快，同时获得了与最先进方法相当的性能。W. Xia 等人则提出了一种用于的基于卷积神经网络和利用专家知识的深度学习框架优化波束成形^[27]，仿真结果表明，与现有算法相比，所提出的 BNN 解决方案在性能和复杂性之间提供了良好的平衡。

雷达阵列天线接收到的期望信号和干扰信号，其入射的到达角度 (Angle of Arrival, AOA) 总是快速变化的，而传统波束形成算法计算量大，无法实时计算。针对这一问题，任燕飞等人提出了一种基于深度神经网络的自适应波束形成 (Deep Neural Network Adaptive Beamforming, DNNABF) 算法^[28]，用入射信号 AOA 组成的向量作为网络输入，网络输出逼近最小方差无失真响应 (Minimum Variance Distortionless Response, MVDR) 算法求得的权矢量，实验结果，如图 8-10 所示。




图 8-10 DNN、CNN 与 MVDR 天线方向图

同样地，中山大学也提出了一种基于深度学习的阵列稳健自适应波束形成方法^[29]。针对计算得到的信号协方差矩阵可能会出现数据缺失的情况，丁梓航等人提出了一种基于深度学习的 FDA-MIMO 雷达协方差矩阵数据恢复方法^[30]，并建立了协方差矩阵恢复-自适应波束形

成的两阶段处理框架，一种双通道生成对抗网络(GAN)来解决矩阵数据恢复问题，实验结果，如图 8-11 所示。




图 8-11 基于不同协方差矩阵的 FDA-MIMO 雷达波束方向图(多干扰源)

在雷达波形及阵列设计方面，深度学习主要用于：

(1) 以频谱共享为目的的发射功率谱设计^[31]：研究人员研究了未来国防部雷达系统将如何与商业通信系统共享频谱。该团队使用机器学习来了解频谱中不断变化的干扰行为，并找到干净的频谱以最大限度地提高雷达性能。一旦识别出干净的频谱，就可以修改波形以最适合频谱。

(2) 多发多收(MIMO)雷达发射波形设计与优化^[32]：研究人员设计了一种快速、优良、自相关和互相关良好的单模波形的多输入多输出雷达设计方法。与仅优化部分指标或仅在可接受的时间内优化短序列的现有方法不同，我们提出了一种综合波形设计方法，以在恒模约束下最小化几乎全部指标的加权和。然后，衍生了一个深度学习框架，称为综合优化网络来处理该问题。数值结果表明，与现有方法相比，该方法具有优越的性能和可接受的优化时间。

(3) 天线阵设计，主要研究方向为 MIMO 雷达子阵设计与优化^[33]：研究人员构建了一个卷积神经网络(CNN)作为多类分类框架，其中每个类指定一个不同的子数组。所提出的网络每次雷达接收到数据时都会确定一个新的阵列，从而使天线选择成为一种认知操作。实验表明，所提出的 CNN 结构比支持向量机提供了 22% 更好的分类性能，并且生

成的子阵列产生的 DoA 估计比随机阵列选择准确 72%。

8.3 基于深度学习的雷达图像处理

8.3.1 雷达低分辨图像处理

雷达扫描模式得到的回波信号为二维方位-距离矩阵，转换为图像后相较于雷达的一维回波序列，在数据形式上包含了空间相关性，相比于 SAR 图像、时频图和距离-多普勒图像等，方位-距离图像由采集的原始数据生成，数据结构的原始性和完整性强，利用卷积神经网络提取特征能够得到更加充分的特征信息，为改善面对复杂背景环境和目标特性时检测性能不佳的问题提供了新的解决途径。

雷达 P 显图(PPI Display)是一种典型的通过极坐标的形式反映雷达距离-方位信息的显示方式。回波的强度可以通过不同的颜色或灰度来表示，用于显示目标的强度信息。通常情况下，雷达站点位于图形的中心，目标的位置由中心点向外延伸的线表示。当目标靠近雷达站点时，线条越接近中心点，表示目标距离雷达站点越近。目标的运动可以通过不同的扫描周期下的回波位置变化来观察。可以帮助雷达操作员了解目标的位置、距离和运动趋势，从而做出相应的决策和措施。此外，通过对 P 显图的观察，还可以识别目标的类型、大小和形状等信息。总之，雷达 P 显图是一种常见的雷达显示方式，用于在水平平面上绘制雷达回波数据，以显示目标的位置、距离和运动情况。陈小龙等人通过将雷达回波转换成 P 显图像，构建训练集(如图 8-12)，然后通过提出的 Precise ROI-Faster R-CNN 目标检测模型进行训练^[34]，然后将实时的回波数据 P 显图像交给模型处理完成目标检测，具体流程如图 8-13 所示。




图 8-12 海上目标雷达图像数据集示意图

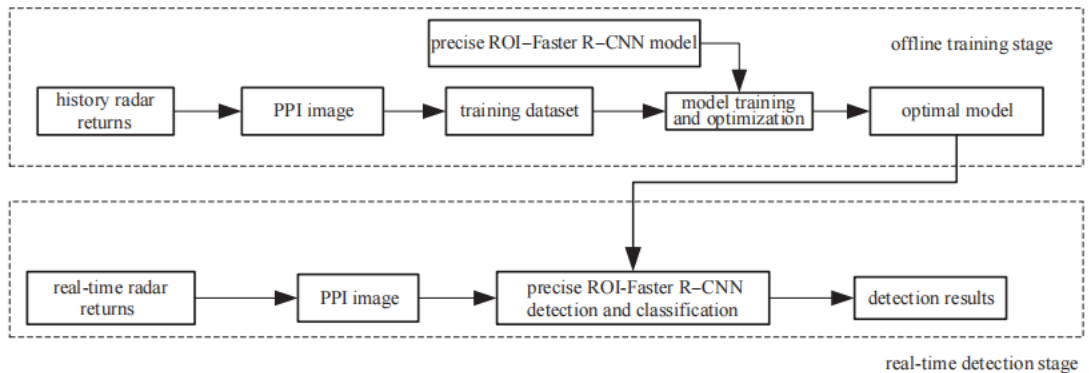


图 8-13 雷达图像海上目标检测算法流程图

传统的雷达目标检测算法大多基于统计理论。它们对于复杂海杂波环境和多样化目标特征的泛化能力较弱，其检测性能会显著下降。Xiaolong.Chen 等人将扫描雷达获得的距离-方位-帧信息转换为平面位置指示器 (PPI) 图像，提出了雷达-PPInet^[35]，并将其用于海洋目标检测，如图 8-14 所示。

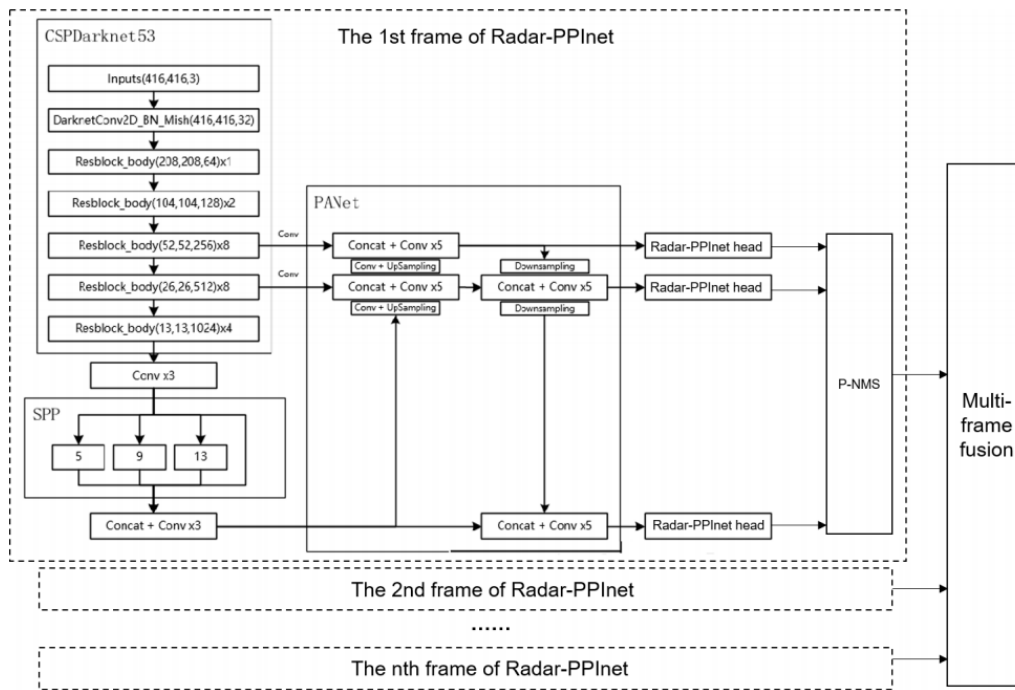


图 8-14 所提出的 Radar-PPInet 的结构

该模型包括 CSPDarknet53、SPP、PANet、功率非极大值抑制 (P-NMS) 和多帧融合部分。通过特征提取网络直接给出预测框坐标、目标类别和相应的置信度。该网络结构强化了感受野和注意力分布结构，进一步提高了网络训练的效率。P-NMS 可以有效改善多目标的漏检问题。而且，多帧融合减少了强海杂波引起的误报，这对于弱目标检测也是一个好处。利用 X 波段导航雷达 PPI 图像数据集的验证表明，与传统的单元平均恒定虚警率检测器 (CA-CFAR) 和两阶段 Faster R-CNN 算法相比，该方法显着提高了检测概率在一定误报概率条件下分别提高 15% 和 10%，更适合各种环境和目标特性。此外，讨论了计算负担，表明 Radar-PPInet 检测模型在参数和计算方面明显低于 Faster R-CNN。图 8-15 显示了 Faster R-CNN 和雷达-PPInet 对单幅雷达 PPI 图像的检测结果，a 表示原始海岸 PPI 图像；b 表示 Faster R-CNN；c 表示 Radar-PPInet；d 表示公海 PPI 原始图像；f 表示 Faster R-CNN；g 表示 Radar-PPInet。在沿海环境中，由于目标数量多且分布密集，使用两阶段算法 Faster R-CNN 很容易出现漏标和误报的情况。从 05b、f 可以清楚地看出，当某些目标较大且回波较强时，可能会出现两个

检测框，从而降低检测精度。当某些目标嵌入或接近复杂环境时，网络会将其判断为环境的一部分。原因可能是生成的数据集中不存在类似的目标环境特征；另一方面，训练损失太大。为了保证不发生拟合，步长设置过大，会导致训练不足。与 Faster R-CNN 相比，Radar-PPInet 具有更好的检测性能，如图 8-15 (c)、(g) 所示。在沿海环境中，Radar-PPInet 可以有效应对复杂环境和多目标，并准确预测大多数目标的位置。在公海环境下，所有目标均可被探测到。Radar-PPInet 强化了网络结构中的感受野和注意力分布结构。通过重复使用卷积后提取的特征图，即进行多次上下采样和残差堆叠，进一步增强了网络训练效率。




图 8-15 Faster R-CNN 和 radar-ppinet 对单张雷达 PPI 图像的检测结果

海洋目标检测一直是目标检测领域的重要课题，国内外学者已取得了丰硕的研究成果，但传统的检测方法仍存在海杂波对目标检测干扰大、目标检测能力有限等问题。近年来，深度学习在目标检测领域得到快速发展和广泛应用，但目前尚无深度学习应用于导航雷达的相关研究。Mou 等人提出了一种基于 Marine-Faster R-CNN 的导航雷达 P 显图像的海洋目标检测方法^[36]，提出了一种特征融合网

络 (Feature Fusion Network, FFNet) 作为 Faster R-CNN 的骨干网络，其次，针对样本的平衡性、多目标检测、尺度归一化的精确性、锚点的尺度等四个方面对 Faster R-CNN 进行了优化，以进一步提高模型检测的准确率和降低虚警率，最终得到 Marine-Faster R-CNN 模型。具体模型如图 8-16 所示。

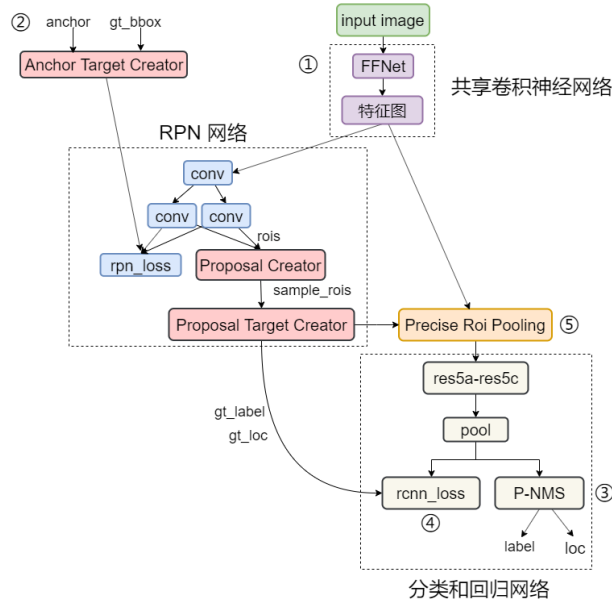


图 8-16 改进的 Faster R-CNN 结构图

主要通过以下方式改进 Faster R-CNN:

(1) 从优化共享卷积神经网络来提高对海上目标检测的检测概率和降低虚警率的角度出发，提出了一种新型的特征融合网络 FFNet 作为 Faster R-CNN 的骨干网络，提高特征提取的精确性，增强对于小目标特征提取和传递的能力，该部分位于 0 中的①。

(2) 从优化 RPN 网络来提高对海上目标的检测概率并降低虚警率的角度出发，采用小尺度锚点 (Anchor Boxes)，改善实际检测时雷达 PPI 图像尺度大而舰船目标尺度小引起的漏检和误检问题，优化部分位于 0 中的②。

(3) 从优化分类和回归网络来提高对海上目标的检测概率的角度出发，基于非极大值抑制 (Non-Maximum Suppression, NMS) 算法提出了一种全新的幂函数非极大值抑制 (Power Non-Maximum Suppression,

P-NMS)算法,改善多目标的区域漏检的问题,提高对海面多个舰船目标的检测效果,优化部分位于0中的③。

(4)从优化分类和回归网络来提高海上目标检测概率并降低虚警率的角度出发,采用 Focal Loss 作为分类和回归网络的分类损失函数,解决正负样本、简单样本和困难样本不平衡问题并改善训练结果,优化部分位于0中的④。

通过收集不同条件下的雷达测量数据构建了自己的海上目标数据集,并从四个方面改进了 Faster R-CNN 目标检测方法。通过训练和优化得到海上目标检测模型。实验结果证明,与传统的 Faster R-CNN 方法相比,基于 Marine-Faster R-CNN 的海洋目标检测方法在准确性和可靠性方面表现出更好的检测性能。另外海尖峰等强海杂波问题可能会带来低信杂波比(SCR),对雷达海洋目标检测造成较大干扰。然而,现有算法的海杂波抑制能力有限,在复杂海洋环境下泛化性较差。设计了一种新型海杂波抑制生成对抗网络(SCS-GAN)如图8-17所示,并将其用于海洋雷达平面位置指示器(PPI)图像检测^[37]。

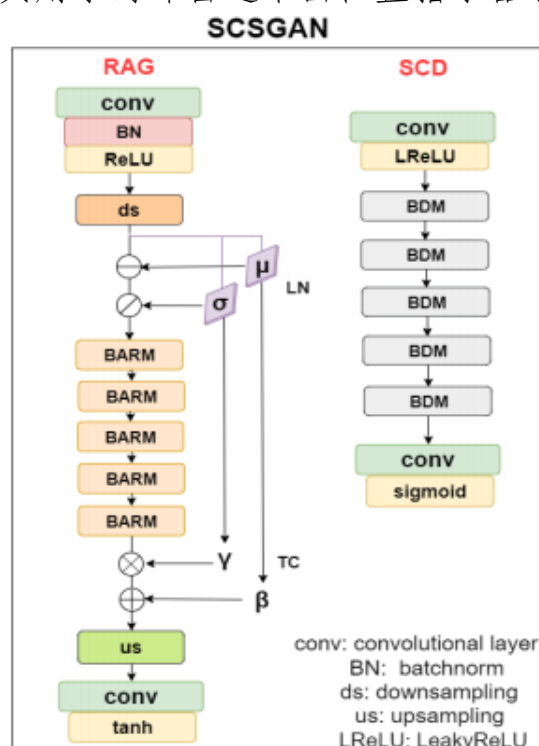


图 8-17 SCS-GAN 模型结构图

SCS-GAN 基于残差网络和注意力模块，其中包括残差注意力生成器 (RAG) 和海杂波鉴别器 (SCD)。为了扩大数据集，提高泛化能力，通过模拟采集的方式构建了无杂波数据集 A、模拟海杂波数据集 B (包含五类海杂波分布) 和实际海杂波数据集 C 真实雷达回波。最后，设计参数杂波抑制比 (CSR) 来评估该方法以及其他去噪和杂波抑制方法 (包括 CBM3D、去噪卷积神经网络 DnCNN、FFDNet 和 Pix2pix) 的海杂波抑制性能。经过实际数据测试，证明 SCS-GAN 具有更快的杂波去除速度、更强的泛化能力，同时图像中的海洋目标得到完整保留。文献^[38]设计了一种杂波抑制和目标检测融合网络 (INet)，通过层归一化-传递和连接方法提取关键目标特征，采用注意力网络抑制杂波和增强目标，构建跨阶段局部残差网络保证检测网络的轻量化和准确性。基于导航雷达在多种观测条件下采集的回波数据，构建了海面目标雷达图像数据集；通过模型的预训练和平面位置显示器 (PPI) 图像的帧间积累对 INet 进行了优化，得到了 Optimized INet (O-INet) 模型。

未来，随着深度学习技术的不断发展，预计它在雷达 P 显图像处理中的应用将进一步加强，进一步改善雷达显图像的质量和处理效率。同时，结合多模态数据和多源信息，如雷达与光学图像的融合，将会进一步推动雷达目标检测和识别等应用的性能提升。

8.3.2 雷达高分辨图像处理

SAR (Synthetic Aperture Radar) 和 ISAR (Inverse Synthetic Aperture Radar) 是两种用于雷达成像的技术。它们都使用雷达系统来获取目标的图像，但在成像原理和应用场景上有所不同。SAR 是一种通过合成大型有效孔径的雷达技术，以获得高分辨率和高质量的地表图像。传统的雷达系统的分辨率受到天线尺寸的限制，而 SAR 通过利用雷达平台的运动，实现合成大孔径，从而具有高分辨率的能力。SAR 系统通过发送连续的脉冲信号并接收反射回来的信号，然后对接收到的信号进行处理，生成具有高空间分辨率的二维图像。SAR 技术

广泛应用于地质勘探、军事侦察、环境监测等领域。ISAR 是一种用于舰船和飞机等目标的雷达成像技术。与 SAR 不同, ISAR 技术的目标是获取目标的横截面图像, 以便对目标的形状、大小和运动状态进行分析。ISAR 系统通过接收目标反射的连续波信号, 并对接收到的信号进行处理, 生成目标的高分辨率图像。ISAR 技术可用于目标识别、目标运动参数估计和目标跟踪等应用领域。无论是 SAR 还是 ISAR, 它们都利用雷达系统通过发送和接收电磁波来获取目标的图像。这些图像在军事、航天、地质和环境领域中有广泛的应用, 可以提供有关目标形状、大小、位置和运动状态的重要信息。

随着合成孔径雷达(SAR)系统应用越来越广泛, 需要处理的 SAR 图像数量越来越多, 对 SAR 图像处理技术提出了更高的要求, 从 SAR 图像中快速并准确地检测目标, 是目前的一个技术研究热点。传统的 SAR 图像目标检测方法可以分为 3 类。第 1 种基于单特征的方法通常利用雷达散射截面积(Radar Cross Section, RCS)信息挑选对比度较亮的部分作为候选目标。其中大多数检测方法使用恒虚警率(Constant False Alarm Rate, CFAR)算法做图像分割和候选目标定位。CFAR 包含多种衍生算法, 包括 CA-CFAR(Cell-average CFAR), SO-CFAR(Smallest of CFAR), GO-CFAR(Greatest of CFAR), OS-CFAR(Order-statistic CFAR) 和 VI-CFAR(Variability Index CFAR)。CFAR 具有恒虚警率和自适应阈值的特性。然而 CFAR 检测器只考虑像素对比度而忽略了目标的结构信息, 从而导致了目标的不精确定位。第 2 种是基于多特征的方法。多种特征如几何结构, 扩展分形(Extended Fractal, EF), 小波系数等可以融合起来检测目标。文献^[39]将梯度纹理显著图与 CFAR 相结合来检测停机坪上的飞机目标。

综合而言, 设计特征是复杂且耗时的, 并且同种特征组合不一定适用于所有的场景。第 3 种是基于先验的方法, 先验知识如成像参数、经纬度信息等需要协同加入检测流程。这类方法较复杂且实际中应用

较少。随着人工智能的发展，机器学习被引入了 SAR 目标检测领域。支持向量机(Support Vector Machine, SVM)和 AdaBoost(Adaptive Boosting)等常用方法在 MSTAR(Moving and Stationary Target Acquisition and Recognition)数据集上表现良好。虽然这些方法比传统方法性能有所提升，但它们仅适用于小样本情况，设计具有高泛化能力的特征难度较高。卷积神经网络(Convolutional Neural Network, CNN)可以自动学习结构化特征并取得较好的性能。文献^[40]和^[41]使用 CNN 对 MSTAR 数据集进行分类并取得较好的效果。

杜兰等人就针对研究了训练样本不足的情况下利用卷积神经网络对合成孔径雷达(SAR)图像实现目标检测的问题，最终达到一个不错的效果^[42]。即使深度学习在物体检测领域取得了非常大的突破，但是鲜有用于合成孔径雷达图像中舰船目标检测，李建伟等人基于深度学习的目标检测方法引入到了 SAR 图像舰船目标检测^[43]，以标准的 Faster RCNN 作为基本结构，并在特征聚合、模型迁移、损失函数以及其他应用细节上进行了创新，在 SSDD 上的实验证明了所提算法具有更高的检测准确率和更少的耗时，检测准确率从标准 Faster RCNN 的 70.1%提升到 78.8%，每幅图像处理时间从 198ms 降低到 183ms。但是方法使用的前提条件是需要收集大量的 SAR 图像舰船目标训练样本，且制作相应的标签用于模型训练，需要消耗较大的人力和物力。

利用大尺度合成孔径雷达(SAR)图像探测舰船目标在军事和民用领域都有重要应用。然而，由于陆地区域的影响，船舶目标很难从周围背景中区分出来，而且会出现很多误报。由于大规模合成孔径雷达图像中的大部分区域被视为背景和杂波，而舰船目标被视为分布不均的小目标，因此舰船目标检测总是会出现误报。面对这些棘手的问题 Z. Cui 等人提出了一种通过 CenterNet 在大规模 SAR 图像中进行船舶检测的方法^[44]。如图 8-18 所示。CenterNet 作为一种无锚方法，将目标定义为一个点，通过关键点估计来定位目标的中心点，可以有效

避免小目标的漏检。同时，CenterNet 中引入了空间洗牌组增强 (spatial shuffle-group enhance, SSE) 注意力模块。通过 SSE，在抑制部分噪声的同时，提取更强的语义特征，以减少近海和内陆干扰造成的误报。

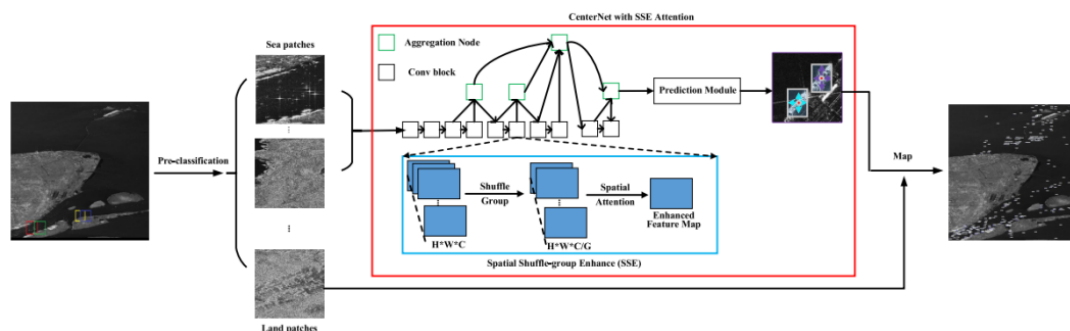


图 8-18 整体流程图

针对 SAR 图像舰船目标检测，同样也存在着因近海岸港口存在着复杂背景的问题，以至于重叠舰船目标无法被准确提取特征信息，造成近海岸的舰船目标出现漏检、误检的情况。像这种问题在也是一直比较令研究者困扰的问题，针对此问题刘朋就借助深度学习网络的优势提出一种复杂场景下的 SAR 图像舰船检测算法，该算法基于 YOLOv5 进行改进，采用 SPPF 结构加强提取特征信息，并融合原 YOLOv5 的 SPP 结构提取的特征信息，这种多级金字塔模块并列融合的方式能有效的检测多尺度舰船目标，使特征信息更好的表达；然后将原模型中的 GIOU 改进为 CIOU，使其可以准确的回归出预测框的位置；最终为了更合理的筛选高于阈值的预测框，改进 NMS (Non-Maximum-Suppression)，采用 Soft-NMS 方法去惩罚衰减高于阈值的边框得分^[45]，合理的去除预测框。整体网络模型如图 8-19 所示。

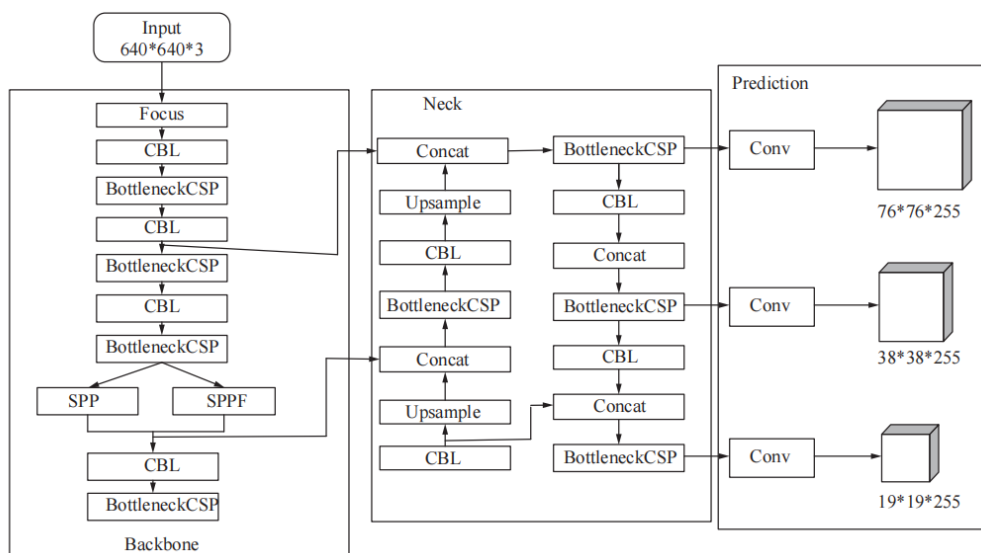


图 8-19 改进的 YOLOV5

改进的模型相比于原模型在 SSDD、SAR-Ship-Dataset 数据集上的 mAP(mean Average Precision) 提高了 5.15% 和 5.06%，改进模型能有效检测近海岸中复杂背景下的 SAR 图像舰船目标。针对传统 SAR 图像飞机检测算法需要人工设计特征且鲁棒性较差的问题，文献^[46]提出了一种基于改进 Faster RCNN 的 SAR 图像飞机检测算法。制作了一个 SAR 图像飞机数据集，以 Faster RCNN 为检测框架，利用改进 kmeans 算法设计更合理的先验锚点框，以适应飞机目标的形状特点；借鉴 inception 模块思想，设计多路不同尺寸卷积核以扩展网络宽度，增强对浅层特征的表达；分析残差网络 Layer5 层的特征输出具有更大的感受野，对其上采样后进行特征融合以利用更多的上下文信息；同时引入 Mask RCNN 算法中提出的 Roialign 单元，消除特征图与原始图像的映射偏差。实验结果表明：相比原始的 Faster RCNN 算法，所提改进的 Faster RCNN 算法在 SAR 图像飞机数据集上平均检测精度提高了 74%，同时保持了较快的检测速度。

随着深度学习和 SAR 技术的快速发展，SAR 图像目标检测的地位越来越高，对 SAR 图像目标检测的研究也不断进步。舰船作为一类重要的目标，在民用领域，舰船检测有助于海洋监控；在军事领域，获取舰船信息具有重要价值。对 SAR 图像舰船目标检测的未来研究方向

如下：

- (1) SAR 图像目标检测网络设计
- (2) 复杂场景下 SAR 图像近岸舰船目标检测算法研究
- (3) 复杂场景下 SAR 图像首尾相连与并列舰船目标检测算法研究
- (4) 小样本目标检测算法研究

8.3.3 信号二维特征图处理

根据多普勒效应，目标相对于雷达做匀变速运动时，其回波信号为线性调频信号。利用时频分析工具将雷达回波信号变换为二维的雷达时频图，根据目标的微动特征在图像中进行目标检测。为了实现基于微多普勒效应的目标识别，通常从目标的微多普勒特征中提取某些判别特征。时频分析能将雷达回波信号中的微多普勒效应可视化，即时频谱图中的微多普勒特征形状。通过提取形状中的相应参数，就可以得到目标物体的微多普勒特征，进而用于分类识别，如图 8-20 所示。




图 8-20 人体各动作微多普勒时频谱图像

基于微多普勒特征的深度学习分类方法与机器学习方法相比具有一定的固有优势。它们较少依赖于领域知识，因为它们可以自动从微多普勒特征中提取特征和分类边界。由于省略了特征提取步骤，它们可以节省特征提取算法所需的处理时间，并避免在做出正确选择时

出现人为错误。在 CNN 的卷积滤波过程中，深度学习分类器在训练过程中可以学习杂波和噪声模式。杂波对其他分类器的性能有重大影响，而深度学习架构拥有着自动消除杂波的能力。此外，深度学习架构可以提取某些重要特征，而手动特征提取可能会错过这些特征。

海军航空大学的陈小龙团队^[47]在对回波信号进行时频分析后，建立了时频图数据集，先后采用 LeNet、AlexNet 和 GoogLeNet 三种卷积神经网络模型检测机动目标，证实了深度学习目标检测方法的检测效果优于传统的动目标检测方法和基于支持向量机的目标检测方法。针对飞鸟和旋翼无人机目标识别的迫切需求，开展微多普勒测量实验研究^[48]。首先对飞鸟翅膀扑翼运动、无人机目标主体运动和旋翼转动进行建模分析与参数化表征，从雷达动目标回波中提取多普勒频移信息；然后利用短时傅里叶变换转换为时频图，对目标微多普勒特征进行精细化描述，并从雷达参数、目标类型、观测条件等多个角度重点分析了微动特征的影响因素；实测数据分析表明：目标旋翼叶片长度越大、转速越高，微多普勒频率越大；叶片数目增多导致微动特征重叠；雷达观测角度、调制周期以及时频分析的时间窗长均会对微动特性产生重要影响。

此后，针对和旋翼无人机进行分类的难题，陈小龙^[49]等人提出一种微运动特征分类方法。采用 K 波段调频连续波(FMCW)雷达，对五种旋翼无人机(SJRC S70 W、DJI Mavic Air 2、DJI Inspire 2、六轴飞行器、单桨固定翼无人机)和飞鸟进行数据采集在室内和室外场景下进行。然后，使用时频(T-F)分析对相应的微多普勒(m-D)信号进行特征提取和参数化。为了增加有效数据集的数量并增强 m-D 特征，通过设置 T-F 图中显示的幅度范围并采用距离-时间(调制周期)图和 T-F 图的特征融合来设计数据增强方法。采用并修改了多尺度卷积神经网络(CNN)，可以提取目标 m 维特征的全局和局部信息，并减少参数计算负担。实测数据集进行验证表明，该算法在短距离和长距离实

验中对无人机和飞鸟的平均正确分类精度比基于 Alexnet 和 VGG16 的 CNN 方法分别提高了 9.4%和 4.6%。

南京信息工程大学的施赛楠等^[50]采用 SPWVD(Smoothed Pseudo Wigner Ville Distribution)时频分析工具将一维回波信号变换为二维时频图,在纯杂波中加入仿真目标,克服样本数量不均衡的难题,构建了半仿真时频图数据集,在 GoogLeNet 的 Inception v3 网络中引入迁移学习模型,对海面目标进行自主检测,消除了人工提取特征的局限性,如图 8-21。Kim 等^[51]利用多普勒雷达对人、狗、马和汽车进行探测,对获得的雷达回波信号进行短时傅里叶变换得到时频图数据集,设计 DCNN 检测模型对人体目标进行检测,达到了 97.6%的检测率。

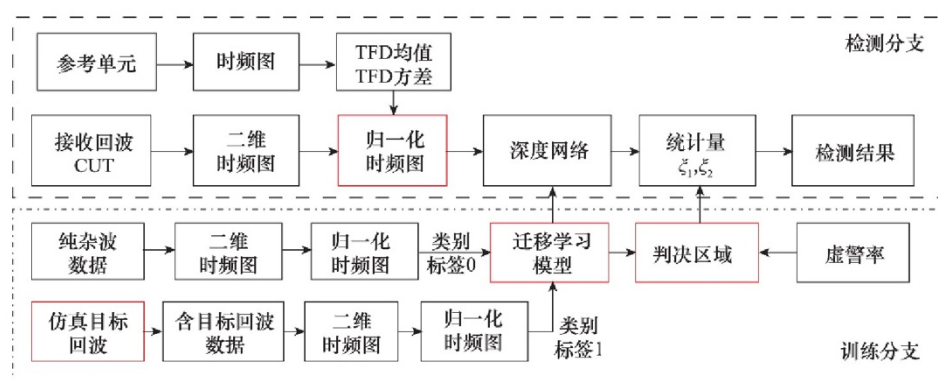


图 8-21 基于时频图自主学习的检测流程图

除了卷积神经网络(CNN),循环神经网络(RNN)也被用于基于微多普勒效应的目标分类。在不同类型的 RNN 中,长短期记忆(LSTM)网络研究内容较多,因为它们可以克服梯度消失/爆炸问题,并且与其他 RNN 架构相比,能够学习长数据序列和短数据序列。

S. Z. G ü r b ü z 等人中提出了一种深度卷积自动编码器(CAE)。它本质上结合了自动编码器和 CNN 的优点,对人类活动进行分类时,准确率为 94.2%^[52]。卷积自编码网络如图 8-22 所示。研究人员还使用混合分类器对基于微多普勒的目标进行分类,它结合了传统的机器学习和深度学习分类器的优点。




图 8-22 卷积自编码网络示意图

雷达数据的采集工作极其费时费力，不易形成有效且大规模的雷达数据集。然而，深度学习分类模型在少样本的情况下往往不能发挥出最好的性能，导致其泛化能力较差，识别精度较低。未来，通过 GAN 网络产生的生成数据扩充雷达数据集，以解决微多普勒特征训练数据不足的问题。

8.4 雷达智能信息处理发展趋势

8.4.1 小样本目标检测

雷达目标检测技术不受天气、光照等诸多条件影响，能够及时准确地提供场景中每个实体目标的详细属性信息，具有较高的军用和民用价值。但实际应用场景的时效性约束和资源限制导致该领域一直存在小样本问题，这严重制约了雷达目标识别技术的发展。虽然传统雷达目标识别技术对数据的需求量较小，但人工提取特征的方式导致该类算法环境适应性差且工程推广能力低。深度学习技术依靠其优秀的自动特征提取能力，大幅提升了雷达目标识别的准确率，但其对大数据的需求依旧制约着模型性能的发挥。因此，如何提升深度学习技术在雷达小样本目标识别应用中的性能成为亟需解决的问题，也是本章的介绍重点。目前小样本学习问题在光学图像识别领域的研究最为广泛，主要研究机器学习模型面对新类少量样本的快速学习能力，代表方法是元学习、迁移学习和强化学习。

8.4.1.1 迁移学习

迁移学习中的模型迁移方法因其高效性在深度学习图像识别领域受到广泛关注，通过知识迁移提升模型学习效率，具体算法流程如下。步骤 1 在源任务上对模型进行预训练。步骤 2 迁移预训练模型的部分或全部结构作为目标任务模型的浅层模块，并冻结该部分模型权重参数和网络结构。步骤 3 通过目标任务的学习对模型的非冻结部分进行微调完成模型训练。模型迁移方法之所以有效，是因为深度学习通常使用神经网络提取样本特征向量，而神经网络浅层部分权值是具有强适应性的共性知识。因此，当源任务与目标任务存在一定相关性时，模型迁移能够实现知识积累，从而降低训练难度，提高模型学习效率，图 8-23 给出了迁移学习流程图。




图 8-23 迁移学习流程图

雷达高分辨率距离像 (HRRP) 目标识别在小样本条件下实现非常困难，针对此问题 Chen. Guo, Haipeng. Wang 等人提出了基于深度迁移学习的目标识别方法^[53]。首先，根据目标域小样本的特点，设计合适的预训练模型，并提出改进的预训练模型；利用模型泛化性能损失函数和源域数据对预训练模型进行从头训练。由于目标域数据集和源域数据集具有不同的维数，微调模型只有与预训练模型相同的卷积层和池化层参数的结构和初始值，对全连接层和输出层进行重置和初始化。在微调过程中，为了解决目标域数据集样本较少，类别不平衡导致识别性能不理想的问题，提出了一种损失函数，可以减少类别之间样本不平衡导致的识别偏差，提高特征可分性。实验结果表明，在小

样本条件下,根据样本数量选择合适的微调方案可以获得较好的识别效果。与从零开始训练的模型相比,该方法在提高识别精度的同时提高了收敛速度。以及模型的稳定性。另一方面合成孔径雷达(SAR)运动目标检测一直是雷达信号处理领域的一项关键技术。然而,由于雷达独特的军事背景,包含地面运动目标的真实 SAR 数据很难获得,导致在应用网络时缺乏标记的运动目标数据。Xuefei.Li 等人提出了一种改进的卷积神经网络(CNN),采用 LMMD 方法对网络进行设计,并通过 LMMD 损失与整个网络的最终分类损失的联合优化,达到了良好的无监督域自适应效果^[54],网络结构如图 8-24 所示。

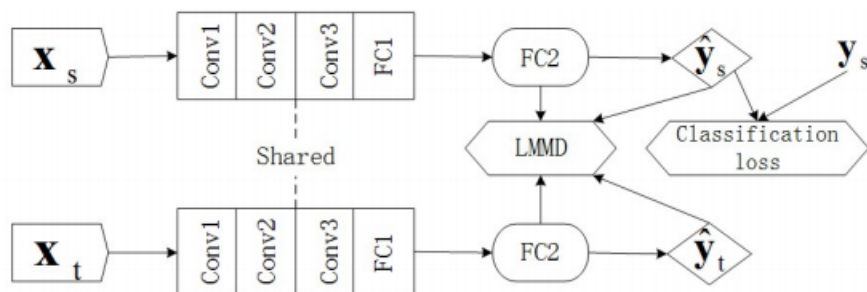


图 8-24 深度迁移学习网络模型

针对 CNN 识别 SAR 目标准确率且运行时间长的问题,文献^[55]提出了一种结合迁移学习和卷积神经网络 VGG16 结构的迁移 VGG16 方法。首先将 MSTAR 数据集中的 SAR 目标通过微调迁移 VGG16 预训练模型提取目标特征;然后通过 Softmax 分类器进行特征分类识别。实验结果表明,通过与现有 VGG16 算法和迁移 LENET 方法对比,迁移 VGG16 的 SAR 目标识别率分别由前者的 86.2%和 90.8%提高到了 94.4%,通过迁移学习 SAR 目标识别得到了不错的增益。合成孔径雷达(SAR)图像的标记样本有限,因此很难学习出完美的卷积神经网络(CNN)模型进行目标分类。常用的单通道 SAR 图像比三通道自然图像的信息要少得多。迁移学习(TL)是提高 CNN 模型泛化能力的有效途径。现有的 SAR 图像 TL 方法通常将知识从三通道自然图像转移到单通道 SAR 图像,其中 SAR 图像只是从一个通道复制到三个通道。这显然是不合理的。实际上,单通道 SAR 图像是复值的,可以通过子孔径分解(SD)

算法将其划分为多个通道(例如,三个通道)。为了充分利用单通道 SAR 图像的复值数据,文献^[56]提出了一种基于 SD(TL-SD)的 TL 方法,该方法可以生成伪彩色 SAR 图像,利用大规模自然图像数据集实现 TL,方法框架如图 8-25 所示。基于 MSTAR 真实数据集的实验结果表明,所提 TL-SD 方法对十类目标的分类平均准确率达到 99.88%,优于其他比较目标分类方法,验证了所提方法的有效性。在未来的工作中,还可以进一步探索 SD 算法,以促进更多的 SAR 图像解译任务。

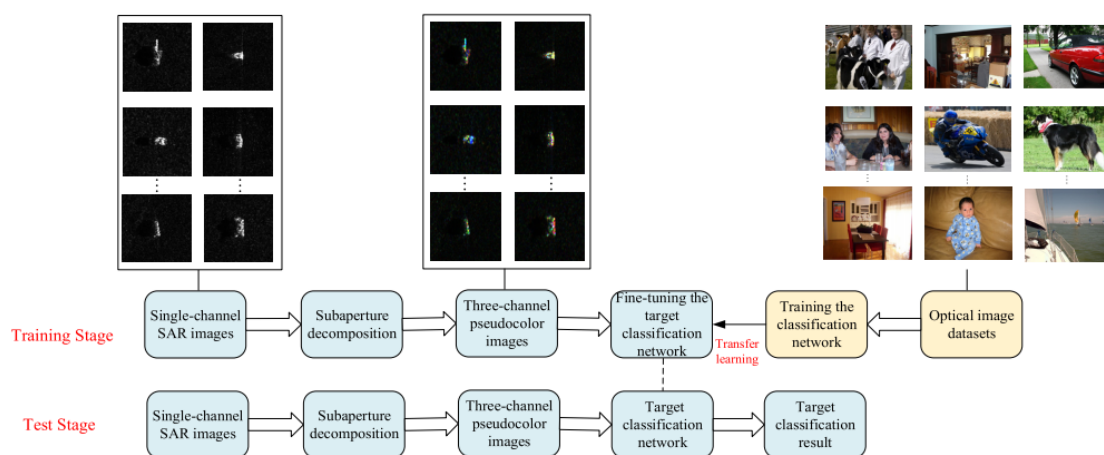


图 8-25 TL-SD 方法框架

迁移学习是一种机器学习方法,通过将知识从一个或多个源领域(通常为大量数据集)迁移到目标领域(通常为少量数据集)来改善目标领域任务的性能。在雷达小样本目标检测任务中,由于数据集规模有限,迁移学习可以成为提高性能和泛化能力的有效手段。具有增强模型泛化能力、减少过拟合、解决数据稀疏问题、加快模型训练速度效果。尽管迁移学习对雷达小样本目标检测具有许多优势,但在实践中也需要注意一些问题:领域差异、选择合适的源域、避免负迁移。总体而言,迁移学习可以帮助改善雷达小样本目标检测任务的性能和泛化能力,但需要综合考虑数据、模型和任务之间的关系,以便进行适当的方法选择和参数调整。

8.4.1.2 强化学习

近年来,深度学习(Deep Learning, DL)作为机器学习领域一个

重要的研究热点，已经在图像分析、语音识别、自然语言处理、视频分类等领域取得了令人瞩目的成功。DL 的基本思想是通过多层的网络结构和非线性变换，组合低层特征，形成抽象的、易于区分的高层表示，以发现数据的分布式特征表示。因此 DL 方法侧重于对事物的感知和表达。强化学习 (Reinforcement Learning, RL) 作为机器学习领域另一个研究热点，已经广泛应用于工业制造、仿真模拟、机器人控制、优化与调度、游戏博弈等领域。RL 的基本思想是通过最大化智能体 (Agent) 从环境中获得的累计奖赏值，以学习到完成目标的最优策略。因此 RL 方法更加侧重于学习解决问题的策略。随着人类社会的飞速发展，在越来越多复杂的现实场景任务中，需要利用 DL 来自动学习大规模输入数据的抽象表征，并以此表征为依据进行自我激励的 RL，优化解决问题的策略。由此，谷歌的人工智能研究团队 DeepMind 创新性地具有感知能力的 DL 和具有决策能力的 RL 相结合，形成了人工智能领域新的研究热点，即深度强化学习 (Deep Reinforcement Learning, DRL)。此后，在很多挑战性领域中，DeepMind 团队构造并实现了人类专家级别的 Agent。这些 Agent 对自身知识的构建和学习都直接来自原始输入信号，无需任何的人工编码和领域知识。因此 DRL 是一种端对端 (end-to-end) 的感知与控制系统，具有很强的通用性。其学习过程可以描述为：(1) 在每个时刻 Agent 与环境交互得到一个高维度的观察，并利用 DL 方法来感知观察，以得到抽象、具体的状态特征表示；(2) 基于预期回报来评价各动作的价值函数，并通过某种策略将当前状态映射为相应的动作。(3) 环境对此动作做出反应，并得到下一个观察。通过不断循环以上过程，最终可以得到实现目标的最优策略。DRL 原理框架如图 8-26 所示，深度强化学习框架中，智能体与环境进行交互，智能体通过深度学习对环境状态进行特征提取，将结果传递给强化学习进行决策并执行动作，执行完动作后得到环境反馈的新状态和奖惩进而更新决策算法。此过

程反复迭代，最终使智能体学到获得最大长期奖惩值的策略。




图 8-26 DRL 原理框架图

大场景合成孔径雷达 (SAR) 图像相对于通用光学图像，复杂背景杂波对目标特征提取影响更大，由于传统基于候选框的深度目标检测算法会在整张特征图上产生大量冗余候选框，因而在 SAR 图像复杂背景杂波影响下会产生大量的虚警，降低目标检测精度。针对该问题，杜兰^[62]等人基于 Faster R-CNN 检测模型，提出结合强化学习自适应候选框挑选的 SAR 目标检测方法。整体框架如下图所示。

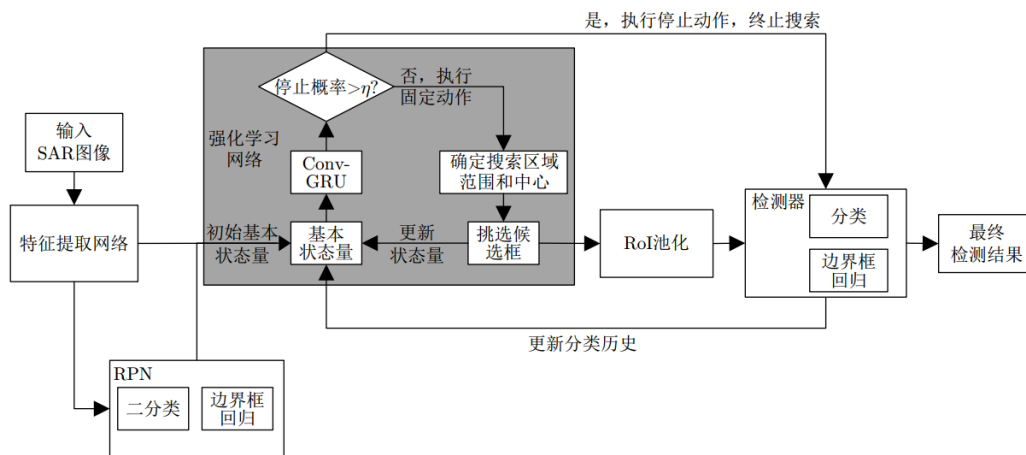


图 8-27 结合强化学习的 SAR 目标检测方法整体框架

该方法能够通过强化学习自适应搜索特征图中可能含有目标的区域，并挑选搜索区域内的候选框继续进行分类、回归。通过准确搜索到含有目标的区域，可以减少复杂背景杂波的影响并减少传统强化学习应用于检测问题的计算量。所提方法利用强化学习序列决策的特点，能够根据图像信息通过强化学习迭代搜索自适应确定图像中可能含有目标的搜索区域的位置。同时，该方法通过在强化学习中使用距离约束，可以根据之前的搜索结果自适应调整下一次搜索区域的尺寸。

基于实测数据的实验结果表明,所提方法能够提升传统深度学习目标检测方法的检测性能。大规模多输入多输出(MMIMO)认知雷达可以通过连续的“感知-动作”循环来增强动态环境中的目标检测能力。在我们之前的工作中, W. Zhai^[63]等人提出了一种基于强化学习(RL)的MMIMO多目标检测方法。然而,该方法由于其不完善的作用和奖励机制,对弱目标的检测性能较差。该文提出一种改进的基于RL的方法,以提高弱目标的检测概率。在动作阶段,发射功率分为全向分量和定向分量,前者显著降低弱目标的未命中检测概率,后者通过将更多功率集中在弱目标上来提高检测概率。此外,还修改了RL的奖励机制,进一步提高了检测性能。此外,发射权重矩阵采用所有单位正交发射波形的波束模式的优化组合来设计,从而大大降低了计算复杂度。仿真结果验证了改进的基于RL的弱目标检测方法的有效性。不仅如此多输入多输出(MIMO)雷达的功率分配是目标跟踪和检测的关键点。多目标多约束优化问题的最优性严格依赖于先验模型,在时变、复杂、非合作环境中难以获得先验模型。最近,深度强化学习(DRL)已被应用于目标跟踪任务,它提供了一种试错交互学习机制来改进策略。与具有完整目标状态转换模型的跟踪任务不同,对于基于DRL的MIMO雷达检测来说,这仍然是一个悬而未决的问题,需要有效地使控制策略适应随机出现的目标环境和广泛的电力传输动作,这导致最终任务奖励稀疏,从而减慢代理的策略学习速度。通过引入领域知识的分析模型(雷达方程)和经验规则(专家偏好),针对于此 Y. Wang^[64]等人提出了一种领域知识辅助DRL(DKADRL)框架如图8-28所示。

其中利用基于领域知识的及时奖励生成器来生成及时奖励,帮助智能体的策略学习。为了调整及时奖励和最终任务奖励的作用,设计了奖励融合模块,随着训练过程的进行,最终任务奖励的作用逐渐增加,从而使智能体的策略收敛到最终优化目标。该算法在两种目标运动场景下进行了验证,结果表明,与基于等功率分配和近端策略优化

(PPO)的功率分配相比，该算法具有更高的目标检测概率和更快的训练速度。

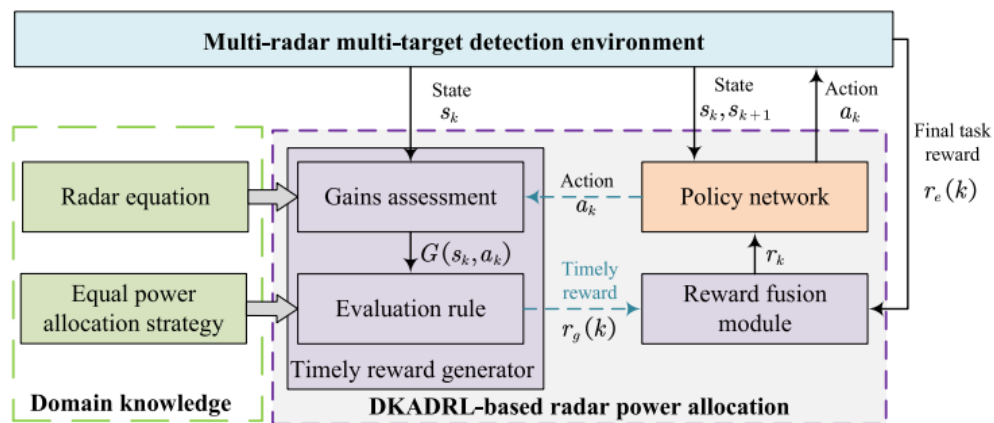


图 8-28 DKADRL 框架

未来强化学习在雷达小样本目标检测领域的发展将着重于提高样本效率、实现零样本目标检测、多模态融合、自监督学习、路径规划和增强鲁棒性等方面。这些趋势将有望推动雷达小样本目标检测的性能和应用范围不断拓展。

8.4.2 无监督或弱监督目标检测

无监督或弱监督目标检测 (Unsupervised or Weakly Supervised Object Detection) 是在缺乏完整标注信息的情况下进行目标检测的方法。无监督目标检测是在没有目标类别标签的情况下进行目标检测，而弱监督目标检测则是在只有部分标注信息或弱标注信息的情况下进行目标检测。这些方法的目标是通过利用有限的监督信息或无监督学习技术来实现目标检测任务。在无监督目标检测中，方法通常依赖于自学习、聚类和生成对抗网络等技术。自学习方法通过对未标注图像进行分析和学习，自动发现和定位图像中的目标物体。聚类方法通过将图像中的特征进行聚类，将相似的特征归为一类，从而发现图像中的目标。生成对抗网络 (GAN) 是由生成器和判别器组成的模型，通过对抗训练的方式生成逼真的图像，其中生成器可以被用于无监督目标检测任务。在弱监督目标检测中，标注信息可能是部分标注框或图像级标签，而不是完整的目标实例级别标注。方法通常依靠注意力机

制、迁移学习和多示例学习等技术来从这些弱标注信息中推断出目标的位置和类别。

无监督或弱监督目标检测是目标检测领域的热门研究方向，因为它们可以在缺乏完整标注信息的情况下提供解决方案。然而，由于缺乏准确的监督信息，这些方法的性能可能相对较低。当前的研究仍在积极探索和改进这些方法，以提高无监督或弱监督目标检测的准确性和鲁棒性。

基于深度学习的合成孔径雷达(SAR)目标检测通常假设训练数据和测试数据取自相同的分布。然而，当雷达传感器发生变化时，这种假设并不总是成立，并且在遇到这种分布不匹配时将导致性能下降。迁移学习将源传感器的标记数据中的知识转移到目标传感器的未标记数据中，为解决这一问题提供了一个很好的思路。Y. Shi 等人提出了一种基于域自适应的跨传感器迁移学习方法^[65]，提高了对未标记目标传感器(域)数据进行 SAR 目标检测的跨传感器鲁棒性，该方法包括三个阶段：像素域多样化(PDD)、多层次特征对齐(MFA)和迭代自训练(IST)。PDD 阶段可以缓解 SAR 目标检测训练数据少的问题，并通过生成过渡域来提高泛化能力。MFA 利用对抗学习的思想，在多层特征空间中学习域不变特征。结构如图 8-29 所示。

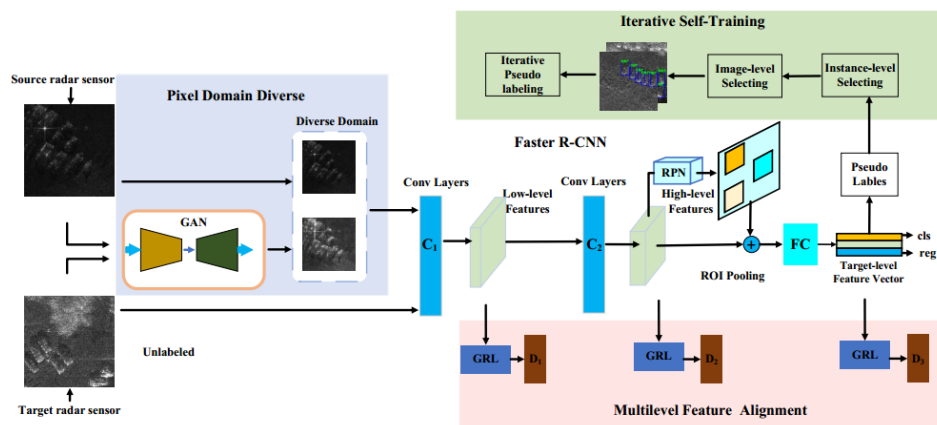


图 8-29 无监督 SAR 目标检测的跨传感器迁移学习结构

雷达测深仪数据广泛用于调查冰冷和干旱地区地下的地质结构和过程。视觉解释是文献中用于从雷达图中提取信息的主要技术之一，

E. Donini 等人提出了一种自动和无监督的技术^[66]，用于提取地下地质目标的信息。该技术建立在三个步骤之上：根据雷达图统计属性生成粗略分割图；通过深度学习细化粗图以检测目标反射；以及分析深层特征以识别埋藏目标。在火星南极附近获得的 MARSIS 雷达数据上测试了所提出的方法。

无监督学习和弱监督学习是两种利用更少标注信息或无标注信息进行训练的学习方法，在雷达目标检测中可以产生重要的影响。它们的发展未来将对雷达目标检测领域带来以下影响和趋势：

(1)降低标注成本：雷达数据通常较难获取标注，因为标注需要由专业人员进行，并且很耗时。无监督学习和弱监督学习的发展可以降低标注成本，使用更少的标注数据来训练模型，从而更好地应对雷达目标检测任务。

(2)更好地利用无监督数据：雷达数据中可能存在大量无标注数据，利用这些无监督数据进行训练可以帮助模型学习到更丰富的特征表示，提高目标检测性能。未来的发展将探索如何将无监督学习应用于雷达目标检测任务，实现更好地利用无标注数据。

(3)强化泛化能力：无监督学习和弱监督学习有助于提高模型的泛化能力，使其在新的、未知的场景中更好地适应和检测目标。这对于雷达目标检测任务尤为重要，因为雷达数据的特征分布可能受到环境和目标属性的影响，因此泛化能力对于应对多样化的场景非常关键。

(4)融合多模态信息：弱监督学习方法可以利用多模态信息(如雷达数据、光学图像、红外图像等)来进行监督学习，以增强模型的性能和泛化能力。未来的发展将鼓励探索如何更好地融合多模态信息来实现更全面和准确的目标检测。

(5)非传统目标检测场景：无监督学习和弱监督学习的发展将使得雷达目标检测可以应用于更广泛的场景，包括一些传统方法难以处理的复杂或特殊情况。

然而，无监督学习和弱监督学习也面临一些挑战：

(1) 特征学习和表示学习的困难：在无监督学习中，特征学习和表示学习是关键挑战。如何从无监督数据中学习到有意义和有用的特征表示是一个复杂的问题，需要深入研究和探索。

(2) 标签不完备性和噪声：弱监督学习中，标签可能是不完备的或包含噪声，这可能会影响模型的训练和性能。需要针对这些问题设计相应的算法来应对。

总体而言，未来无监督学习和弱监督学习在雷达目标检测领域的发展将对提高目标检测性能、降低标注成本、融合多模态信息和应用于非传统场景等方面产生积极的影响。需要在研究中充分考虑数据的特点和实际应用需求，持续推进相关技术的发展和 innovation。

8.4.3 多维多通道特征融合检测

机器学习目标检测技术需要人工提取特征，特征维数通常较少。深度学习目标检测技术可以自动提取特征。两种特征提取方法的机理不同，提取的特征各异。可将机器学习检测技术与深度学习检测技术进行融合，提高特征的维度。不同特征对应不同物理属性，可以提供更丰富的目标信息。不同特征具有不同的区分能力和鲁棒性，通过多特征融合可以实现互补，提高识别性能。不同通道雷达系统观测角度不同，可以提供目标的不同方向信息。例如，地基雷达和空中雷达可以观测到目标的不同方向，通过多通道融合可以得到目标的全方位特征，提高识别效果。因此，多维、多通道特征融合检测是实现雷达目标识别高性能的关键技术，它通过信息的互补和优势互补，可以同时提高识别性能和系统鲁棒性。

海军航空大学海上目标探测团队提出了基于双通道卷积神经网络(DCCNN)和误报可控分类器(FACC)的海洋目标检测方法^[67]，如图8-30。结果表明，与单通道CNN和定向梯度支持向量机(Hog-SVM)直方图分类相比，DCCNN特征提取模型和Softmax分类器的结合可以实

现更高的性能和可控的误报率。陈小龙等人还从雷达信号数据结构和维度出发，提出了多维雷达信号多通道融合的智能处理框架^[68]，通过多维特征的提取和多通道融合实现对多维雷达数据的多通道检测和分类，通过改变数据输入的形式，丰富提取的特征信息，进一步提高目标检测的性能。

未来，通过多维特征的提取和多通道融合实现对多维雷达数据的多通道检测和分类，通过改变数据输入的形式，丰富提取的特征信息，进一步提高目标检测的性能，是雷达目标识别领域的发展方向。

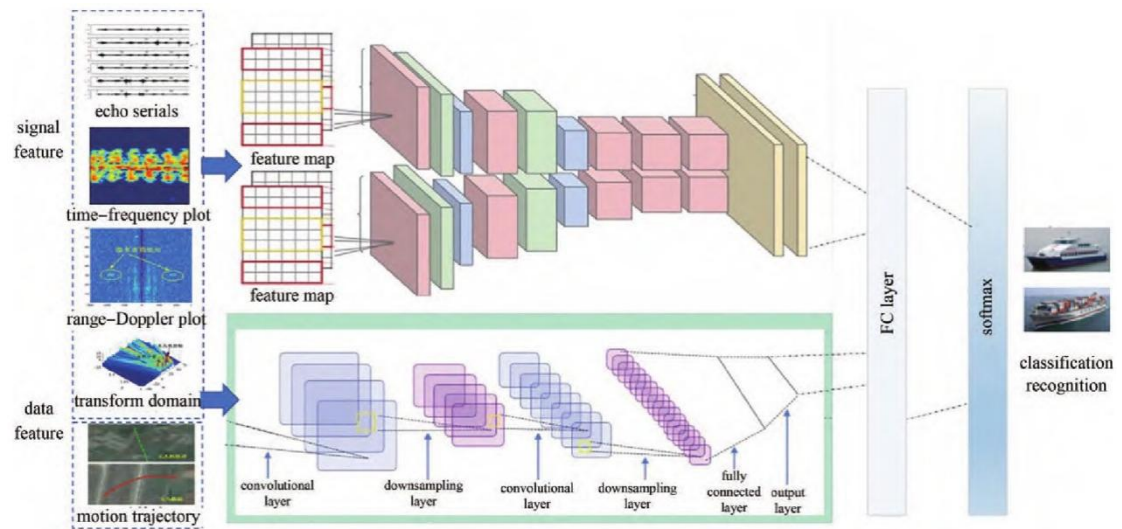


图 8-30 多维度输入和多通道神经网络

8.4.4 可解释人工智能

深度学习的可解释性问题是当前人工智能领域的研究热点和难点，是实现可靠、可信和透明的人工智能系统的重要基础，如图 8-31。随着机器学习和深度学习的发展，人工智能技术已经逐渐应用在各个领域。然而采用人工智能的最大缺陷之一就是它无法解释预测的依据。模型的黑盒性质使得在医疗、金融和自动驾驶等关键任务应用场景中人类还无法真正信任模型，从而限制了这些领域中人工智能的落地应用。推动可解释人工智能(Explainable Artificial Intelligence, XAI)的发展成为实现关键任务应用落地的重要问题。

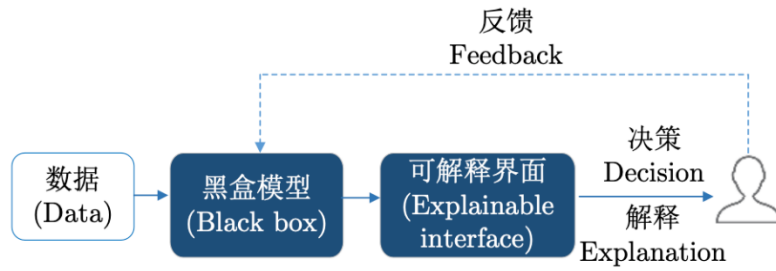


图 8-31 可解释性学习

目前，构建本身具有内在可解释性的神经网络大致有如下方法：一是基于注意力模型 (Attention)。注意力模型源于人脑的注意力机制，其数学本质是一种对数据的加权策略，注意力矩阵体现了模型在决策过程中的感兴趣区域，因而具有良好的可解释性。二是浅层统计模型的深度化。相较于大多数深度神经网络模型，统计学习模型具有完备的理论基础、可解释性强和易于优化等诸多优点。三是基于物理模型。真实物质世界其实是遵循着一定的物理规律，机器学习模型也要遵循这样的物理规则，因此可以尝试对物理模型进行建模。四是知识的嵌入与融合。深度神经网络具有强大的表示学习能力，但是忽略了一定的先验知识，通过引入语义概念和语义关联等高层信息，引导模型进行特征学习和推理，不仅可以增强特征的表示能力，还能使模型具有更好的解释性。

深度学习技术已被成功应用于解决 SAR 图像目标识别问题，并显著超越了传统方法的性能，但其内部工作机理不透明、解释性不足，成为制约 SAR 图像目标识别技术可靠和可信应用的瓶颈。深度学习的可解释性问题是目前人工智能领域的研究热点与难点^[69]。M. Datcu 等人提出将 SAR 数据案例的数据科学可解释性范式转变为 SAR 的可解释人工智能 (XAI)^[70]，如图 8-32。目标是使用基于完善模型的可解释数据转换来生成人工智能方法的输入，为训练过程提供知识丰富的反馈，并从数据中学习或改进高复杂性的未知或非形式化模型。田野等人基于专家知识增加了用于挖掘通道间叠掩特征和干涉相位叠掩特征的模块，提高算法的准确率与鲁棒性，同时也能够有效地减轻模型在小

样本数据集上的训练压力。

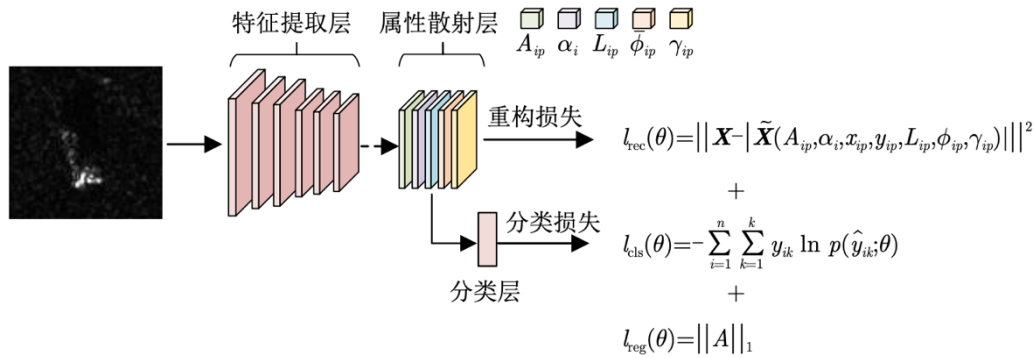


图 8-32 物理知识引导的 SAR 特征学习网络

近年来，在 SAR 图像解译主要聚焦信号特性理解和图像语义理解两大方向，如图 8-33。深层次地整合理论驱动和数据驱动的方法在 SAR 图像解译领域尤为重要，数据驱动的方法擅长从大规模数据中自动挖掘新模式，对物理过程能起到有效的补充；反之，在数据驱动方法中加入可解释的物理模型能提升深度学习算法的透明度，并降低模型对标记样本的依赖。L.Liao 等人通过将高分辨率 (HRR) 雷达信号的物理生成机制与神经网络相结合，开发了一种可解释的深度概率模型，以学习 HRR 雷达信号中可以表征目标物理结构的潜在特征^[72]。

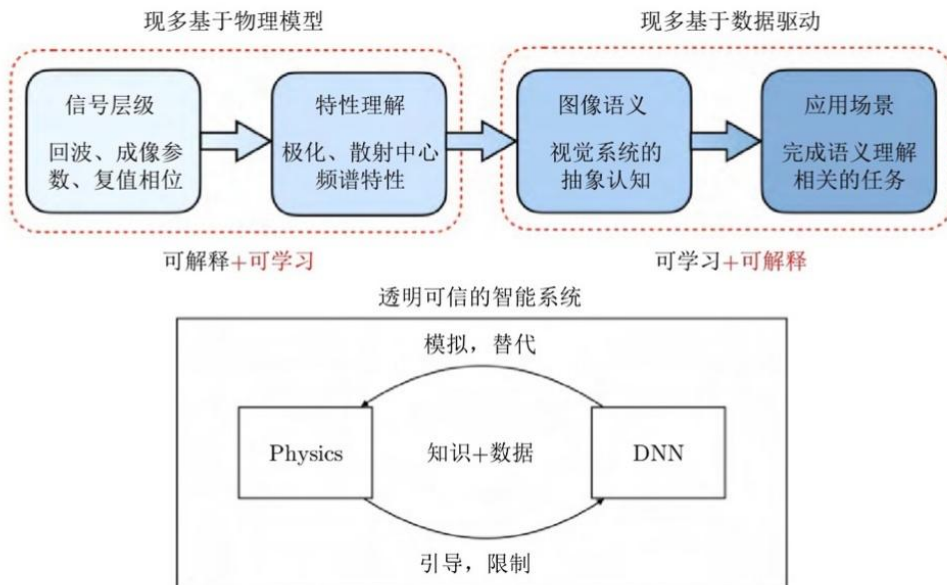


图 8-33 物理可解释的深度学习 SAR 图像处理流程

知识驱动和数据驱动相结合的后深度学习时代已经到来，可解释

的内在物理机理和可学习的深度神经网络优势互补，具有广阔的发展前景。未来，如何构建和表达先验知识，并嵌入到深度模型的学习和推理过程中，实现有效的“人在环路”的人机协同计算，发展解释性强、泛化性好、鲁棒性高的模型和方法是一个重要方向。

本章撰写人员：陈小龙、邓振华、何肖阳、关键、杜晓林、薛伟、苏宁远；

参与撰写单位：海军航空大学，哈尔滨工程大学烟台研究院，烟台大学）

参考文献

- [1] Ningyuan Su, Xiaolong Chen, Jian Guan, Yong Huang. Maritime Target Detection Based on Radar Graph Data , Graph Convolutional Network. IEEE Geoscience & Remote Sensing Letters, 2022, 19: 1-5.
- [2] 韩冰鑫.基于机器学习的雷达杂波抑制方法研究[D].西安电子科技大学, 2021.
- [3] 施端阳,林强,胡冰等.遗传算法优化神经网络的雷达杂波抑制方法[J].现代防御技术, 2021, 49(06): 80-89.
- [4] 施端阳,林强,胡冰等.基于 LVQ 神经网络的雷达杂波抑制方法[J].火力与指挥控制, 2023, 48(04):37-44.
- [5] X. Tang, D. Li, W. Cheng, J. Su and J. Wan, "A Novel Sea Clutter Suppression Method Based on Deep Learning with Exploiting Time-Frequency Features," 2021 IEEE 5th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), Chongqing, China, 2021, pp. 2548-2552, doi: 10.1109/IAEAC50856.2021.9390660.
- [6] Y. Wang, W. Zhao, X. Wang, J. Chen, H. Li and G. Cui, "Nonhomogeneous Sea Clutter Suppression Using Complex-Valued U-Net Model," in IEEE Geoscience and Remote Sensing Letters, vol. 19, pp. 1-5, 2022, Art no. 4027705, doi: 10.1109/LGRS.2022.3214633.

- [7] 段克清,李想,行坤等.基于卷积神经网络的天基预警雷达杂波抑制方法[J].雷达学报,2022,11(03):386-398.
- [8] X. Mou, X. Chen, J. Guan, Y. Dong and N. Liu, "Sea Clutter Suppression for Radar PPI Images Based on SCS-GAN," in IEEE Geoscience and Remote Sensing Letters, vol. 18, no. 11, pp. 1886-1890, Nov. 2021, doi: 10.1109/LGRS.2020.3012523.
- [9] 杨宏宇,王峰岩.基于深度卷积神经网络的气象雷达噪声图像语义分割方法[J].电子与信息学报,2019,41(10):2373-2381.
- [10] Z. Cui, X. Wang, N. Liu, Z. Cao and J. Yang, "Ship Detection in Large-Scale SAR Images Via Spatial Shuffle-Group Enhance Attention," in IEEE Transactions on Geoscience and Remote Sensing, vol. 59, no. 1, pp. 379-391, Jan. 2021, doi: 10.1109/TGRS.2020.2997200.
- [11] X. Ye, J. Qian, L. Wang and Y. Wang, "Noise suppression of ISAR micro cluster targets based on Generated Adversarial Network," 2021 CIE International Conference on Radar (Radar), Haikou, Hainan, China, 2021, pp. 704-707, doi: 10.1109/Radar53847.2021.10028484.
- [12] Zhou, Haoqiu, Xuan Feng, Zejun Dong, Cai Liu, and Wenjing Liang. 2021. "Application of Denoising CNN for Noise Suppression and Weak Signal Extraction of Lunar Penetrating Radar Data"*Remote Sensing* 13, no. 4: 779.
- [13] 耿常青,杨承志,吴宏超等.基于卷积神经网络的微弱雷达信号增强技术研究[J].战术导弹技术, 2018, No. 192 (06): 101-105. DOI: 10.16358/ j.issn. 1009-1300. 2018.8.108.
- [14] 曹鹏宇,杨承志,石礼盟等.基于 DAE-GAN 网络的 LPI 雷达信号增强[J].系统工程与电子技术,2021,43(09):2493-2500.
- [15] 苏琮智,吴宏超,杨承志等.基于 RSETransformer 的低截获概率雷达信号增强[J].战术导弹技术, 2022, No. 215 (05): 44-54+140. DOI: 10.16358/ j.issn. 1009-1300. 20220096.

- [16] Y. Kong, D. Feng and J. Zhang, "Radar HRRP Target Recognition Based on Composite Deep Networks," 2022 International Applied Computational Electromagnetics Society Symposium (ACES-China), Xuzhou, China, 2022, pp. 1-5, doi: 10.1109/ ACES-China56081. 2022.10064953.
- [17] T. Tang, C. Wang and M. Gao, "Radar Target Recognition Based on Micro-Doppler Signatures Using Recurrent Neural Network," 2021 IEEE 4th International Conference on Electronics Technology (ICET), Chengdu, China, 2021, pp. 189-194, doi: 10.1109/ ICET51757. 2021.9450934.
- [18] 苏宁远, 陈小龙, 陈宝欣, 关键. 雷达海上目标双通道卷积神经网络特征融合智能检测方法. 现代雷达, 2019, 41(10):47~52.
- [19] Xiaolong Chen, Ningyuan Su, Yong Huang, Jian Guan. False-Alarm-Controllable Radar Detection for Marine Target based on Multi features Fusion via CNNs. IEEE Sensors Journal, 2021, 21(7): 9099 - 9111.
- [20] 王治飞, 于俊朋, 杨予昊等. 基于帧间多维特征的深度学习雷达目标检测技术 [J]. 现代雷达, 2022, 44(12): 48-54. DOI: 10.16592/ j.cnki. 1004 -7859. 2022. 12. 007.
- [21] Z. Zeng, J. Sun, Z. Han and W. Hong, "Radar HRRP Target Recognition Method Based on Multi-Input Convolutional Gated Recurrent Unit With Cascaded Feature Fusion," in IEEE Geoscience and Remote Sensing Letters, vol. 19, pp. 1-5, 2022, Art no. 4026005, doi: 10.1109/LGRS.2022.3192289.
- [22] G. Dong and H. Liu, "A New Image Simulation Technique for Deep-Learning-Based Radar Target Recognition," in IEEE Transactions on Instrumentation and Measurement, vol. 72, pp. 1-10, 2023, Art no. 2512610, doi: 10.1109/TIM.2023.3272383.
- [23] 施端阳, 林强, 胡冰等. 深度迁移学习的两阶段雷达目标检测方法[J]. 现代雷达, 2022, 44(12): 34-41. DOI:10.16592/ j.cnki.1004-7859. 2022.12.005.

- [24] T. Chen, X. Deng, P. Wang, J. Ding, Y. Dong and Y. Wang, "Radar HRRP Target Recognition Based on an ADAM-CNN with Side-Information," 2021 CIE International Conference on Radar (Radar), Haikou, Hainan, China, 2021, pp. 1384-1387, doi: 10.1109/Radar53847.2021.10028490.
- [25] J. Qin, Z. Liu, L. Ran, R. Xie, J. Tang and Z. Guo, "A Target SAR Image Expansion Method Based on Conditional Wasserstein Deep Convolutional GAN for Automatic Target Recognition," in IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 15, pp. 7153-7170, 2022, doi: 10.1109/JSTARS.2022.3199091.
- [26] H. Huang, Y. Peng, J. Yang, W. Xia and G. Gui, "Fast Beamforming Design via Deep Learning," in IEEE Transactions on Vehicular Technology, vol. 69, no. 1, pp. 1065-1069, Jan. 2020, doi: 10.1109/TVT.2019.2949122.
- [27] W. Xia, G. Zheng, Y. Zhu, J. Zhang, J. Wang and A. P. Petropulu, "A Deep Learning Framework for Optimization of MISO Downlink Beamforming," in IEEE Transactions on Communications, vol. 68, no. 3, pp. 1866-1880, March 2020, doi: 10.1109/TCOMM.2019.2960361.
- [28] 任燕飞, 杜盈, 张劲东. 基于深度神经网络的自适应波束形成算法 [J]. Telecommunication Engineering. 2022; 62(7):852-858.
- [29] 中山大学. 一种基于深度学习的阵列稳健自适应波束形成方法:CN202210957643.X[P]. 2022-11-22.
- [30] 丁梓航, 谢军伟, 王博. 基于深度学习的 FDA-MIMO 雷达协方差矩阵缺失数据恢复方法[J]. 雷达学报 . doi:10.12000/JR23002
- [31] DEVCOM U S A, AFFAIRS A R L P, TECH V. Army fast-tracks adaptable radars for congested environments [J]. Army Communicator, 2020, 6: 1-6.
- [32] J. Hu, Z. Wei, Y. Li, H. Li and J. Wu, "Designing Unimodular Waveform(s) for MIMO Radar by Deep Learning Method," in IEEE Transactions on Aerospace

- and Electronic Systems, vol. 57, no. 2, pp. 1184-1196, April 2021, doi: 10.1109/TAES.2020.3037406.
- [33] ELBIR A M, MISHRA K V, ELDAR Y C. Cognitive radar antenna selection via deep learning[J]. IET Radar, Sonar& Navigation, 2019, 13(6): 871-880.
- [34] 陈小龙, 牟效乾, 关键. 对海雷达多维图像特征融合智能检测方法[J]. Journal of terahertz science and electronic information technology, 2022, 20(10): 1006-1016.
- [35] Chen, Xiaolong; Guan, Jian; Mu, Xiaoqian; Wang, Zhigao; Liu, Ningbo; Wang, Guoqing. Multi-Dimensional Automatic Detection of Scanning Radar Images of Marine Targets Based on Radar PPI-net. Remote Sensing. 2021, 13(19): 3856.
- [36] Xiaolong Chen, Xiaoqian Mu, Guan Jian, Ningbo Liu, Wei Zhou. Marine target detection based on Marine-Faster R-CNN for navigation radar PPI images. Frontiers of Information Technology & Electronic Engineering, 2022, 23(4): 630-643.
- [37] Xiaoqian Mou, Xiaolong Chen , Jian Guan, Yunlong Dong, , Ningbo Liu. Sea Clutter Suppression for Radar PPI Images Based on SCS-GAN. IEEE Geoscience & Remote Sensing Letters, 2021, 18(11): 1886-1890.
- [38] 牟效乾, 陈小龙, 关键, 周伟, 等. 基于 INet 的雷达图像杂波抑制和目标检测方法. 雷达学报, 2020, 9(4): 640–653.
- [39] Tan Yi-hua, Li Qing-yun, Li Yan-sheng, et al.. Aircraft Detection in high-resolution SAR images based on a gradienttextural saliency map[J]. Sensors, 2015, 15(9): 23071–23094.
- [40] Ding Jun, Chen Bo, Liu Hong-wei, et al.. Convolutional neural network with data augmentation for SAR target recognition[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(3): 364–368.

- [41] Chen Si-zhe, Wang Hai-peng, Xu Feng, et al.. Target classification using the deep convolutional networks for SAR images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(8): 4806–4817.
- [42] 杜兰, 刘彬, 王燕, 等. 基于卷积神经网络的 SAR 图像目标检测算法[J]. 电子与信息学报, 2016, 38(12): 3018-3025.
- [43] 李健伟, 曲长文, 彭书娟, 等. 基于卷积神经网络的 SAR 图像舰船目标检测[J]. 系统工程与电子技术, 2018, 40(9): 1953-1959.
- [44] Z. Cui, X. Wang, N. Liu, Z. Cao and J. Yang, "Ship Detection in Large-Scale SAR Images Via Spatial Shuffle-Group Enhance Attention," in IEEE Transactions on Geoscience and Remote Sensing, vol. 59, no. 1, pp. 379-391, Jan. 2021, doi: 10.1109/TGRS.2020.2997200.
- [45] 闵锋, 刘朋. 改进 YOLOv5 的 SAR 图像近海岸舰船目标检测算法研究[J]. 微电子学与计算机, 2023, 40(4): 38-46.
- [46] 李广帅, 苏娟, 李义红. 基于改进 Faster R-CNN 的 SAR 图像飞机检测算法[J]. 北京航空航天大学学报, 2021. DOI:10.13700/j.bh.1001-5965.2020.0004.
- [47] 牟效乾, 陈小龙, 苏宁远, 等. 基于时频图深度学习的雷达动目标检测与分类[J]. 太赫兹科学与电子信息学报, 2019, 17(1):105-111.
- [48] 陈小龙, 南钊, 关键, 陈唯实. 飞鸟与旋翼无人机雷达微多普勒测量实验研究. 电波科学学报. 2021, 36(5): 704-714.
- [49] Chen, Xiaolong, Hai Zhang, Jie Song, Jian Guan, Jiefang Li, , Ziwen He. Micro-Motion Classification of Flying Bird , Rotor Drones via Data Augmentation , Modified Multi-Scale CNN. Remote Sensing. 2022, 14(5):1107.
- [50] 施赛楠, 董泽远, 杨静, 等. 基于时频图自主学习的海面小目标检测[J]. 系统工程与电子技术, 2021, 43(1):33-41.
- [51] KIM Y, MOON T. Human Detection and Activity Classification Based on Micro-Doppler Signatures Using Deep Convolutional Neural Networks[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(1):8-12.

- [52] M. S. Seyfioğlu, A. M. Özbayoglu, and S. Z. Gürbüz, "Deep convolutional autoencoder for radar-based classification of similar aided and unaided human activities," *IEEE Trans. Aerosp. Electron. Syst.*, vol. 54, no. 4, pp. 1709–1723, Aug. 2018.
- [53] Guo C, Wang H, Xia X, et al. Deep Transfer Learning Based Method for Radar Automatic Recognition with Small Data Size[C]//2021 IEEE International Conference on Unmanned Systems (ICUS). IEEE, 2021: 995-999.
- [54] Li X, Wu D, Zhu D. Multi-channel SAR moving target detection based on simulation samples and transfer learning[C]//2021 CIE International Conference on Radar (Radar). IEEE, 2021: 2054-2057.
- [55] 任硕良, 索继东, 佟禹. 卷积神经网络结合迁移学习的 SAR 目标识别[J]. *电光与控制*, 2020, 27(10): 37-41.
- [56] Wang, X. Fu and K. Xia, "Target Classification for Single-Channel SAR Images Based on Transfer Learning With Subaperture Decomposition," in *IEEE Geoscience and Remote Sensing Letters*, vol. 19, pp. 1-5, 2022, Art no. 4003205, doi: 10.1109/LGRS.2020.3027363.
- [57] 孙晶明, 虞盛康, 孙俊. 基于元学习的雷达小样本目标识别方法及改进[J]. *系统工程与电子技术*, 2022, 44(6): 1839-1845.
- [58] Liu Q, Zhang X, Liu Y, et al. Multi-polarization fusion few-shot HRRP target recognition based on meta-learning framework[J]. *IEEE Sensors Journal*, 2021, 21(16): 18085-18100.
- [59] 吕艺璇, 王智睿, 王佩瑾, 等. 基于散射信息和元学习的 SAR 图像飞机目标识别[J]. *雷达学报*, 2022, 11(4): 652-665.
- [60] L. Tian, B. Chen, Y. Peng, C. Du, Z. Wu and H. Liu, "Meta Network for Radar HRRP Noncooperative Target Recognition with Missing Aspects," *IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium*,

- Waikoloa, HI, USA, 2020, pp. 2053-2056, doi: 10.1109/IGARSS39084.2020.9323129.
- [61] Z. Ren, W. Jiang and X. Zhang, "Few-Shot HRRP Target Recognition Method Based on Gaussian Deep Belief Network and Model-Agnostic Meta-Learning," 2022 7th International Conference on Signal and Image Processing (ICSIP), Suzhou, China, 2022, pp. 260-264, doi: 10.1109/ICSIP55141.2022.9887225.
- [62] 杜兰, 王梓霖, 郭昱辰, 等. 结合强化学习自适应候选框挑选的 SAR 目标检测方法[J]. 雷达学报, 2022, 11(5): 884-896.
- [63] W. Zhai, X. Wang, M. S. Greco and F. Gini, "Weak Target Detection in Massive MIMO Radar via an Improved Reinforcement Learning Approach," ICASSP 2022 - 2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Singapore, Singapore, 2022, pp. 4993-4997, doi: 10.1109/ICASSP43922.2022.9746472.
- [64] Y.Wang, Y. Liang, H. Zhang and Y. Gu, "Domain Knowledge-Assisted Deep Reinforcement Learning Power Allocation for MIMO Radar Detection," in IEEE Sensors Journal, vol. 22, no. 23, pp. 23117-23128, 1 Dec.1, 2022, doi: 10.1109/JSEN.2022.3211606.
- [65] Y. Shi, L. Du, Y. Guo and J. Chen, "Cross Sensor Transfer Learning for Unsupervised SAR Target Detection," 2021 CIE International Conference on Radar (Radar), Haikou, Hainan, China, 2021, pp. 2082-2086, doi: 10.1109/Radar53847.2021.10028188.
- [66] E. Donini, F. Bovolo and L. Bruzzone, "An Unsupervised Deep Learning Method for Subsurface Target Detection in Radar Sounder Data," 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS, Brussels, Belgium, 2021, pp. 2955-2958, doi: 10.1109/IGARSS47720.2021.9554785.
- [67] CHEN, XIAOLONG, SU, NINGYUAN, HUANG, YONG, et al. False-Alarm-Controllable Radar Detection for Marine Target Based on Multi

- Features Fusion via CNNs[J]. 2021, 21(7): 9099-9111. DOI: 10.1109/ JSEN. 2021.3054744.
- [68] 陈小龙,牟效乾,关键. 对海雷达多维图像特征融合智能检测方法[J]. 太赫兹科学与电子信息学报, 2022, 20(10): 1006-1016. DOI: 10.11805/ TKYDA 2022119.
- [69] 郭炜炜,张增辉,郁文贤,等. SAR 图像目标识别的可解释性问题探讨[J]. 雷达学报, 2020, 9(3): 462-476. doi: 10.12000/JR20059
- [70] M. Datcu, Z. Huang, A. Anghel, J. Zhao and R. Cacoveanu, "Explainable, Physics-Aware, Trustworthy Artificial Intelligence: A paradigm shift for synthetic aperture radar," in IEEE Geoscience and Remote Sensing Magazine, vol. 11, no. 1, pp. 8-25, March 2023, doi: 10.1109/MGRS.2023.3237465.
- [71] 黄钟铃,姚西文,韩军伟. 面向 SAR 图像解译的物理可解释深度学习技术进展与探讨[J]. 雷达学报, 2022, 11(1): 107-125. doi: 10.12000/JR21165
- [72] L. Liao, L. Du and J. Chen, "Interpretable Deep Probabilistic Model for HRR Radar Signal and its Application to Target Recognition," in IEEE Journal of Selected Topics in Signal Processing, vol. 16, no. 4, pp. 775-790, June 2022, doi: 10.1109/JSTSP.2022.3160241.
- [73] T. Wu *et al.*, "A Brief Overview of ChatGPT: The History, Status Quo and Potential Future Development," in *IEEE/CAA Journal of Automatica Sinica*, vol. 10, no. 5, pp. 1122-1136, May 2023, doi: 10.1109/JAS.2023.123618.
- [74] A. M. J. Hashana, P. Brundha, M. U. Ahamed Ayoobkhan and F. S, "Deep Learning in ChatGPT - A Survey," 2023 7th International Conference on Trends in Electronics and Informatics (ICOEI), Tirunelveli, India, 2023, pp. 1001-1005, doi: 10.1109/ICOEI56765.2023.10125852.

第9章 深度学习与智慧海洋相关应用

我国拥有300多万平方公里的内海、领海和专属经济区，在党的十八大、十九大以及二十大报告中，均对“建设海洋强国”提出了要求与展望，涉及军事、国防、环境与资源保护等多个领域的发展与策略部署。海洋信息的获取对于海洋资源勘探、海洋环境监测以及海上国防军事等方面均具有重要的意义。由于人工智能、计算智能和神经网络展示了其在信号/图像分析、对象检测和模式识别等方面的强大能力，其在海洋图像智能化领域中受到的关注不断上升。近年来，深度学习技术在海量图像数据信息挖掘中大放异彩，涌现出大量的融合深度学习与大数据等前沿技术的任务与感知双重驱动的智能应用。对于海洋图像相关应用的研究从未止步，且与新兴视觉相关技术的结合愈加紧密。

9.1 海洋图像处理

水下图像是获取海洋信息的重要媒介，由于海洋环境的特殊性，水下图像在获取、传输过程中均面临众多挑战，如拍摄平台晃动易造成图像离焦模糊、信道快时变易引起图像产生传输失真等等。同时，在水下图像的相关应用方面，也存在着图像处理、图像优化等需求。本文以任务为导向，归纳总结水下图像处理的重要任务如下表 9-1 所示。

表 9-1 水下图像处理算法

水下图像处理重要任务	切入角度
图像压缩	变换域、压缩感知
图像增强	水下成像模型、深度学习模型
图像拼接	特征图像匹配、多尺度图像融合
图像分割	聚类分割、水平集理论、多阈值分割

在近年来的发展过程中，其重要进展如下图9-1所示：

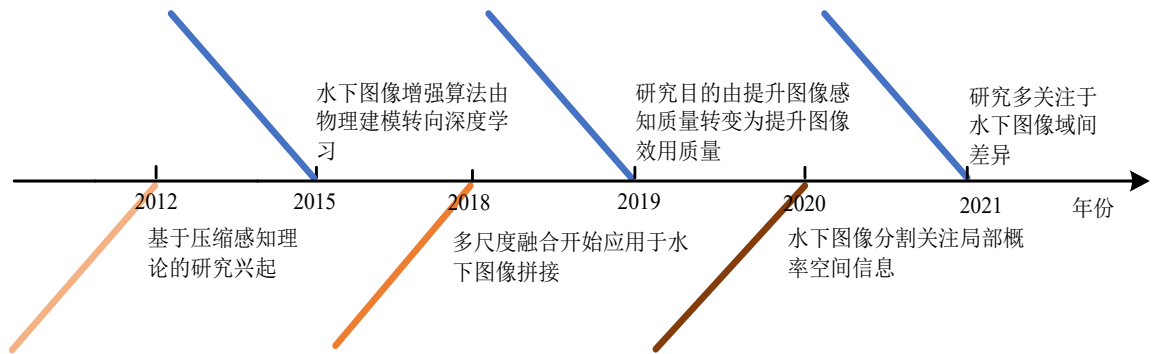


图 9-1 水下图像处理技术发展

水下图像在采集与传输过程中，常遇到传输带宽有限与图像质量低劣两大问题。一方面，由于电磁波在水下的衰减严重，海洋中往往采用声通信的形式进行信息传输，而水声信道的带宽极其有限。水下图像压缩算法是针对带宽受限问题的重要解决方案，是实现高效信息分析的基础，其内核是最大限度地利用不同场景下的冗余信息。另一方面，海洋环境相比大气环境更为复杂，恶劣环境条件影响着图像的采集过程，使图像出现噪声、蓝绿色调、离焦模糊、湍流模糊等影响质量的不利特性。为此，水下图像增强技术能够有效改善水下图像的退化问题^[1]。且对于具有特殊应用背景的水下图像而言，增强不仅仅要提高视觉效果，还应突出图像中的有效信息。

为了进一步提高后续智能应用的效率，帮助水下自主机器人实现导航、定位和测绘等功能，水下图像拼接与分割成为水下应用中最常见的预处理手段。水下图像拼接技术可以生成大幅度、高分辨率、宽视角的图像，准确、鲁棒、快速地实现全景拼接。水下图像分割技术可以将图像中具有不同特性的区域按照像素级进行划分并从中提出感兴趣区域。然而，多见于声呐图像的局部畸变与边缘弱化情况、水下光学图像普遍存在的非均匀光照、低对比度等现象，以及在图像传输过程可能会为图像引入的块效应、模糊效应、振铃

效应等压缩伪影，都为拼接与分割任务引入了不利特性，对准确预处理带来了干扰。因此，为避免出现不精确或过拟合问题，需要充分考虑水下特性。下图9-2示例展现了水下图像拼接、分割的结果：




图 9-2 水下图像拼接、分割结果

水下图像压缩算法与自然图像压缩算法目的类似，即在不降低质量的前提下对数据进行压缩。相应地，压缩比和失真比共同决定了图像压缩算法的性能。Anjum等人提出了一种可靠且节能的基于机器学习(ML)的水下图像传输系统，其中使用基于数据的方法压缩图像并学习鲁棒压缩代码^[2]。该系统使用自动编码器(AE)来实现智能、数据驱动的编码参数选择。Liu^[3]采用自编码器对水下图像进行极限比特率压缩。然后，提出了一种多步训练策略，通过逐步学习信道退化特征来提高解码器的鲁棒性。最后，自动编码器通过两条路径对图像进行编码，从而在重构图像时实现高效的压缩和更高的图像质量。

为缓解图像采集、传输过程引入的失真，提升水下图像的感知质量，往往需要通过噪声去除与颜色校正对图像进行一定程度的增强。随着水下智能应用的发展，为缓解水下降质因素对水下应用带来的不利影响，在对图像进行信息分析之前，通常需要利用清晰化手段实现图像恢复。目前关于水下图像增强的研究多集中于水下光学图像，主要包括有海洋雪噪声的去除、色彩降维的校正以及模糊、

有雾的恢复。此外，声呐图像增强的研究主要集中于斑点噪声的去除。

去噪是图像增强中最为基础的环节，大多数水下图像去噪算法都基于特定类型的噪声设计。随着生成对抗网络的发展，Guo^[4]、Zhou等人^[5]先利用其进行域迁移，合成未失真的水下图像，获取足量的配对数据，再在此基础上构建了一系列端到端的增强网络。随着数据量的提升，神经网络的优势逐渐扩大，Islam等人^[6]通过对全局内容与颜色、风格特征以及局部纹理的评估，制定了一个多模式的水下图像感知质量目标函数来约束整体模型训练方向。Li等人^[7]将知识驱动的物理模型与数据驱动学习网络结合，利用多颜色空间嵌入，提出多色空间编码增强网络。考量到水下复杂环境的多样性，Fu等人^[8]基于U-NET网络架构将空间与通道尺度分别归一化处理，通过消除相关性来提取水下图像的真实特征，再从中重构出原始图像。Lin等人^[9]提出失真引导的图像复原算法，构建了水下图像失真检测与修复数据集，提出了两阶段的图像修复框架，将复杂的修复任务拆分为两个阶段：失真检测与引导修复阶段。设计失真引导模块与信息筛选模块以提升最后的修复性能。失真引导模块能够利用失真检测的信息，对不同的失真给予不同的修复策略引导。信息筛选模块过滤失真图像的严重失真信息防止其在网络中前向传播，并留下有用信息以帮助修复。

通过图像拼接技术能够得到视场更大、表达更直观的水下图像，为实现海底测绘、海洋探测等任务提供基础，尤其对于侧扫声呐、前视声呐与多波束声呐图像而言，图像拼接技术是实现图像智能分析、应用的必要基础。图像拼接可以分为图像匹配和图像融合两部分，其中图像匹配是关键步骤，要点在于通过匹配点构建图像序列之间的变换矩阵。融合是图像拼接的补充步骤，融合是为了实现整体的亮度和颜色的均衡一致，然而，在拍摄水下图像时，点光源照射以及非线性像差往往导致图像出现非均匀光照、扭曲、畸变、模糊等缺陷。

水下图像的质量大大限制了图像匹配技术的准确率，为水下图像拼接任务带来了更大难度。在图像融合方面，为避免引入额外的伪影，研究人员大多基于多尺度分析进行图像融合^[10]。Sheng等人^[11]在预处理水下图像后利用修改后的深度卷积神经网络进行特征提取，通过改进的RANSAC(RANdom SAmple Consensus)方法剔除误匹配点。该方法能够检测到更多的特征点，实现了匹配精确率和召回率的大幅度提。

图像分割是根据表现出一致性或相似性的特征划分图像为明显不同区域的技术。水下图像分割技术通过实现水下图像目标与背景的分割，为后续智能应用提供基础。水下图像分割算法需要克服水下光学图像亮度不均、轮廓边缘特性不一致、弱特征的不利性质，获得精确的目标边缘分割效果。Nezla等人尝试采用语义图像分割的方法对水下目标进行探测，该以基于UNet的语义分割网络为基本框架，并将其扩展到对水下鱼类知识图像数据集的精确分割^[12]。Xu等人根据声纳图像的特点，提出了一种基于深度CNN图像去噪的图像去噪分割算法(DnCNN)，该算法融合了感受野块和注意搜索功能^[13]。

9.2 海洋媒体信息质量感知

图像具有文字数据等无法比拟的直观效果，在海洋信息的表达形式中，图像已成为重要的组成部分。然而水下图像往往面临着质量不高的困境，在图像采集过程中，常见的降质因素可以概括如下：1) 由于不同波长的光在水下衰减速度不同所造成的色彩降维，这使得水下光学图像多呈现蓝绿色调；2) 水体本身及其他物质的吸收作用随水深加重，图像易出现欠曝光的情况，同时，水下拍摄时往往需要人为添加点状光源辅助照明，极易产生低亮度、非均匀光照等现象；3) 复杂的水下环境中多见光线散射作用，图像易出现模糊、有雾的情况，此外，水流波动以及拍摄平台抖动易引发诸如湍流模糊或离焦模糊等现象；4) 由于人为干扰以及海洋微生物的存在，在光学图像上多见有海洋雪现象，同

时,受到水下声波传播特性影响,在声呐图像上多见有斑点噪声;5) 在声呐工作时,声波频率与穿透力成反比,为取二者之折中,声呐图像往往存在分辨率不高的现象。这些因素导致水下图像普遍存在低对比度、低清晰度、蓝绿色调、噪声、模糊等问题。下图展示了典型降质现象:图 9-3(a)所示为由色彩降维所引起的蓝绿色调;图 9-3(b)-(c)为亮度不佳情况下拍摄的水下图像,图 9-3(d)所示为离焦模糊,其成因是拍摄平台抖动;图 9-3(e)所示为由光散射作用形成的有雾图像;图 9-3(f)所示为海洋雪现象,其成因源自于已死或将死的动植物(浮游生物)、原生生物(如硅藻)、细菌、粪便颗粒、泥沙和尘土等,表现为图像上雪花状的噪点;图 9-3(g)为声呐图像常见的斑点噪声,其成因源自海底混响;图 9-3(h)为典型低分辨率声呐图像。




图 9-3 典型降质现象

当采集设备与陆地分析终端进行通信时,具有快时变、窄带宽、快衰弱等特性的水声信道决定了图像的传输和压缩过程均不可避免地会为图像引入失真。图像质量的降低将进一步造成图像分析与应用过程的误判与漏判。因此,在实际水下应用中,为了实现图像质量的监测与

控制，往往引入图像质量评价。预测所得质量可用于采集、传输图像过程中的质量监控、图像增强算法的性能测度、自适应智能传输控制等方面。水下图像质量评价的主流方式如下表9-2 所示：

表 9-2 水下图像质量评价主流方式

水下图像质量评价主流方式	工作思路
主观质量评价	单刺激、双刺激、成对比较
全参考质量评价	保真度、相似度
无参考质量评价	自然性、退化模型
部分参考质量评价	效用值、图像理解

其中，主观质量评价利用人眼视觉主观感受确定图像质量，客观质量评价利用计算机算法估计人眼视觉主观感受，智能地实现图像质量实时监控。目前最主流的做法是通过特征提取、机器学习等计算机算法，模拟人眼视觉系统运作机理，实现图像质量的客观评价。相比传统光学图像，针对水下图像质量评价的相关研究较少，以下根据评价过程是否参考来自原始图像的信息，总结几类经典的与最新的水下图像质量评价算法。

全参考质量评价，全参考质量评价需要完整的原始图像信息作为待评价图像的比较对象，常被用于图像压缩、增强等能够提供完整参考图像的应用中。因此，相较于水下光学图像，关于声呐图像全参考质量评价的研究会更多。由于参考图像的存在，全参考质量评价算法性能往往优于非全参考算法。

根据参考方式的不同，全参考质量评价算法可以分为基于失真度与基于相似度两种。前者根据人眼视觉系统(Human Vision System, HVS)定义失真，通过参考原始图像定义待评价图像的失真程度，后者参考原始图像的特征信息，量化待评价图像的质量。水下图像 JND 模型能够帮助水下通信系统最大限度地减少信道资源浪费，吴迪等人^[14]利用全参考的损伤感知网络来预测失真图像相对于参考图像是否有感知损失，根据预测结果反馈调整压缩率。Zhang 等人^[15]

对多尺度提取的结构和轮廓信息进行像素级融合进而提出声呐图像质量评测算法,在声呐图像质量数据库(Sonar Image Quality Database, SIQD)上测试表明,该算法达到了较高的准确性与一致性。

无参考质量评价,与全参考质量评价相反的,是完全不需要任何参考信息的无参考质量评价。鉴于水下图像质量与其退化特性息息相关,无参考质量评价算法主要分为针对水下光学图像的评价以及针对声呐图像的评价。

对于水下光学图像,基于深度学习的策略无须手工设计特征和测量分量,不受水下图像的退化类型限制。郭继昌等人^[16]先采用深度神经网络提取水下图像的特征,再使用提取的特征和标定的水下图像质量分数训练回归模型。该方法预测准确度高、鲁棒性强。

在海洋相关应用中,水下图像往往具有明确的任务背景,因此需要根据效用对图像质量进行评估。传统的图像质量评价方法通常以人眼视觉系统感知的图像保真度或美学特性作为评价标准。然而,效用和感知质量之间的低相关性导致传统的图像质量评价方法无法直接用于水下图像的效用质量评价,因此有必要以效用为导向,面向特定任务,设计基于效用指标的质量评价算法。主观数据集是完成客观质量评价算法的重要基础,但是目前没有针对特定任务的图像主观质量数据集。文献[17]基于水下鱼类检测任务,构建主观图像质量数据集。本文基于效用质量评价标准,选取相应水下素材,有针对性地对图像进行不同区域不同程度的劣化,形成具有内容多样性、失真类型有针对性的图像数据集,并设计相应主观实验过程,以此构建一个面向目标检测的水下图像效用质量数据集。

同时,作者提出了基于迁移学习的图像效用质量评价方法。本文利用迁移学习,将具体任务中所关注的高层语义特征迁移至模型中,同时借助预训练,有效缓解了深度学习中的过拟合问题,得到

了一个基于学习的水下图像效用评估方法。实验结果表明，该方法在图像效用质量数据集中得到了最好的性能。

对声呐图像而言，由于水下环境的复杂性以及声呐成像的本质导致声呐图像对比度差、分辨率低且细节模糊。超分重建技术可以提高图像分辨率，缓解工作距离对声呐成像精度的制约。对超分重建声呐图像进行效用质量评价，可以衡量重建结果，指导优化重建过程。现有光学图像数据集的质量评价指标更多的是探讨图像感知失真，而对声呐场景图像来说，主要强调的是图像完成某种任务时的有用程度。文献[18]提出任务导向的主观质量评价指标，并基于该评价指标，建立了首个效用质量的超分重建声呐图像主观数据集，该数据集更准确反映图像在具体任务中的可用性，适用于有任务需求的场景。

由于声呐图像多应用于目标识别任务，文献[18]在研究大脑识别机制的基础上，研究了超分重建声呐图像效用感知算法。当数据量超过某个临界值后，神经网络因其能学习到更多知识而表现出更优的性能。因此，作者通过提取 VGG19 的各卷积层特征，并引入通道注意力模块和尺度自适应模块将不同层次和通道的特征连接起来。同时，该方法采用迁移学习将预训练网络参数作为模型的初始参数，并微调网络以适应超分重建声呐图像质量评价任务的需求。

9.3 水下机器视觉

机器视觉技术是一个发展迅速的新兴领域。机器视觉技术在图像处理与质量评价的基础上，进一步以计算机模拟信息处理过程，最终实现信息的理解与智能处理。21世纪以来，随着大规模数据集的出现与计算机硬件的发展，数据驱动的机器视觉技术研究拥有了平台支撑。随着卷积神经网络等深度学习算法的兴起，机器视觉技术在目标识别、目标检测、目标跟踪等任务中取得了瞩目的成绩。近年来，随着对海洋的认

知与开发步伐的加快，以上任务的场景渐渐扩展到了海洋环境中，如海洋生态监测、水下救援、地质测绘等应用，均对机器视觉技术有巨大需求。下图9-4展示了机器视觉技术应用于水下图像的简单示例：




图 9-4 机器视觉技术应用示例

尽管机器视觉技术在大气环境中的应用已普遍成熟，但鉴于水下图像与大气自然图像之间的显著差异，大气中的机器视觉技术应用于水下会面临以下典型问题：

1) 准确性不高：水下光/声学图像与自然图像的内容及特征相去甚远，水下图像有效特征的提取以及各个特征之间的相关性等尚有许多不明确。同时，水下图像在采集传输过程中易受到噪声、海洋生物、普通扰动等因素的干扰，且水下信道复杂多变，暂时还没有完善的模型。鉴于大气环境中的机器应用往往忽略了以上因素，因此将大气环境中的技术直接应用于水下图像，将不可避免地导致准确性不高的问题。

2) 泛化性能差：水下图像采集成本高、难度大、稳定性低，采集设备在水下的活动能力远低于大气环境中的设备，因此水下图像数据集多呈现规模小、类别不平衡等问题。以上水下数据集的特殊性，对于数据驱动算法的泛化性能是一巨大考验。实验表明，大气环境中的相关技术在水下数据集中往往具有过拟合的问题，因此提升泛化能力是水下机器视觉技术的研究关键。

3) 实时性较差：水声信道具有带宽有限、多径、快衰落等特点，这将对信号的实时传输带来巨大的挑战。另一方面，水下环境瞬息万变，且应用多处于无人值守的状态，这要求机器具备快速判断、反馈以及处理的能力，以便应对环境的变化。传统机器视觉技术在实时性方面考量不能满足水下应用的需求，因此常出现实时性较差的问题。

表 9-3 水下机器视觉关键应用

水下机器视觉关键应用	主流算法
目标识别	聚类、深度卷积神经网络
目标检测	Faster RCNN、YOLO、深度卷积神经网络
目标跟踪	粒子滤波、深度卷积神经网络

水下图像于目标识别任务的关键特征并不突出，而有效的特征表达是目标识别任务能否成功的关键。另一方面，水下图像与大气自然图像相比，具有完全不同的目标、背景与应用场景，水下图像目标识别的特征提取往往反映了海洋环境特有的需求。水下背景复杂、目标形变等现象导致数据呈现类间差距小、类内差距大的不利特点。Cai 等人^[19]融合水下目标的语义特征与其视觉显著特征，建立了 UDTRNet (Underwater Distortion Target Recognition Network)，缓解了失真干扰下识别精度低的情况。

数据库有限是声呐图像识别任务面临的一大难点，文献[20]通过对样本数据集分块以增加样本数量，采用基于稀疏表示的字典学习方法训练样本字典实现分类。Huo 等人^[21]将半合成数据生成方法与迁移学习相结合，利用深度卷积神经网络实现分类任务，准确率达到 97.76%。声呐图像识别任务的另一大难点在于其并不显著的特征伴随着严重的噪声，文献^[22]利用深信度网络学习得到的权值矩阵来自适应调整卷积神经网络滤波器算子的权值分布。实验结果表明卷积神经网络的平均分类正确率为 79.6%，而自适应权值卷积神经网络能够达到 84%。

水下目标多见遮挡、重叠、形变，面对水下图像数据集规模以及数据集质量的限制，如何在样本有限、难样本的情况下实现对目标更高精度的检测、如何提高模型泛化性能是水下目标检测的主要难点。针对这一难点，Sung^[23]、陈禹蒲等人^[24]基于著名的目标检测网络——YOLO(You Only Look Once)系列模型结构，利用数据预处理和迁移学习，仅需少量样本进行适用性微调即获得较高的检测准确率。Jiang等人^[25]先对卷积得到特征图进行锐化或增强处理，再利用提出的通道级信道锐化注意模块(Channel Sharpening Attention Module, CSAM)融合图像信息，进一步提升检测精度。为了避免在多变的水下环境中发生鱼类的误检和漏检，Zhao等人^[26]基于Cascade RCNN(Cascade Regions with CNN features)模型提出了Composited FishNet，通过辅助骨干网络学习水下场景变化信息，减少了水下环境信息对物体特征的干扰，加强了骨干网络目标特征的信息输出。

声呐图像有限的样本数据往往遭受严重噪声干扰，Jiang等人^[27]引入生成对抗网络，选取声呐图像部分高信息量的样本进行标注以降低标注成本，又通过不断迭代选取、更新模型的方式将主动学习算法和检测模型融合，对比经典的目标检测算法SSD(Single Shot multibox Detector)、YOLO等性能均有所提升。

目标跟踪，目标跟踪算法的准确性由预测目标中心位置与真实目标中心位置之间的误差来评估，通过统计距离符合阈值的视频帧在整个视频序列帧数中的占比来描述跟踪性能。水下目标跟踪为分析海洋生物行为、监测海洋提供了关键的信息，而水下的复杂场景为任务实现带来了更加严峻的挑战。水下目标往往存在变形现象且易受到背景、照明变化以及遮挡的影响，Gupta等人^[28]利用Simase模型学习鱼类外观的相似性，通过长短期记忆(Long Short Term Memory, LSTM)模型学习目标运动的相似性，通过联合学习提出了DFTNet (Deep Fish Tracker)。

对于目标检测算法尤其是基于深度学习的目标检测算法，需要大量的数据进行训练，表9-4列举了水下光学目标检测算法研究中公开采用的数据集资源，供学者们开展算法验证。

表 9-4 水下光学目标检测算法研究中公开采用的数据集

数据集	年份	数据集大小	物体	来源	分辨率	网址
Wild Fish Marker	2015	929+1005 正样本 3167 + 2061 负样本数据集	鱼和其他的海底生物	NOAA 数据集	多变的	https://swfscdata.nmfs.noaa.gov/labeled-fishes-in-the-wild/
HabCam underwater	2019	10 465	扇贝、沙钱、石头、个别鱼	2019 年环境监测的海洋视频自动分析挑战赛	2720x1024	https://habcam.whoi.edu/
MOUSS	2019	159	鱼	2019 年环境监测的海洋视频自动分析挑战赛	968x728	https://www.viametoolkit.org/
MBARI	2019	666	鱼类	2019 年环境监测的海洋视频自动分析挑战赛	1920x1080	https://www.mbari.org/
Fishclef2014	2014	24872	12 个鱼类	Fish4knowledge 水下数据集	320x240 640x480	https://www.imageclef.org/2014/lifeclef/fish
Fishclef2015	2015	9162 个标注, 超过 20 000 个图像	15 种鱼的类别	Fish4knowledge 水下数据集	320x240	https://www.imageclef.org/lifeclef/2015/fish
Seaclef2016	2016	9000 多个标注和 20000 多张样本图像	15 种鱼的类别	Fish4knowledge 水下数据集	320x240	https://www.kaggle.com/2016/sea .
Brackish	2019	25613 个注释, 数据集共包括 14 5186 帧	大鱼、小鱼、水母、螃蟹等 6 种	brackish water	多变的	https://www.heywhale.com/home/aalborguniversity/brackish-dataset
URPC2021	2021	7600+1200 张带标注的水下图像	海参、海胆、扇贝、海星	全国水下机器人大赛 URPC	多变的	https://www.heywhale.com/home/aalborguniversity/brackish-dataset
UDD	2022	1827	海参、海胆、扇贝	真实海底图片	多变的	https://github.com/chongweiliu/UDD_Official
UWD	2020	10000	同上	真实海底图片	多变的	
DUO	2021	6671+1111 张带标注的水下图像	同上	真实海底图片	多变的	https://github.com/chongweili/DUO

Marine Litter	2019	5720	塑料垃圾、人为目标、生物		480x320	
TrashCan	2020	7212	海底垃圾、动植物等22类	J-EDI (JAMSTEC E-Library of Deep-sea Images)	480x320	https://conservancy.umn.edu/handle/11299/214865
SUIM	2020	SUIM1525	鱼类、珊瑚、植物、人、残骸等8类		多变的	https://irvlab.cs.umn.edu/resources/suim-dataset

对于鱼类检测和物种分类，最常用的是Fish4Knowledge数据集，该数据集包括数据集A和数据集B两部分，数据集A包含23种鱼类的27370张图像。数据集B克罗地亚鱼类数据集包含12种鱼类的794幅图像，分辨率为1280×960，包含带边界框的带注释的真值（GT）和物种名称。Lifeclef数据集包含Fishclef2014数据集、Fishclef2015数据集、Seaclef2016数据集3个鱼类数据集，Fishclef2014数据集数据来源是Fish4knowledge水下数据集，Fishclef2014数据集中训练集包含285个视频，19868个鱼类注释，包含10种鱼的类别。Fishclef2015数据集训练数据集包括20个手动标注的视频，共15种鱼的类别，共包含9162个标注。Seaclef2016数据集基于2014Fishclef和2015Fishclef数据集，在两个数据集的基础上增加了鲸鱼、海豚、海床、珊瑚等目标，训练集包含20个低分辨率视频和20000多张样本图像。5个视频的分辨率是640×480，其余15个视频的分辨率是320×240。JÄGERJ等对Seaclef2016数据集进行了标注。WildFishMarker数据集是在2015年提出的，数据来源是美国国家海洋和大气管理局（NOAA）数据集，该数据集包括鱼类、无脊椎动物和海床的图像，训练集由929个图像文件组成，其中包含1005个带相关标注的标记鱼。在海洋生物检测中不仅仅是对鱼类感兴趣，另一个关键领域是监测底栖生物，如扇贝和珊瑚。HabCam数据集包含250万张带注释的图片，主要是扇贝，也有鱼类和海星。2018年和2019年“用于环境监测的海洋视频自动化分析”研讨会中发布了MOUSS数据集、MBARI水下数据集，这些数据集都

包含目标的注释，注释用**Boundingbox**或者关键点标出。MOUSS数据集包含159副包含注释的鱼类图像，MBARI水下数据集包含666副鱼类图像。**Brackish**数据集于丹麦北部的海峡中拍摄，包含鱼类、螃蟹和其他海洋生物，目标的位置用边界框进行注释，有14518个图像，包含6个类别的28518个标注信息。

针对水下机器人自主抓取所需的感知探测技术，中国连续数年举办了全国水下机器人大赛(**Underwater Robot Professional Contest, URPC**)，采集海参、海胆、扇贝、海星等近海底常见目标构建数据集。URPC2017存在大量相似或重复的图像，精简后的URPC2018常用于算法的对比，后续的版本在前一年的图像库中逐渐增加新图像。美中不足的是，URPC的部分数据缺少海星标签，容易出现错误或标签缺失，并且测试集图像的标注没有公开。RUIE(**Real-time Underwater Image Enhancement**)数据集构建了目标检测子集，但是图像数量不多。为了解决上述问题，UDD(**Underwater open-sea farm object Detection Dataset**)收集了高清海底图像并进行了精细的标注；UWD(**UnderWater Dataset**)收集了URPC及大量互联网图像，构建超过一万张图像的大型数据集进行模型训练。DUO(**Detecting Underwater Objects**)基于相关数据集进行收集和重新注释，并公平比较了十余种通用目标检测模型的效果，为后续研究提供了重要实验数据支撑。

参考文献

- [1] 丛润民, 张禹墨, 张晨, 等. 深度学习驱动的水下图像增强与复原研究进展, 信号处理, 2020, 36(9): 1377-1389
- [2] K. Anjum, Z. Li and D. Pompili, Acoustic Channel-aware autoencoder-based compression for underwater image transmission. 2022 Sixth Underwater Communications and Networking Conference (UComms), Lerici, Italy, 2022.

- [3] J. Liu, F. Yuan, C. Xue, et al. An efficient and robust underwater image compression scheme based on autoencoder, in IEEE Journal of Oceanic Engineering, 2023.
- [4] Y. Guo, H. Li, P. Zhuang. Underwater image enhancement using a multiscale dense generative adversarial network. IEEE Journal of Oceanic Engineering, 2020, 45(3): 862-870.
- [5] Y. Zhou, K. Yan, X. Li. Underwater image enhancement via physical-feedback adversarial transfer learning. IEEE Journal of Oceanic Engineering, 2022, 47(1): 76-87.
- [6] M. J. Islam, Y. Xia, J. Sattar. Fast underwater image enhancement for improved visual perception. IEEE Robotics and Automation Letters, 2020, 5(2): 3227-3234.
- [7] C. Li, S. Anwar, J. Hou, et al. Underwater image enhancement via medium transmission-guided multi-color space embedding. IEEE Transactions on Image Processing, 2021, 30: 4985-5000.
- [8] Z. Fu, X. Lin, W. Wang, et al. Underwater image enhancement via learning water type desensitized representations, ICASSP 2022 - 2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Singapore, Singapore. IEEE,2022: 2764-2768.
- [9] Z. Lin, W. Chen, W. Lin, et al. A distortion-guided strategy for efficient underwater image restoration, OCEANS 2022, Hampton Roads. IEEE, 2022:1-5.
- [10] C. O. Ancuti, C. Ancuti, De Vleeschouwer, et al. Color balance and fusion for underwater image enhancement. IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society, 2018, 27(1): 379-393.
- [11] M. Sheng, C. Tang, Z. Cui, et al. A joint framework for underwater sequence images stitching based on deep neural network convolutional neural network. International Journal of Advanced Robotic Systems, 2020, 17(2).

- [12] N. A. Nezla, T. P. Mithun Haridas and M. H. Supriya, Semantic segmentation of underwater images using UNet architecture based deep convolutional encoder decoder model, 2021 7th International Conference on Advanced Computing and Communication Systems (ICACCS), Coimbatore, India, 2021.
- [13] H. Xu, L. Zhang, M. J. Er, et al. Underwater sonar image segmentation based on deep learning of receptive field block and search attention mechanism, 2021 4th International Conference on Intelligent Autonomous Systems (ICoIAS), Wuhan, China, 2021.
- [14] 吴迪, 袁飞, 程恩. 水下图像仅可察觉差异预测模型. 厦门大学学报(自然科学版), 2021, 60(1): 91-96.
- [15] H. Zhang, D. Li, S. Li, et al. Using multiscale structural fusion for sonar image quality evaluation, 2020 5th International Conference on Mechanical, Control and Computer Engineering. Harbin, China. IEEE, 2020: 2331-2335.
- [16] 郭继昌, 李重仪, 张艳, 等. 面向水下图像的质量评价方法. 中国图象图形学报, 2017, 22(1): 1-8.
- [17] 林荣福. 面向目标检测的水下图像质量评价. 福州: 福州大学, 2022.
- [18] 郑素梅. 超分重建声呐图像的质量评价. 福州: 福州大学, 2023.
- [19] L. Cai, C. Chen and H. Chai. Underwater distortion target recognition network (UDTRNet) via enhanced image features. Computational Intelligence and Neuroscience, 2021, 2021: 4193625.
- [20] 吴迪. 稀疏表示理论研究及其在水下视觉导航数据中的应用. 哈尔滨: 哈尔滨工程大学, 2016.
- [21] G. Huo, Z. Wu and J. Li. Underwater object classification in sidescan sonar images using deep transfer learning and semisynthetic training data. IEEE Access, 2020, 8: 47407 - 47418.
- [22] 焦佳. 基于深度学习的水下声纳图像分类方法研究. 哈尔滨: 哈尔滨工程大学, 2018.

- [23] M. Sung, S-C. Yu and Y. Girdhar. Vision based real-time fish detection using convolutional neural network, OCEANS 2017 - Aberdeen. Aberdeen, UK. IEEE, 2017: 1-6.
- [24] 陈禹蒲, 马晓川, 李璇. 基于YOLOv3锚框优化的侧扫声呐图像目标检测 [J/OL]. 2022-06-08.
- [25] L. Jiang, Y. Wang, Q. Jia, et al. Underwater species detection using channel sharpening attention, Proceedings of the 29th ACM International Conference on Multimedia. New York, NY, USA. ACM, 2021: 4259-4267.
- [26] Z. Zhao, Y. Liu, X. Sun, et al. Composited FishNet: Fish detection and species recognition from low-quality underwater videos. IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society, 2021, 30: 4719-4734.
- [27] L. Jiang, T. Cai, Q. Ma, et al. Active object detection in sonar images. IEEE Access, 2020, 8: 102540-102553.
- [28] S. Gupta, P. Mukherjee, S. Chaudhury, et al. DFTNet: Deep fish tracker with attention mechanism in unconstrained marine environments. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-13.

第10章 深度学习与医工结合相关应用

近年来，深度学习技术一直都处于科研界的前沿。深度学习模型在各个领域的良好效果引发了在更多领域利用该技术进行数据挖掘和分析的热潮，在医学和生物认知领域也同样引起了重视。深度学习在医疗方面的应用，最具代表性的就是医学影像学方面的应用。因为深度学习具有自动地从数据中学习深层次、更具鉴别性特征的能力，因此在医学图像分析领域取得了突破性进展。

本章首先介绍了医学图像的背景知识，然后探讨深度学习方法在医学影像领域的应用，重点讨论深度学习在病理分析方面的应用。

10.1 医学影像

随着医学成像技术和计算机技术的不断发展和进步，医学图像分析已成为医学研究、临床疾病诊断和治疗中一个不可或缺的工具和技术手段。近几年来，深度学习已经迅速发展成为医学图像分析的研究热点，已经广泛应用于医学图像分类、检测、分割、配准、检索、图像生成和增强等领域。

10.1.1 常见医学图像类型

MRI 图像：核磁共振图像（MRI），该图像是人体组织器官和病灶中的氢原子核在外部强磁场作用下产生的磁共振信号大小的度量，并通过计算机对体外核磁共振信号探测器接收到的信息数据进行 3D 图像重建。它能够提供非常清晰的人体软组织解剖结构和病灶影像。

CT 图像：计算机断层扫描（CT）利用精确准直的 X 射线束对人体某部位一定厚度的断面进行照射扫描，并由与射线线束一起旋转的探测器接收透射穿过该断面的 X 射线，最后，计算机根据探测器接收到的 X 射线信号数据重建相应人体断面的 3D 图像。它具有亚毫米级的空间分辨率，能够提供清晰的人体骨性组织解剖结构和病灶影像，已广泛应用于多种临床疾病检查和辅助诊断。

X 射线图像：医学 X 射线图像是人体不同组织器官和病灶的电子密度度量影像。基于 X 射线的成像包括 2 维的计算机放射成像、数字化 X 射线摄影术、数字减影血管造影术和乳房 X 线摄影术，以及 3D 的螺旋计算机断层扫描术等，已广泛地应用于骨科、肺部、乳腺和心血管等临床疾病检测和辅助诊断，但是 2 维 X 射线图像不能提供人体组织器官和病灶的三维立体信息。

超声成像：利用超声束扫描人体，通过对反射信号的接收、处理，以获得体内器官的图像。近年来，超声成像技术不断发展，出现了 3D 彩超、超声全息摄影、体腔内超声成像、彩色多普勒成像及超声生物显微镜等新的超声成像技术。

PET 图像：正电子发射断层扫描 (PET) 利用 F18 等放射性元素标记的示踪剂 衰变时发射的正电子信息成像，因此，PET 图像是相应示踪剂放射性活度的度量，能提供肿瘤生物学特性(如葡萄糖代谢、乏氧、增殖等)信息，其标准摄入量大小可用于临床辅助判别肿瘤良/恶性。PET 能提供比 CT、MRI 更直观、更精确的可视化生物学与放射生物学特性信息。

病理图像：是指切取一定大小的病变组织，采用苏木精和曙红 (H & E) 等染色方法将切片组织做成病理玻片，然后用显微镜成像技术对微观的细胞和腺体成像。通过对病理图像进行分析，可探讨病变产生的原因、发病机理、病变的发生发展过程，从而做出病理诊断。

10.1.2 常见的医学图像分析任务

医学图像分类与识别：临床医生需要借助医学图像来辅助诊断人体是否有病灶，并对病灶的轻重程度进行量化分级，因此自动识别图像中的病灶区域和正常组织器官是医学图像分析的基本任务。

医学图像分类可以分为图像筛查和目标或病灶分类。图像筛查是深度学习在医学图像分析领域中的最早应用之一，是指将一个或多个检查图像作为输入，通过训练好的模型对其预测，输出一个表示是

否患某种疾病或严重程度分级的诊断变量。图像筛查属于图像分类任务，图像分类是深度学习方法最擅长的任务之一，例如国际上著名的 Large Scale Visual Recognition Challenge (LSVRC) 竞赛所提出的最新模型已经可以把 ImageNet 数据库上分类错误率降到了 3% 以内。

目标或病灶的分类可以辅助医生对疾病进行诊断，如对乳腺病灶进行良恶性分类。其处理过程通常首先通过预处理方法识别或标记出的特定区域，然后再对特定区域进行目标或病灶分类。精确的分类不仅需要病灶外表的局部信息，而且还需结合其位置的全局上下文信息。

医学图像定位与检测：人体组织器官解剖结构和病灶区域的定位是临床治疗计划和干预流程中非常重要的预处理步骤，定位的精度直接影响治疗的效果。图像目标定位任务不仅需要识别图像中的特定目标，而且需要确定其具体的物理位置。图像目标检测任务则需要把图像中所有目标识别出来，且确定它们的物理位置和类别。

准确地在医学图像中定位特定生物标记或解剖结构在临床治疗中具有非常重要的意义，直接关系到治疗效果的好坏。医学图像定位常需要分析 3D 体素信息。为了使用经典深度学习算法进行 3D 数据处理，一些方法将 3D 空间看成 2D 正交面的组合，这样可将定位任务转换为分类任务，利用通用深度学习框架进行处理。Yang 等人^[30]结合三个正交方向 CNN 的信息识别股骨末端的标记，标记 3D 位置定义为三个 2D 图块的交点。Vos 等人^[31]通过将 3D CT 体积解析成 2D 形式，识别目标 3D 矩形包围盒，进而定位到感兴趣的肝脏、主动脉弧和下降主动脉等解剖区域。

而医学图像的感兴趣目标或病灶检测的关键是对每个像素进行分类。目前大多数基于深度学习目标检测系统采用 CNN 执行像素分类任务，然后采用某种形式的后处理方式得到目标。Chen 等人^[32]利用多个 2D 深层特征近似表达 3D 医学图像的特征，结合 SVM 分类器，实现敏感性加权图像 (Susceptibility weighted imaging, SWI) 自动检

测脑微出血 (Cerebral microbleeds, CMBs), Shin 等人^[33] 将 SAE 深度学习应用于 MRI 图像上检测腹部器官, 先以非监督方式学习空间特征, 然后基于兴趣点进行多器官检测。

医学图像分割任务: 图像分割是识别图像中感兴趣的目标区域内部体素以及外部轮廓, 它是临床手术图像导航和图像引导肿瘤放疗的关键任务。

医学图像中器官及其子结构的分割可用于定量分析体积和形状有关的临床参数, 如心脏的心室体积和收缩射出率。另一方面, 在采用智能调强放疗技术对肿瘤进行治疗时, 危及器官勾画是制定放疗计划中非常重要的步骤之一。深度学习广泛应用于此类任务, 主要包括组织病理学图像和显微镜图像分割、脑组织结构分割以及心脏心室分割等领域。

10.2 病理分析

(1) 基于 MRI 的直肠癌病理完全反应预测方法研究

直肠癌的发病率和致死率在世界范围内已经逐步升高, 而检测出直肠癌晚期的患者占到七成。这类患者目前的治疗方式是新辅助放化疗配合切除手术, 部分患者在经过诊断后处于病理完全反应状态并可以避免切除手术, 但医生在放化疗治疗前无法确定。因此利用深度学习进行直肠癌患者病理完全反应的预测来辅助医生的判断是很有必要的。徐等人^[1]围绕直肠癌病理完全反应预测开展了以下的研究: 现有的直肠癌相关研究较少考虑到 MRI 图像中直肠组织高度相似性的特点而容易忽视细节特征, 以及没有考虑到不同切片中肿瘤信息不同的影响。针对这些问题, 作者提出两阶段的直肠癌肿瘤分割和预测网络。1) 分割阶段。针对容易忽略直肠的病变信息的问题, 提出了多尺度空洞卷积模块。在卷积过程中有利于减轻下采样导致的图像分辨率降低以及信息丢失的影响, 同时因为空洞的作用使模型拥有了更大的感受野。此外还引入了注意力机制模块, 在

扩大感受野的同时进一步聚焦特征区域。2) 预测阶段。现有的大部分研究采用多数投票和平均的思想对得到的每张切片进行整体预测, 但每张切片所包含的肿瘤信息(比如肿瘤大小、肿瘤覆盖率等)并不相同, 不能以相同的方式处理每张切片。针对这个问题, 本文提出权重分配的思想, 按照肿瘤区域像素点的数量占整个病例的切片的所有肿瘤区域像素点数量的比例来分配权重, 提高了预测的合理性和准确性。目前, 关于直肠癌的研究大多使用私有数据集, 数据体量偏小, 而且大多研究采用的依然是二维图像数据, 忽略了整体数据切片之间的连续性。1) 针对数据体量的问题, 提出一种基于 DCGAN 的改进生成对抗网络来生成直肠癌数据, 利用上采样和卷积来代替 DCGAN 生成器中的反卷积操作以及在判别器上采用拥有重叠池化的 AlexNet 结构来降低“伪影”的影响, 扩增有效数据量从而提升预测效果。2) 针对二维数据忽略切片间连续性病变特征问题, 提出采用三维图像数据和三维预测网络, 并嵌入不同的注意力模块, 进一步提升网络的预测性能。

(2) 基于深度学习胃病理切片分类算法研究。

我国是胃癌高发国家, 病理图像诊断是诊断胃癌最可靠的方法。数据显示, 目前我国的执业病理医生不足 2 万人, 病理医生缺口达 9 万人, 所以需要开发基于深度学习的胃病理切片分类方法以辅助医生进行诊断。此外, 胃病理切片图像特征复杂, 不同组织细胞形态差异大且癌细胞与正常细胞相似度高, 目前已有的胃病理切片分类算法分类准确率不够理想。因此, 文献[2]以深度学习理论为基础, 对胃病理切片分类方法展开研究。根据医生阅片的习惯即通过不同分辨率下的病理切片进行诊断, 引入多尺度提取图像特征的方法, 提高模型的性能。由此提出三个分类网络模型: 模型一由特征金字塔网络模块和连接网络层组合而成, 图像输入网络后经过特征金字塔网络模块, 输出不同尺度的多个特征图, 然后通过连接网络层将

这些特征图结合起来，最后通过分类器输出分类结果。模型二的结构以 ResNetv2 结构为基础，利用金字塔卷积模块代替其残差分支中的卷积层以达到多尺度提取图像特征的效果，进一步引入注意力机制模块，加强其通道和空间信息的连接传递。模型三受到空洞卷积的启发，利用空洞空间金字塔池化模块的多个不同大小的空洞卷积提取不同尺度的图像信息，输入一个空间金字塔池化结构进行融合，该模型在第二个网络层后引入全局特征提取层提取全局图像特征，然后和空洞空间金字塔池化模块提取的特征融合起来，将得到的融合特征图输入一个连接网络层进一步提取特征。最后根据实际应用情况，本文联合以上三个网络组成一个完整的胃病理切片分类系统，并利用投票算法对三个网络的预测结果进行投票，根据实验结果，该方法进一步提升分类结果的准确率。

(3) 基于结肠镜图像的息肉分割。

结肠镜是筛查结肠息肉最有效方式，然而该方法存在医生易疲劳、经验性强以及漏诊率高等不足。设计自动息肉分割神经网络作为医学诊断的辅助方法可有效解决上述问题。现存息肉分割网络无法较好适应结肠镜图像中息肉和结肠组织对比度低和息肉尺寸变化大的特点。针对上述问题，文献[3]提出了级联结构注意力机制网络（Cascaded Structure Attention Mechanism Network, CSAMNet），其由两个编解码网络构成级联结构，后一级网络优化前一级网络的预测结果。CSAMNet 的两级网络间引入了反向注意力模块，使得后一级网络关注前一级网络忽略的部分。本文还设计了多尺度特征聚合模块嵌入到网络中，提高了模型对于息肉尺寸变化大的适应能力。此外，现存轻量化结肠息肉分割网络中多数采用 U 型架构，其编码端依据已有的分类网络进行搭建，不能满足语义分割对于多尺度特征和可伸缩感受野的要求，且解码端的底层特征图尺寸较大增加了计算负担，但对性能贡献不大。针对上述问题，本文提出了短期密集连接注意网络（Short-Term Dense Concatenate Attention Network, STDCANet）。编码

端嵌入了短期密集连接注意模块，此模块以较低的计算复杂度提取了多尺度特征并保留了可伸缩感受野。局部解码器作为解码端，其丢弃了底层特征而仅聚合高层特征加速了模型推理。在 CVC-ClinicDB、Kvasir-SEG测试集上获得了较好的测试性能，且具有较低的复杂度和较短的推断时间。

(4) 基于深度学习的视网膜血管分割

在 2019 年 10 月，根据世界卫生组织发布的一份世界宣明会报告，世界范围内超过 4.18 亿人患有青光眼、糖尿病视网膜病变 (Diabetic Retinopathy, DR)、老年性黄斑变性 (Age-related Macular Degeneration, AMD)或其他可导致失明的眼部疾病^[4]。许多眼底病变都会发生在血管的周围，视网膜眼底图像中包含丰富的视网膜血管特征^[5,6]。视网膜血管分割得到的视网膜特征可以用于辅助糖尿病视网膜病变等眼病的诊断，对这些疾病的预防和治疗具有重要意义。近年来基于深度学习的血管自动分割算法以自动提取图像特征，精度高，速度快的这些优点吸引了大量研究。

数据库与评价标准：深度学习本质上是基于数据驱动算法，高质量的图片数据库对深度学习算法的性能极为重要。世界上许多研究机构建立并公开了其眼底图像数据库，以期推进深度学习技术在视网膜血管分割上的发展。其中影响较大的有荷兰的 DRIVE 数据库，美国的 STARE 数据库，此外还有英国的CHASE_DB1 数据，捷克的 HRF 数据库等。表 10-1是眼底图像开源数据库的综合信息，这些开源数据库对分割算法的进步起到了很好的推动作用。

表 10-1 眼底图像数据库

数据库	数量	尺寸	FOV	相机	获取链接
DRIVE	40	565*584	45°	Canon CR5 non-mydratic 3CCD camera	https://drive.grand-challenge.org/DRIVE/
STARE	20	700*605	35°	TopCon TRV-50 fundus camera	http://cecas.clemson.edu/~ahoover/stare/
HRF	45	3504*2336	60°	-	https://www5.cs.fau.de/

					research/data/fundus-images/
CHASE-DBI	28	999*960	30°	-	https://blogs.kingston.ac.uk/retinal/chasedb1/
IOSTAR	30	1024*1024	45°	EasyScan camera	http://www.retinacheck.org/download-iostar-retinal-vessel-segmentation-dataset

分割算法介绍：早期使用的医学图像分割神经网络主要为全卷积神经网络和编码解码网络，在这些网络基础上发展了很多不同结构的神经网络。根据网络架构特点，近年来用于视网膜血管分割的神经网络可以分为级联结构、多路径、多尺度类型的神经网络。近期提出的视网膜血管分割算法主要是基于全卷积神经网络。从网络架构上，全卷积神经网络可划分为编码解码结构和多尺度神经网络。

1) 级联结构神经网络

级联结构神经网络由两个相似网络间串联而成。前一级网络产生了血管分割图，后一级网络可以在前一级网络的输出血管分割图基础上对血管分割结果的结构进行细化，对血管像素的预测结果进行优化，典型结构见图 10-1。这种网络对于视网膜血管的空间结构的预测能力优势明显。如 Wu, Yicheng 等人^[7]设计了名为 NFN+w/o Ics 级联结构的神经网络，前向网络将输入转换为粗血管分割图，后一级网络调整粗血管分割图分类错误的像素，重新优化血管的空间结构。基础模型和 NFN+w/o Ics 模型(级联结构,无跳跃连接结构)在 DRIVE 数据集上设计对比实验，NFN+w/o Ics 模型在 AUC、AUPR、ACC 等指标上分别上升了 0.3%、0.79%、0.12%，体现了级联结构在模型中改善了分割血管的连通性，提升了结构预测的能力，提升了模型的性能。Wu, Yicheng 等人^[7]提出的多尺度跟踪网络(Multiscale Network Followed Network, MS-NFN)包含 NFN 模块。每个 NFN 模块由两个子网络(up-pool网络或者 pool-up 网络)形成了级联结构。对两个不同路径的 NFN 模块网络生成的血管分割图进

行平均得到最后的血管分割结果。Lian, Sheng 等人^[8]提出了基于全局和局部增强图片的残差 U-net 网络，其中用于粗分割的 WUN(Weighted U-Net) 模块和用于细化的 WRUN(Weighted Res-Unet)模块组成了级联结构。全局增强眼底图的图像切片作为 WUN输入生成粗分割血管图，局部增强的图像切片、相应金标准的图像切片以及前一级网络的粗分割血管图作为 WRUN 的联合输入来训练网络。这个模型能够很好的处理光照，硬性区域视盘，病变区，边缘区，视盘区等异常噪声区域。同时该模型能够很好的分割处细小和模型的血管，又能保持视网膜血管的几何连接。

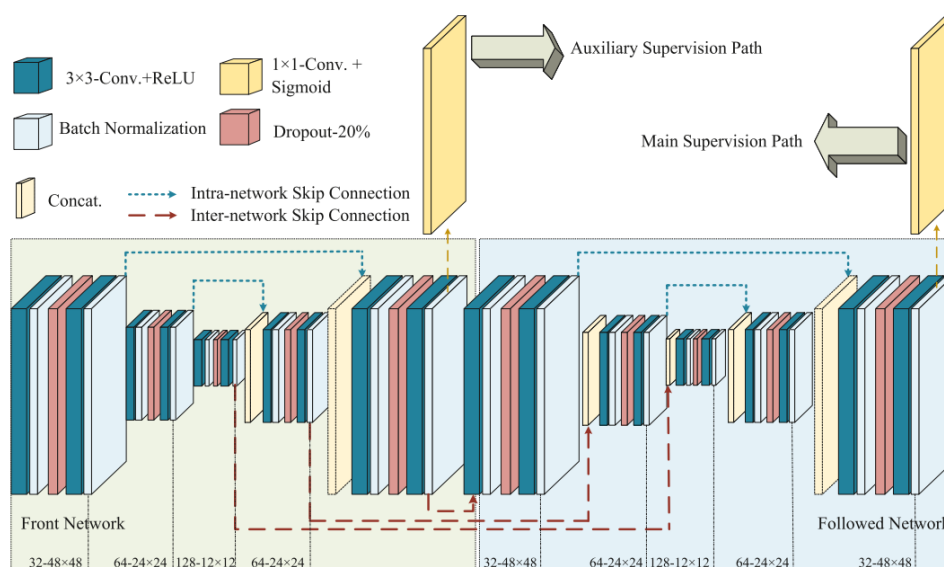


图 10-1 NFN+神经网络的结构图

2) 多路径神经网络

多路径神经网络是2个及以上不同路径的神经网络并行组成的网络架构(图10-2)，每条路径关注图像不同特征的信息，比如一个路径关注全局特征，另一个路径就关注局部特征，最后将两个路径的产生的特征图进行整合得到最后的结果。这种神经网络可以整合更多的语义信息，同时对于感兴趣的区域有更好的针对性，有利于毛细血管和薄血管的分割，多路径神经网络对于图像分割领域来说是

一个新的尝试。如 Tian, Chun 等人^[9]模拟了初级视觉皮层对多路径信息处理的神经编码机制，提出了多路径卷积神经网络分割方法，两个路径分别为高频特征提取路径和低频特征提取路径，其中高频提取路径关注图像的局部信息，低频特征提取路径关注图像的全局信息。Yan, Zengqiang 等人^[10]提出的深度学习模型分为厚血管分割、细血管分割、和血管特征融合三个阶段。对粗血管和细血管进行分离分割可以获得更好的鉴别特征，所以最大限度地减少了粗细血管比例不平衡所带来的负面影响，血管融合阶段通过进一步识别非血管像素来改善血管整体厚度一致性细化了结果。Wang, Bo 等人^[11]提出的 DEU-Net 网络有两种编码路径:一种是带有大核的空间路径以保留空间信息，另一种是带有多尺度卷积块的上下文路径以捕获更多语义信息。Wu, Yicheng 等人^[12]提出的Vessel-Net 网络，在模型优化过程中引入了传统的监管路径、丰富特征的监管路径和两种多尺度的监管路径。Khan, Tariq M 等人^[13]提出的网络其中一条路径提取目标清晰的边缘，另一条通过空间金字塔池化模块将几种不同的分辨率的特征进行汇集去提取显著的语义信息。

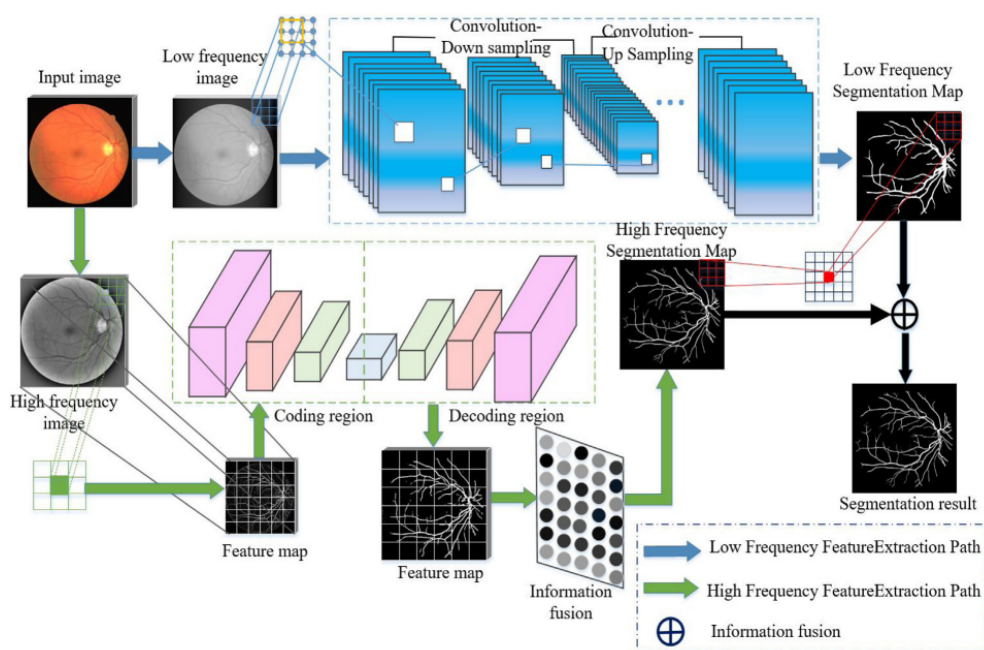


图 10-2 Tian, Chun 设计的多路径卷积神经网络

3) 多尺度神经网络

多尺度神经网络是对不同尺度大小的特征图进行整合，典型结构见图10-3，考虑到高层特征和底层特征不同的优势，高层特征有助于像素的分类，底层特征可以帮助像素的定位。将不同层级的语义相互整合可以获得更加全面的信息。如Song, Joonyoung 等人^[14]提出的神经网络，该网络以图像切片作为输入，每个模块创建固定大小的特征图，然后将这些不同尺度的特征图组合成一个单独的特征图。Feng, Shouting 等人^[15]提出一种交叉连接卷积神经网络(Cross-connected Convolutional Network, CcNet)，主路径和次路径之间的交叉连接融合了多层次的特征，根据学习到的特征预测像素的类别。Hu, Kai 等人^[16]提出基于改进的交叉损失函数的卷积神经网络进行多尺度特征图的整合，并且引入了全连通条件随机场(fully connected Conditional Random Field, CRFs)来消除特征图噪声和边缘模糊的问题来细化特征图,从而得到最后的分割结果。Guo Song 等人^[17]提出的 BTS-DSN 网路引入了 bottom-top short connections 和 top-bottom short connections 的连接方式，bottom-top short connections 将底层的语义信息传递给高层，细化了高层侧输出的结果，缓解了由于降采样操作高层侧输出糊化的问题，top-bottom short connections 将高层的结构信息传递给底层，优化了底层侧输出的结构信息，减少了底层侧输出的噪声。Zhang, Boheng 等人^[18]提出了基于全卷积神经网络的架构，将相邻的卷积层提取的特征融合在一起，可以将底层的消息尽可能的传输到顶层。同时引入文献[19]中的 Atrous Convolution 来取代常规的卷积操作。Xu, Rui 等人^[20]采用不同膨胀率的并行放大卷积滤波器设计多尺度聚合块，并嵌入网络中，充分探索利用多尺度信息。在CHASE-DB1 和 HRF 中的性能表现了文中提出的方法的有效性，解决了毛细血管尺度变化大，不利于分割的问题。

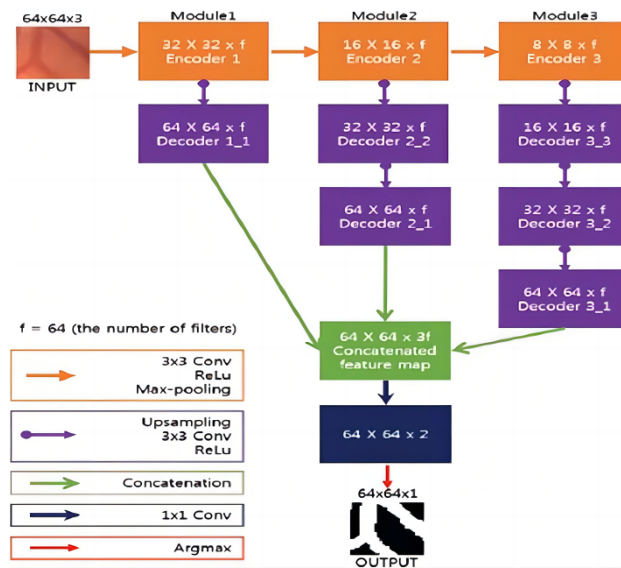


图 10-3 Song, Joonyoung 等人设计的整合多层语义的神经网络

现实部署的尝试。在移动设备硬件资源不足的情况下，包含大量参数的神经网络的现实部署就会存在一些限制。一方面神经网络不能超过设备的存储和计算大小的极限，另一方面还要满足一定的性能要求。在视网膜血管分割任务中，相关人员探索了轻量级的卷积神经网络。如 Hajabdollahi 等人^[21]提出了一种基于量化和剪枝相结合的神经网络。其中全连接层被量化，卷积层被修剪，网络的参数减少了 60%。在 STARE 数据集上 SE=75.99%，SP=97.57%，ACC=95.81%，算法在 SE 和 SP 的指标上获得了当前接近最优的性能，证明了简化 CNN 有作为便携式视网膜诊断设备中血管自动分割方法的潜力。随后，Laibacher 等人^[22]提出了 M2U-Net 网络的参数只有 0.55M,相较于 U-Net网络 31.03M 的参数来说是明显降低，在 Rockchip RK3399 平台上进行测试时，M2U-Net 的推断时间只需要为 5.87s，而在 U-net 的推断时间则需要141min，证明了网络实时分割的潜力。Li 等人^[23]沿用 U 型网络的结构并整合了注意力机制模块，模块提升了中间层的利用率，适当的减少模型的深度，最深的特征图仅仅只有 128 通道，模型总共只有 0.4M 的参数。Wei ^[24]等人考虑到人工设计神经网络是非常费时的，所以基于遗传算法自动设计一个轻量级的 U 型网络，网络对于每张图片的推断时间只有 27ms，网络大小仅有 1.2M。Atli ^[25]等人提出了一种新颖的全卷积神经网络，利用上采样和下采样的方式构建了形状类似正弦

波的网络，网络的每张图片的推断时间为 35ms。表10-2是近些年关于轻量化网络的总结。通过以上总结可以看到神经网络可以落地应用的潜力。在移动设备硬件资源局限的情况下，设计一个性能达标并且参数尽可能小的神经网络是一个值得探索的方向。

表 10-2 轻量级网络的性能及参数对比

作者	年份	方法	数据库	SE	SP	ACC	推断时间	网络参数
Hajabdollahi, Mohsen	2018	量化和剪枝	STARE	75.99%	97.57%	95.81	-	减少60%参数
Laibacher, Tim	2018	U型网络+ bottleneck+ resbottleneck	DRIVE	-	-	96.30%	5.87s	0.55M
Li,Xiang	2020	U型网络+ 注意力机制	DRIVE	79.21%	98.10%	95.68%	-	0.4M
Wei, Jiahong	2020	网络结构搜索+ 遗传算法	DRIVE	83.00%	98.43%	97.07%	27.5ms	1.2M
Atli, Ibrahim	2021	全卷积神经网络	DRIVE	82.60%	98.24%	96.85%	35ms	-

10.3 辅助诊断

(1) 骨髓受累 PET-CT 图像融合分类技术研究。

弥漫性大B细胞淋巴瘤是一种常见的非霍奇金淋巴瘤，而骨髓受累是弥漫性大B细胞淋巴瘤最常见的表现之一，尽早发现骨髓受累并治疗，被证实是可延长患者的生存期。但目前存在三个难点：一是早期临床表现不典型，易被漏诊或误诊；二是常用的骨髓检测方式仅取部分区域(骨髓受累可发生在全身)且大多为侵入式患者易出现感染等风险；三是诊断骨髓受累需要丰富的病理医生进行细致的观察。探究基于深度学习模型构建骨髓受累辅助诊断模型可有效解决上述问题。

由于临床诊断骨髓受累需要使用多种图像，文献[26]使用PET和CT图像数据提出了一种图像融合识别BMI方法。该模型有效地整合了PET和CT图像的互补信息，相较于单一模态，能够获得更好的分类性能。首先使用ResNet残差模块作为特征提取层，保留网络从ImgeNet数据集学习到的权重

，用医学图像数据集训练重置末端全连接的参数并在特征提取层使用权重共享策略，避免数据集过小造成过拟合。同时本文考虑CNN对图像特征长距离关系处理能力弱，提出将Swin-Transformer对融合后的特征图再次进行提取特征，增强全局上下文信息，提升网络对融合信息的细化能力，最后通过Softmax分类器输出结果。模型所用骨髓受累数据集由福建省立医院提供，实验结果表明，通过图像融合网络的深度学习算法能达到较高性能，网络的分类精度在测试数据上达到了97.8%的准确率，证明该模型网络在辅助诊断上具有可行性。为了进一步提高准确率，文献[26]提出的图像融合分类模型，选取当前流行的网络(RepVGG、EfficientNet、ConvNext)作为特征提取器，同时仍然使用Swin-Transform对融合特征进行提取，并使用ACC、TPR、SPC作为指标，衡量模型改进前后的性能。实验证实，利用性能高的特征提取器对原有图像融合网络进行改进，是提高模型的性能和减少实际应用时的误判率的关键；基于EfficientNetB2网络特征器与原有的Basicblock相比，其精度高达99.1%，有效提高了准确率。

针对上述方法存在参数量过大的问题，文献[26]提出图像融合网络的轻量化改进模型。该模型利用轻量级网络替代上述方法实验中网络特征提取器，同时使用MLP特征提取层替换网络中复杂性较高的Swin-Transformer网络。实验表明，该模型的网络参数量与原来网络相比降低到7%以内，在牺牲少量的模型准确率精度下，推理速度提高了2~3倍，达到了网络轻量化的效果。并证实了MLP可以通过足够多的层数和参数来学习到与Swin-Transformer相当的特征表示能力。

(2) 基于三维深度学习的肺结节良恶性分类和数据增强研究。

肺癌是发病率和死亡率最高的恶性肿瘤之一，严重损害人们的健康。肺结节是肺部的微小病灶，有良恶性之分，其中恶性肺结节是肺癌的早期表现形式。所以对肺结节进行良恶性分类对于尽早发现肺癌具有十分重要的意义。基于人工的肺结节良恶性分类有工作量大、难度高和易受主观性

影响等缺点，而将深度学习用于肺结节良恶性分类可弥补传统人工分类方法的不足。

为减少肺结节良恶性分类网络在应用阶段所需的运行内存和分类时间，文献[27]提出了一种可结构重参数的三维卷积神经网络3DSERepVGG用于肺结节分类。该网络在训练阶段含有三条路径并行的结构，通过多路径的结构提升网络的分类性能，而在应用阶段通过结构重参数的方法合并路径转化为单路径网络，减少应用阶段的网络规模。同时为提升所提网络的性能，在网络中引入三维的通道注意力SE模块，该模块可获取特征图中每个通道的重要程度，并根据重要程度的不同给通道分配不同的权重，以提高模型分类的效果。结果表明，所提分类网络在LUNA16数据集上取得的88.06%准确率，优于比较的现有肺结节分类网络模型，且能在应用阶段通过结构重参数减少38.44%的运行内存和15.64%的分类时间。

数据集规模是影响深度学习算法性能的重要因素，为提升肺结节良恶性分类的效果，文献[27]提出一种基于三维生成对抗网络的肺结节数据增强方法。所提的生成对抗网络模型结合了DCGAN的卷积神经网络结构和WGAN-GP的损失函数。卷积神经网络结构能增强模型对肺结节数据的特征提取能力，而WGAN-GP的损失函数能提高模型的训练稳定性。并在模型的训练方式上引入一种从小尺寸到大尺寸的分阶段训练方法，使网络训练更稳定更快，生成的数据质量更高。结果表明，所提的生成对抗网络模型能生成质量较高的三维肺结节数据，并且将生成的三维肺结节数据用于数据增强能有效提高网络的分类效果，本文所提的3DSERepVGG网络在数据增强后分类准确率提升到89.05%。

(3) 基于双模态多任务学习的结直肠癌新辅助治疗预测研究。

结直肠癌(Colorectal cancer, CRC)是胃肠消化系统恶性肿瘤之一。随着我国人民物质和生活水平的提高，受到过高的蛋白质、脂肪和能量食物的超剂量食用以及日趋严重的人口老龄化的影响，预测未来结直肠癌发病率升高趋势明显，因此对于结直肠癌的治疗已经成为重要

的研究问题。准确预测新辅助治疗达到病理完全缓解(Pathological complete remission, pCR)有利于结直肠癌患者避免无效的治疗。然而预测pCR需要医生手动标记病灶区域再对其进行特征提取用于诊断预测,因此在实现轻量化满足临床要求的前提下,应用深度学习进行全面预测并自动分割病灶区域进行相应的疾病诊断确诊就显得极为重要,这不仅能够减少诊断判别时人为因素的干扰,也能为医生临床判断提供强有力的辅助意见。

随着深度学习的蓬勃发展,研究人员逐渐开始使用深度学习的方法来进行医学上的病灶分割,近五年来越来越多利用放射影像图片并基于深度学习的结直肠癌病灶分割算法开始出现。针对利用结直肠癌病灶区域复杂多变和边缘模糊的特点设计的现有轻量化分割网络较少的问题,文献[28]提出了高效金字塔语境引导网络(EPCG-Net)解决方案,并提出高效金字塔语境注意力网络(EPCAt-Net)解决现有 pCR 诊断网络性能较差的问题。EPCG-Net 在编码模块中加入高效金字塔通道注意力(EPCA)模块学习多尺度全局特征,并采用残差思想与语境引导块提取的局部特征相结合以学习丰富语义特征。EPCAtNet 采用 EPCG 块作为网络的主干部分,对所提取到的特征输入自注意力层和前馈全连接层实现进一步的压缩分析,充分发挥 EPCG 块和 Transformer 编码块的优势。实验表明,较最优对照网络性能得到有效提升且参数量和浮点运算数显著下降。

针对现有 pCR 诊断系统中算法模块以单任务模型为主导导致不同任务的信息无法相互促进、单模态放射影像无法合理利用不同模态间相互补充的信息以及非对等匹配的多模态数据集的融合鲜有深入研究的问题,文献[28]提出基于非对等匹配双模融合多任务网络(UDMFm-Net)的解决方案,并提出改进的动态损失策略以解决多任务学习倾斜问题。UDMFm-Net 通过 UDMF 模块实现 CT 与 MRI 模态信息的有效融合,并与 EPCG-Net 采用输入输出多对多的方式相

结合，融合后的特征与 EPCat-Net 采用多任务硬共享方式实现特征的有效交互。通过中山大学附属第六医院 CT 和 MRI 模态数据集上的实验表明，网络在改进动态损失策略的辅助下，多任务共享情况的准确率较单任务得到有效提升，且优于对照的多任务网络。通过非对等匹配双模态模块融合后，网络在CT 模态的病灶分割性能上达到了最优。

(4) 基于深度学习的肛瘻MRI分类算法研究。

克罗恩病患者在发病过程中会出现肛瘻病变。尽早诊断克罗恩病肛瘻并尽快治疗，被证实可以提高肛瘻的治愈率。但目前存在两大难题：一是早期发病的克罗恩病肛瘻常被误诊为腺源性肛瘻；二是相当比例的克罗恩病肛瘻因肠道病变不典型而延迟诊断。在 AI 辅助诊断领域，相比精度高但模型复杂的网络，人们更加关注可以线下部署简单且实时诊断性能高的 CNN，高性能轻量化 CNN 网络框架成为了计算机辅助诊断领域的研究重点。因此，探索基于深度学习算法构建克罗恩病肛瘻和腺源性肛瘻的磁共振诊断模型具有显著的应用价值与意义。

针对克罗恩病肛瘻诊断易于与腺源性肛瘻混淆，识别准确率较低的问题，文献[29]提出了基于肛瘻磁共振图像和改进 MobileNetV2 网络的肛瘻图像诊断分类方法，构建以 MobileNetV2 为核心主干的轻量级特征提取网络。在模型中嵌入通道与空间注意力增强模块，提升网络对关键特征的感知能力；设计多尺度特征融合模块，增强网络的感受野；利用迁移学习策略优化模型参数，进一步提升模型诊断准确率。在自建的 An-FisMRI400 肛瘻数据集上的实验结果表明：首先，提出的改进模型结合迁移学习策略的准确率、灵敏度和特异性分别为 82.15%、83.71%和 80.50%，相比其他类比网络，平均提升了约 3 个百分点。其次，以患者为参考对象，改进的模型结合迁移学习获得了最高的 AUC 值（0.965），模型最稳健。此外，通过可视化不

同诊断模型的识别图像效果实验,表明本文提出的改进模型对病理图像的感兴趣区域相比其他模型更为精准,聚焦区域更加集中。

针对基于卷积神经网络对图像特征长距离依赖关系捕获不太理想限制识别准确率,以及克罗恩病肛瘘与周围组织存在一定关联的问题,文献[29]提出了卷积神经网络和视觉 Transformer 相结合的混合模型 CVT-HNet。模型前部分特征提取层由 MV2-CA 模块组建, MV2-CA 模块主要包括倒残差瓶颈结构,其中嵌入坐标注意力机制模块,提升模型对图像上下文信息的感知能力;模型后半部分特征提取层由 MV2-CA 和 Transformer Encoder 模块串联堆叠组建,其 Transformer Encoder 模块主要由多头注意力机制、前馈网络结合恒等映射结构组成,增强局部特征和全局信息的交互能力,提升网络对深层具体语义信息的细化能力,进一步提高模型识别准确率。实验结果表明:首先,基于非迁移学习策略, CVY-HNet 获得 80.66% 的准确率,相比改进的 MobileNetV2 模型提升了近 1.5 个百分点,并与其他类比网络相比,平均提升了约 2 到 7 个百分点。其次,以患者为参考对象,所提模型获得了最高的 AUC 值(0.958),模型最稳健。

参考文献

- [1] L. Li, B. Xu, Z. Zhuang, et al. Accurate tumor segmentation and treatment outcome prediction with DeepTop[J]. Radiotherapy oncology,2023,183:109550.
- [2] 陈孟锐. 基于深度学习胃病理切片分类算法研究[D].福州大学, 2023.
- [3] 张孝辉. 基于结肠镜图像的息肉分割神经网络研究[D]. 福州: 福州大学, 2022.
- [4] T. Li, W. Bo, C. Y. Hu, et al. Applications of deep learning in fundus images: A review[J]. Medical Image Analysis:2021,69.
- [5] Y. Wu, Y. Xia, Y. Song, et al. NFN+: A novel network followed network for retinal vessel segmentation[J]. Neural Networks:2020.

- [6] X. Li, Y. C. Jiang, M. L. Li, et al. Lightweight attention convolutional neural network for retinal vessel image segmentation[J]. IEEE Transactions on Industrial Informatics: 2021,17(3): 1958-1967.
- [7] Y. Wu, Y. Xia, Y. Song, et al. Multiscale network followed network model for retinal vessel segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. 2018.Springer, 119-126.
- [8] S. Lian, L. Li, G. Lian, et al. A global and local enhanced residual u-net for accurate retinal vessel segmentation[J]. IEEE/ACM transactions on computational biology and bioinformatics:2019.
- [9] C. Tian, T. Fang, Y. Fan, et al. Multi-path convolutional neural network in fundus segmentation of blood vessels[J]Biocybernetics and Biomedical Engineering:2020.
- [10] Z. Yan, X. Yang and K-T Cheng. A three-stage deep learning model for accurate retinal vessel segmentation[J]. IEEE journal of Biomedical and Health Informatics: 2018, 23(4): 1427-1436.
- [11] B. Wang, S. Qiu and H. He. Dual encoding U-Net for retinal vessel segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention.2019.Springer, 84-92.
- [12] Y. Wu, Y. Xia, Y. Song, et al. Vessel-Net: retinal vessel segmentation under multi-path supervision[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention.2019.Springer, 264-272.
- [13] T. M. Khan, F. Abdullah, S. S. Naqvi, et al. Shallow vessel segmentation network for automatic retinal vessel segmentation[C]//.2020 International Joint Conference on Neural Networks (IJCNN).2020.IEEE, 1-7.
- [14] J. Song and B. Lee. Development of automatic retinal vessel segmentation method in fundus images via convolutional neural networks[C]//.2017 39th

- Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC).2017.IEEE, 681-684.
- [15] V. Cherukuri, V. K. BG, R. Bala, et al. Multi-scale regularized deep network for retinal vessel segmentation[C]//.2019 IEEE International Conference on Image Processing (ICIP). 2019, IEEE, 824-828.
- [16] K. Hu, Z. Zhang, X. Niu, et al. Retinal vessel segmentation of color fundus images using multiscale convolutional neural network with an improved cross-entropy loss function[J]. *Neurocomputing*: 2018,309: 179-191.
- [17] S. Guo, K. Wang, H. Kang, et al. BTS-DSN: Deeply supervised neural network with short connections for retinal vessel segmentation.[J]*International journal of medical informatics*: 2019,126: 105-113.
- [18] B. Zhang, S. Huang and S Hu. Multi-scale neural networks for retinal blood vessels segmentation[J]. *arXiv preprint arXiv: 1804.04206*: 2018.
- [19] X. Xiao, S. Lian, Z. Luo, et al. Weighted Res-UNet for high-quality retina vessel segmentation[C]//.2018 9th International Conference on Information Technology in Medicine and Education (ITME).2018.IEEE, 327-331.
- [20] R. Xu, X. Ye, G. Jiang, et al. Retinal vessel segmentation via a semantics and multi-scale aggregation network[C]//.ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP).2020.IEEE, 1085-1089.
- [21] M. Hajabdollahi, R. Esfandiarpour, K. Najarian, et al. Low complexity convolutional neural network for vessel segmentation in portable retinal diagnostic devices[C]//.2018 25th IEEE International Conference on Image Processing (ICIP).2018.IEEE, 2785-2789.

- [22] T. Laibacher, T. Weyde and S. Jalali. M2U-Net: Effective and efficient retinal vessel segmentation for resource-constrained environments[J]. arXiv preprint arXiv: 1811.07738:2018.
- [23] X. Li, Y. Jiang, M. Li, et al. Lightweight attention convolutional neural network for retinal vessel segmentation[J]. IEEE Transactions on Industrial Informatics: 2020.
- [24] J. Wei and Z. Fan. Genetic U-Net: Automatically designing lightweight U-shaped CNN architectures using the genetic algorithm for retinal vessel segmentation[J]. arXiv preprint arXiv:2010.15560:2020.
- [25] İ. Atli and O. S. Gedik. Sine-Net: A fully convolutional deep learning architecture for retinal blood vessel segmentation[J]. Engineering Science and Technology, an International Journal: 2021, 24(2): 271-283.
- [26] 周颖. 骨髓受累PET-CT图像融合分类技术研究[D]. 福州: 福州大学, 2023.
- [27] 杨福盛. 基于三维深度学习的肺结节良恶性分类和数据增强研究[D]. 福州: 福州大学, 2022.
- [28] 胡益煌. 基于双模态多任务学习的结直肠癌新辅助治疗预测研究[D]. 福州: 福州大学, 2023.
- [29] 邓珂. 基于深度学习的肛瘘MRI分类算法研究[D]. 福州: 福州大学, 2023.
- [30] Yang D, Zhang S T, Yan Z N, Tan C W, Li K, Metaxas D. Automated anatomical landmark detection on distal femur surface using convolutional neural network. In: Proceedings of the 12th International Symposium on Biomedical Imaging. New York, NY, USA: IEEE, 2015. 17–21.
- [31] de Vos B D, Wolterink J M, de Jong P A, Viergever MA, Išgum I. 2D image classification for 3D anatomy localization: employing deep convolutional neural networks. In: Proceedings of the 9784, Medical Imaging 2016: Image Processing. San Diego, California, US: SPIE, 2016, 9784:Article No. 97841Y.

- [32] Chen H, Yu L Q, Dou Q, Shi L, Mok V C T, Heng PA. Automatic detection of cerebral microbleeds via deep learning based 3D feature representation. In: Proceedings of the 12th International Symposium on Biomedical Imaging (ISBI). New York, NY, USA: IEEE, 2015. 764–767.
- [33] Shin H C, Orton M R, Collins D J, Doran S J, Leach M O. Stacked autoencoders for unsupervised feature learning and multiple organ detection in a pilot study using 4D patient data. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(8): 1930–1943.

第 11 章 深度学习在大数据处理中的应用

深度学习技术在大数据处理中占据巨大优势，前文已经展示了深度学习用于数据驱动的建模研究，本章分别就深度学习在天文、医疗以及金融大数据领域的应用展开论述，通过列举实际案例，详细的讨论了大数据技术在实际生产、生活中的应用。

11.1 天文大数据

神秘而深邃的宇宙包含的海量数据，为天文学家提供了丰富的研究内容，天文数据是人类宝贵的科研资料，也是人类了解和研究宇宙奥秘的第一手素材。在人类不断探索宇宙奥秘的过程中，随着科学技术的不断进步，特别是望远镜设计与制造技术、探测器设计与制造技术、信息与计算技术等的发展，天文学已经进入大数据时代。例如，通过融合数百亿天体的多波段巡天数据库，进而我们可以对宇宙的大尺度结构以及银河系的精细结构进行深入研究；同样，利用高级数据挖掘手段，我们可以在庞大的天文数据流中发现稀有甚至新的天体类型；另外，对天文的海量数据的深入挖掘，可以帮助我们揭示类星体、星系和星系团的演化，还可以将实验室所得的数值模拟结果与观测得到的精确数据通过数据挖掘手段进一步比对分析等。目前，天文学研究已经成为一项以数据为中心，为数据所驱动的科研活动。驱动这场变革的背后推手除了有不断丰富的天文数据，还有互联网带来的便捷的数据访问和资源共享。现代天文数据库中蕴含的信息内容十分丰富，所以归档分类和数据挖掘以及大数据应用不仅是必要的而且是必需的。

近十几年，各种先进的大型地面望远镜和空间望远镜不断涌现，例如 SKA、MWA、GMT、LSST、GTC、TMT、E-ELT、ALMA 等等。通过这些科学巡天项目的调研开展，天文数据出现了爆炸式的增长。如何从这些大数据集中有效地选择科学目标，成为了一件重大而富有挑战性的任务。换句话说，如何从海量的天文数据中自动提取出有用的信息

或科学知识，对天文学家来说是一项新的不可避免的任务。



图 11-1 SKA 和 MWA

11.1.1 天文大数据概述

随着天文观测技术的发展，天文数据正在以 TB 级甚至 PB 量级的速率不断增长。目前，世界上许多国家都开展了大规模的天空调查项目，每天产生大量的天文数据。虽然业界对大数据的看法不尽相同，但大数据应具备的 4V 特征已达成共识，即：Volume（大量）、Velocity（高速）、Variety（多样）、Veracity（精确）或 Value（价值）。而天文数据具备 4V 特征，因此天文数据是大数据。在难以获取其他大数据时，不妨考虑根据天文学领域的需求，结合计算机科学、模式识别、系统科学等相关学科领域的理论与方法，研究与发展天文大数据的处理技术。

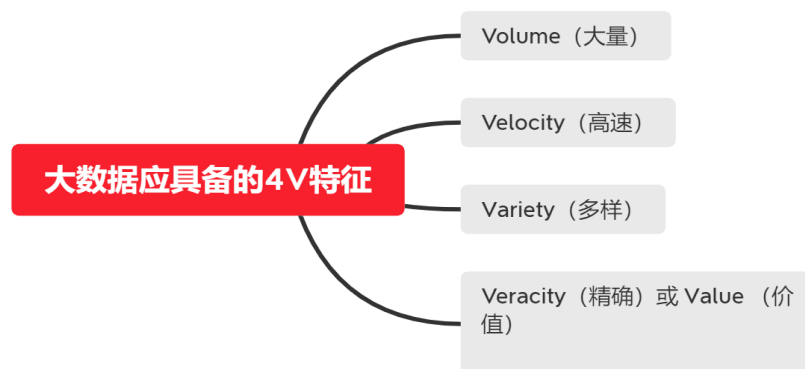


图 11-2 大数据 4V 特征

特别是进入 21 世纪后，天文学进入了数据井喷的发展阶段，每秒产生的数据量已经达到 TB 级。特别是在射电天文学需要大数据图

像处理技术领域的加持,做到快速、准确地恢复、重建、加强工作和天文图片收集的数据分类步骤,以便天文工作者在后期处理时可以更深入的进行信息收集和使用,这样可以在庞大繁杂的数据中获取更多有用的信息。如当前世界 10 多个国家参与在建的 SKA 项目是世界上最大的综合孔径射电望远镜阵列,它是用来实现平方公里的规模接待区,相当于 140 个足球场面积的大小,具有极高的灵敏度和时频分辨率,它更像是一个“软件望远镜”,SKA 产生的数据流远远超过世界互联网的总和,以满足探索宇宙起源、星系演化、宇宙学、暗能量研究以及寻找原始生命分子和地外生命等科学目标,英国协会科学和发现中心的伊恩-格里芬博士说:“SKA 计划将为天文学家提供一个全新的科研工具,彻底改变我们对宇宙以往的了解。由于面积极其庞大,这个望远镜将会显示出很多星系中一些令人难以置信的细节,通过研究那些神秘天体,例如黑洞,有助于论证及检测爱因斯坦的相对论,让天文学家了解更多关于宇宙早期的”。这些大型天文射电望远镜创造的数据量不可计数,所以数据的处理成为了亟待解决的问题,而传统的方法难以对目前庞大的天文数据量进行快速、高效的处理与分析,大数据技术正是要在天文领域进行更为广泛深入的应用。不同于其他具有商业价值的大数据应用领域,研究天文大数据是面向基础自然科学研究领域的应用,对人类科学文明的发展具有深远意义。相信天文大数据可以推动对大数据研究的发展,而大数据在天文学的应用又可以推动天文学方向的有更多的令人惊叹的发现,在研究技术上形成百花齐放的局面。

天文学已成为数据密集型的重要学科,这主要是考虑到以下几个原因。首先天文学最早采用 CCD 和数字相干器等现代数字探测器的科学,并将科学计算应用于数据处理,把数值模拟作为一种科研工具。国际天文领域中 e-Science 的文化理念早在 20 世纪 80 年代,在英特网(WWW)和商业数据库诞生之前,就被培育起来。为了统一标准,

天文学家早在 20 世纪 80 年代初就设计了领域内通用的数据交换标准格式，即 FITS。至此，天文数据集的体重从最初的千字节到兆字节，20 世纪 80 年代末发展到千兆字节，90 年代中期到万亿字节，到如今已达每秒 TB 的数据量。

第二个重要的因素是包括美国宇航局 (NASA) 在内的一批空间机构为其太空科学计划建立起一批数据中心，在经过一定的保护期后，这些机构即将这些科学数据向全社会开放共享。这些做法不但推动了数据库和数据管理工具的发展，也逐渐培育出科学数据开发共享和重复利用的科学文化。这些数据中心成为今天虚拟天文台的发祥地和重要基础。

第三个重要因素是大型数字巡天计划的出现，并成为天文数据的主要来源。利用照相底片做巡天观测，通过扫描实现数字化，这样的传统巡天工作在 20 世纪 90 年代便寿终正寝。传统巡天计划造就了第一个万亿字节量级的天文数据集，即数字化帕洛玛巡天 (DPOSS)。这个记录很快被斯隆数字巡天 (SDSS) 等纯数字的巡天计划打破。除了取得瞩目的科学成果，现代数字巡天计划还改变了天文学的研究模式和天文学家的思维模式。基于现代巡天数据库，科研人员不依赖于望远镜也能做出优秀的研究成果。数字巡天时代的天文学发展不但需要天文学家的个人智慧，更需要大型科研团队的协同创新。

11.1.2 天文大数据目标及挑战

超大型天文射电阵列观测技术的出现不仅能够让研究人员观测到新的天文现象，更能用于验证已有物理模型的正确性，这些最新的天文成果的发现是建立在海量天文数据的近乎实时产生、管理与分析的基础上，因此给目前的天文射电望远镜的数据管理提出了很大的挑战。大型射电天文望远镜每天采集到大量的观测数据，以往对于这些数据的校准、分类、成像等初步分析通常需要人工干预。到了天文大数据时代，这种方式不仅消耗了大量的人力，而且数据处理的效率低，

严重阻碍了数据的快速归档和后期的深入分析。天文大数据的目标，就是应用各种大数据技术对天文领域的大数据进行进一步处理、归类、细化、分析，对产生的数据做到充分利用，以进一步激化对天文学方向的几大科学基础问题的解答。但是其中遇到的挑战也是不断升级，如何对每天采集的数据进行高效、准确的分类，实现数据的快速归档，这一过程变得越来越繁杂，想要充分利用海量的历史数据，解决天文领域中关键的科学问题甚至有新的发现，这对天文大数据技术的挑战极大，这些技术难点都成为目前天文大数据领域的重点突破口。

新一代概要式巡天能够实现对大面积天区的快速、多次扫描，从而产生很多倍于传统数字巡天的数据量。新一代概要式巡天计划的实施把数据处理和分析的对象从海量数据集变为海量数据流，研究工作的复杂度进一步提升。很多物理过程和事件持续的时间很短，要求近乎实时地完成目标证认、特征提取、天体分类、图像处理、随动观测优先级确定等工作。这些雄心勃勃的项目将考验科学家处理数据的能力。图像需要进行自动处理，这意味着数据需要被简化为可处理的大小，或者转换成最终结果。

11.1.3 天文大数据理论及技术

我们迫切地需要大数据技术，天文领域的井喷式的数据量，我们已无法消化。甚至有很多最新的惊人发现是源于多年前的观测数据，如一个偶然的发现：银河系中心附近存在着数千个黑洞，这个发现并不是利用并不是来自于一些最先进的望远镜，甚至都不是最近的观测数据，其中一些数据其实是 20 年前就已经收集到。研究人员通过挖掘以前的、长期存档的数据，发现了黑洞。因为大数据时代改变了科学的发展方式，像这样的发现只会变得越来越普遍。

我们需要数据挖掘、分类、归档的处理，当然大数据应用于天文方面的不止这些。我们可以进行大样本观测的机器学习。依据 SDSS, PANSTARR, LAMOST 等巡天观测数据和机器学习方法发现并获得规律，

解决宇宙天文学的前沿问题。依托 FAST 等各类射电望远镜,在脉冲星、FRB 和地外文明等方面的观测研究,将人工智能方法应用于脉冲星的搜寻以及发现地外文明的线索。开发海量天文数据的分布式存储与处理算法,建立一流的天文数据处理和存储中心。

大数据采用到的技术主要是四个方面:大数据采集、大数据预处理、大数据存储、大数据分析。在天文领域,数据采集则完全交由各级天文台处理,主要的难点在于后面的预处理、存储、分析等。进十几年天文学已经逐渐转向了数据分享、共同参与的方式,比如由一个虚拟天文台(virtual observatory, VO)构成,它是通过先进的信息技术将全球范围内的天文研究资源无缝透明连结在一起形成的数据密集型网络化天文学研究和科普教育环境。其将全球的天文数据库连接起来和科普教育环境.其将全球的天文数据库连接起来形成一个多波段的数字星空,一个全球性的天文数据网格,让科学家和普通用户能够基于数据发现、高效。同时,观测采集而来的数据往往是杂乱无章的,为了便于处理,首先使用一些方法对天文数据进行分类,如逻辑回归等。

在分类结束后,我们需要对不同数据源的数据进行模式匹配、数据冗余、数据值冲突检测与处理。还有数据的快速转换,在得到数据之后需要将海量数据快速转换得到相应格式文件。现有的海量数据,同样需要精简其数据量,以得到较小的规模,包括数据方聚集、维规约、数据压缩、数值规约、概念分层等等。

在预处理之后,需要将采集到的数据进行存储,包含了三种典型路线:基于 MPP 架构的新型数据库集群,基于 Hadoop 的技术扩展和封装,大数据一体机。目前比较常见的存储方式是 Hadoop 的技术扩展和封装,基于内存计算的 Hadoop 分布式集群技术在迭代式机器学习和交互式数据挖掘应用等方面表现出明显的优势,此技术为海量天文数据挖掘提供了新的手段和方法。

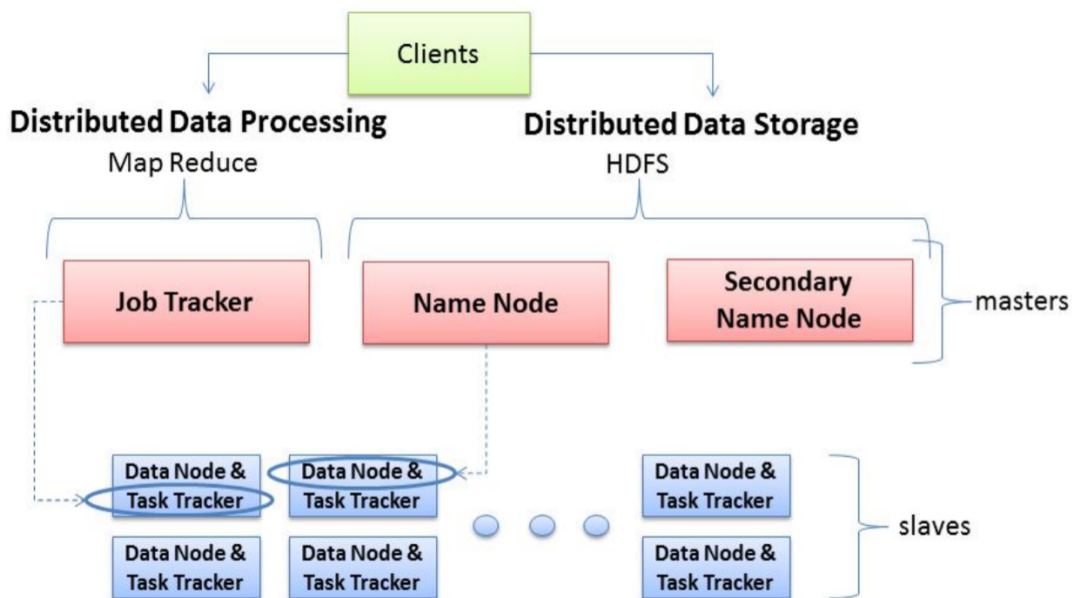


图 11-3 Hadoop 的集群架构图

11.1.4 应用实例

案例一、基于深度学习的致密源射电天文图像反卷积

射电综合成像将许多小孔径天线综合成为一个大的虚拟孔径天线，大幅度提高了射电望远镜的分辨率。在该技术中需要应用反卷积来消除点扩展函数 (PSF) 的影响，特别是 PSF 旁瓣的影响。精确重建致密发射源一直是需要面对的重大挑战之一，例如在再电离时期 (EoR) 成像中精确去除致密源的前景。CLEAN 算法及其变体是广泛应用于射电综合成像的反卷积方法，但是这些方法仍然难以准确重建致密源。

在本案例中提出了一种数据驱动的方法，用于高度准确地重建致密射电源。这是一种有监督的端到端学习方法，可以从脏图和参考图像之间的数据对中学习有效映射。这种数据驱动方法使用了在致密源的 SKA 模拟数据集上训练的深度神经网络 deepDeconv，可以更准确的从低角分辨率的脏图中重建致密特征。实验结果表明，基于 deepDeconv 的新模型图像重建精度比基于 CLEAN 的算法有了很大提高，重建的总通量更精确，峰值信噪比 (PSNR) 和成像保真度更高，重建结果直观性能更好。

(1) **射电综合成像**：利用孔径合成(AS)技术，将多个小天线组合成一个大的虚拟天线。与直接成像系统不同的是，AS 望远镜捕捉空间目标的傅里叶系数，然后进行傅里叶反变换重建空间图像。由于天线数量有限，傅里叶系数在实际应用中非常稀疏，导致图像非常模糊。为了去除/减少模糊，需要对获取的脏图进行去卷积操作。图 11-4 为射电综合孔径成像原理。




图 11-4 射电综合成像原理

给定原始空间图像 $I(l, m)$ ，对应频域图像为 $V(u, v)$ ，它们是傅里叶变换对，分别为亮度函数和可见度函数。如果获取所有的傅里叶系数，那么 $I(l, m)$ 可以完全重构。然而，实际情况是 $V(u, v)$ 在傅里叶域中是稀疏采样的。因此，采样可见度函数 $V^D(u, v)$ 仅在 AS 系统中可用，表示为

$$V^D(u, v) = V(u, v) \times S(u, v) \quad (11-1)$$

其中， $S(u, v)$ 是频域的采样函数。对上式的两边应用傅里叶反变换，可以得到

$$I^D(l, m) = \iint_{\Sigma} V(u, v) S(u, v) \exp(-2i\pi(ul + vm)) dudv \quad (11-2)$$

其中， $I^D(l, m)$ 是 $V^D(u, v)$ 傅里叶反变换后所得的脏图。由于频域的卷

积运算等同于空域上的乘积运算，所以上式可写为

$$I^D(l, m) = I(l, m) \otimes B^D(l, m) \quad (11-3)$$

其中， $B^D(l, m)$ 是采样函数 $S(u, v)$ 傅里叶反变换后所得的脏束或点扩展函数 PSF

$$B^D(l, m) = \iint_{\Sigma} S(u, v) \exp(-2i\pi(ul + vm)) \, dudv \quad (11-4)$$

因此在实际观测系统中，我们获取的是空域上的脏图 $I^D(l, m)$ ，而不是实际的真实图像 $I(l, m)$ 。而脏图由于受到脏束 $B^D(l, m)$ 的污染，并不能直接用于天体物理分析，为重建 $I(l, m)$ ，需要去除脏束的影响，这个过程通常称为反卷积。

(2) **基于深度学习的反卷积算法：**本案例提出的用于深度重建致密射电源的卷积神经网络 deepDeconv，在网络结构上改进了 DnCNN 来让其更适应于致密源的重建工作。如图 11-5 所示是 deepDeconv 的卷积神经网络的结构设计。

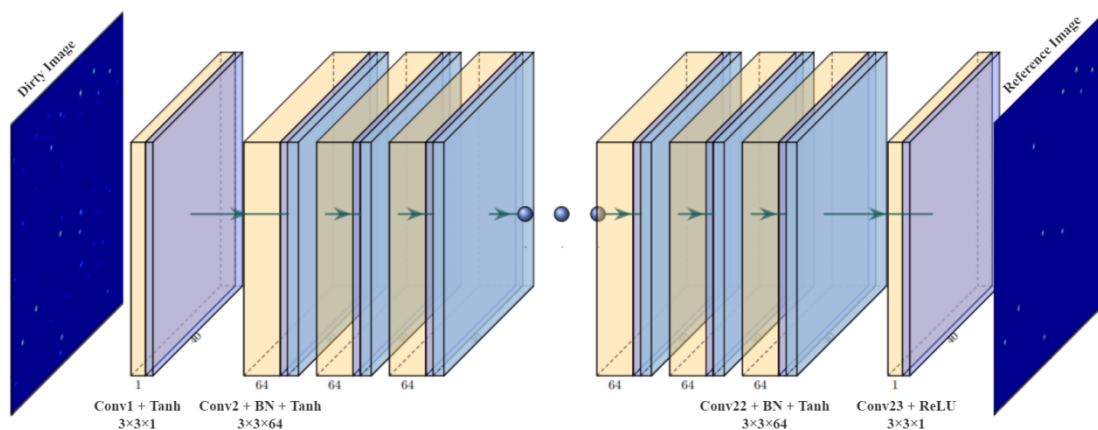


图 11-5 用于致密源重建的 deepDeconv 的结构

在图 11-5 中，每个层次有两到三层，依次分为卷积层、批量归一化层、激活函数层。脏图与参考图像之间的学习方式为有监督学习，该映射/模式用于去除 PSF 效应，训练过程采用端到端的方式。输入图集来自脏图，输出图集来自参考图，实际上学习的映射就是这两者之间大量的图像对关系。该表达中包含了前向层的简单特征分布到反向层的复杂特征分布，这样的基于复杂度的不同分层可以更好地展示对 PSF 的逆过程。这个模型中用到的损失函数和激活函数可以分别表

示为

$$L(\theta) = \frac{1}{2N} \sum_{i=1}^N \|I_i^{dirty}(\theta) - I_i^{ref}(\theta)\|_2^2 \quad (11-5)$$

$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (11-6)$$

$$\text{ReLU}(x) = \max(0, x) \quad (11-7)$$

式(11-5)为损失函数,式中 I_i^{dirty} 表示脏图, I_i^{ref} 表示参考图,该式表达了脏图和参考图之间的平均均方误差,这有助于抑制训练过程中的震荡。一般认为损失越小,两者之间的差异越小,当损失函数趋于0且不再下降,由学习模型重建的图像就倾向于参考图像。式(11-6)和(11-7)为激活函数,两者适用于不同的环境,模拟了该非线性神经网络求解非线性解的过程。本案例的模型在最后一层将tanh函数放在ReLU函数后。

(3)实验与结果分析:通过将本案例提出的deepDeconv和CLEAN算法进行比较来验证该方法的有效性。稀疏分布的致密源重建实验结果如图11-6所示。图中左上为deepDeconv重建结果,右上为CLEAN算法的重建结果,左下为deepDeconv重建结果与相应参考图之间的差,右下为CLEAN算法重建结果与相应参考图之间的差,可以直观的感受本案例所提出的模型在稀疏分布的致密源重建结果上的有着优越的性能。




图 11-6 稀疏分布的致密源重建结果及对比

案例二、基于生成对抗网络的太阳图像反褶积[16]

太阳射电天文学自诞生起就受到科学界的广泛关注，进展都非常迅速，至今已有 80 余年的发展历程。太阳射电天文学主要目的是探索太阳的物理本质，它主要是通太阳射电观测设备观测的数据研究太阳爆发活动中射电波段的辐射，再联系太阳别的电磁波辐射与粒子发射的相关信息综合分析太阳。迄今，射电天文领域已经观测到了大批的数据信息，理论上的研究讨论也逐步加深，全世界范围内已建造数百台太阳观测设备。

近年来，深度学习（DL）和人工智能技术迅猛发展，在多个学科领域得到了广泛关注和应用，特别是在计算机视觉和语音识别领域[17]，其强大的特征学习能力达到了超越人类的水平。天文学研究也不甘落后，涌现出一些应用深度学习进行数据分析的工作。DL 的优势是双重的。首先，它可以从大量的数据中学习模型，这将更适用于实际。其次，DL 不需要完全掌握物理过程的知识。输入和输出之间的极端非学习关系是通过数据密集的方式学习的。这种优势使得 DL 具有更大的灵活性和适用性。

（1）生成对抗网络：GAN（生成对抗）[18]是最近提出的 DL 模型，在多种应用中得到了广泛的研究，特别是图像重建，如图像去噪、图像合成、超分辨率等。GAN 由一个发生器和一个鉴别器组成，如图 11-7 所示。

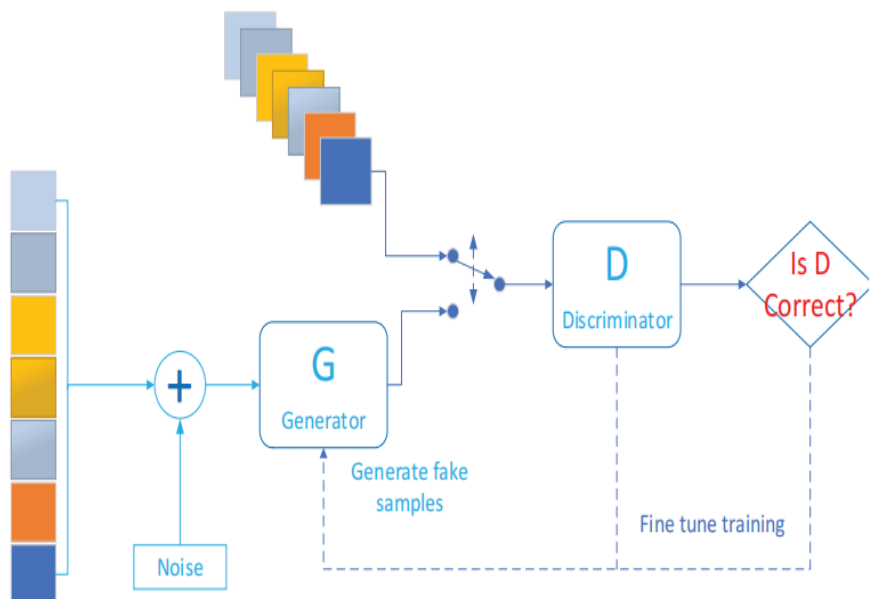


图 11-7 生成式对抗神经网络^[19]

在图 11-7 中，真实/原始图像和假图像都被送入 GAN。生成器试图使虚假的图像接近于真实/原始的图像。与此同时，鉴别器作为检测器，将生成器伪造的图像与真实/原始图像进行区分。通过对抗学习，生成器可以获得训练样本的分布，从而产生新的/未知的样本，而鉴别器可以很好地区分真伪。另外，在一次又一次地学习伪造者(生成器)的欺骗之后，鉴别器变得越来越好。重复这一过程，最终使生成器可以伪造非常接近真实数据的数据，同时，鉴别器也成为一种优秀的检测器。GAN 的原理起源于零和极小极大博弈，其数学表示为

$$G^* = \arg \min_G \max_D L_{GAN}(G, D) \quad (11-8)$$

$$L_{cGAN}(G, D) = E_{x,y}[\log D(x, y)] + E_{x,z}[\log(1 - D(G(x, z)))] \quad (11-9)$$

其中 D 为检测器，G 为发生器，y 为实像，G(x,z) 为假像。y 来自真实数据的分布，x 来自我们的模拟数据(例如，图像处理中降级的图像)，z 来自随机噪声。对于优化 D，我们期望真实数据上的 D(y) 越大，生成器 G 生成的假数据上的 D(G(x,z)) 越小。对于优化 G，我们期望它能够生成足够多的真实样本 G(x,z) 来成功欺骗 D。在训练过程中，D 和 G 通过固定一个和优化另一个来交替优化。

(2) 基于生成对抗网络的太阳图像反褶积：在案例模型中，生成器

是一个经典的 UNet，由多层卷积和转置卷积组成，提出的模型从数据中学习，没有任何约束，完全是数据驱动的，如图 11-8 所示。从图 11-8 来看，UNet 是一个自动编码器的形状。编码器获得输入的压缩表示，而解码器对该表示进行解压缩以重构输入。UNet 最值得注意的是的特点是编码器和解码器的相应层之间的跳跃式连接。这种跳跃连接可以将图像的高级语义信息和低级特征结合起来，有利于图像处理任务，特别是对于语义信息较少的图像，如医学和天文学图像。该识别器是由 5 个卷积层组成的一般卷积神经网络。

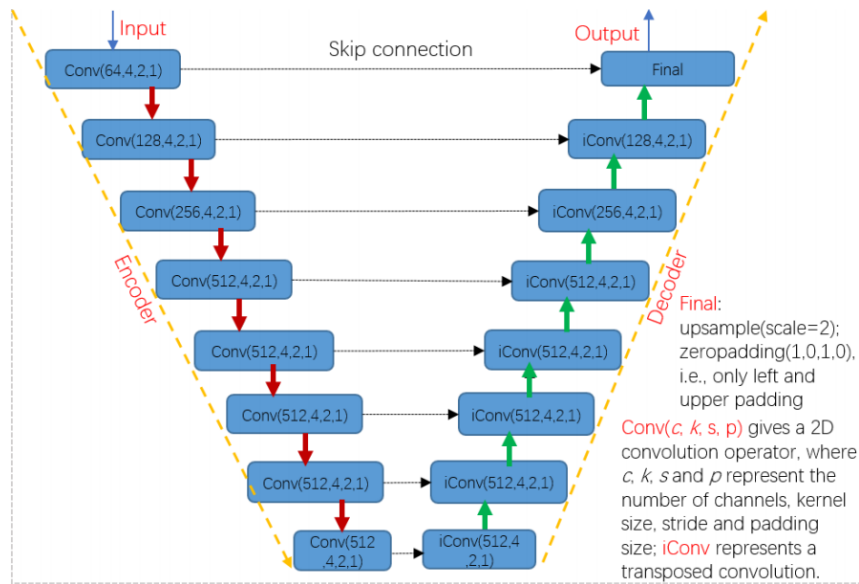


图 11-8 提出的 AS 图像反褶积模型^[16]

11.2 医疗大数据

本节将对大数据背景下的医疗领域发展情况进行综述，首先概述目前大数据技术在智慧医疗领域的研究现状；其次，提出现阶段医疗大数据面临的问题及挑战；然后，对现有的医疗大数据的理论与技术进行分析总结；最后，提供可供读者实施的医疗大数据应用案例。

11.2.1 医疗大数据概述

从大规模研究队列的快速识别和建立，到人工智能辅助的临床决策支持系统，大数据正在改变着医学研究与实践。本节将对医疗大数据的应用场景进行介绍，并分析医疗中的数据来源及特征，对大数据

技术对医疗领域的意义进行总结。

根据大数据技术是否应用于临床医疗分为两类，即医疗卫生统计信息化建设、临床医疗支持及精准医学建设。目前，科研人员在这两方面开展前沿学术研究，致力于用数据技术造福人类。下面将举例对以上两个方面进行介绍：

1、医疗卫生统计信息化建设

大数据背景下开展医疗卫生信息统计工作，需要借助计算机系统，将两者融合起来，实现数据的统一分析、整合、统计工作。传统的数据处理方法早已不能满足现代的医疗卫生数据的统计需求，急需借助大数据，通过其海量的存储空间等优势进行数据处理，使得卫生数据处理可以满足不断增长的需求，为大数据背景下医疗卫生信息统计工作提供便捷性，也成为目前医疗卫生信息处理的重要方式。大数据技术已广泛应用于医疗管理、药品开发以及医保基金监管等领域，例如，医疗行业监管中所应用的智能医疗、医保基金监管中所应用的智能医疗、医疗科研与药品研发中所应用的智能医疗、医疗服务优化中所应用的智能医疗以及在医院内部管理中所应用的智能医疗。

在医疗管理方面，我国已建立了多个针对医疗服务供方和需方的预警模型，对医保欺诈行为进行了较为准确的检出与预测；在医疗监管方面，通过建立以电子病历系统为核心的医院信息化系统实现智能化的医院管理，既可节省人力成本提高服务效率，也可便利民众就医。

2、临床医疗支持及精准医学建设

临床医疗支持及精准医学为复杂疾病的防控和治疗提供了新思路，通过个人基因组和其他生物大数据的挖掘，为病人提供个体化的风险预测、诊断和治疗方案，从而优化医疗资源的配置。发展精准医学，科学有效的配置医疗资源，是医疗卫生事业发展的迫切需求。在临床的各个阶段发挥着不同作用。

在院前管理方面，智能健康管理系统可借助智能穿戴设备和监测

反馈系统主动采集服务人群的个人健康信息，并实时向医疗端和家属端反馈；在院内诊疗方面，医学影像系统可以更快、更准确地识别病灶和癌变组织，被广泛应用于癌症早筛、内镜检查和病理学检查。智能诊断系统，又称为“辅助诊断系统”，是依靠学习典型病例的方式获得模拟医生医疗思维能力的一种智能医疗系统，能够在一定程度上缓解专家数量不足和基层医生诊疗水平总体偏低的困境。智能治疗系统主要是指手术治疗系统，又被称为是“手术机器人”，相较于前两类系统其侵入性更强。手术机器人具有三维透视功能，其精准的操作能够达到医生不能达到的效果；在院后康复方面，智能随访系统主要通过智能信息采集、反馈，以实现病人与主管医生的实时交互，以便为患者提供实时的个性化康复理疗方案，且能有效保证及时实施

早期，大部分医疗相关数据是纸张化的形式存在，而非电子数据化存储，比如官方的医药记录，收费记录，护士医生手写的病例记录，处方药记录，X光片记录，磁共振成像（MRI）记录，CT影像记录等等。随着强大的数据存储，计算平台，及移动互联网的发展，现在的趋势是医疗数据的大量爆发及快速的电子数字化。以上提到的医疗数据都在不同程度上向数字化转化。移动互联网、大数据、云计算等多领域技术与医疗领域跨界融合，新兴技术与新服务模式快速渗透到医疗各个环节，并让人们的就医方式出现重大变化，也为中国医疗带来了新的发展机遇。

随着医疗卫生信息化建设进程的不断加快，医疗数据的类型和规模也在以前所未有的速度迅猛增长，甚至出现了很多主流软件，能够在合理的时间内达到摄取、管理并整合成为能够帮助医院进行更积极目的经营决策的有用信息的地步。医疗数据主要的数据来源如下图。



图 11-9 医疗大数据来源

(1) 患者就医过程中产生的信息：如挂号阶段的个人姓名、年龄、住址、电话，面诊阶段的身体状况、医疗影像，缴费阶段的费用信息、报销信息、医保使用情况等信息等。

(2) 临床医疗研究和实验室数据：主要是实验中产生的数据，也包含患者产生的数据。临床和实验室数据整合在一起，使得医疗机构面临的数据增长非常快，一张普通 CT 图像含有大约 150 MB 的数据，一个标准的病理图则接近 5 GB。如果将这些数据量乘以人口数量和平均寿命，仅一个社区医院累积的数据量就可达数万亿字节甚至数千万亿字节(PB)之多。

(3) 制药企业和生命科学的数据：主要是实验中产生的数据，也包含患者产生的数据。药物研发所产生的数据是相当密集的，对于中小型企业也在百亿字节 (TB) 以上的。在生命科学领域，随着计算能力和基因测序能力逐步增加，美国哈佛医学院个人基因组项目负责人詹森·鲍比就认为，到 2015 年，将会有 5000 万人拥有个人基因图谱，而一个基因组序列文件大小约为 750MB。

(4)可穿戴设备所产生的数据：主要通过各种穿戴设备（手环、起搏器、眼镜等）收集人体的各种体征数据。随着移动设备和移动互联网的飞速发展，便携式的可穿戴医疗设备正在普及，个体健康信息都将可以直接连入互联网，由此将实现对个人健康数据随时随地的采集，而带来的数据信息量将更是不可估量的。

医疗数据具备一般的数据特性：规模大、结构多样、增长快速、价值巨大，同时其作为医疗领域产生的数据也同样具备医疗性：多态性、不完整性、冗余性、时间性、隐私性：

多态性：医疗数据包含有像化验产生的纯数据，也会有像体检产生的图像数据类似心电图等信号图谱，医生对患者的症状描述以及跟进自己经验或者数据结果做出的判断等文字描述，另外还有像心跳声，哭声，咳嗽声等类似的声音资料，同时现代医院的数据中还有各种动画数据（像胎动的影像等）。

不完整性：由于各种原因导致有很多医学数据是不完整的，像医生的主观判断以及文字描述的不完整，患者治疗中断导致的数据不完整，患者描述不清导致的数据不完整等。

冗余性：医疗数据量巨大，每天会产生大量多余的数据，这给数据分析的筛选带来困难。

时间性：大多医疗数据都是具有时间性、持续性的，像心电图，胎动思维图均属于时间维度内的数据变化图谱。

隐私性：隐私性也是医疗数据的一个重要特性，同时也是现在大部分医疗数据不愿对外开放的一个原因，很多医院的临床数据系统都是相对独立的局域网络，甚至不会去对外联网。

通过对医疗数据的分析，人类不但能够预测流行疾病的爆发趋势、避免感染、降低医疗成本等，还能让患者享受到更加便利的服务。大数据在带来巨大技术挑战的同时，也带来了巨大的技术创新和商业机遇。大数据分析能挖掘医疗行业的巨大商业价值，实现医疗行业的各

种增值服务，进一步提升医疗行业的经济效益和社会效益。

11.2.2 医疗大数据目标及挑战

目前，全球医疗健康数据已有数百 Exabyte (EB)，并在加速增长。这些宝贵的医疗数据资源对于疾病的预测管理和控制、医疗研究以及医疗信息化问题的研究都有着非常宝贵的价值，医疗大数据的主要目标总结如下。

通过充分应用医疗大数据技术大规模减少医疗开支：

(1) 比较效果研究：将患者的个人特征信息、疾病相关数据和治疗效果数据进行全面比对分析，进而对多种治疗措施进行深入比较，最终确定适用于特定患者的最佳治疗方案。

(2) 临床决策支持系统，以数据驱动的临床决策支持系统利用大数据分析技术使得自身更加智能，可以提高医疗工作者工作效率和医疗服务的质量。

(3) 医疗大数据可视化提升了医疗数据及过程的透明度，其一可以促进医疗业务流程的优化，降低医疗成本的同时提升医疗服务的质量，其二医疗工作者和患者之间在医疗行为上更为透明，有效缓解了医疗矛盾和并减少医疗纠纷的发生。

(4) 远程慢病患者实时监控，通过各类可穿戴式健康设备对慢病患者进行远程监控并记录相关数据，通过对大数据的收集及分析可以帮助医疗工作者制定针对该患者的治疗措施。

(5) 对病人档案的先进分析，对病人档案方面的大数据分析可以预测病人对各类疾病的易感情况。

对医疗支付方来说，通过大数据分析可以更好地对医疗服务进行定价：

(1) 自动化系统，通过大数据检测医疗索赔案件中的欺诈行为。

(2) 基于卫生经济学和疗效研究的定价计划。

医疗产品公司可以利用大数据提高研发效率：

(1) 预测建模, 在新药物的研发阶段, 可以通过数据建模和分析, 确定最有效率的投入产出比, 从而配备最佳资源组合, 可以降低医药产品公司的研发成本并更快地得到回报。

(2) 提高临床试验设计质量的统计工具和算法。

(3) 临床药物实验数据分析, 通过对临床试验数据和患者就诊记录以及疗效数据进行大数据分析可以发现药物隐含的适应症及相关副作用。

(4) 个性化治疗, 将临床业务大数据和基因大数据进行融合分析, 发掘适应于患者个体的个性化治疗手段, 这将使治疗过程更加具有针对性, 有助于降低治疗费用和周期及提升治疗效果, 真正实现以“患者为中心”的理念。

(5) 疾病模式分析, 如流感、埃博拉病毒等大规模传染病的疾病模式分析, 包括传染模式、发病周期、病毒基因序列等相关大数据分析, 可以帮助国家和药物研发机构快速地制定研发战略, 配备研发资源。

大数据分析为医疗服务行业带来新的商业模式: 网络平台和社区, 普通人在诸如推特、微博等互联网社交平台上一些包含医疗信息的日常记录, 以及在谷歌、百度等搜索引擎对一些疾病、家庭药物用品的搜索记录, 都可以用来做大数据分析以及相关疾病的预防。此外还有一些专门的健康相关网络平台利用大数据技术, 患者及医生可以方便地找到与之有关的患者、治疗方案等信息。

大数据应用帮助改善对于公众健康的监控公共卫生部门: 可以通过覆盖全国的医疗数据中心, 对传染病、大规模伤亡事件等进行全面监测, 并通过集成疾病监测和响应程序, 快速进行响应。

大数据技术为医疗领域带来重大变革, 然而当前医疗大数据的发展仍面临重重阻碍, 具体问题列举如下:

(1) 医疗数据共享程度低、质量差

大数据技术能否在临床上得到广泛应用，关键在于大数据的基础设施建设，没有庞大的医疗健康大数据基建投入，难以实现智能医疗的广泛应用和长远发展。目前，全国绝大多数医疗机构没有运行电子病历系统，在一些偏远地区连电脑也没有配置。与此同时，各个医疗机构之间信息不能互通有无，区域的医疗大数据中心、全国的大数据中心尚未建立，无力形成医疗数据传输的互联互通与共享。整体上，我国的医疗健康大数据存在分散化、低质化的特征，难以满足快速发展的智能医疗产业，现阶段运行于部分地区或机构的智能医疗系统很难进行广泛推广。

（2）大数据医疗面临的法律问题

大数据医疗在临床应用中可能引发三个方面的法律责任：其一是因其本身缺陷导致的产品侵权责任，或者在刑事上构成生产、销售不符合标准的医用器材罪；其二是医务人员与智能医疗共同造成医疗事故，可能构成医疗损害赔偿赔偿责任、医疗事故行政责任，情节严重的构成医疗事故罪；其三是智能医疗系统在采集、存储、传输数据时导致个人信息和个人隐私泄露的，可能侵犯个人隐私权、个人信息权利或构成侵犯公民个人信息罪。

（3）大数据医疗面临的技术问题

医疗信息化一直在推动着医疗服务和临床研究的迅速改善，但过程中所生产的医疗数据仍然存在一些固有的特点和复杂性，因此很难被二次利用。另外，随着这些医疗数据集不断变大，处理的难度也一直在加大，常规的数据分析手段越来越力不从心。

随着云计算的推动，医疗信息化势必空前发展，医疗大数据时代必然到来。当然云计算在催生大数据产生的同时，也是分析和利用大数据的最有效手段。医疗大数据理论的提出为大数据技术在医疗领域的应用提供了新思想，医疗大数据技术的发展为解决医疗领域的问题提供了新手段。

11.2.3 医疗大数据理论及技术

医疗大数据特指在医疗领域内产生的大数据，临床医疗是其数据来源的一个方面。在临床医疗领域，由于医疗记录的多样性和医疗信息系统的异构性，也随着医学信息系统在全世界各地医院大规模的应用，医疗数据的容量近年来正在不断地膨胀。这些宝贵的医疗数据资源对于疾病的预测管理和控制、医疗研究以及医疗信息化问题的研究都有着非常宝贵的价值。

从医疗大数据自身特征及产生领域来看，医疗大数据的来源广泛，数据类型和处理方法千差万别，但基本处理流程都是一致的。按照大数据处理的实际需要和一般过程可将大数据领域里的技术分为大数据采集、存储、处理和呈现等相关技术。对于传统医疗数据而言，一般数据来源单一，数据集规模较小，因而不需要太大的存储介质和太强的计算处理能力，往往采用现有关系型数据库技术或者并行数据仓库等技术即可存储、处理和利用。与之相比，大数据环境下数据来源异常广泛且数据的类型更加多样，需要收集、存储和处理分析的数据体量庞大，对数据的应用及展现能力要求很高，并且十分注重数据处理的时效性及可用性。构建医疗大数据处理系统主要有以下四个阶段，其中包含的相关医疗大数据技术介绍如下：

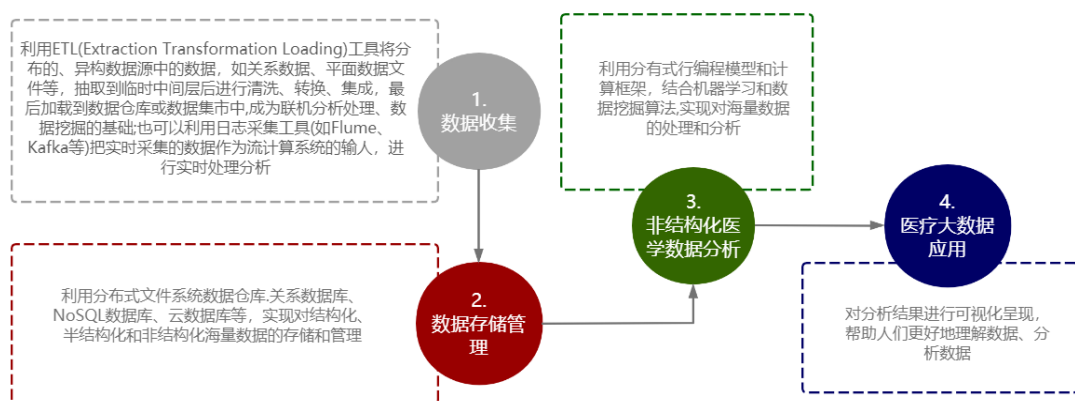


图 11-10 医疗大数据不同层面及其功能

数据收集技术:

大数据采集是指通过各种方式获得数量庞大、类型众多的结构化、半结构化及非结构化的海量数据,是大数据处理流程中最基础的一步。

在数据的实时性和可靠性的要求下，需要实现以分布式平台为基础的高速高可靠数据的抓取或采集（Extract）数据全映像的大数据收集技术，实现高速数据解析、转换（Transform）与装载（Load）的大数据整合技术，以及实现数据一致性与安全性保证的大数据安全技术。

数据存储管理技术：

大数据存储与管理要同时解决大数据在物理层面和逻辑层面的存储和管理问题。在物理层面上，需要构建可靠的分布式文件系统，例如 HDFS，提供高可用的、高容错的、弹性可配置的、高效低成本的大数据存储技术。在逻辑层面上，需要研究大数据建模技术，提供分布式的非关系型大数据管理与处理能力，异构数据的数据融合和数据组织能力。

非结构化医学数据分析技术：

大数据分析是整个大数据处理流程中最核心的组成部分，旨在通过大数据分析过程发掘数据中的价值所在。面对大数据分析的要求，传统的数据处理分析方法已经不能满足大数据环境下数据分析的需求。大数据处理分析遵循三个原则：是全体数据，非随机数据；是混杂性，非精确性；是相关关系，非因果关系。这些原则是大数据分析区别于传统数据处理的需求、方向和技术要求。在海量数据的背景下，单纯地依靠单服务器的计算能力，已经不能满足大数据处理时效性的要求，可以通过 MapReduce 等并行处理技术来提高数据的处理速度，并使系统具备可扩展性和高可用性等优势。

电子化的医疗数据方便了存储和传输，但是并未达到进行数据分析的要求。大约 80% 的医疗数据是自由文本构成的非结构化数据，其中不仅包括大段的文字描述，也包括包含非统一文字的表格字段。通过医学自然语言理解技术，将非结构化医疗数据转化为适合计算机分析的结构化形式是医疗大数据分析的基础。深度医学语言理解技术不仅识别各种医学概念在自然语言中的丰富表达，还通过医学语意分析

识别否定、推测、假设、条件、个人病史、家庭病史等语意，以及严重程度、解剖位置等各种修饰。语意分析结果可以方便各种维度、深度的数据分析，结合语意搜索技术进行病历的精准查询和匹配。例如目前尚在推广的电子病历分析正是该技术的体现。

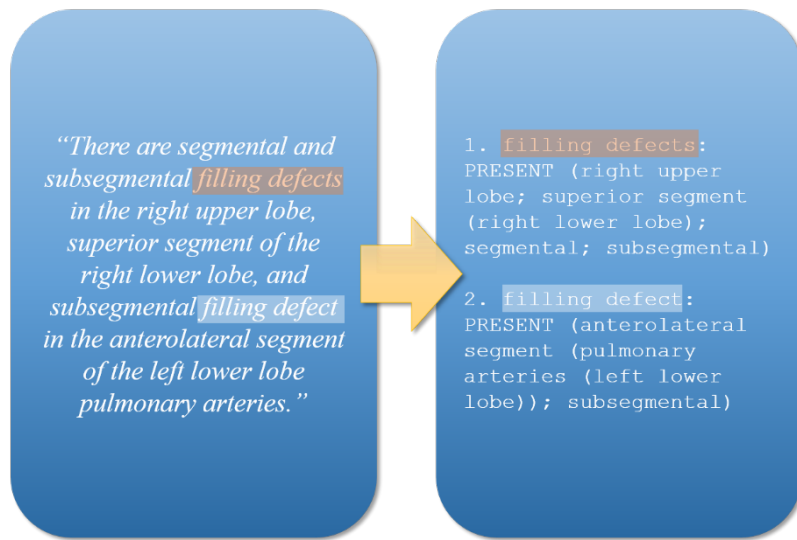


图 11-11 通过医学语言理解技术结构化自由文本

医疗大数据应用技术：

将大数据分析结果解释与呈现给用户是大数据处理过程的最终目的。传统的数据显示方式不能满足大数据分析结果复杂性和数据量大的要求，大数据可视化技术被引入用以更加有力直观地解释大数据分析结果。

在大数据相关技术得以发展的今天，研究人员有机会并有能力来利用医疗大数据这笔财富，医疗大数据技术的发展揭示了医疗大数据背后的集体智慧，给医疗信息系统用户提供相对可靠的个性化推荐，以提高日常工作的效率。

11.2.4 应用实例

本节结合医疗领域的应用背景，为读者提供医疗大数据的应用案例。本案例主要涉及医学数据处理与临床疾病诊断，涵盖深度学习框架、Linux 等系统及软件的使用方法。本案例适合高校大数据教学，

可以作为学习大数据课程后的综合实践案例。通过本案例，有助于读者综合运用大数据课程知识和各种工具软件，实现医疗大数据的应用实例。

案例 1、基于卷积神经网络的 CT 图像肺癌检测

当前在我国肺部疾病尤其是肺癌的发病率和死亡率在所有癌症中均排在第一，因此对于肺癌的早期防治以及确诊之后的及时治疗变得尤为重要。计算机辅助诊断已在一些医学领域取得媲美人类专家的诊断水平，但在肺部疾病的诊断中还存在准确率较低，而治疗不够精确等临床问题。该领域也是目前医疗大数据技术的研究热点。

本案例主要采用 Python 作为编程语言，构建 3D 卷积神经网络创建肺结节探测器，预测患者患癌的可能性，具有一定的参考价值。模型训练数据自来源于美国国家癌症研究所提供的高分辨率的肺部 CT（计算机断层扫描）图像[1]。实验环境规定如下：在 64 位的 Windows 10 系统下，结合 TensorFlow 0.12.0 和 Keras 库实现该网络模型。采用的数据集是由公开数据集 LIDC-IDRI 转化而来的，医生为 800 多个病人的 CT 图像标记了 1000 多个肺结节。因此，可以从整张 CT 图像中的标记周围裁剪出小型 3D 图像，将这些小型 3D 图像与结节标记直接对应，从而利用神经网络学习这些特征，训练出一个神经网络来检测肺结节，并评估结节的恶性程度，预测患者患癌的可能性。其中，预测时神经网络通过滑动窗口的方式来遍历整张 CT 图像，分别判断每个滑动窗口所包含的区域是否含有恶性信息的可能性。整体实验框架如下图所示：

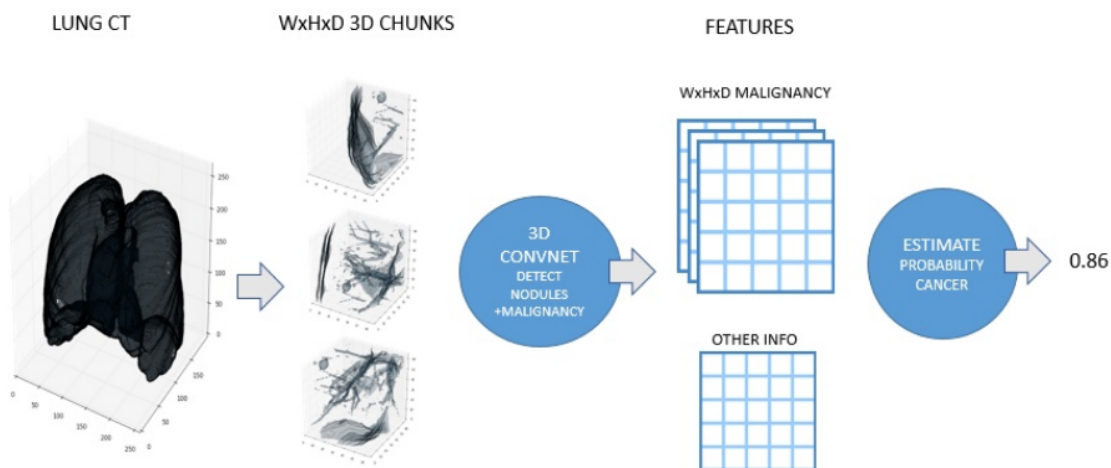


图 11-12 实验框架

1、数据预处理和创建训练集

(1) 数据预处理

在预处理过程中，首先对 CT 图像进行缩放，保证图像中的每个像素点只表示 1mm^3 的体积；然后将 CT 图像的像素强度转换为 HU 值，并最大化 HU 值后进行归一化处理；最后，确保所有 CT 图像都具有相同的方向。

(2) 训练集构建

构建 U-net 网络分割肺部区域。根据观察 CT 图像，可利用肺组织的边缘构建相应的框架找到肺结节。在分割掩膜边缘进行采样标注，从而分割得到肺部组织。

表 11-1 带有标记的不同数据集

描述	数量	权重	模型
Positive doctor labels from LIDC	5000	5	1&2
Candidates (v2) from LUNA16	400000	1	1&2
Non-lung tissue edge random samples	150000	1	1&2
LUNA16 False positives	7000	3	1&2
NDSB positive, negatives	1400	20	Only 2

建立一个结节观测器，用于调试所有的标记。LIDC 数据集的说

明文档表明医生被要求忽略大于 3cm 的结节，由于这些被忽略的结节会影响分类器的准确度，因此删除了与这些结节相重叠的部分。




图 11-3 CT 图像中的标记（左上为 LUNA16 V2 的数据；右上为非肺组织的边缘；左下为假阳性的区域；右下为被移除的无标注区域）

3D 卷积神经网络的训练方法和网络结构：数据集正反两类样本量比为 5000：500000，且正面例子的大小和形状有很大差异。因此在 CT 图像的滑动窗口中，建立小型 3D 卷积神经网络。

第一个目标为训练一个可作为基础的结节检测器。首先对正例进行上采样（upsample），将正反两类的样本比上调至 1：20；然后进行一些图像增强操作以提高模型的泛化能力。

设计好分类器后，再训练一个用于预测恶化程度的回归模型，将肿瘤恶化程度划分为 1（很可能不是恶性）~5（很可能是恶性），且为了强调肿瘤的恶化程度，对之前的划分平方运算后将范围扩大到 0~25。计划使用同一个网络，以多任务学习的方法，同时进行分类结点和估计恶化程度这两个任务。

采用基于 C3D 神经网络（类 VGG 网络）得到最终的分类评估网

络。首先将输入大小设置为 $32 \times 32 \times 32 \text{mm}$ ；对 Z 轴进行 average pooling 操作；最后，在网络的终端引入 Bottleneck features。

表 11-2 3D 卷积神经网络结构示意图

Layer	Params	Activation	Output	Remark
Input			$32 \times 32 \times 32, 1$	
Avg pool	$2 \times 1 \times 1$		$16 \times 32 \times 32, 1$	Downsample z-axis
3D conv	$3 \times 3 \times e3$	relu	$16 \times 32 \times 32, 64$	
Max pool	$1 \times 2 \times 2$		$16 \times 16 \times 16, 64$	Axes are same again
3D conv	$3 \times 3 \times 3$	relu	$16 \times 16 \times 16, 128$	
Max pool	$2 \times 2 \times 2$		$8 \times 8 \times 8, 64$	
3D conv(2x)	$3 \times 3 \times 3$	relu	$8 \times 8 \times 8, 256$	
Max pool	$2 \times 2 \times 2$		$4 \times 4 \times 4, 256$	
3D conv(2x)	$3 \times 3 \times 3$	relu	$4 \times 4 \times 4, 512$	
Max pool	$2 \times 2 \times 2$		$2 \times 2 \times 2, 512$	
3D conv	$2 \times 2 \times 2$	relu	$1 \times 1 \times 1, 64$	Bottleneck features
3D conv	$2 \times 2 \times 2$	sigmoid	$1 \times 1 \times 1, 1$	Nodule detector
3D conv	$2 \times 2 \times 2$	None	$1 \times 1 \times 1, 1$	Malignancy estimator

2、癌症预测

训练好网络后，下一步是让神经网络检测结节并估计其恶化程度。建立的 CT 结节观察器能够在人眼只能看到很少量的假阳性结节的情况下，检测到更多结节。然而由于它错过了一些非常大的明显结节，所以影响了对于假阴性的得分，有时使 LogLoss 升高了 3.00。因此，对 CT 图像进行两次下采样 (downsample)，并让网络在 1, 1.5 和 2 这三个尺度上预测。




图 11-14 恶性肿瘤检测结果（左图表明没有很好地检测到大气节，图像缩放为 1 倍大小；右图表明检测效果较好，图像放大为 2 倍大小）

添加额外的特征，构建梯度增强分类器（共使用 7 个特征）来预测一年内患者是否患癌。

主要由两个模型组成：

第一个模型基于所有的 LUNA16 数据集构建而成；

第二个模型通过选择 NDSB3 数据集中疑难病例和假阳性病例主动学习构建而成。

观察网络对 CT 图像的结节检测时，模型效果很好。对于第一阶段数据集，logloss 为 0.43，公开排行榜的 ROC 准确率为 0.85，对于第二阶段数据集，logloss 为 0.40，私人数据集的 ROC 准确率更高。因为在实际判断中，部分结节容易被忽视，对于放射科医师来说，本案例提供的自动结节检测的模型具有实用价值。

本案例仍存在不足之处，为了达到更好的预测效果，可以进行如下改进：建立放射科医师基准线，即根据一个放射学家在这个数据集上的具体表现，建立一个具有参考意义的基准；对 NDSB 数据集的恶性肿瘤标注，即输入更多精确标记的例子，进一步提升算法准确度；尝试更多不同的神经网络结构。

案例 2、基于卷积神经网络的新冠肺炎分割

2019 年新型冠状病毒（COVID-19）于 2020 年初在全国蔓延，在全球 200 多个国家大规模爆发导致近 2 年面临严重的健康生存危机。根据世界卫生组织（World Health Organization, WHO）数据显示，截至 2021 年 11 月 25 日，全球累计确诊人数超过 2.58 亿，死亡人数超过 517 万，对公众健康和经济造成重大影响。然而，仍然缺乏对新冠肺炎引起的肺部感染进行有效量化的研究。医学影像分割作为诊断框架的基本且具有挑战性的任务，在基于 CT 图像测量的新冠肺炎感染的精确量化中起着至关重要的作用。

本案例采用 python 语言，使用 TensorFlow 框架来构建基于 U-Net 的 2D 分割模型，实现冠状病毒 CT 扫描分割，具有极大的现实意义。模型训练的数据集包含 20 个标记的 COVID-19 CT 扫描。左肺、右肺和感染由两名放射科医生进行标记，并由经验丰富的放射科医生进行验证。实验环境规定如下：在 64 位的 Windows10 系统下，结合 TensorFlow 和 Keras 库实现该网络模型。(源代码参考附录)

实验所用数据集均为 .nii 格式，可使用 ITK-SNAP 软件可视化。数据集包括超过 40 名 COVID-19 患者的 100 张轴向 CT 图像的数据集，这些图像是可公开访问的 JPG 图像转换而来的，放射科医生使用 3 个标签对图像进行分割，分别是毛玻璃(肺部结节的影像学的名称)、实变和胸腔积液(如图 11-15 所示)。通过训练一个 2D 多标签的 U-Net 模型并应用该模型，尝试实现自动分割，来辅助临床医生做出诊断。




图 11-15 数据集标签样例(红色表示毛玻璃、绿色表示实变、蓝色表示胸腔积液)

整体实验思路分为一下五个步骤进行：

- 读取.nii 格式的元数据；
- 读取胸部 CT 扫描数据；
- 将数据格式进行转换以训练模型；
- 构建 U-Net 模型；
- 训练并测试模型。

1、数据预处理

读取数据：Nibabel 包是专门用于读取.nii 格式的医学数据，可实现读取图像、查看图像长宽高、图像进行仿射变换等功能。读取的数据包含 4 个部分，分别是原图(ct_scan)、肺部标签图(lung_mask)、感染标签图(infection_mask)和肺和感染标签图(lung_and_infection_mask)，如图 11-16 所示：




图 11-16 a.原图、b.肺部标签图、c.感染标签图、d.肺和感染标签图

数据格式转换：使用 `astype` 函数将元数据类型转换为 `uint8`，最后输出图像矩阵形式。该案例最后将进行训练的数据均为 128×128 大小的 `jpg` 格式图片。

2、分割模型构建

本案例用 `U-Net` 作为模型的主干网络，`U-Net` 是一种卷积神经网络，主要用于生物学医学图像分割，在前面的章节已经有介绍过，这里不在赘述。该案例中对其架构进行了改进和扩展，以处理更少的训练图像，并产生、更精确的分割。其主要思想是用连续的层来补充通常的收缩网络，其中集中操作被上采样操作取代，因而提高了输出的分辨率。该网络只使用每个卷积的有效部分，没有任何全连接层。模型结构如下图所示。

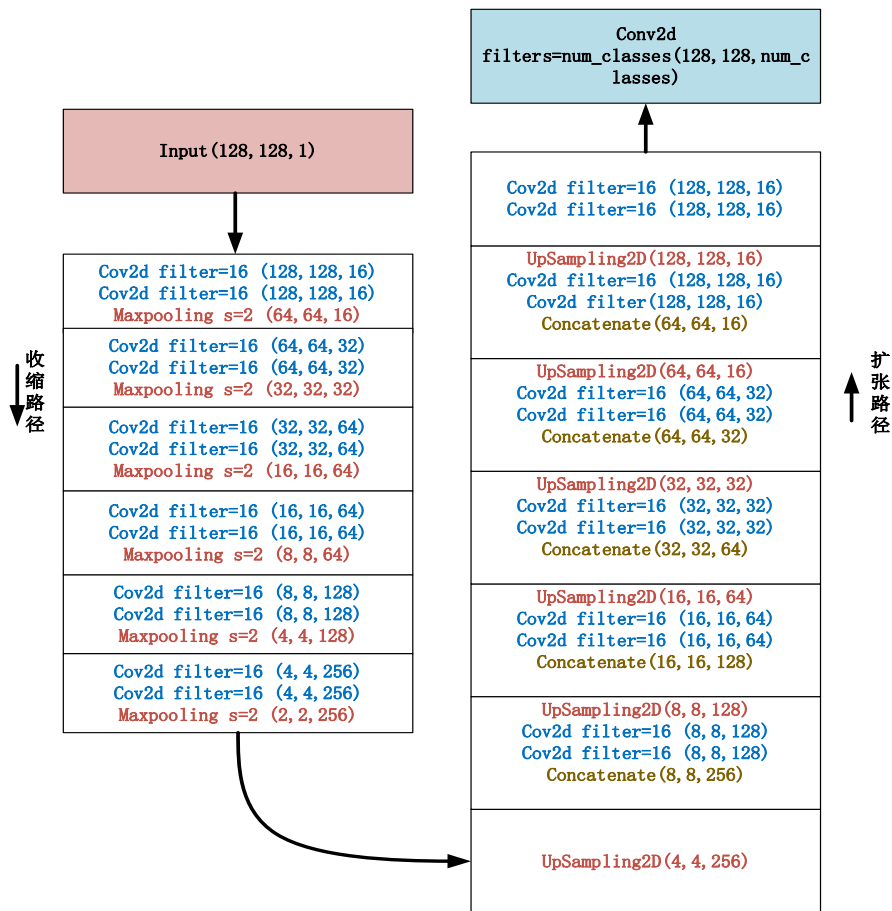


图 11-17 模型结构图

构建好模型后，对所有的输入图像的像素都除以 255，使得最后的像素值范围为 (0,1)。将数据集以 9:1 划分训练集和测试集。训练的 epoch 可以根据自己的实现过程根据 loss 进行调整。

3、测试模型

训练好网络之后，之后就是用测试集去测试我们的模型，通过设置评价指标来进行模型评估。在医学图像分割中常用的评价指标包括召回率、Dice 系数、精确率、豪斯多夫距离以及均交并比等，本次案例使用的是精确率。下图是训练过程中迭代数与精确率的关系。




图 11-18 精确率与迭代次数关系

这里训练的仅仅是一个基础网络，读者可以根据自己的能力对网络进行改进，从而实现得到更好的分割结果。图 11-19 是模型测试结果可视化，通过测试我们训练的模型，可以发现，能够实现较为理想的感染部位分割。




图 11-19 测试结果: (a) 肺部原图; (b)感染原图; (c) 预测分割结果

本案例仍存在不足之处，为了达到更好的分割效果，读者可以根据以下建议对该案例进行改进：

- (1) 扩增数据集。基于深度学习的模型极度的依赖数据量，更大的数据量能提高模型的泛华能力，防止过拟合。
- (2) 修改参数。修改 epoch 数或更换损失函数、激活函数等，并不一定会使得实验结果更好，可以作为改进参考方案。

(3)改进模型。更换模型的主干网络，比如用 ResNet、VGG 等；或者引入优化模块，比如特征金字塔池化、注意力机制以及扩张卷积等。

案例 3、基于卷积神经网络的胸透病理识别

胸部 x 光是筛查和诊断许多胸、肺部疾病最常见的放射学检查之一。许多现代医院的医疗影像存储与传输系统(Picture Archiving and Communication system, PACS)中积累和存储了大量的 x 射线影像学研究和放射学报告。如何能够促进需要大量数据的深度学习模式，以构建真正大规模的高精度计算机辅助诊断(computer aided diagnosis, CAD)系统，仍然是一个悬而未决的问题。

在本案例中，我们提出了基于卷积神经网络的胸透病理识别方法。主要采用 Python 作为编程语言，构建基于 DCNN 的胸透病理识别分类器。对常见的 8 种疾病，包括：肺不张 (Atelectasis)、心脏肥大 (Cardiomegaly)、积液 (Effusion)、浸润 (Infiltrate)、肿块 (Mass)、结节 (Nodule)、肺炎 (Pneumonia) 和气胸 (Pneumothorax) 进行分类识别。实验环境规定如下：在 64 位的 Windows10 系统下，结合 Caffe 框架实现该网络模型。采用的数据集是美国国立卫生研究院发布一个新的胸片数据库“ChestX-ray8”，它包含了 32,717 名独特患者的 108,948 张正面 x 光图像，这些图像使用自然语言处理从相关的放射学报告中提取了 8 个疾病图像标签(其中每个图像可以有多个标签，如图 11-20 所示)。

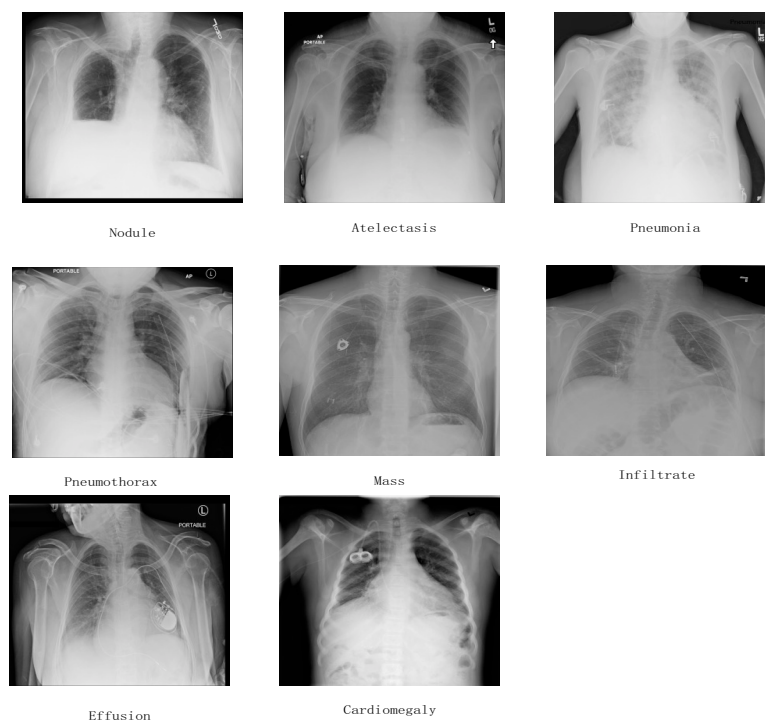


图 11-20 八种肺部病理

胸透 X 光作为放射学中最常见的检查，是检测和可视化身体器官异常的有效诊断工具，全球每天都有大量的人肺部患病和死亡，需要对大量患者进行肺部检测，胸透 X 光是诊断相关问题的有效成像技术。深度学习技术提供了强大的分析能力来研究大量胸透 X 光图像。这对开发 CAD 系统、协助临床医生做出正确的判断有重要意义。

1、数据准备

本案例使用所提出的 ChestX-ray8 数据库，评估和验证统一的疾病分类和定位框架。数据库中总共有 108,948 张正面 x 光图像，其中 24,636 张图像包含一种或多种病理。其余 84,312 张图片为正常病例。对于病理分类和定位任务，我们将整个数据集随机分为三个子组，通过随机梯度下降(SGD)进行 CNN 微调:即训练(70%)、验证(10%)和测试(20%)。

2、分类识别模型构建

本案例的目标是首先检测每个 X 光图像中是否存在一个或多个病理，然后使用从网络中提取的激活和权重来定位它们。通过训练弱监督多标签分类模型来解决这个问题。

首先搭建基 DCNN 的弱监督胸透病理识别模型，模型框架包括多标签设置、转换层以及多标签分类损失层。其中多标签设置通过采用长度为 8 的向量表示，比如 $[0,0,0,0,0,0,0,0]$ 表示正常、 $[1,0,0,0,0,0,0,0]$ 表示换第一种病、 $[1,0,1,0,0,0,0,0]$ 表示同时患有第一和第三种病。转换层主要是将前几层的激活转换为统一维度的输出，由于预训练 DCNN 体系结构种类繁多，转换层有助于将预先训练的 DCNN 模型的权重以标准形式传递下来，这对于在病理定位步骤中使用该层的激活来进一步生成热图至关重要。多标签分类损失层通过引入正、负平衡因子来加强正例的学习，克服标签稀疏的问题。弱监督病理定位主要通过全局池层、预测层和边界框实现。在多标签图像分类模型中，全局池和预测层不仅被设计为用于分类的 DCNN 的一部分，而且被设计为生成病理的似然图，即热图。热图中具有峰值的位置通常对应于高概率的疾病模式的存在。边界框能通过热图对一个特定胸部疾病类别的大致空间位置定位。模型实现的总体框架如图 11-21 所示。

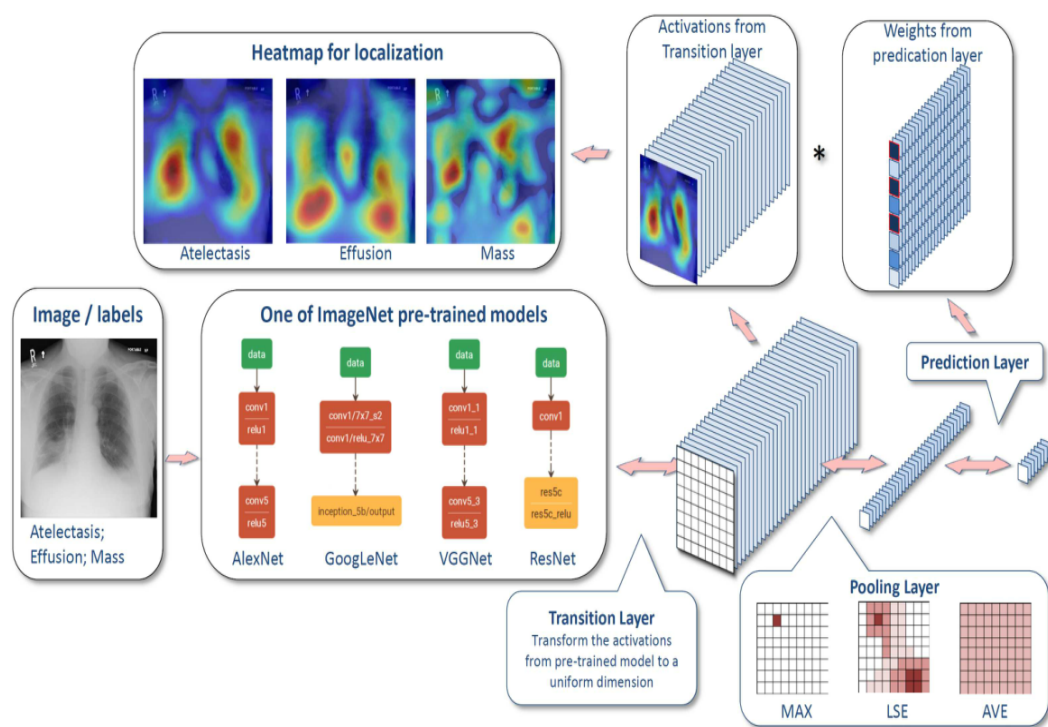


图 11-21 实验框架图

3、测试模型

通过测试，模型能很好的对病理实现定位和分类。目前，构建真正大规模、全自动的高精度医疗诊断系统仍然是一项艰巨的任务。ChestX-ray8 数据库可以使渴望数据的深度神经网络范例创建具有临床意义的应用。

11.3 金融大数据

大数据应用涉及各个方面，医疗领域利用机器学习及时诊断和预测病情，农业生产领域基于人工智能的病害虫防护系统得到推广，金融领域银行采用营销策略及时向客户推送广告信息和推荐顾客肯感兴趣的产品和优惠信息，这些应用都体现了大数据无处不在，我们的生活离不开大数据。前面两节分别介绍了大数据在天文和医疗方面的应用，本节主要介绍大数据在金融领域的应用。

11.3.1 金融大数据概述

金融大数据是指运用大数据技术和大数据平台开展金融活动和进行金融服务而产生的大数据，金融大数据对金融行业积累的大数据以及外部数据进行云计算等信息化处理，结合传统金融，开展资金融通、创新金融服务。根据金融行业的分类，可以将大数据金融细分为大数据银行、大数据证券和大数据保险三个应用场景。

金融大数据在银行的应用场景，比较典型的银行的大数据应用场景集中在数据库营销、用户经营、数据风控、产品设计和决策支持等。目前来讲，大数据在银行的商业应用还是以其自身的交易数据和客户数据为主，外部数据为辅，以数据分析为主，预测性数据建模为辅，以经营客户为主，经营产品为辅，银行大数据主要应用在客户画像、精准营销、风险管控、运营优化四大方面。

金融大数据在证券行业上的应用，证券行业的主要收入来源于经纪业务、资产管理、投融资服务和私募基金投资等。外部数据的分析，特别是行业数据的分析有助于其投融资服务和投资业务，证券行业的

大数据应用主要是通过数据挖掘和分析找到高频交易客户、资产较高的客户和理财客户，借助于数据分析的结果，证券公司就可以根据客户的特点进行精准营销推荐针对性服务，就目前来看国内证券行业的大数据应用主要用来进行股价预测，客户关系管理和投资景气指数预测。

金融大数据在保险行业的应用，由于保险行业主要通过保险代理人 与保险客户进行连接，对客户的基本信息和需求掌握很少，因此极端依赖外部保险代理人 和渠道（银行）。在竞争不激烈的情况下，这种连接客户的方式是可行的，保险行业的产品是一个周期性产品，保险客户再次购买保险产品的转化率何老，所以经营好老客户是保险公司的一项重要任务，保险公司的数据主要集中在产品系统和交易系统之中，利用客户行为来制定车险价格，利用客户外部行为数据来了解客户需求向目标用户推荐合适保险产品。

金融大数据来源有多个渠道，其中主要的数据来源如下图：

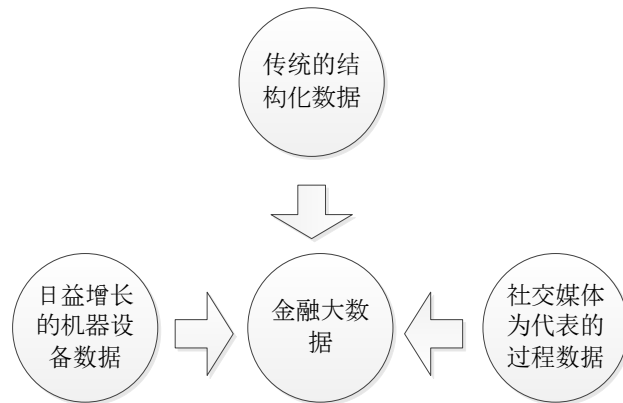


图 11-22 金融大数据来源

金融大数据的来源主要可分为三类：

- (1) 传统的结构化数据：如各种数据库和文件信息等。
- (2) 社交媒体为代表的过程数据：数据如用户偏好、习惯、特点、发表的言论、朋友圈之间的关系等。
- (3) 日益增长的机器设备以及传感器所产生的数据，例如柜面监控视频、呼叫中心语音手机和 ATM 等记录的位置信息等。

目前，随着人工智能的发展，国内不少银行已经开始尝试通过大数据驱动业务运营，如中信银行使用大数据技术实现了实时营销，光大银行建立了社交网络信息数据库，招商银行则利用大数据发展小微贷款等。在大数据时代，各金融企业充分利用大数据带来的发展机遇并取得了高效的收益。建设银行、农业银行等采用面部识别、指纹识别登录 APP 也属于大数据的简单应用。

相比于传统金融数据，大数据金融以大数据云计算为基础，以大数据自动计算为主，不需要大量人工，运营成本较低，并且可以实时精准营销个性化服务，充分体现了大数据为我们生活带来的便利。大数据金融的价值非常大，它为银行业、金融业的发展奠定了强大的基础支撑。

从金融应用层面出发，我们列举了一部分大数据金融带来的价值。金融大数据的主要价值分析如表 11-3。

表 11-3 金融大数据价值

销售机会增多	金融企业掌握海量数据，结合用户搜索行为、交易行为等洞察消费者需求进而有针对性对产品进行生产、改进和营销。
客户服务改善	在客户体验方面，通过对交易数据、多渠道交互数据等的全面分析，帮助企业真正了解客户需求，并预测客户未来行为；在客户情感分析方面，通过对客服中心、社交媒体等数据的文本分析、语音分析，改进并优化客户服务。
客户流失预警	分析用户在整个相关产品里的使用行为的数据，识别可能流失的客户以及可能导致客户放弃的原因，如客户对产品不满意以便企业进行有效改进。
运营效率提升	从销售、业务流程、资金需求预测方面提高运营效率。
金融产品创新	高端数据分析系统和综合化数据分享平台能够有效地对接银行、保险、证券等金融产品，使金融企业能够从其他

	领域借鉴并创造出新的金融产品。
商业模式创新	通过对人体的心率、体重、血脂、血糖等数据分析，预测客户的健康指数，帮助人身保险公司提高客户识别率，制定个性化的费率和承保方案。
风险管控加强	通过对最底层交易数据的全面甄别和分析，使企业能够提高风险透明度，实现事前预警事中控制。

11.3.2 金融大数据目标及挑战

为了顺应大数据时代的发展，金融大数据的应用得到了普及，为各金融企业带来了高效的利益。金融大数据的目标主要是，个性化推荐即就是银行根据客户的喜欢进行服务或者银行产品的个性化推荐，对客户群进行精准定位分析其潜在金融服务需求，进而有针对性的营销推广；实时营销，金融企业根据客户的实时状态进行营销、客户生命周期管理即为了保证金融企业的运行需要进行新客户获取、客户防流失和客户赢回，金融大数据可以高效解决这些问题。

但是要对海量数据进行获取、分析和处理并不是一件简单的事，在这过程中会遇到一些挑战：

1、银行拥有的客户信息不全面。了解客户信息不仅要考虑银行业务所采集到的信息，更应考虑整合外部更多的数据以扩展对客户了解，这就需要银行在数据采集上采取措施以获得广泛的数据源。

2、大数据金融信息安全问题。在大数据产业呈现爆炸式增长的同时，其大数据信息安全水平却呈现非对称发展，现在金融信息化已全面进入信息安全管理阶段，对计算机信息系统有着高度的依赖性，使得进入信息安全面临多方面的威胁，包括大数据集群数据库的数据安全威胁、智能终端的数据安全威胁以及数据虚拟化带来的泄密威胁。

3、改进金融行业的控制手段。在大数据时代背景下金融行业若要提高自身管理水平，那么就务必要改进数据挖掘手段。一方面，金融行业可利用各种数据挖掘软件、计算机技术、网络技术等信息化

管理的各个业务环节，以便能够对金融业务情况的动态信息进行准确掌握，这样一来，无疑有利于更好地提高金融行业的管理水平。另一方面，金融机构管理人员可应用人工智能技术来对比分析形成价值链中的各个作业环节、各个部门的成本支出情况，进一步细分每项价值增值活动，最大限度地减少成本支出。与此同时，还应该对金融行业的各个环节等都要加大数据挖掘方法的利用，可结合自身实际情况来建立数据挖掘手段应用反馈与评价机制，若数据挖掘手段出现问题，那么在第一时间内及时反馈、按时整改，并且还要评价数据挖掘成效，做到有功则奖、有过则罚。此外，金融机构管理人员还可以利用大数据技术来综合分析当前管理情况，以此来获取全面而具体的信息，便于及时发现问题、评估问题、分析问题、解决问题，将隐患控制在“萌芽状态”，能够为金融机构管理层的重大决策提供了准确的参考，促使金融机构实现稳定、有序、高效发展。值得注意的是，金融机构还要注意选择先进、科学的大数据挖掘方法，并且将其运用到实际的工作之中，以此来达到控制目标。

总的来说，大数据在金融行业越来越得到广泛的应用，给各金融企业反击的机遇，各基于大数据分析的软件平台顺应趋势，为金融机构提供量身定制的大数据分析服务，以此帮助金融机构应对未来挑战。

11.3.3 金融大数据理论及技术

金融大数据技术的产生集合了数据收集、数学建模和其他方法来有效控制和管理。由于使用了大数据和云计算等新技术，在金融行业建立云数据平台将大大降低金融机构的运营成本。因此，金融行业区块链的技术将持续严格控制数据安全，面向数据存储的创新应用模型将为金融业提供更大空间。

技术起到对业务的支撑作用，在金融领域，大数据相关技术的采用主要有五个处理流程，相关技术主要在这五个流程中体现：

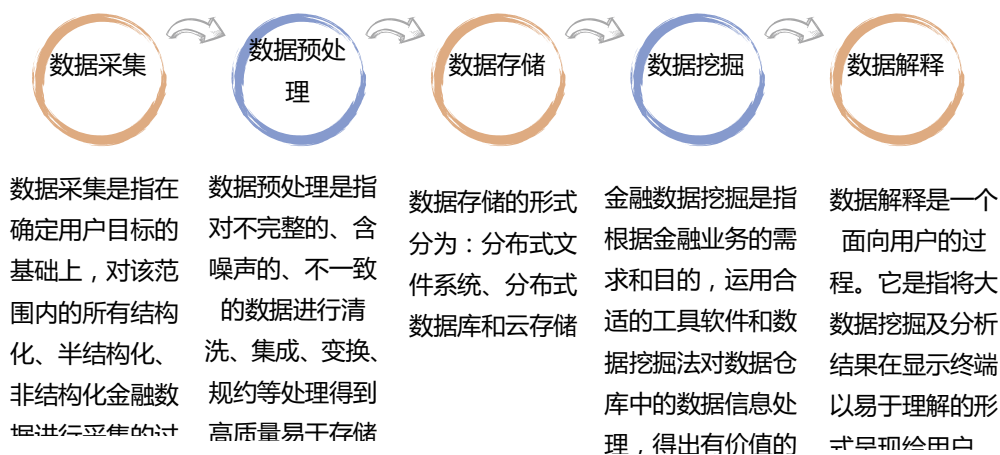


图 11-23 金融大数据处理流程

数据采集：数据采集是对金融大数据的获取过程，数据采集的方式主要有以下三个：

(1) 系统日志采集：从各种日志源上收集日志存储到一个中央存储系统中，以便于后期知道找谁解决问题，定位解决问题，了解客户需求进行个性化营销。

(2) 网络数据采集：网络数据采集是指利用互联网搜索引擎技术从网站抓取数据信息,为了高效地获取有用信息一般可进行 Python 爬虫获取或者利用工具八爪鱼、火车采集器、搜集客不用编写代码即可快速进行网页数据的获取。

(3) 开源数据源：直接使用互联网上的开源数据源

数据存储：数据存储的方式主要包含分布式文件系统、分布式数据库和云储存几种。

(1) 分布式文件系统：分布式文件系统指文件系统管理的物理存储资源不一定直接连接在本地节点上，而是通过计算机网络与节点相连，众多的节点组成一个文件系统网络，众多的节点可以分布在不同的地点，通过网络进行节点间的通信和数据传输。HDFS 是 Hadoop 分布式文件系统，具有高容错性的特点。

(2) 分布式数据库：利用网络将物理上分布的多个数据存储单元连接起来组成的逻辑数据库称为分布式数据库。基本思想是将集中式

数据库中的数据，分散存储到多个数据存储节点上，并通过网络节点连接起来，以获取更大的存储容量和更高的并发访问量。分布式数据库具有高扩展性、高并发性、高可用性以及更高的数据访问速度。

(3) 云存储：云存储是一种以数据存储管理为核心的云计算系统，它是指通过集群应用、网络技术和分布式文件系统等功能，将网络中大量各种不同类型的存储设备通过应用软件集合起来协同工作，共同对外提供具有数据存储和业务访问功能的一个系统。云存储方式具有高安全性和节约存储空间的优点。

数据挖掘：数据挖掘部分可以说是金融数据处理流程的关键部分，该部分涉及十大算法。分类算法，其中含有六大算法 C45、贝叶斯、SUM、KNN、Adaboost、CART；聚类算法，含有 K-Means、EM；关联分析，含有 Apriori；连接分析，含有 PageRank。该部分通过算法分析采集到的金融数据得到有用信息，列如张某近五年购买的保险业务以及其关注保险信息的行为。向量和矩阵被用在数据挖掘中，比如我们常把对象（列如图像）抽象为矩阵，计算特征值和特征向量，用特征向量来近似代表物体的特征，这是大数据降维的基本思路。

在数据挖掘分类算法中，比较经典的是贝叶斯算法。贝叶斯算法一般指的是朴素贝叶斯算法。假设我们把每个样本数据用 n 维特征向量来描述 n 个属性的值，即： $X=\{x_1, x_2, \dots, x_n\}$ ，假定总共有 m 个类，分别用 C_1, C_2, \dots, C_m 表示。给定一个未知的数据样本 X (属于未知分类)，使用朴素贝叶斯分类法，如果要将在未知的样本 X 分配给某个类 C_i ，则一定满足下列等式：

$$P(C_i | X) > P(C_j | X) \quad \text{式中, } 1 \leq j \leq m, j \neq i \quad (11-10)$$

根据贝叶斯定理，由于 $P(X)$ 对于所有类为常数，最大化后验概率 $P(C_i | X)$ 可转化为最大化先验概率 $P(X | C_i)P(C_i)$ 。如果训练数据集有许多属性和元组，计算 $P(X | C_i)$ 的开销可能非常大，为此，通常假设各属性的取值互相独立，这样先验概率 $P(x_1 | C_i), P(x_2 | C_i), \dots, P(x_n | C_i)$

可以从训练数据集求得。根据此方法，对一个未知类别的样本 X ，可以先分别计算出 X 属于每一个类别 C_i 的概率 $P(X|C_i)P(C_i)$ ，然后选择其中概率最大的类别作为其类别。

朴素贝叶斯算法成立的前提是各属性之间互相独立。当数据集满足这种独立性假设时，分类的准确度较高，否则可能较低。另外，朴素贝叶斯算法没有具体分类规则输出，这是该算法的一个不足。

数据挖掘中比较常用的聚类算法是 **k-means** 算法。它是一种简单的迭代型聚类算法，采用欧式距离作为相似性检测指标，从而发现挖掘数据中的 K 个分类，且每个类的中心是根据类中所有值的均值得到，每个类用聚类中心来描述。对于给定的一个包含 n 个 d 维数据点的数据集 X 以及要分得的类别 K ，选取欧式距离作为相似度指标，聚类目标是使得各类的聚类平方和最小，即最小化：

$$J = \sum_{k=1}^k \sum_{i=1}^n \|x_i - u_k\|^2 \quad (11-11)$$

结合最小二乘法和拉格朗日原理，聚类中心为对应类别中各数据点的平均值，同时为了使得算法收敛，在迭代过程中，应使最终的聚类中心尽可能的不变。

数据解释：利用可视化技术、人机交互、数据起源等新的方法将结果展示给用户。其中数据可视化的过程主要通过图形化方法进行清晰、有效的数据传递，比如 Python 中的 **matplotlib** 和 **seaborn** 具有强大的图表功能，它提供了许多特殊的金融图表，可用于可视化历史股价数据或者金融数据。基本思想是使用单个图元元素表示数据库中的每一个数据项，大量的数据集组成数据图像，并以多维数据的形式表示数据的各个属性值。人机交互的过程主要是通过系统输入、输出设备，以有效的方式实现人与系统之间信息交换的技术。其中，系统可以是各类机器、计算机和软件。用户界面或人机界面是人机交互所依托的介质和对话接口，通常包括硬件和软件系统。人机交互技术是一种双向的信息传递过程，既可以由用户向系统输入信息，也可以由系

统向用户反馈信息。

11.3.4 应用实例

大数据在金融方面应用非常广泛。在处理庞大数据时，Python常常是作为大数据信息处理的首选工具。Python 凭借其简单、易读、可扩展性以及拥有巨大而活跃的科学计算社区，在需要分析、处理大量数据的金融行业方面得到了广泛而迅速的应用，并且成为该行业开发核心应用的首选编程语言。同时，本书上一章提到的 TensorFlow 是非常重要的深度学习大数据模型框架。此部分提供了一个深度学习与大数据金融相结合的学习案例，它使用 TensorFlow 框架来预测股票价格数据，供读者学习。股票价格是典型的时间序列，会受到经济环境、政府政策、认为操作等多种复杂因素的影响，基于历史数据会呈现一定的趋势，所以我们利用人工智能技术对此进行预测分析具有一定的实用性，在金融行业取得了一定的发展成果。

案例 1、使用 TensorFlow 框架预测股票价格数据

在实际工作中，金融工作者常常需要预测股票数据。本案例主要采用 Python 作为编程语言，借助深度学习框架 TensorFlow 搭建简单神经网络对 500 支股票进行处理并预测价格，有一定的参考价值。模型训练数据自来源于 <http://files.statworx.com/sp500.zip>。本案例主要为了建立一个完整的 TensorFlow 深度学习框架模型，不对效率、输出结果等进行更精确的要求。

在该案例中，实现步骤可大概分为六个阶段，一般深度学习也都分为这六个步骤。

- (1) 实验准备阶段，下载实验所需要的第三方库
- (2) 加载和初步清洗数据集
- (3) 设置模型参数，使得数据集可迭代，因为我们在深度学习中训练数据是按批次进行的，我们需要利用设置合适的 batch 和合适的

批次 epoch

- (4) 设置网络模型,该模型采用整流线性单元(ReLU)激活函数
- (5) 定义损失函数和优化器
- (6) 训练模型

以下是详细实现过程:

1.准备阶段导入库和数据

`import pandas as pd` #pandas 库主要作用是及时进行数据清洗和整理,
`numpy` 库用于数组计算具有强大的计能力

```
import numpy as np
import tensorflow as tf
tf.disable_v2_behavior()
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
import time
```

2.数据处理

```
# 读取数据集
data=pd.read_csv('data_stocks.csv')
# 数据清洗, 去掉无用的列
data.drop('DATE',axis=1,inplace=True)
# 划分训练集和测试集
data_train = data.iloc[:int(data.shape[0] * 0.7), :]
data_test = data.iloc[int(data.shape[0] * 0.3):, :]
# 数据归一化处理
scaler = MinMaxScaler(feature_range=(-1, 1))
scaler.fit(data_train)
data_train = scaler.transform(data_train)
```

```
data_test = scaler.transform(data_test)
```

在数据加载处理中，我们需要将数据集分为训练和测试数据，分配为 **7:3**,即数据集中 **70%**为训练集，**30%**为测试数据集。

3.设置模型相关参数

```
# 设置 X 值和 Y 值
```

```
X_train = data_train[:, 1:]
```

```
y_train = data_train[:, 0]
```

```
X_test = data_test[:, 1:]
```

```
y_test = data_test[:, 0]
```

```
# 设置超参数
```

```
input_dim = X_train.shape[1] #输入数据维度
```

```
output_dim = 1 #输出数据维度
```

```
hidden_1 = 1024
```

```
hidden_2 = 512
```

```
hidden_3 = 256
```

```
hidden_4 = 128
```

```
hidden_5 = 128
```

```
batch_size = 256 # 训练批次大小
```

```
epochs = 15 # 训练轮数
```

注意超参数设置是为了设置输入数据和输出数据的维度、隐藏层的层数和训练批次以及训练轮数，一般情况下超参数的设置在开始学习过程之前，而不是通过训练得到的参数数据。通常情况下，需要对超参数进行优化，以选择一组最优超参数，以提高模型的性能和效果。

```
tf.reset_default_graph()
```

```
# 设置占位符
```

```
X = tf.placeholder(shape=[None, input_dim], dtype=tf.float32)
```

```
Y = tf.placeholder(shape=[None], dtype=tf.float32)
```

4、设置网络模型

```
# 设置网络层
```

```
#W1=tf.get_variable('W1',[input_dim,hidden_1],initializer=tf.contrib.layers.xavier_initializer(seed=1))
```

```
W1=tf.get_variable('W1',[input_dim,hidden_1],initializer=tf.truncated_normal_initializer(stddev=0.1))
```

```
b1=tf.get_variable('b1',[hidden_1],initializer=tf.zeros_initializer())
```

```
W2=tf.get_variable('W2',[hidden_1,hidden_2],initializer=tf.truncated_normal_initializer(stddev=0.1))
```

```
b2=tf.get_variable('b2',[hidden_2],initializer=tf.zeros_initializer())
```

```
W3=tf.get_variable('W3',[hidden_2,hidden_3],initializer=tf.truncated_normal_initializer(stddev=0.1))
```

```
b3=tf.get_variable('b3',[hidden_3],initializer=tf.zeros_initializer())
```

```
W4=tf.get_variable('W4',[hidden_3,hidden_4],initializer=tf.truncated_normal_initializer(stddev=0.1))
```

```
b4=tf.get_variable('b4',[hidden_4],initializer=tf.zeros_initializer())
```

```
W5=tf.get_variable('W5',[hidden_4,hidden_5],initializer=tf.truncated_normal_initializer(stddev=0.1))
```

```
b5=tf.get_variable('b5',[hidden_5],initializer=tf.zeros_initializer())
```

```
W6=tf.get_variable('W6',[hidden_5,output_dim],initializer=tf.truncated_normal_initializer(stddev=0.1))
```

```
b6=tf.get_variable('b6',[output_dim],initializer=tf.zeros_initializer())
```

```
# 激活函数，网络的隐藏层需要被激活函数激活
```

```
h1 = tf.nn.relu(tf.add(tf.matmul(X, W1), b1))
```

```
h2 = tf.nn.relu(tf.add(tf.matmul(h1, W2), b2))
h3 = tf.nn.relu(tf.add(tf.matmul(h2, W3), b3))
h4 = tf.nn.relu(tf.add(tf.matmul(h3, W4), b4))
h5 = tf.nn.relu(tf.add(tf.matmul(h4, W5), b5))
out = tf.transpose(tf.add(tf.matmul(h5, W6), b6))
```

5. 定义损失函数和优化器

```
# 损失函数
loss = tf.reduce_mean(tf.squared_difference(out, Y))
# 定义优化器
optimizer = tf.train.AdamOptimizer().minimize(loss)
```

6. 模型实现

```
with tf.Session() as sess:
```

```
# 初始化所有变量
    sess.run(tf.global_variables_initializer())
    for e in range(epochs):
        # 随机取出数据
        shuffle_indices = np.random.permutation(np.arange(y_train.shape[0]))
        X_train = X_train[shuffle_indices]
        y_train = y_train[shuffle_indices]

        for i in range(y_train.shape[0] // batch_size):
            start = i * batch_size
            batch_x = X_train[start : start + batch_size]
            batch_y = y_train[start : start + batch_size]
            sess.run(optimizer, feed_dict={X: batch_x, Y: batch_y})
```

```
if i % 50 == 0:
    print('MSE Train:', sess.run(loss, feed_dict={X: X_train, Y:
y_train}))

    print('MSE Test:', sess.run(loss, feed_dict={X: X_test, Y: y_test}))
    y_pred = sess.run(out, feed_dict={X: X_test})
    y_pred = np.squeeze(y_pred)
    # 这里务必设置画布大小，否则会出现图像重
叠的情况

    plt.figure(figsize=(16, 12))
    plt.plot(y_test, label='test')
    plt.plot(y_pred, label='pred')
    plt.title('Epoch ' + str(e) + ', Batch ' + str(i))
    plt.legend()
    # 这里不采用 plt.show 方法，直接导出到文件中
    filepath='output/'+str(e)+'_'+str(i)+'.jpg'
    plt.savefig(filepath)
    plt.plot(data['SP500'])
```

训练结果：

MSE Train: 0.00031331243



图 11-24 误差曲线(蓝色表示测试数据、橙色表示预测结果)

根据图 11-24 的测试结果表明当损失函数大约为 0.0003 时测试结果较好，我们的预测数据接近于测试数据，具有可行性。该模型可以用于预测金融行业股票价格波动趋势。

11.4 本章小结

本章主要从深度学习在天文大数据、医疗大数据和金融大数据三方面应用展开介绍。以实际案例进行分析，阐述大数据在各个领域上的应用。金融大数据应用中介绍了 TensorFlow 框架预测股票价格数据案例。大数据的应用远不止医疗、天文、金融这几方面，它几乎包含了我们工作、学习、生活中的一切应用。本书介绍以上三个典型应用主要为了让读者理解大数据的应用场景和实际案例。

参考文献

- [1] <https://wiki.cancerimagingarchive.net/display/Public/LIDC-IDRI>
- [2] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri and R. M. Summers, "ChestX-Ray8: Hospital-Scale Chest X-Ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases," 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, pp. 3462-3471, doi: 10.1109/CVPR.2017.369.
- [3] Zhou S, Zhang X, Zhang R. Identifying Cardiomegaly in ChestX-ray8 Using

- Transfer Learning. *Stud Health Technol Inform.* 2019 Aug 21;264:482-486. doi: 10.3233/SHTI190268. PMID: 31437970.
- [4] A.A.A rdakani, U.R.A charya, Sheldon horowitz abibollahi, arjun ohammad, Helen.COVIDiag: A clinical computer-aided diagnosis (CAD) system for COVID-19 diagnosis based on CT images [J].*International Journal of Medical Radiology*, 201,44(02):239-240.
- [5] Wang, Xiaosong, et al. "Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases." *Proceedings of the IEEE conference on computer vision and pattern recognition.* 2017.
- [6] 钱维扬,王俊义,仇洪冰.基于Hadoop的数据挖掘技术在测光红移上的研究[J]. *电子技术应用*, 2016, 42(09):111-114.DOI: 10.16157/j.issn.0258-7998.20111-09.029.
- [7] YORK D G,ADELMAN J,ANDERSON J E,et al.The Sloan digital sky survey:Technical summary[J]. *Astron. J.*,2000,120(3) :338-347.
- [8] FEVRE L, VETTOLANI G, MACCAGNI D, et al. VirmosVLT deep survey [C]. *Astronomical Telescopes & Instrumentation*, 2003,4834: 173-182.
- [9] CAPACCIOLI M,ARNABOLDI M,MANCIN D,et al.The VST-VLT survey telescope[C]. *Instrumentation and Measurement Technology Conference*,1999,2 :7711-781.
- [10] Zhang, L., Zhang, M., Liu, X. The adaptive-loop-gain adaptive-scale CLEAN deconvolution of radio interferometric images. *Astrophysics and Space Science*, 2016, 361(153):1-11-
- [11] Zhang, L., Bhatnagar, S., Rau, U., Zhang, M. Efficient implementation of the adaptive scale pixel decompositioin algorithm. *Astronomy & Astrophysics*, 2016, 592, (A128):1-5.
- [12] Zhang, L. Fused CLEAN deconvolution for compact and diffuse emission.

- Astronomy & Astrophysics, 2018, 618(A117):1-11-
- [13] 卫星奇, 张利, 吴康宁, 卢梅, 王蓓, 贺春林, 潘伟. 基于深度学习的低频 SKA 带宽涂污效应矫正方法. 软件工程与应用, 2022, 11(1):72-80.
- [14] 王丹, 张彦霞, 赵永恒, 等. 测光红移算法概述[J]. 天文学进展, 2008, 26(3) : 2611-277.
- [15] 卢梅, 张利, 李丹宁, 米立功, 刘祥, 张明, 贺春林, 潘伟, 王蓓. 基于深度学习的 SKA 图像反卷积研究. 应用数学进展, 2022, 11(2):613-620.
- [16] 宋烜, 韩冀中, 王凯, 高建. 用 MapReduce 实现天文星表交叉认证[J]. 计算机应用研究, 2010, 27(10):3740-3743.
- [17] 唐远志, 张利, 王旭, 肖一凡, 陈丽绵, 冉文兵. 低频 SKA 极化探究 I: 极化效应对 EoR 信号的影响. 应用物理, 2022, 12(1):35-45.
- [18] Zhang, L., Mi, L. G., Zhang, M., Liu, X., He, C. L. Adaptive-scale wide-field reconstruction for radio synthesis imaging. Astronomy & Astrophysics, 2020, 640(A80):1-10.
- [19] Zhang, L., Xu, L., Zhang, M. Parameterized CLEAN Deconvolution in Radio Synthesis Imaging. Publications of the Astronomical Society of the Pacific, 2020, 132(1010):1-13.
- [20] Zhang, L., Mi, L.G., Zhang, M., Liu, X., Xu, L., Wang, F., Ruan, Y.J., Li, D.Y. Parameterized Reconstruction with Random Scales for Radio Synthesis Imaging. Astronomy & Astrophysics, 2021, 646(A44):1-11-
- [21] ZHAO Qing, SUN Ji-zhou, YU Ce, et al. A paralleled large-scale astronomical cross-matching function [C] // Proc of Lecture Notes in Computer Science, vol 5574. 2009: 604-614.
- [22] 张利, 肖一凡, 米立功, 唐远志, 赵庆超, 卢梅, 李桂城, 卫星奇, 王蓓, 刘祥, 张明, 谢泉. 射电天文图像重建算法研究综述. 图像与信号处理, 2021, 10(1):1-10.
- [23] CGP. Report on cross matching catalogues [EB /OL] .(2003-09-29)

- [2009-12-14].[http: / /wiki.astrogrid.org /pub /Astrogrid /DataFe-derationandDataMining /cross.htm](http://wiki.astrogrid.org/pub/Astrogrid/DataFederationandDataMining/cross.htm).
- [24] POWER R.Cross match simulation[CP /OL].(2007-04-23) [2009- 12-14].[http: //www.ict.csiro.au /staff /robert.power/projects/CM/ ps/cm.htm](http://www.ict.csiro.au /staff /robert.power/projects/CM/ ps/cm.htm).
- [25] O'MALLEY O.TeraByte sort on Apache Hadoop [EB/OL] .(2008- 05) [2009-12-14] .[http: / /sortbenchmark.org /YahooHadoop. pdf](http://sortbenchmark.org /YahooHadoop. pdf).
- [26] CUTRI R M,SKRUTSKIE M F,VAN DYK S,et al.2MASS all sky catalog of point sources,the IRSA 2MASS all-sky point source cata- log,NASA/IPAC infrared science archive [EB/OL] . (2003) [2009-12-14] .<http: / /irsa.ipac.caltech.edu /applications/Gator/>.
- [27] CHURCHWELL E , BABLER B L , MEADE M R , et al.The Spitzer/GLIMPSE surveys: a new view of the milky way [J] .Publica- tions of the Astronomical Society of the Pacific, 2009, 121: 213-230.
- [28] Zhang, L., Xu, L., Zhang, M., Wu, Z.Z. An Adaptive loop gain selection for CLEAN deconvolution algorithm. Research in Astronomy and Astrophysics, 2019, 19(06):79-1~79-11-
- [29] 汪森.基于 Spark 射电干涉阵成像算法实现研究[D].昆明理工大学,2021.DOI:10.27200/d.cnki.gkmlu.2021.000780.
- [30] Zhang, L., Mi, L. G., Xu, L., Zhang, M., Li, D.Y., Liu, X., Wang, F., Xiao, Y. F., Wu, Z.Z. Adaptive Scale Model Reconstruction for Radio Synthesis Imaging. Research in Astronomy and Astrophysics, 2021, 21(3):63-1~63-11.
- [31] Zhang, L., Xu, L., Mi, L. G., Zhang, M., Liu, X., Wang, F., Ruan, Y.J., Li, D.Y. Deconvolution with hybrid parameterizations for radio emission reconstruction. Research in Astronomy and Astrophysics, 2021, 21(4):101-1~101-10.
- [32] Billade B, Flygare J, Dahlgren M, et al. A wide-band feed system for SKA band 1 covering frequencies from 350–1050 MHz[C]//2016 10th European Conference on Antennas and Propagation (EuCAP). IEEE, 2016:

1-3.

- [33] Hollitt C, Johnston-Hollitt M, Dehghan S, et al. An Overview of the SKA Science Analysis Pipeline[J]. arXiv preprint arXiv:1601.04113, 2011-1-3.
- [34] Xu L, Sun W Q, Yan Y H, et al. Solar image deconvolution by generative adversarial network[J]. Research in Astronomy and Astrophysics, 2020, 20(11): 170.
- [35] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[J]. Advances in neural information processing systems, 2014, 27.
- [36] Mirza M, Osindero S. Conditional generative adversarial nets[J]. arXiv preprint arXiv:1411.1784, 2014.

第 12 章 深度学习在三维点云技术中的应用

12.1 点云感知定义概述

点云是三维空间点集合的数据表示,已经成为三维表示中最重要的数据格式之一。根据点云数据采集设备的不同,点云由几何信息(三维几何坐标)和一系列可选的关联属性信息(如法向量、强度、颜色、反射率等)组成。作为 3D 世界的数字表示,点云通常用于描绘物体的表面并准确地反映其属性。

点云感知包括人眼感知和机器感知两大类。人眼感知是指依赖人眼视觉机理(如质量评价、显著性检测)去感知点云数据,广泛应用于数字文化遗产保护、自由视觉传播、3D 沉浸式交互等应用场景。在点云的压缩、传输、处理过程中不可避免地会引入一些失真,这些失真使得点云的视觉质量下降,进而影响人眼感知,因此研究人眼对点云的视觉感知建模可以显著提高点云系统处理点云数据的能力。机器感知是指计算机系统能够理解和处理点云数据进行感知(如分类、分割、检测、跟踪等机器任务),在自主导航、实时监测、地理信息系统、视觉分拣机器人等领域备受关注。对点云进行机器感知建模,可以采用神经网络对退化点云数据进行感知效益分数回归,以感知机器视觉效益。在机器感知建模指导下,可以促使保留更多适用于下游机器任务的信息,得到更有利于视觉任务的点云数据。

点云压缩是实现高效存储和传输点云数据的关键课题。点云庞大的数据量给存储设备和通信网络带来了沉重的负担,阻碍了其进一步的应用。具体而言,典型的体素化点云序列(30 秒,每秒 60 帧,10 位深度和每帧 500,000 个点)的几何信息在没有任何压缩的情况下花费大约 3.14GB 的存储空间。如果考虑属性信息,比如 8 位深度的颜色信息,数据量将达到 5.66GB 左右。这使得点云的广泛应用变得不切实际,因此有效的点云压缩方法是必要的。点云压缩的目标是减少点云数据的存储和传输开销,同时保留重要的几何和语义信息,以便

后续的感知任务可以正确处理点云数据。压缩点云数据可以降低传感器数据的带宽需求，提高点云系统的实时性能。此外，深度学习的发展为点云压缩领域带了更进一步的契机，深度神经网络强大的学习能力与压缩中所需要的隐式学习不谋而合。在近年的研究中，基于深度学习的点云压缩方法成为主流，且有部分基于深度学习点云压缩方法的率失真性能和峰值信噪比质量已经超过了非深度的点云压缩方法。因此，深度点云学习方法是未来点云压缩的发展趋势。

点云增强是近年来点云智能系统的重要组成部分。该技术也广泛应用于最近的 3D 视觉应用中，如自动驾驶、卫星地图等。所有这些应用都高度依赖于高质量的数据收集，但由于现实世界的复杂环境，最初收集的点云通常是原始的。这些原始数据会因为噪声和失真而阻碍决策，不能直接应用于一些下游模型，如何处理这些原始数据至关重要。点云增强被视为点云压缩的数据处理。因为许多原始点云数据包含噪声和异常值，所以首先需要对采集到的点云进行清洗和采样，清洗和采样称为点云压缩的预处理。其中，点云去噪和点云降采样技术是预处理中的重要组成部分。预处理会影响压缩性能，因为点云的划分通常取决于点云的稀疏性和分布。点云经过压缩和传输后，需要根据相应的下游任务进行进一步处理。我们将其称为点云压缩的后处理。后处理也是必要的，因为它可以解决经典点云智能系统中的两个问题。第一个问题是现有的压缩方法无法直接面对下游任务，它们无法知道哪些点是真正关键的。第二个问题是解码后的一些几何信息和属性信息很容易丢失和失真，这可能是由量化和数据传输引起的。这两个问题目前都没有得到很好的解决，因此后处理是桥接压缩到下游任务的合理解决方案。后处理主要包括上采样、帧插值、补全和压缩伪影去除。预处理和后处理所利用的具体技术是点云增强。

12.2 点云感知建模

12.2.1 质量评价概述

在视觉领域中,点云感知质量通常用于描述点云系统捕获、处理、存储、压缩、传输和显示点云信号的准确程度。点云质量评价是指通过设计主观实验或客观模型以评估点云系统维持点云质量的能力。点云质量评价在点云相关系统的设计中有重要的作用。其可以指导处理和显示点云的系统的设计和性能评估。比如,点云显示系统可以参考质量评价得到的质量分数来确定合适的可视化方案。随着多媒体技术发展和网络基建的完善,位于终端的用户对视觉内容的体验质量的要求日益严格。点云作为常用的三维视觉数据表达形式之一,用户在通过设备体验点云内容时,呈现系统应该赋予用户沉浸感和舒适感。质量评价可以保证点云数据在满足处理和呈现的要求时,其质量能够达到范围内的最优,从而使点云内容满足终端用户的视觉需求。

根据进行测试的主体,点云质量评价可以划分为主观质量评价和客观质量评价。在主观质量评价中,实验人员就所要评估的点云系统的功能修改系统的相关参数,应用修改后的点云系统得到相对应的处理后的点云,记为受损点云。实验人员将点云内容呈现给测试人员。测试人员根据其主观感受对点云内容的质量进行评估并打分,然后实验人员对收集到的分数进行处理得到点云的平均意见分数(Mean Opinion Score, MOS),作为点云的主观质量分数。因为在主观质量评价的主体是人,其所得质量分数最接近真实的点云质量,所以主观质量评价被认为是最准确和最可靠的质量评价方法。客观质量评价的主体为机器,其设计和应用客观模型评估输入点云的质量。

目前较为常用的主观评价方法有双激励损伤量表(Double-stimulus Impairment Scale, DSIS)和绝对等级评分(Absolute Category Rating, ACR)。DSIS 方式首先将未经处理的原始点云(参考点云)呈现给测试人员,在测试人员仔细观察之后,将同一点云内容的受损版

本(受损点云)呈现给测试人员。测试人员凭借其对参考点云的记忆,对受损点云的质量分数进行评分。与 DSIS 方式相比, ACR 方式并不会将原始点云的内容呈现给测试人员,而是直接让测试人员评估受损点云。测试人员凭借其想象的原始点云对受损点云进行评分。ACR 方式在评分时不提供参考点云的方式更加符合三维内容的用户消费习惯,而 DSIS 方式则更符合内容提供方的对点云内容评估的需求。

虽然主观质量评价中测试人员的参与使得主观质量评价的结果准确可靠,但是这也导致较成本偏高,使得主观实验难以被广泛地应用于工业生产。点云客观质量评价通过设计客观模型对点云的视觉质量进行评估。客观质量评价的主体是机器,其较低的成本能够在一定程度上解决主观质量评价难以广泛应用的问题。

点云客观质量评价问题的本质为回归问题。提取的点云特征在处理后将作为回归算法的输入,拟合得到点云的客观质量分数。根据是否可获得原始点云,客观质量评价可分为全参考(Full-reference)质量评价、部分参考(Reduced-reference)质量评价和无参考(No-reference)质量评价。与其他两类评价方式相比,全参考质量评价在业界的关注更高,与其相关的研究和文献也更为丰富。随着深度学习在计算机视觉领域的发展,无参考质量评价受到越来越多学者的关注。

12.2.2 点云质量建模

主观质量建模:

主观感知质量评价相对于客观评价能够获得更为准确的点云质量。该质量分数可用于客观评价模型的设计和测试。同时点云视觉产品的提供商可以通过主观质量评价实验评估渲染方式、呈现设备等可视化方案提供的视觉效果,从而确定最优的方案以保证产品的质量。在构建点云质量评价数据库时,也需要对选取的点云内容应用主观实验以得到点云对应的 MOS 分数。因此,点云主观质量评价在学界和工业界有显著的研究意义和应用价值。

点云主观实验可以分为选取点云内容、引入失真、设计渲染方案和查看协议、呈现点云及评分和意见分数处理五个步骤。

在选择用于实验的点云数据时，实验人员需要根据后续实验需要使用到的点云的类别和属性进行选择。根据呈现的内容，点云可以划分为物体点云和场景点云，其中物体点云又可分为非人物点云和人物点云。点云数据的属性除了包含几何信息外，还可能包括颜色、法向量、透明度等信息。另外，点云数据还可以分为动态点云和静态点云，实验人员根据实验需求选择这两种点云。

在选取原始点云时需要考虑的因素包括：点云的密集程度、点云的实例种类、点云的几何结构、颜色特征等。在主观实验中常用的失真类型有**高斯噪声**、**下采样**、**压缩**和**基于八叉树的剪枝(Octree-prune)**等。实验人员可以通过调整参数来控制点云失真的程度，从而获得不同质量的点云数据。**高斯噪声**指服从高斯分布的一类噪声。在点的某一属性上添加噪声后，处理后的点的属性值与原始点的值之间存在一定偏差。**八叉树**是一种树形数据结构，每个内部节点都有八个子节点，对应将三维空间八等分割所得结构，故八叉树多用于描述三维数据。通过设定八叉树的深度可以控制每个叶节点包含点的个数，深度越大，每个叶节点包含点个数越少，处理后的点云质量越高。点云压缩通常用于减小点云数据占用硬盘空间，以便于储存和传输。常用的压缩方法为**动态影像专家小组(Moving Picture Experts Group, MPEG)**定义的两种点云压缩标准：**基于视频的点云压缩(Video based Point Cloud Compression, V-PCC)**和**基于几何的点云压缩(Geometry based Point Cloud Compression, G-PCC)**。**V-PCC**的失真程度可以通过量化参数来控制，而**G-PCC**的失真程度则可以通过体素大小和块大小来控制。**下采样**是一种在保留点云的三维结构信息的同时减小点云的数据量的操作。常用的下采样方式有**体素下采样**、**均匀下采样**、**几何下采样**和**随机下采样**等。

点云的渲染方式可以分为两大类，基于三维的方式和基于投影的方式。其中基于三维的方式又可以分为基于点的方式、基于立方体的方式和基于重建网格的方式。基于点的方式和立方体的方式多采用修改点或立方体的大小和形状的方式来渲染，基于重建网格的方式则采用点云表面重建算法将点云渲染为网格。最常用的表面重建算法为泊松重建。基于投影的方式则是从不同角度将点云投影为图片。最常用的投影方式为垂直投影，该方式将点云中的各点或体素化的体素垂直投影到某一平面。

查看协议涉及到评估主体观察点云内容的方式，其主要分为被动方式和交互方式。采用被动方式的主观实验中，测试人员不能控制实验点云，而是观看实验人员设计的内容，其通常为一段环绕点云的视频或从不同角度拍摄的点云照片。在采用主动方式的主观实验中，实验主体可以自由控制观察点云的角度、距离或渲染方式等。

作为常用的三维视觉数据类型之一，点云不仅可以通过二维显示器呈现，也可以通过头戴设备进行呈现。打分方法多采用五分制或类似标准，五分制中各分数对应含义见表 1。基于前文提到的两种常用方式——DSIS 和 ACR 衍生了多种主观评分方式。如在 DSIS 的基础上，改变呈现原始点云和受损点云的顺序，可以得到序列式呈现方法和同时呈现方法。

表 12-1 5 分制主观评分标准。

分数	描述
5	无法分辨的
4	可分辨但不令人烦恼的
3	轻微令人烦恼的
2	令人烦恼的
1	十分令人烦恼的

客观质量建模：

根据是否应用深度学习算法提取点云的特征，客观评价模型可以分为基于传统方法的客观评价模型和基于人工智能的客观评价模型。基于传统方法的客观模型可划分为基于几何属性统计特征的评价模型、基于人类视觉感知的评价模型、基于投影图像质量评价的评价模型。在基于几何属性统计特征的评价模型的设计中，常用的统计特征有点间距离、点面距离和纹理描述算子等。基于人类视觉感知的评价模型则是根据人类视觉系统(Human Vision System, HVS)相关理论进行设计。其研究受到 HVS 相关研究的启发。基于投影图像质量评价的评价模型则是将点云投影为二维图像，采用图像质量评价模型评估所得图像的质量分数，处理得到点云的质量分数。

基于人工智能的客观模型可划分为基于投影图像的评价模型和基于三维点云的评价模型。目前全参考质量评价和部分参考质量评价大多采用基于传统方法的客观评价模型。无参考质量评价由于其无法获得原始点云的信息，故该类客观评价模型大多采用深度学习进行设计。

基于统计学习的点云客观质量评价模型大多是全参考质量评价方法，即评价过程中需要参考原始点云进行质量评估，从点云处理方式的角度可以将这些方法分为以下几种，包括基于几何整体失真统计的质量评价方法、基于人眼视觉感知的质量评价方法、基于投影图像的质量评价方法。

基于几何整体失真统计的质量评价方法利用统计学习理论从三维几何结构衡量原始参考点云与失真点云之间的直接差异，逐点计算原始参考点云与失真点云之间的空间距离差异。当前，基于几何整体失真统计的质量评价方法从差异计算方式上主要可以分为：点到点误差(Point-to-Point)、点到面误差(Point-to-Plane)、面到面误差(Plane-to-Plane) 几类。

逐点误差统计方法虽然从细微角度捕获了点云的几何失真，但是并不能准确地反应人眼视觉系统 HVS (Human Visual System) 的感知质量。研究发现，在观察事物时，人眼视觉系统 HVS 感知过程具有以下特点：(1) 人眼感知并不局限于物体的具体点上，而是对局部区域的整体感知；(2) 在视觉系统从观察到理解的过程中，视觉光束被分成不同的子带或通道，一些重要的信息特征会被视觉皮层进行特征提取、过滤、聚集等操作。因此，HVS 对所观察事物的局部区域几何结构和属性特征的感知更为敏感。基于 HVS 感知的生理特点，一些研究者基于块聚类 and 图相似性理论探究了基于人眼视觉感知的点云质量评价方法。当前，基于人眼视觉感知的质量评价方法主要可以分为两类算法模型，一类是基于块投影的算法模型，一类是基于图相似性理论的算法模型。

基于投影的质量评价方法将具有三维数据结构的点云从不同视角投影到二维图像数据，利用图像质量评价中成熟有效的方法对每个投影的图像进行质量评价，进而加权求出对应失真点云的质量等级。利用投影图像对点云进行质量评价的主要依据包括以下几点。首先，图像是人眼感知信息的主要来源，它能充分捕捉物体/场景的纹理和几何信息，反映真实的视觉感受。其次，点云的投影方向和数量可以根据任务需求灵活选择，投影后的图像能够充分展示三维点云在各个视角上的视觉信息。最后，目前存在大量且有效的图像质量评价方法可供直接利用，这对探索二维图像代替点云进行质量评价提供了有力的支持和工具，也大大节省了研究基于图像质量评价方法的时间。

近年来，人工智能在各个领域表现出优越的性能，一直受到研究者的追捧和广泛应用，点云质量评价也不例外。深度学习的优势在于数据特征提取，尤其是在图像/视频处理任务中取得了巨大的成功。深度学习模型需要以大量的数据训练为驱动，泛化性能优于传统方法。目前基于深度学习的点云质量评价方法有两类：基于 3D-to-2D 投影

的质量评价模型和基于点云的质量评价模型。

借鉴于深度学习在图像/视频处理任务中取得的巨大成功，许多研究者将 3D 点云数据投影为 2D 图像数据，利用深度学习设计质量评价模型。点云投影是将点云从不同的视角和方向投影到图像平面上，但是基于深度学习模型的质量评价方法主要任务和难点在于如何设计高效的特征提取模型，以准确地捕获投影图像质量来评估点云质量。

不同于投影的方法，基于点云的质量评价模型不需要转换点云的数据形式，直接利用点云中具有三维数据结构的点数据完成特征提取和质量评价。点云投影必然会造成三维结构信息的丢失，这也是研究者直接基于点云进行质量评价的原因之一。基于点云的质量评价模型一般以下几个模型：关键点提取与聚类、特征提取、质量预测。由于点云中包含大量的点，一般有几十万到几百万个点不等，直接输入模型会产生巨大的计算量，因此对点云进行关键点提取与聚类是十分必要的。点云中所提出的关键点能够表示出点云的主体骨架，而对每个关键点的局部区域聚类能够展示点云的局部信息特征，这一步骤不仅大大减少了点的数量，而且保留了点云的主要视觉特征。特征提取与质量预测步骤则是根据所设计的深度学习模型提取聚类点块（Patch）特征并融合回归得到最终的预测分数。

12.2.3 点云显著性概述

随着多媒体技术的飞速发展，3D 点云广泛应用于人们的生产和生活中，同时造成了数据规模的爆炸式增长和产生大量的冗余信息。如何从海量的信息数据中去除冗余，找到我们真正需要和感兴趣的信息，已经成为许多发展领域亟待解决的问题，也是计算机视觉和多媒体领域的研究热点。考虑到人类视觉系统能够快速高效地从外界场景中捕捉有效信息同时有意识地忽略大量干扰信息，许多研究人员通过设计各种算法来模拟生物注意力机制，从而达到对从外界感知的大量信息进行筛选处理的目的。

视觉显著性是指在视觉场景中，一些区域或物体对视觉注意力更具有吸引力、更容易被注意到的程度，因此是一种相对属性。许多因素，如颜色、对比度、方向、形状、亮度等，会增加物体或场景区域的视觉显著性，使其更容易被观察者注意到。因为场景的显著性不仅仅决定了生物视觉系统对该场景的感知细节，而且可以通过计算场景的显著性分布，帮助由计算机模拟的人工视觉系统从海量的场景数据中快速识别和定位场景的关键信息，提升系统的处理效率。因此，视觉显著性在生物和人工视觉系统的注意力分配中起到了关键的作用，无论处于各种场景中，都可以根据场景不同区域的显著性程度预测视觉系统的注意力分布情况。

显著性检测，又叫视觉显著性预测，是预测人类视觉系统注意力在各类数据中的分布情况，模拟生物注意力机制从海量的信息中提取对于特定视觉任务起到主导作用的关键信息，并过滤掉冗余的干扰信息的底层计算机视觉任务，可以帮助计算机高效的完成特定的视觉任务。显著性检测作为许多计算机视觉任务的上游任务，它的输出可以作为其他视觉任务的预处理步骤，包括数据分割、目标识别、场景理解、多媒体数据质量评价和视觉媒体修复增强等。然而由于人类视觉系统具有高度的复杂性，现有的显著性检测算法得到的计算结果仍然与真实的生物注意力分布情况有着相当的差距，需要更加深入的研究和探索。尽管如此，显著性检测已经表现出了巨大的应用价值和发展潜力，因此该领域的研究者一直在投入大量的时间和精力探索视觉显著性机理，并且提出了许多经典的显著性检测模型。

12.2.4 显著性检测

面向点云的显著性检测研究目前仍然处于萌芽阶段，并且现有的点云显著性检测算法均是基于传统手工特征提取的方法，具有更大潜力的基于深度学习的方法还没有被探索。由于目前尚没有基于深度学习的点云显著性检测相关的研究，下面我们对一些经典的基于传统手

工特征的点云显著性检测算法进行介绍,这些传统方法也可以为未来深度学习方法的设计提供有用的借鉴。

Akman 和 **Jonker**[29]究点云显著性检测任务的研究者之一,他们提出的方法可以挖掘不规则点云包含的显著性特征来计算点云的显著图。具体而言,作者通过采用不同尺度的局部表面属性(LSP)以及点与相机之间的距离来计算两个单独的显著图。最后通过对计算的两个显著图进行平均值来获得对整个点云样本的综合显著性表征。

Shtrom 等人[30]提出的点云显著性检测算法旨在处理包含上百万个点的大规模点云。受人眼视觉系统分层感知机制和现有面向图像显著性检测算法的启发,即低层的信息可以检测点云精细的显著性特征,而高层的信息则可以确定了整个点云样本的吸引人眼球的区域,作者提出了视觉形式可能拥有一个或多个组织形式的重心的假设。他们通过设计一个高效的点云显著性特征描述符和差异性度量来分层计算点云的显著性表征,最后将不同层次的显著表征平均成一个准确的点云显著图。

受基于图像块的图像显著性检测算法的启发,**Tasse** 等人[31]出了一种基于聚类的点云显著性检测方法。所提出的方法首先将点云通过模糊聚类分解为小的点云簇,然后评估每个点云簇的唯一性和空间分布,并将这些值组合成关于点云簇的显著性函数。最后通过计算每个点所归属点云簇的概率来计算点云样本中每个点的显著值。实验表明,该方法可以在不使用任何拓扑信息的情况下,在假阳性和假阴性错误率之间实现了良好的平衡。

受人类视觉系统特征的启发,**Ding** 等人[32]提出一种多层次特征感知的点云显著性检测算法,该方法首先根据每个点的局部上下文计算点云的局部独特性,然后使用随机游走排名方法对所有簇中的每个点引入簇级全局稀有性细化。其中,局部独特性表示了每个点与其局部周围点的差异,而全局稀有性旨在描述整个独特区域并抑制频繁出

现的区域。最后，作者提出了一个优化框架来整合局部独特值和全局稀有值以获得点云的最终显著性检测结果。

12.3 深度学习点云压缩

12.3.1 国内外研究进展

随着 3D 采集技术的不断发展，3D 传感器的成本逐步降低，推广应用范围不断扩大，涵盖各种类型的传感器，如 3D 扫描仪、LiDAR 和 RGB-D 相机。这些传感器能够获取丰富的立体数据，包括外观形状、大小、三维空间位置等几何信息，以及颜色、不透明率、反射率等特征信息。与二维图像相比，立体数据能够更好地识别机器周围环境，捕捉目标的细节信息。点云是在三维空间中定义的点集合，已成为三维表示中最重要的数据格式之一。3D 点云由具有几何和属性信息的点组成，其中几何信息表示点在笛卡尔坐标系中的位置 (X, Y, Z)，而属性信息描述了每个点的视觉表现，通常用色彩值 (RGB 或 YUV) 表示，并带有法向量信息等。通常情况下，几何坐标使用浮点数表示，但在大规模高密度点云压缩中，常采用整数表示，以节省 CPU 计算时间和优化内存使用。因此，需要对几何坐标进行基于整数规则网格的量化。

目前，点云处理面临以下难点：一是点云的稀疏特点导致远处物体的点数量比近处物体少得多；二是点云的不规则性使得有效搜索临近点变得困难；三是纹理信息的缺失使得不同目标的识别较为困难；四是点云数据的无序性使得采用深度学习等方法进行分析十分困难，不同顺序的输入矩阵可能得到完全不同的结果；五是点云数据的旋转不变性，由于点云数据表示的是三维物体，所以整体数据的旋转不会改变数据特征，但这也导致识别的困难性。

点云压缩可分为无损压缩和有损压缩两种方式。无损压缩通过消除统计冗余使数据更紧凑，并完整保留原始信息。然而，有损压缩则通过量化过程移除不必要的视觉冗余信息。无论采用哪种方式，都需

要进行数据去相关处理。压缩的最高级别是冗余减少的维度，包括一维遍历、二维映射和三维去相关这三种不同的模式。第二级别涉及几何和特征信息的压缩，包括三种方法：细节划分级、聚类方法和基于变换的技术。前两级之间交错，第三级则涉及处理几何信息的数据结构，包括各种类型的基于树的表示，如八叉树、二叉树和 kd 树。

目前点云压缩算法主要分为三个方向：第一种是基于图像视频的点云压缩算法，它主要采用传统图像处理的框架进行点云数据的位置坐标压缩，基本思路是将三维的点云数据采用极坐标转换等方法进行二维映射，产生类似深度图的信息，然后利用传统图像视频编码算法进行编码。然而，基于传统方法的点云压缩没有考虑坐标转换过程中可能带来的损失，导致压缩性能不高。第二种思路是基于八叉树的深度点云压缩算法，它的编码过程先对点云坐标数据进行量化，删除点云中位置相同的点，然后建立八叉树节点表示方法，每个节点信息代表当前节点以及子节点的二值表示。随后，利用熵编码对节点占位码信息计算频率表，即每个坐标值出现的次数和概率，再根据转换后的概率进行算术编码（Arithenco），并使用相反的过程进行算术解码（Arithdeco）以及坐标值的还原。第三种思路是利用体素网格的结构表示进行压缩，它将八叉树的节点用体素化的包围盒表示，这种紧凑表示能更好地生成上下文信息。之后，再利用体素块上下文信息进行当前点坐标的概率预测，主要利用后验概率生成的方法，例如自回归或超先验进行编码。基于体素化的方法常常结合深度学习的算法进行点云压缩处理。

V-PCC（Video-based Point Cloud Compression）是一种用于动态点云压缩的整体框架[1]，与传统的二维视频压缩类似，V-PCC 的整体编码过程可分为四个步骤：补丁生成、几何/纹理图像生成、附加数据压缩和视频压缩。在视频压缩过程中，可以采用已发布的视频编码标准 H.265/HEVC 进行压缩。G-PCC（Geometry-based Point Cloud

Compression) 是一种基于几何的编码方法[2]。几何坐标编码是先对坐标值进行变换,之后进行量化取整去除重复点坐标,第三步则利用八叉树结构进行数据体素化,体素化过程是对输入的三维位置进行二值化来得到位置表示,通过创建一个边界框来计算对象在所有 xyz 方向上的最大尺寸,然后将最大尺寸用作给定比特范围的最大值,八叉树非常适合于稀疏采样的点云,八叉树构建过程是对体素化的包围盒进行更加细致的点云数据划分。当完成了体素化后每个 3D 点位置可以表示为八叉树中的叶节点,在这种情况下可以实现近无损压缩。八叉树形成后,每个含有一个或多个点的体素通过预测、变换和量化等常规压缩过程进行熵编码预测过程。

当几何体素完成编码,就确定了编码所需的点数,根据需要编码的几何体选择适当数量的属性,因此将几何体素和重建结果作为颜色编码过程的输入,就是上图编码器 **attribute encode** 部分示意图,如果几何体素编码是无损的或接近无损的,则点的数目将保持与输入点云相同。因此颜色重采样过程主要与颜色变换有关,例如 RGB 转 YUV 或者 YUV 转 RGB。如果几何体素编码是有损的,则颜色重采样过程必须将一个或多个颜色值映射到一个颜色值。颜色重采样后,选定颜色值的处理顺序与几何体素编码的顺序相同,几何体素编码顺序由细节层次生成重新计算。使用层次计算时在每个层次上对点进行分组和排序,并且生成过程将以相同的方式在解码器处重复进行,以确保颜色值与几何信息相匹配。如果要对颜色值进行编码,最好使用预测或变换来利用相邻颜色值之间的高相关性。

几何解码过程:按照编码流程相反的方式进行几何和颜色值信息的解码,几何解码流程是先对八叉树编码的码流数据进行算术解码,在利用八叉树建树过程进行编码数据的还原,同时利用重建坐标进行颜色信息解码。

目前,点云压缩的两个方向都有广阔的前景。V-PCC 可以利用

现有的视频编码标准技术，实现点云压缩技术的快速实现，适用于消费电子行业、沉浸式多媒体等领域的推广应用。而 G-PCC 则针对点云数据进行更精细化的操作和压缩，虽然计算量更大，但压缩性能和 3D 还原程度更好，适合于自动驾驶、机器人操作、医疗辅助等领域的应用，并具有广阔的应用前景。

12.3.2 基于深度学习的点云压缩

点云具有稀疏性、无序性和非结构化性，这使得深度学习不能直接应用于点云数据。因此，我们需要进行一些预处理方案。常见的预处理方法包括体素化、缩放和划分。点云在计算机中以坐标的形式存储，而深度学习难以直接理解和处理坐标的存在。体素化的引入解决了这个问题[3]。体素化过程引入了几何坐标的整数表示，使得深度学习方法可以与点云压缩结合。缩放通常在视频编码或图像编码中使用，它被认为是一种在降低码率的同时保留视频或图像质量的方法[4]。而划分是针对特定的点云，将其分为多个互不重叠的尺寸相同的块，以实现在压缩和解压缩过程中的并行处理，从而加快处理效率。根据点云压缩任务的不同类型，可以进行不同类型的划分，例如根据还原质量进行分类（有损压缩与无损压缩）、根据处理方法进行分类（传统编码与深度方法）、根据空间维度进行分类（一维、二维与三维）、根据数据结构进行分类（树、块、体素、图等）。

八叉树是基于树的点云编码数据结构的典型例子，它为点云提供了可以操作的数据结构。它从一个根节点开始，递归地定义点云的整个空间。从理论上讲，它可以无限逼近所需的精度。八叉树使得点云压缩的码率消耗更少，压缩效果更显著[5]。在 2009 年 Lien 等人也提出了利用 K-D 树作为数据结构，代替八叉树[6]。Kathariya 提出了利用二叉树与四叉树的结合来取代八叉树，从而获得更高的编码增益[7]。最近的研究更多地将数据结构的建立视为一种预处理操作，利用数据结构将点云转换为与所提压缩方法相符合的模型。例如，PCGCV1

将点云划分为不同的、互不重叠的块，再利用超先验预测上下文，并使用传统算术编码器生成码流[8]。文献[9]提出图变换方法，先利用树结构对点云空间进行划分，再利用体素空间的关系构造了拉普拉斯图，这是首次提出的基于图变换的点云属性压缩方法。还有学者实现了八叉树与注意力机制的结合，取得了 SOTA 的点云压缩效果。

Quach 等人首次将深度学习与点云压缩结合，提出了 PCC_GEO_CNN_V1[10]，该方法利用 3D 卷积自编码器构建编解码模型。这一框架为利用深度学习进行点云压缩任务提供了指导性意见。随后，Quach 又提出了 PCC_GEO_CNN_V2[11]，其中包括一系列改进方法，如利用 Focal loss 作为损失函数和改进熵模型等。另一种针对雷达点云压缩方案是 MuSCLE[12]，该方法研究雷达点云跨多帧时空关系以降低几何和强度值的比特率。MuSCLE 提出了一种条件熵模型来建模八叉树符号概率，该熵模型考虑了粗粒度级别几何和前向帧几何以及密度信息之间的关系，并通过采用可学习的概率来编码全部码流数据以得到紧凑的特征表达。

在文献[13]中，Wang 提出了一种端到端的有损点云压缩方法 Learned-PCGC，该方法采用深度神经网络（DNN）构建变分自编码器结构来压缩点云几何坐标。Learned-PCGC 的输入数据是体素化分块成非重叠的 3D 立体块，体素化后的数据传输到堆叠的三维卷积生成潜在特征和超先验。超先验模块用于提升熵编码潜在特征的条件概率估计。在训练过程中，Learned-PCGC 采用加权二值交叉熵损失（WBCE）作为优化目标，并在推理阶段引入自适应阈值来减少空值体素块，试验表明该方法性能优于 MPEG PCGC。此外，文献[14]中还提出了针对 Learned-PCGC 的改进版本。为了解决点云数据的稀疏性，[14]提出了一种多尺度端到端的点云有损压缩方法 PCGCV2，该方法通过逐步采样进行点云几何坐标的层次重建。PCGCV2 采用基于稀疏卷积的自编码器结构进行点云压缩与重建。针对只有二值占位属

性的输入点云,PCGCV2 在 bottleneck 层转换成下采样点云,bottleneck 层同时处理几何和对应的特征属性值。几何占位通过八叉树编码器进行无损压缩,属性值则利用可学习的概率上下文模型进行有损压缩。

针对静态动态点云压缩,Que 提出了一种基于八叉树的两阶段点云压缩方法 VoxelContext-Net[15]。该方法结合了八叉树和体素表示的优点,采用体素上下文来压缩八叉树数据结构。首先,VoxelContext-Net 提取局部体素表示,在构建的八叉树结构上为每个节点编码空间邻居上下文信息。其次,在熵编码阶段提出了一个基于体素上下文的熵模型,以无损的方式压缩非叶子节点的符号。针对动态点云,该方法引入了来自时间邻域点云的局部体素表示,以探索时序依赖关系。为了缓解八叉树构建过程中产生的失真,VoxelContext-Net 提出了基于体素上下文的三维坐标改进方法,以在解码端产生更准确的重建点云,该三维坐标优化方法同时适用于静态和动态点云。为了保证足够的上下文建模点云数据分布,Fu 提出了一种利用多上下文的深度点云压缩模型 OctAttention[16]。该方法通过收集兄弟节点与祖先节点的信息以无损的方式编码八叉树符号序列。OctAttention 设计了一个具有大感受野的条件熵模型,该模型建模兄弟和祖先节点上下文,以探索邻居节点之间的依赖关系,并利用注意力机制加强上下文中节点的相关性。在训练过程中,他引入了一种掩模操作来平衡编码时间和性能。

12.3.3 云压缩标准

PCC (Point Cloud Compression) 的讨论始于 2013 年,起初是为了处理沉浸式呈现,后来更多数据和证据表明了 PCC 的必要性,2015 年开始进行探索性实验。测试工具为 Point Cloud Library,支持静态和动态点云对象,可以压缩几何和特征信息。经过前期确立点云压缩技术在消费电子工业的需求,MPEG 成立了 MPEG-3DG 工作组,并将点云压缩标准按处理方法划分为基于视频的点云压缩 (V-PCC),

基于几何的点云压缩 (G-PCC), 以及基于深度学习的点云压缩 AI-PCC。V-PCC 旨在为需要实时解码的应用提供低复杂度的解码能力, 如虚拟/增强现实、沉浸式通信等。V-PCC 利用现有和未来的视频压缩技术, 以及一般的视频生态系统 (硬件加速、传输服务和基础设施), 同时实现新型的应用模式。在第 124 届 MPEG 会议中, 参考模型编码器显示了 125:1 的压缩率, 并实现了良好的感知质量。截至 2018 年 10 月, V-PCC 标准已进入委员会起草阶段。G-PCC 被认为可以为自动驾驶、3D 地图和其他利用激光雷达生成的点云 (或类似内容) 的应用程序提供高效的无损和有损压缩。G-PCC 包括几种几何驱动方法, 标准于 2019 年 3 月提升至委员会起草阶段。AI-PCC 则致力于使用深度学习的方法解决点云压缩的码率优化问题。并且在 2019 年之后针对点云压缩提出多个具有代表性的方法和提案, 其压缩性能也超越了一些传统压缩算法。

MPEG 提出了多项关于点云压缩的提案, 例如 m58216 提出了一种基于查找表的点云几何压缩方法[17], 试验表明相较于 G-PCC 压缩方法, 其具有更好的 D1 PSNR 和 D2 PSNR 性能。而 m58297 总结了当前基于深度的点云压缩方法的性能[18], 针对密集点云数据表现较好, 而针对稀疏点云较为困难。m58166 分析了 ADL-PCC 模式选择模块的行为[19], 并通过自适应方式限制编码模式数量, 减少编码器复杂性。m58167 提出了一种基于八叉树数据结构的深度熵编码模型[20], 利用神经网络和上下文信息预测八叉树节点的概率分布表, 实现了性能和复杂度的优化。m58170 定义了对现有深度点云压缩方案的评估, 包括针对稀疏点云的性能评估需要与 GPCC 进行对比, 对于稠密点云, 需要与 GPCC 和 VPCC 进行对比[21]。同时, 也对数据集的选择、深度框架的选择以及交叉验证等模块进行了定义, 以更好规范深度点云编码相关的 MPEG 提案格式。

从现有的 MPEG 点云编码标准来看, 目前基于深度学习的点云

编码方案仍然是主流。尽管在处理静态点云数据方面性能提升显著，但在数据结构、网络结构、熵模型等方面仍有许多优秀的创新想法。然而，对于动态点云数据，由于场景复杂多样、数据量庞大，压缩难度较大，而且现有的动态点云压缩方案较为有限，需要持续跟进动态点云压缩的发展。当前点云在各个领域得到广泛应用，包括 3D 扫描和建模、环境监测、农林业、生医影像、CAD、自动驾驶等。随着压缩技术的进步，未来点云应用还将扩展到实时便携设备上，实现自主导航、VR/AR 等领域的应用。基于 GPU 的计算设备使得高密度的 3D 点云数据的实时获取和可视化成为可能。与 3D 网格相比，3D 点云具有更简单、高密度、更接近实际的表示优势，但同时面临拓扑和连续信息缺失的困难。此外，点云数据量庞大，需要有效的压缩方法来确保数据的存储和传输，包括几何和特征信息的提取。因此，ISO/MPEG 正在推进 3D-PCC 标准化进程。

12.4 深度学习点云增强

12.4.1 点云压缩修复

近些年来，点云已经被广泛的应用到实际场景中，例如自动驾驶、城市建模和虚拟/增强现实。这些新型应用为人类生活带来了极大的便利，同时也产生了巨大的研究和商业价值。然而，现有点云数据采集和生成的方式会造成远远超过视频图像的存储和传输负担。因此，在点云应用任务兴起的的同时，相应的点云压缩算法和框架进入研究者

$$d_{EMD}(S_1, S_2) = \min_{\phi: S_1 \rightarrow S_2} \frac{1}{|S_1|} \sum_{x \in S_1} \|s - \phi(x)\|_2$$

的视野。近几年，为人们熟知的运动图像专家组（MPEG）提出了基于几何的点云压缩标准（GPCC）和基于视频的点云压缩标准（VPCC）。尽管有损模式下点云码流的减少有利于大型点云数据的存储和传输，但它会不可逆的产生信息丢失，无论是对于点云几何信息还是属性信息。大量文献表明，信息损失会极大的限制或降低点云在下游任务的

性能表现。例如，在自动驾驶应用上，解码端对码流进行重建，并得到带有信息损失的点云。失真点云会严重影响到现有点云处理算法对行人、车辆等目标识别和分割的准确度。对此，对压缩点云进行质量修复，不仅能够提高人眼主观体验，而且有利于提高下游点云任务的性能表现。压缩修复方式可根据修复方法是否参与点云压缩编码过程分为结合编码端的联合修复框架和以后处理形式的质量修复框架。点云是由三维空间中的点集合的数据表示，已经成为三维表示中最重要的数据格式之一。根据点云数据采集设备的不同，点云由几何信息（三维几何坐标）和一系列可选的关联属性信息（如法向量、强度、颜色、反射率等）组成。作为 3D 世界的数字表示，点云通常用于描绘物体的表面并准确地反映其属性。

点云感知包括人眼感知和机器感知两大类。人眼感知是指依赖人眼视觉机理（如质量评价、显著性检测）去感知点云数据，广泛应用于数字文化遗产保护、自由视觉传播、3D 沉浸式交互等方面。在点云的压缩、传输、处理过程中不可避免地会引入一些失真，这些失真使得点云的视觉质量下降，进而影响人眼感知，因此研究人眼对点云的视觉感知建模可以显著提高点云系统处理点云数据的能力。机器感知是指计算机系统能够理解和处理感知点云数据（如分类、分割、检测、跟踪等机器任务），在自主导航、实时监测、地理信息系统、视觉分拣机器人等领域很受欢迎。对点云进行机器感知建模，可以采用神经网络对退化点云数据进行感知效益分数回归，以感知机器视觉效益分数。在机器感知建模指导下，可以促使保留更多适用于下游机器任务的信息，得到更有利于视觉任务的点云数据。

点云压缩是实现高效存储和传输点云数据的关键课题。点云庞大的数据量给存储设备和通信网络带来了沉重的负担，阻碍了其进一步的应用。具体而言，典型的体素化点云序列（30 秒，每秒 60 帧，10 位深度和每帧 500,000 个点）的几何信息在没有任何压缩的情况下花

费大约 3.14GB 的存储空间。如果考虑属性信息，比如 8 位深度的颜色信息，数据量将达到 5.66GB 左右。点云的庞大数据量使得点云的广泛应用变得不切实际，因为有效的点云压缩方法是必要的。点云压缩的目标是减少点云数据的存储和传输开销，同时保留重要的几何和语义信息，以便后续的感知任务可以正确处理点云数据。压缩点云数据可以降低传感器数据的带宽需求，提高点云系统的实时性能。深度学习的发展为点云压缩领域带了更进一步的契机，深度神经网络强大的学习能力与压缩中所需要的隐式学习不谋而合。在今年的研究中，基于深度学习的点云压缩方法成为主流，且有部分基于深度学习点云压缩方法的率失真性能和峰值信噪比质量超过了非深度的点云压缩方法。因此，深度点云学习方法是未来点云压缩的发展趋势。

点云增强是近年来点云智能系统的重要组成部分。该技术也广泛应用于最近的 3D 视觉应用中，如自动驾驶、卫星地图等。所有这些应用都高度依赖于高质量的数据收集，但由于现实世界的复杂环境，最初收集的点云通常是原始的。这些原始数据会因为噪声和失真而阻碍决策，因此原始数据不能直接应用于一些下游模型，如何处理这些原始数据至关重要。点云增强被视为点云压缩的数据处理。首先需要对采集到的点云进行清洗和采样，清洗和采样称为点云压缩的预处理。此操作是必要的，因为许多原始点云数据包含噪声和异常值。其中，点云去噪和点云降采样技术是预处理中的重要组成部分。预处理会影响压缩性能，因为点云的划分通常取决于点云的稀疏性和分布。点云压缩和传输后，需要根据相应的下游任务再次对点云进行进一步处理。我们将其称为点云压缩的后处理。后处理也是必要的，因为它可以解决经典点云智能系统中的两个问题。第一个问题是现有的压缩方法无法直接面对下游任务，它们无法知道哪些点是真正关键的。第二个问题是解码后的一些几何信息和属性信息很容易丢失和失真，这可能是由量化和数据传输引起的。这两个问题目前都没有得到很好的解决，

因此后处理是桥接压缩到下游任务的合理解决方案。后处理主要包括上采样、帧插值、补全和压缩伪影去除。预处理和后处理所利用的具体技术是点云增强。




图 12-1 点云几何压缩失真及修复

压缩点云修复不同于压缩图像或点云修复。后者只需要考虑其颜色属性的失真及修复，而前者还包括点云几何坐标的失真修复。在图像或视频的压缩修复任务，相比于传统修复方法，基于深度学习的方法已成为研究趋势，并取得更好的修复质量。类似的，基于深度学习的点云压缩修复问题在近两年逐渐成为研究热点。接下来，我们将主要讨论以后处理形式的压缩修复质量修复的现有相关工作和研究趋势。

对于压缩点云的几何修复问题，我们需要分析几何信息在压缩过程中失真的原因。几何压缩失真是有损压缩算法对于点云几何坐标进行体素化和量化引起的。它会同时造成点云中点的数量和坐标的不可逆变化。如图 1 所示，我们以 MPEG 的标准点云测试序列中的某一个点云为例，从左至右分别表示原始点云、压缩点云和修复点云。从图中可以看出点云在压缩后，点数会减少并变得稀疏。点的空间几何位置由原始点云的杂乱无序变得网格规则化，即位置偏移会导致语义信息产生失真。因此，现有基于深度学习的几何压缩修复方法一般会同时考虑以上两种几何失真特点。

现有方法主要分为基于三维卷积的点云几何修复方法和基于稀疏卷积的点云几何修复方法。基于三维卷积的几何压缩修复方法主要是参考二维图像的压缩修复框架，它通过三维卷积神经网络来对几何坐标点的占位概率进行预测。有研究人员提出使用简单的 UNet 网络

结构来提取点云在三维网格空间中的深度特征，并通过交叉熵损失函数来对网格点的概率进行监督训练。当前点输出的值越接近于 1，说明其在原始点云中存在的概率越大。同时，采用多尺度的深度特征提取模块能同时处理多种几何失真程度的压缩点云。然而，这类方法因其使用三维卷积带来的巨大计算开销难以保证质量修复的实时性。另外，该类方法忽略了体素化过程给点云几何信息带来的失真。基于这些问题，有研究团队针对大型稀疏点云设计出全新的稀疏卷积框架来高效的解决大型点云处理问题。稀疏卷积框架只对实际占有点进行局部特征提取，并结合一些常规卷积网络的设计技巧，进一步提取点云的深度特征。常规的三维卷积网络需要对大型点云进行分块处理，这一过程一定程度上破坏了点云的全局特征。而稀疏卷积能够将大型点云直接作为网络输出，既保证了处理速度，也保留了点云的完整性。类似的，稀疏卷积框架也是对点的占位概率进行预测，并通过反稀疏卷积操作来生成大量的候选点，极大增加了点云特征的丰富性。

无论是基于三维卷积还是基于稀疏卷积的几何压缩修复方法，均是对体素化的点云进行处理。一些研究表明，体素化过程破坏了点云语义特征的连续性，尽管对下游点云处理任务的影响小于压缩过程带来的影响。对此，一些研究将基于点的点云处理方法（PointNet）直接用于点云几何压缩修复。基于三维卷积或稀疏卷积的深度学习方式使用体素化后以整型坐标的原始点云进行有监督学习，而基于点的点云处理方法是使用浮点型坐标形式的原始点云进行训练。尽管后者能够保持几何的连续性，它需要对大型点云进行批量或者并行处理。



图 12-2 点云属性压缩失真及修复

目前,基于深度学习的点云几何压缩修复方法面临的挑战主要有以下几点:1)适用于大型点云的深度学习框架和算法平台仍然需要进一步发展来更高效的进行点云任务处理。2)现有方法正在积极探索点云压缩失真自身的特点并设计出相应的有效的修复模块。相比于图像和视频压缩修复任务,上述问题需要进行拓展和分析。3)现有基于深度学习的点云几何压缩修复方法一般是面向单一点云几何压缩算法框架下的质量修复,如果设计出通用的、面向多种场景点云数据和几何压缩算法的压缩修复方法是具有挑战性的,也是未来的研究趋势。4)现有基于深度学习的点云几何压缩修复方法主要围绕单帧静态点云进行几何修复,难以满足绝大多数真实场景应用需求。如何准确的提取动态点云帧间运动信息,对动态压缩点云的几何修复至关重要。目前,有研究人员借助基于深度学习的动态点云几何压缩方法,来尝试进行动态压缩点云的几何修复。

相比于压缩点云的几何修复任务,压缩点云的属性修复问题也逐渐成为新的点云增强研究方向。现有的点云属性压缩算法一般依赖于前期的几何压缩过程,且参考了图像和视频的压缩编码框架。这一特点为基于深度学习的点云属性压缩修复方法提供了重要的指导。然而,在点云几何有损的模式下,点云属性修复面临的挑战急剧增加。因此,现有基于深度学习的点云属性压缩修复方法主要面向几何无损和属性有损模式下的属性质量修复。类似的,我们也对属性失真现象进行简单的分析。如图 2 所示,我们以某一个 MPEG 的标准测试点云为例,并采用八叉树结构下的几何无损和 RAHT 属性有损模式进行属性压缩。从左至右依次为压缩点云,修复点云和原始点云。从图中可以看出点云属性压缩算法会严重破坏颜色信息的连续性,且产生明显的模糊效应和块效应。产生这些现象的原因是点云属性压缩算法使用了多细节层次划分和块级别的属性量化操作。

一些研究将三维图卷积神经网络引入到点云属性修复任务，研究动机来源于图结构能够高效的组织点云数据，并深度提取点云邻域关系和空间特征信息。同时，该修复方法考虑到属性压缩算法中的细节层次划分策略，使用多尺度的图注意力机制来自适应的学习有效的点云特征。然而，基于图卷积神经网络的点云属性压缩修复方法难以适配大型点云的情况，构建大型点云的图结果会产生巨大的计算开销。因此，类似于基于稀疏卷积的点云几何压缩修复方法，有研究表明先使用稀疏卷积框架对压缩点云的几何进行建模，再使用稀疏卷积网络对点云的属性进行深度特征提取。基于稀疏卷积的点云属性压缩修复方法可以参考基于深度学习的压缩图像和视频修复方法。例如，关于特征通道的注意力机制、多尺度感受野以及频域分离等高效的特征模块设计被引入到基于稀疏卷积的点云属性压缩修复方法。

目前，基于深度学习的点云属性压缩修复方法面临的挑战主要有以下几点：1) 现有属性修复方法主要是在几何无损模式下进行的，然而现实场景很难保证点云几何信息的完整性。如何同时考虑几何有损和属性有损的点云压缩修复是一个巨大的挑战，并有效建立和充分利用几何和属性的潜在关系将是这类问题的关键。2) 现有属性修复方法局限于面向静态点云属性压缩，针对动态点云的属性修复也是未来的研究趋势。它涉及到点云帧间的运动关系建模，其几何位置的无序性和不规则性带来的挑战远远高于视频帧间特征提取。此外，基于深度学习的动态点云属性修复一定程度上可以借鉴现有的基于深度学习的三维场景流估计方法，这一点类似于视频修复中借助二维光流进行的帧间特征对齐的策略。

上述对基于深度学习的点云压缩修复问题在研究现状、主要方法、存在问题和挑战以及未来研究趋势等几个方面的整体分析，我们能够得出以下一些结论和展望：1) 基于深度学习的点云压缩修复方法研究近两年在学术界已进入点云处理及应用方向的研究人员的视野，并

吸引着相关其他领域学者的关注。2) 基于深度学习的点云压缩修复方法研究在工业界和商业推广上突显出重要的、急需的应用趋势,且在多媒体应用与感知生态链上扮演着坚实的一环。同时,基于深度学习的点云压缩修复方法研究能够积极有效的辅助和增强点云在大量机器视觉任务上的表现。3) 基于深度学习的点云压缩修复方法在发展过程中,能够不断吸收图像视频等其他多模态信息处理方法和匹配点云压缩技术发展轨迹,在相互交流和融合中与时俱进,为推动科技应用生态圈的蓬勃发展做出源源不断的贡献。

12.4.2 点云补全

点云补全是 3D 计算机视觉中的重要任务,其旨在从残缺或局部的输入点云生成和估计完整点云。最近,深度学习方法的应用极大地提升了点云补全任务的性能和鲁棒性。尽管如此,造成点云残缺的原因有很多,比如信号丢失,物体间遮挡,盲区等。这使得补全的点云的质量需要被进一步增强以满足实际的应用需求。点云补全的目标是将残缺的输入点云重建为具有完整 3D 结构的点云。补全后的点云需要与人眼感知保持一致。

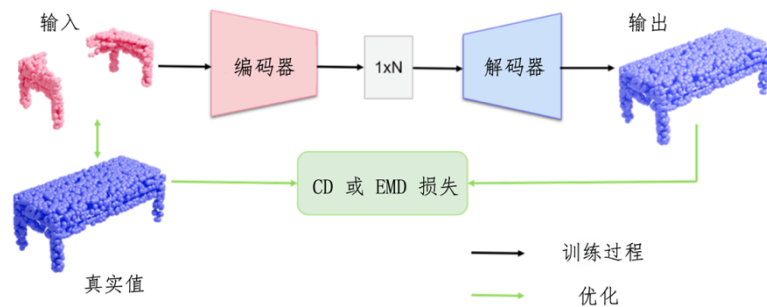


图 12-3 点云补全方法的基本框架

传统点云补全方法通常借鉴基于扩散的或基于块的图像补全方法。这些方法只关注点云局部区域的信息而并未考虑到局部区域的全局关系。随着基于深度学习的点云框架的发展,许多相关的点云补全方法表现出了显著的性能。此处将介绍具有代表性的基于深度学习的

点云补全方法并描述这些方法的基本过程。如图 3 所示，基于深度学习的点云补全方法的基本框架包括编码器，解码器和优化器。其中编码器用于提取点云的局部和全局的特征；解码器则在该特征的基础上生成和细化补全的点云；而优化器则是用于最小化损失函数以使模型收敛。不同的方法会使用不同的增强模型作为额外的部分来提升方法的性能。接下来介绍三种具有代表性的方法：基于点的方法 TopNet[22]，基于图的方法 FoldingNet[23]和基于生成模型的方法 Vaccine-style-net[24]。

TopNet 的解码器采用树形结构来生成一组随机的点。其计算流程包括一个两阶段的编码器和一个树状的解码器。新的根-树结构的解码器将编码器所得的特征视作 3D 形状的表达，从而生成相应的点云。其树状解码器的每个结点为一个点云子集。解码器的根结点将编码器所得的特征向量作为输入，应用 M_1 个多层感知网络来生成 M_1 个 C 维的特征向量对应与第一层的 M_1 个结点。每层得到的特征向量与编码器所得特征向量拼接后继续向下进行计算。最后一层的特征向量的维度为 3 维。

迄今为止，FoldingNet 是最为广泛使用的解码部分，其灵感来源于具有弹性的纸的折叠。可以观察到 3D 点云通常是从物体表面获取的，而 3D 物体的表面本质上是二维流形。FoldingNet 的编码器采用 PointNet，其可以看作将点云转化为关键字的投影。FoldingNet 将 2D 网格变形/拉伸/切割为 3D 表面，其变形的程度由相邻的网格间的联系来控制。重建的点可以代表折叠和训练过程中的中间步骤，因此变形力的变化可以可视化。FoldingNet 的整体结构如图 4 所示，其可以划分为两个部分：编码器采用多层感知网络和基于图的网络层。解码器则采用三层感知层来将 2D 固定的网格转化为点云。解码器输入的关键字为编码器的输出，其被重复 m 次后被拼接成网格矩阵形成新的矩阵，在经过编码器转化为 3 维点云。

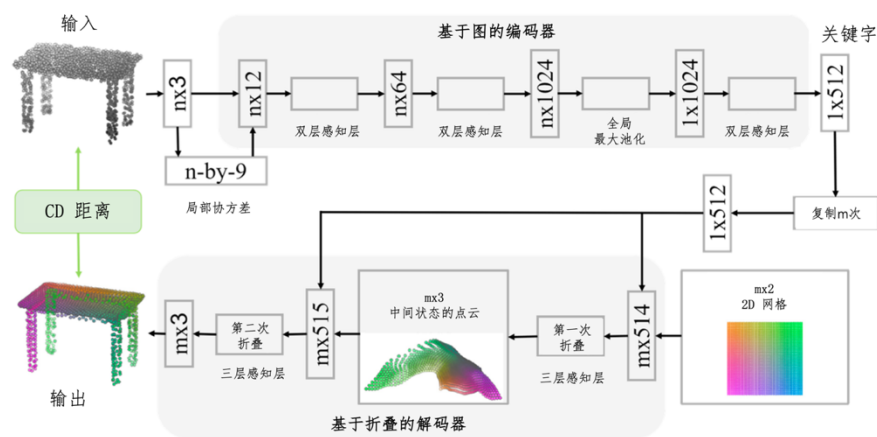


图 12-4 FoldingNet 的整体结构[23]

Vaccine-Style-Net 的设计受到生物学的启发。Vaccine-Style-Net 是为解决 3 个挑战而提出的。这 3 个挑战为 1) 生成的点云通常服从稀疏的分布；2) 生成的点云的分辨率受到其模型架构的限制；3) 现有方法不能很好地得到物体的 3D 光滑表面，尤其是大型区域受损场景点云。

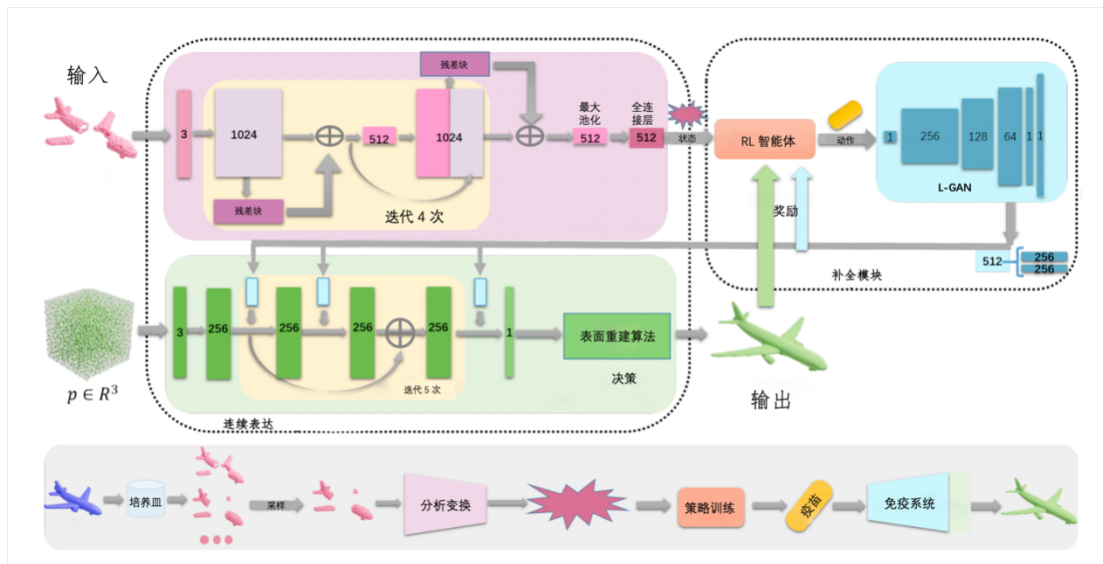


图 12-5 Vaccine-Style-Net 的架构[24]

如图 5 所示，Vaccine-Style-Net 的架构包含三个组件：掩码生成模块，连续性表达模块和点云补全模块。掩码生成模块将点云进行遮掩，模拟点云的缺损，以评估模型的泛化性和鲁棒性。连续性表达模块为 3D 表面的决策边界赋予概率，采用二分类神经网络来估计该概

率。采用连续的表述可以使模型生成高分辨率的点云和光滑的表面。得到了点云的隐式表达后，点云补全模块训练一个隐空间的 GAN 来实现隐空间补全。GAN 使用第二步预训练得到的分类网络来为噪声输入生成 3D 形状的表达。采用强化学习来指导点云的补全。

12.4.3 点云上采样

在现实世界中，点云通常由激光雷达采集，其中可能包含大量点。但在某些点云处理任务中，需要对点云进行降采样，以实现实时性和高效率。但是，降采样后的点可能会丢失一些局部细节信息，这不利于曲面重建和点云分析。

我们可以发现，点云上采样的重点是通过为下采样点云补充点来丰富坐标信息。给定一个稀疏点云 $P_S = \{p_i \in \mathbb{R}^3 | 0 \leq i < n\}$ 点云上采样的目的是从 P_S 中恢复出一个稠密点云 $P_D = \{p_i \in \mathbb{R}^3 | 0 \leq i < rn\}$ ，其中 n 是点的数量， r 是点的上采样因子[26]。这也是一个求解困难的问题。换句话说，给定一个密集的点云，它可以生成许多下采样的稀疏点云，反之亦然。早期的一些点云上采样方法[3, 23, 42]主要是根据现有的有限点云估计三维曲面。优化方法善于逼近局部几何形状，在以往的研究中已成为一种流行的策略。然而，先验信息主导了数学建模，带来了信息瓶颈。随着机器学习和深度学习的发展，最近基于学习的上采样方法考虑利用可训练的模型直接从输入的稀疏点云中恢复稠密点云。特别是深度学习已经显示出惊人的潜力，深度神经网络的优势在于可以充分利用外部数据。根据深度监督学习的常用规则，给定输入数据和相应的标签，就可以通过梯度下降的方法训练深度网络。其次，对于点云上采样，训练深度网络需要丰富的稀疏点云和相应的密集点云作为训练样本。给定稠密点云 P_D ，稀疏点云由下采样函数 f_l 生成。因此，给定 P_S 和上采样网络 U_θ ，其中 θ 是可训练的网络参数，学习过程被视为优化下式[26]：

$$\theta^* = \operatorname{argmin} L(U_\theta(P_S), P_D)$$

其中, L 是训练中的损失函数。它用于测量上采样点云与目标高密度点云之间的距离。距离有多种形式, 如豪斯多夫距离 (Hausdorff distance)、倒角距离 (Chamfer distance)、点到面距离 (point-to-surface distance) 和地球移动距离 (Earth Mover's Distance)。在此, 本书主要介绍 EMD 距离, 其中, S_1 和 S_2 表示两个点集。该指标试图计算一个双投影 $\phi: S_1 \rightarrow S_2$ 以最小化上采样点云与目标密集点云之间的平均距离。而且 S_1 和 S_2 的大小应相同。可以写成

$$d_{EMD}(S_1, S_2) = \min_{\phi: S_1 \rightarrow S_2} \frac{1}{|S_1|} \sum_{x \in S_1} \|s - \phi(x)\|_2$$

12.5 技术展望

随着深度学习技术的不断发展, 及其在点云压缩与增强领域应用的逐步成熟, 基于深度学习的点云压缩与增强将具有更加广阔的发展和空间。虽然目前对于该领域的初步技术探索已经取得了一定的成效, 但是可以预见, 在深度学习的加持下, 点云压缩与增强未来可以在以下几个方面持续实现技术的突破和应用的拓展。

网络架构的优化与创新: 未来, 我们将会见证更多针对点云数据的深度学习网络的优化和创新。目前主流的点云压缩与增强技术主要基于卷积网络 (如 PointNet、PointNet++、SparseConv 等), 少量的方法已经将注意力 (Attention) 研究的最新进展引入到该领域, 未来的研究可能将集中在更高效、更适应点云处理的网络结构上。可能会有更多基于图和注意力机制的方法出现, 以更好地捕捉点云之间的拓扑关系和显著性区域, 从而提高点云数据的表示和压缩效率。

多模态数据融合: 点云数据通常与其他传感器数据 (如图像、激光雷达等) 相结合, 形成多模态数据。未来, 我们可以期待更多的研究集中于如何更好地融合多模态数据, 以提高点云数据的质量和可用性。深度学习在多模态数据融合方面的应用将进一步推动点云压缩与增强技术的发展。

面向特定场景点云压缩与增强：目前，许多点云压缩与增强的方法都是针对一般性的场景进行设计的，这样的通用性设计虽然可以在某些情况下表现良好，但在特定场景下往往会造成性能不尽如人意的问題。基于对特定场景的分析，发展专门的压缩与增强处理算法是有效提升算法性能的有效途径。例如，在室内环境下，点云数据可能会出现大量的平面结构，而在室外场景，点云数据则可能包含大量的曲面或不规则形状。通过充分利用这些场景的先验信息，可以设计出更加精确和紧凑的压缩方案，从而在特定场景下实现更好的点云数据压缩效果。

硬件加速与云计算：随着深度学习模型的不断发展和复杂化，对计算资源的需求也越来越高。未来，我们可以预期硬件加速技术（如 GPU、TPU 等）的持续发展，以及云计算在点云压缩与增强方面的应用。这将使得深度学习算法能够更快速地处理大规模点云数据，并在实时场景下得到更广泛的应用。

算法鲁棒性研究：尽管已有的点云压缩与增强算法在实验数据集上表现良好，但在面对真实场景数据时，往往会面临数据的不确定性、噪声、遮挡、采样不均匀等问题，这些因素可能会降低算法的性能和鲁棒性。未来，专门针对提升算法的鲁棒性开展有针对性的研究也具有非常大的潜力。

实际应用拓展：除了传统的点云数据处理领域，未来深度学习在点云压缩与增强方面的应用将不断拓展到更多实际场景中。例如，自动驾驶领域将会更多地应用压缩或者增强点云数据来实现环境感知和路径规划；虚拟现实和增强现实技术也会更多地利用预处理后点云数据来实现更真实的交互和场景重建。

综上，目前深度学习点云压缩和增强方法还处于早期发展阶段，许多关键性的问题还没有得到解决。通过进一步深化研究、改进算法和拓展实验验证，深度学习点云压缩与增强技术将能够逐渐迈向成熟，

从而带来更多的实际应用和发展机遇。

本章编写人员：高伟、李革、范松林、谢良、高文旭、汪继龙、李浩辉、李要、刘旺

参考文献

- [1] GRAZIOSID, AKAGAMIO, UMAS, et al. An overview of ongoing point cloud compression standardization activities: video-based (V-PCC) and geometry-based (G-PCC) [J]. APSIPA Transaction Signal and Information Processing, 2020, 9.
- [2] G-PCC codec description, ISO/IEC JTC1/SC29/WG11 input document N0011, Online, October 2018.
- [3] R. L. de Queiroz and P. A. Chou. 2017a. Motion-Compensated Compression of Dynamic Voxelized Point Clouds. IEEE Transactions on Image Processing 26, 8 (Aug 2017), 3886–3895.
- [4] Bruckstein A M, Elad M, Kimmel R. Down-scaling for better transform compression[J]. IEEE Transactions on Image Processing, 2003, 12(9): 1132-1144.
- [5] Huang Y, Peng J, Kuo C C J, et al. Octree-Based Progressive Geometry Coding of Point Clouds[C]//PBG@ SIGGRAPH. 2006: 103-110.
- [6] Lien J M, Kurillo G, Bajcsy R. Multi-camera tele-immersion system with real-time model driven data compression[J]. The Visual Computer, 2010, 26(1): 3-15.
- [7] Kathariya B, Li L, Li Z, et al. Scalable point cloud geometry coding with binary tree embedded quadtree[C]//2018 IEEE International Conference on Multimedia and Expo (ICME). IEEE, 2018: 1-6.
- [8] Wang J, Zhu H, Liu H, et al. Lossy point cloud geometry compression via end-to-end learning[J]. IEEE Transactions on Circuits and Systems for Video

- Technology, 2021, 31(12): 4909-4923.
- [9] Zhang C, Florencio D, Loop C. Point cloud attribute compression with graph transform[C]//2014 IEEE International Conference on Image Processing. IEEE, 2014: 2066-2070.
- [10] Quach M, Valenzise G, Dufaux F. Improved deep point cloud geometry compression[C]//2020 IEEE 22nd International Workshop on Multimedia Signal Processing. IEEE, 2020: 1-6.
- [11] Quach M, Valenzise G, Dufaux F. Learning convolutional transforms for lossy point cloud geometry compression[C]//2019 IEEE international conference on image processing. IEEE, 2019: 4320-4324.
- [12] Biswas S, Liu J, Wong K, et al. Muscle: Multi sweep compression of lidar using deep entropy models[J]. Advances in Neural Information Processing Systems, 2020, 33: 22170-22181.
- [13] Wang J, Zhu H, Liu H, et al. Lossy point cloud geometry compression via end-to-end learning[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2021, 31(12): 4909-4923.
- [14] Wang J, Ding D, Li Z, et al. Multiscale point cloud geometry compression[C]//2021 Data Compression Conference. IEEE, 2021: 73-82.
- [15] Que Z, Lu G, Xu D. Voxel context-net: An octree based framework for point cloud compression[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 6042-6051.
- [16] Fu C, Li G, Song R, et al. Oct, Attention: Octree-based Large-scale Contexts Model for Point Cloud Compression[J]. arXiv preprint arXiv:2202.06028, 2022.
- [17] m58216, [G-PCC] Post-processing geometry super-resolution based on lookup tables, Renan U. B. Ferreira, Tomás M. Borges, Diogo C. Garcia, Ricardo L. de Queiroz, october 2021.
- [18] M58297, [AI-3DGC] Summary of the Performance Analysis of Current

- AI-based Available Solutions for PCC, Alexandre Zaghetto, Danillo Graziosi, Ali Tabatabai, October 2021.
- [19] m58166, On ADL-PCC Mode Selection, Online, October 2021.
- [20] m58167, Point cloud geometry compression using learned octree entropy coding, Online, October 2021.
- [21] m58170, [AI-3DGC] On Experiments with Learning-based PCC, Online, October 2021.
- [22] L. P. Tchapmi, V. Kosaraju, H. Rezatofghi, I. Reid and S. Savarese, "TopNet: Structural Point Cloud Decoder," 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Long Beach, CA, USA, 2019, pp. 383-392, doi: 10.1109/CVPR.2019.00047.
- [23] Y. Yang, C. Feng, Y. Shen and D. Tian, "FoldingNet: Point Cloud Auto-Encoder via Deep Grid Deformation," 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018, pp. 206-215, doi: 10.1109/CVPR.2018.00029.
- [24] Wei Yan, Ruonan Zhang, Jing Wang, Shan Liu, Thomas H. Li, and Ge Li. 2020. Vaccine-style-net: Point Cloud Completion in Implicit Continuous Function Space. In Proceedings of the 28th ACM International Conference on Multimedia (MM '20). Association for Computing Machinery, New York, NY, USA, 2067–2075.
- [25] Alexa, M., Behr, J., Cohen-Or, D., Fleishman, S., Levin, D., and Silva, C. T. Computing and rendering point set surfaces. *IEEE Trans. Vis. Comput. Graph.* 9, 1 (2003), 3–15.
- [26] Li, Z., Li, G., Li, T. H., Liu, S., and Gao, W. Semantic point cloud upsampling. *IEEE Transactions on Multimedia* (2022), 1–1.
- [27] Huang, H., Wu, S., Gong, M., Cohen-Or, D., Ascher, U. M., and Zhang, H. R. Edge-aware point set resampling. *ACM Trans. Graph.* 32, 1 (2013), 9:1–9:12.

- [28] Wu, S., Huang, H., Gong, M., Zwicker, M., and Cohen-Or, D. Deep points consolidation. *ACM Trans. Graph.* 34, 6 (2015), 176:1–176:13.
- [29] Akman, O., Jonker, P. (2010). Computing Saliency Map from Spatial Information in Point Cloud Data. In: Blanc-Talon, J., Bone, D., Philips, W., Popescu, D., Scheunders, P. (eds) *Advanced Concepts for Intelligent Vision Systems. ACIVS 2010. Lecture Notes in Computer Science*, vol 6474. Springer, Berlin, Heidelberg.
- [30] E. Shtrom, G. Leifman and A. Tal, "Saliency Detection in Large Point Sets," 2013 IEEE International Conference on Computer Vision, Sydney, NSW, Australia, 2013, pp. 3591-3598, doi: 10.1109/ICCV.2013.446.
- [31] F. P. Tasse, J. Kosinka and N. Dodgson, "Cluster-Based Point Set Saliency," 2015 IEEE International Conference on Computer Vision, Santiago, Chile, 2015, pp. 163-171, doi: 10.1109/ICCV.2015.27.
- [32] X. Ding, W. Lin, Z. Chen and X. Zhang, "Point Cloud Saliency Detection by Local and Global Feature Fusion," in *IEEE Transactions on Image Processing*, vol. 28, no. 11, pp. 5379-5393, Nov. 2019, doi: 10.1109/TIP.2019.2918735.