

密级：公开

北京邮电大学

# 硕士学位论文



题目：基于域迁移的气象卫星图像云分类技术研究

学 号：2020140254

姓 名：孔祥羽

学科专业：通信工程(含宽带网络、移动通信等)

培养方式：全日制

导 师：张彬

学 院：人工智能学院

2023年06月05日

中国·北京

密级：公开

# 北京邮电大学

## 硕士学位论文（专业学位）



题目：基于域迁移的气象卫星图像云分类技术研究

学 号：2020140254

姓 名：孔祥羽

学科专业：通信工程（含宽带网络、移动通信等）

培养方式：全日制

导 师：张彬

学 院：人工智能学院

2023年6月5日

Secret Level: public

# Beijing University of Posts and Telecommunications

Thesis for Master Degree (Professional Degree)



**TITLE: Research On Meteorological Satellite  
Image Cloud Classification Technology  
Based On Domain Adaptation**

Student ID: 2020140254

Candidate: Xiangyu Kong

Subject: Communication Engineering

(including broadband network, mobile communication, etc.)

Training method: full-time

Supervisor: Bin Zhang

Institute: School of artificial Intelligence

June 5, 2023

## 答辩委员会名单

职务	姓名	职称	工作单位
主席	肖波	副教授	北京邮电大学
委员	杨红英	高级工程师	中国电力科学院新能源研究所
委员	刘刚	副教授	北京邮电大学
秘书	张彬	副教授	北京邮电大学
答辩日期	2023年5月30日		

# 基于域迁移的气象卫星图像云分类技术研究

## 摘要

云在天气预报、气象灾害预防和生态环境监测中起着重要作用，因此对云的精准分类具有重要意义。传统的云分类方法主要利用统计观测和阈值筛选等人工方式，无法满足实时分类的要求。近年来，随着深度学习的发展，利用遥感数据和神经网络技术对云进行分类成为研究热点。

在当前的云分类任务中，现有的深度神经网络方法与遥感数据的融合性不佳，未能充分发挥气象卫星性能。此外，不同卫星之间数据分布差异较大，使得在不同域中获取全方位、细粒度的云分类标签费时费力。为节省计算资源和降低标注成本，如何在标注完备的气象卫星数据域中训练出高性能的模型，并将此模型迁移到不同卫星数据域中应用，成为一个亟需解决的实际问题。因此，本文围绕基于域迁移的气象卫星图像云分类技术开展了以下的工作：

1.针对气象卫星图像的特点，本文设计了通道维度特征融合、多尺度特征融合和像素级别注意力机制模块，创新地实现了近似实时的10类云分类。同时，提供了可视化的结果展示，提高了云分类结果的可读性。

2.针对不同卫星之间通道缺省导致的域间差异问题，本文提取气象卫星的数据特征，通过对抗学习弱化域间差异，实现了风格一致性迁移，进而解决了目视解译难的实际问题。同时验证了气象卫星领域内域迁移的可行性，为本文构建最终的云分类域迁移模型提供了有力支持。

3.针对比目视解译更复杂的云分类域迁移问题，本文在风格一致性迁移的基础上，增加了内容一致性模块设计，以提升云分类模型的泛化能力，更好地利用气象卫星数据，实现了更具普适性的云分类任务。

综上所述，本文提出的基于域迁移的气象卫星图像云分类技术具有重要的应用价值和科学意义，可以为天气预报、气象灾害预防和生态环境监测等领域提供更好的支持。

**关键词：**云分类 无监督域迁移 迁移学习 语义分割 深度学习

# RESEARCH ON METEOROLOGICAL SATELLITE IMAGE CLOUD CLASSIFICATION TECHNOLOGY BASED ON DOMAIN ADAPTATION

## ABSTRACT

Cloud plays an important role in weather forecasting, meteorological disaster prevention, and ecological environment monitoring, therefore accurate cloud classification is of great significance. Traditional cloud classification methods mainly use manual methods such as statistical observation and threshold screening, which cannot meet the requirements of real-time classification. In recent years, with the development of deep learning, using remote sensing data and neural network technology for cloud classification has become a research hotspot.

In the current cloud classification task, the existing deep neural network methods have poor fusion with remote sensing data, and have not fully exerted the performance of meteorological satellites. In addition, there are significant differences in data distribution between different satellites, making it time-consuming and laborious to obtain comprehensive and fine-grained cloud classification labels in different domains. How to train a high-performance model in the domain of complete meteorological satellite data annotation, and apply this model to different satellite data domains to save computational resources and reduce annotation costs, has become an urgent practical problem. Therefore, this paper focuses on the research work of meteorological satellite image cloud classification technology based on domain transfer:

1. In view of the characteristics of meteorological satellite images, this paper designs channel dimension feature fusion, multi-scale feature fusion, and pixel-level attention mechanism modules, which innovatively achieve nearly real-time classification of 10 types of clouds. At the same time, visualization results are provided to improve the readability and

visualization effect of cloud classification results.

2. In response to the current problem of domain differences caused by channel defaults between different satellites, this paper extracts data features of meteorological satellites, weakens domain differences through adversarial learning, and achieves style consistency transfer, thereby solving the practical problem of visual interpretation. At the same time, the feasibility of domain transfer in the field of meteorological satellites is verified, providing strong support for the construction of the final cloud classification domain transfer model in this paper.

3. In response to the more complex cloud classification domain transfer problem compared to visual interpretation, this paper adds a content consistency module design based on style consistency transfer to improve the generalization ability of cloud classification models and better utilize meteorological satellite data to achieve more universal cloud classification tasks.

In summary, the meteorological satellite image cloud classification technology based on domain transfer proposed in this paper has important application value and scientific significance, and can provide better support for fields such as weather forecasting, meteorological disaster prevention, and ecological environment monitoring.

**KEY WORDS:** cloud classification; unsupervised domain adaptation; transfer learning; semantic segmentation; deep learning

# 目 录

第一章 绪论.....	1
1.1 研究背景及目的.....	1
1.2 国内外研究现状概述.....	2
1.3 待解决问题.....	3
1.3.1 气象卫星云分类待解决问题.....	3
1.3.2 云分类域迁移待解决问题.....	3
1.3.3 目视解译问题.....	4
1.4 主要工作与组织结构.....	4
1.4.1 论文主要工作.....	4
1.4.2 组织结构.....	6
第二章 相关技术及研究 .....	9
2.1 气象卫星图像云分类技术研究 .....	9
2.1.1 基于阈值的传统云分类技术.....	9
2.1.2 基于形态学处理的传统云分类技术.....	10
2.1.3 基于机器学习的气象卫星图像云分类技术 .....	11
2.1.4 基于深度学习的气象卫星图像云分类技术 .....	12
2.2 域迁移技术研究.....	14
2.2.1 基于特征对齐的域迁移技术.....	15
2.2.2 基于模型自适应的域迁移技术.....	16
2.2.3 基于生成式训练的域迁移技术.....	17
2.2.4 基于对抗性训练的域迁移技术.....	18
2.2.5 基于元学习的域迁移技术.....	19
2.3 遥感气象领域中域迁移的研究 .....	20
2.4 本章小结.....	20
第三章 数据描述及准备 .....	21
3.1 数据描述.....	21
3.1.1 葵花 8 号(Himawari-8)气象卫星数据 .....	21
3.1.2 风云 4 号气象卫星数据.....	23
3.1.3 基于葵花 8 号的云分类标签数据.....	25
3.1.4 数据可视化对比.....	26
3.2 数据准备.....	27
3.3 本章小结.....	28
第四章 基于气象卫星的像素级云分类模型的设计与实现 .....	29
4.1 像素级云分类模型设计(VecNet).....	29

4.2 关注通道维度的特征融合模块设计 .....	31
4.3 多尺度特征融合的云分类模块设计 .....	32
4.3.1 云分布呈现空间分异性.....	32
4.3.2 多尺度特征融合的云分类模块.....	32
4.4 像素级别的注意力机制模块设计 .....	33
4.4.1 注意力机制.....	33
4.4.2 像素级别的注意力机制模块.....	34
4.5 实验细节与评估指标.....	35
4.5.1 实验细节.....	35
4.5.2 评估指标.....	36
4.6 实验结果与对比分析.....	36
4.6.1 消融实验.....	36
4.6.2 经典模型性能对比.....	37
4.6.3 可视化结果分析.....	38
4.7 本章小结.....	40
第五章 基于域迁移的气象卫星云分类模型的设计与实现 .....	41
5.1 基于域迁移的气象卫星图像云分类模型设计 .....	41
5.2 风格一致性迁移.....	42
5.2.1 特征编码器设计.....	42
5.2.2 源域分割网络/目标域特征提取器设计 .....	43
5.2.3 域鉴别器设计.....	43
5.3 内容一致性迁移.....	44
5.3.1 内容一致性意义.....	44
5.3.2 基于 Patch 的内容一致性模块设计.....	44
5.4 实施细节和评估指标.....	46
5.4.1 实验细节.....	46
5.4.2 评估指标.....	47
5.5 实验结果与对比分析.....	47
5.5.1 模型性能对比.....	47
5.5.2 相关消融实验.....	48
5.5.3 可视化结果分析.....	50
5.6 本章小结.....	51
第六章 总结与展望 .....	52
6.1 论文总结.....	52
6.2 未来工作展望.....	53
参考文献.....	55

# 第一章 绪论

## 1.1 研究背景及目的

云在天气预报和警报中起着关键作用，它们协助推动了地球上的水循环和整个气候系统。在气象领域中，云类型的精准评价对于天气预报、气象灾害预防和生态环境监测具有重要意义。

过去已有的方法大部分均利用统计观测、阈值筛选等人工方式完成对于云的分类。近年来，卫星技术的进步让遥感数据研究云的特性提供了极大便利，且由于深度学习的迅猛发展，使得神经网络技术与遥感领域结合成为了可能。并且由于云种类在日常生活、气象研究、工业施工等多个方面均为极大的影响因素，所以使用遥感领域的气象卫星数据，完成实时的云分类任务成为了目前研究的热门领域。

另外，伴随对科学探测和研究、天气预报、跟踪导航等各个领域的需求，越来越多的气象卫星被发射至太空，完成气象领域相关任务。除按照轨道分为极轨气象卫星和同步气象卫星之外，由于探测通道、卫星姿态、数据传输方式的不同，卫星观测数据间具有特征化、个性化和不兼容等特点，进而造成了不同气象卫星数据域间存在差异问题。很多研究在标注完备的气象卫星数据域内，训练出高性能模型，再将此模型迁移应用到不同卫星数据域之中，以节省算力和人力标注成本。已有的域迁移工作中，基于对抗的方式和基于生成的方式占据了极大比重。但如何能够精准分析出对抗和生成的内部原理，并将其应用在气象卫星领域内，就成为了本课题文的研究内容之一。除此之外，还需研究确定完成域迁移后的数据特征，能否有目的性的应用至云分类任务中，支撑本科题的研究目标。

另外，此部分研究需要完成对气象卫星数据的深刻深入理解。对哪种气象卫星数据可以提取特征，提取后的数据特征是否可用于域迁移有精确判断。另外，如何能够将域迁移技术应用在气象领域，且在此领域内做出适应性调整和改变，均为本部分研究所待调研和解决的内容。

综上所述，如何能够对可利用的气象卫星，更普适性实现及时的云分类便成为了本文研究目的与研究方向。

## 1.2 国内外研究现状概述

根据国际卫星云气候学项目(ISCCP)的定义,目前云包括卷云、环云、深对流云、高云、中云、低云、积云、层云、层积云和无云十种类型。

近年来,随着气象卫星观测技术的不断提高,获取的卫星图像数据也越来越多。其中,云分类技术是气象卫星应用中的一个重要研究领域。基于阈值法的传统云分类方法是气象学领域中最先应用的一种云分类方法。其基本思想是根据气象卫星图像灰度阈值对图像进行数值化处理,将云和非云像素分开后,使用不同范围对该像素点上云类别进行细分。

传统的基于阈值法的云分类方法简单易懂,且计算效率较高,是气象卫星图像云分类中最先的一种方法。但是,该方法的准确性较低,对于复杂的云层结构难以处理,且需要手动设定阈值,不同图像需要不同的阈值,操作复杂。因此,在实际应用中,该方法已经逐渐被基于深度学习的方法所替代。例如,Zhang 等人<sup>[1]</sup>使用葵花 8 号卫星数据训练了全卷积神经网络,并成功应用该网络完成了提取对流云的任务,本论文将在 2.1 节中更为详细的介绍深度学习方法在气象卫星图像的研究现状。

当直接使用标记数据进行训练和测试新数据会面临数据分布显著差异的挑战,进而造成模型在不同领域的数据上表现出明显的性能衰退,这种差异被称为域差异。无监督域适应(UDA)方法旨在提取不同领域的数据和知识,以减轻领域转移的影响。实现无监督领域适应目标的最简单方法之一是将其他域的数据外观转化为类似或标准样式,这些方法统称为生成性训练(GT)方法<sup>[2-11]</sup>。预训练的模型通常在这些方法中表现良好。然而,这些方法中大多数依赖于生成方法,有时不够稳定,因此难以保证语义一致性。为了解决这个问题,出现了一种全新的学习方法,即对抗性训练(AT)。许多基于 AT 的方法试图通过计算到窄边缘分布或联合分布的距离<sup>[12-15]</sup>或设计一个域鉴别器来实现域混淆<sup>[16-22]</sup>,以识别不同域之间的多层次域不变特征。然而,这些方法很难跨域对齐同一类别,可能会由于对源域知识的过度学习而导致目标域上的负转移。

在现实生活或工业场景中,无监督领域适应方法可能面临越来越复杂的问题,例如不一致的类别空间来源、目标域中未知类别的出现<sup>[23-26]</sup>、来自不同设备的数据收集引起的多域迁移<sup>[27-30]</sup>、由于源域数据注释不准确和特征提取问题<sup>[31,32]</sup>引起的频谱和时间转移等问题以及障碍监督学习<sup>[33,34]</sup>。因此,基于上述问题,标准的无监督域适应方法需要进行扩展,以应对不一致的标签空间设置下的挑战,例如开放集域自适应(OSDA)和部分域自适应(PDA)等。

目前,基于深度学习的云分类方法已经成为当前的主流,但是在现实应用中,不同气象卫星所获取的图像数据存在着很大的差异,因此如何解决不同气象卫星图像之间的域差异,成为了当前研究的热点问题。换言之,基于域迁移的气象卫星图像云分类技术研究,旨在通过深度学习和域迁移方法,克服不同气象卫星图像之间的域差异。目前,国内外的研究者已经开展了相关的研究工作。在遥感气象卫星数据领域,这种域迁移的影响因素可以分为三类:与数据采集和成像相关的因素、与任务和注释相关的因素以及其他因素。通过考虑这些因素,可以更好地应对领域转移挑战,并提高模型的泛化性能和实用性。

本小节仅对国内外研究现状进行系统性概述,在第二章中将分类别完成相关技术及研究的详细介绍。

### 1.3 待解决问题

深入分析国内外研究现状后,本文将基于域迁移的气象卫星图像云分类技术研究待解决问题细化如下:

#### 1.3.1 气象卫星云分类待解决问题

过去气象卫星的云分类任务大部分基于传统阈值方法,云产品分类生成速度较慢,实时性差。已有的云分类深度学习方法虽在速度上有所提升,但准确度低,精确度差,难以实际应用。

传统阈值方法在实现从气象卫星数据到输出云类型的过程中,需要人为选取阈值,对于像素级的云分类任务而言,需要耗费大量时间和算力。除此之外,复杂的预处理过程,手动多维参数的选取和人工分析的干预处理,都会给云分类任务的准确度和可信度增加不确定性。

相比阈值法,目前云分类任务中已有的深度神经网络方法遥感数据融合性差,未充分利用气象卫星数据特点,参数量庞大,推理速度较慢。并且,获取人工标注或成熟卫星云产品提供的细粒度标注费时费力,训练出的模型分类精度较低,很难满足目前需求。

#### 1.3.2 云分类域迁移待解决问题

目前域迁移技术大量应用于深度学习的语义分割之中。不同于图像分类等任务,由于语义分割需要像素级别的人工标注,费时费力,无法大规模实施。根据调研,目前已有借助于计算机虚拟图像技术,如3D游戏,用户可以几乎无成本地获得无限量自动标注数据。换言之,目前的域迁移技术主要在学术集上表现

良好, 相比其他领域而言, 深度学习技术和气象领域目前结合较少, 少有工作完成在气象卫星数据特征域的迁移。

区别于普通数据集, 不同气象卫星由于需要提取不同波段的信息, 因此会存在通道数量不匹配的问题。但气象卫星均是从太空对地球及其大气层进行气象观测, 本质上观测的内容一致, 因此不同的气象卫星观测结果一定存在着内在联系。

而且, 在实际的遥感应用中, 要实现精确的地面观测, 仍存在许多实际问题。例如, 在观测过程中可能需要识别未知的类别, 或者可以与多颗卫星结合, 以实现综合判断。目前已知的多种气象卫星, 如葵花 8 号气象卫星和风云 4 号气象卫星, 二者数据由于探测波段、传感器设计等多方面因素, 会存在通道数量不匹配的问题。而目前的深度学习由数据驱动, 因此必然存在由于数据域差异导致的模型泛化性能差问题。

以上述两卫星为例, 葵花 8 号气象卫星拥有 16 通道数据, 而风云 4 号气象卫星仅有 14 通道数据, 由通道数量不匹配出现的数据域差异问题, 进而引发的模型泛化能力差问题都是实际应用中需要迫切解决的难点。另外, 对于后续发射计划中的更多气象卫星, 同样可能出现通道不匹配, 目标域无标签和下游任务表现差强人意的现象。因此, 如何在标注完备的气象卫星数据域中训练出高性能的模型, 并将此模型迁移到不同卫星数据域中应用, 成为一个亟需解决的实际问题。

### 1.3.3 目视解译问题

目视解译, 作为域迁移领域中的一个代表性问题, 同样是气象卫星领域需要解决的重点。由于风云 4 号卫星缺少一个可见光通道, 其生成的可见光图片对比葵花 8 号气象卫星来说存在不符合观感、下游任务使用不佳的问题。解决此问题的关键在于弱化域间差异, 完成风格一致性的迁移任务, 但截止目前仍没有明确且高速有效的解决方案。所以, 如何在完成上述两个问题的基础之上, 解决已有的气象卫星目视解译问题也成为本文的研究重点。

因此, 本文基于域迁移领域内现有技术, 以云分类作为主要切入点, 完成气象卫星数据特征域的迁移, 解决目视解译问题, 最终实现基于域迁移的气象卫星云分类任务。

## 1.4 主要工作与组织结构

### 1.4.1 论文主要工作

本文基于域迁移领域内的问题, 针对性完成气象卫星数据的域迁移工作, 并将云分类作为主要切入点, 最终设计出基于域迁移的气象卫星云分类模型。

如图 1-1 所示,为解决立项依据中所提出的待解决问题,本文主要从两部分开展工作:第一部分设计出基于气象卫星数据的像素级云分类模型,针对单一气象卫星完成云分类任务。在此基础上,第二部分引入不同域卫星数据,完成域迁移的云分类任务,构建出基于域迁移的气象卫星云分类模型。

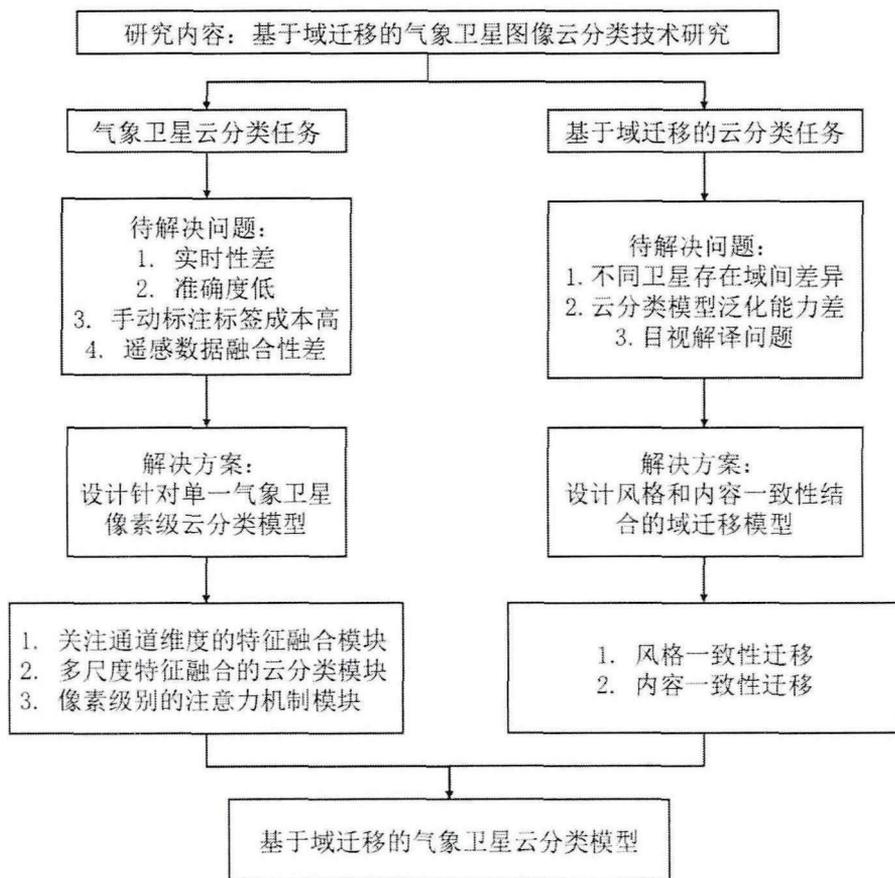


图 1-1 本文具体的研究内容组成图

### 1. 气象卫星云分类任务主要工作:

传统的云分类方法存在实时性差、准确度低和手动标签标注成本高等问题。因此,本文的第一部分工作致力于完成针对单一卫星的像素级云分类任务。通过设计通道维度的特征融合、多尺度的特征融合的云分类和像素级别的注意力机制模块,创新地实现了准确高效的 10 类云分类。

### 2. 基于域迁移的云分类任务主要工作:

本文第二部分工作通过对气象卫星数据的特点进行分析,更好地理解数据的特点和局限性,从而有针对性地提取出关键特征。接着,本文利用已提取出的特征,实现了针对气象卫星数据的风格一致性迁移和内容一致性迁移。风格一致性迁移可以初步解决不同气象卫星数据之间的域迁移问题,实现数据的风格一致性

转换。再通过内容一致性迁移，可以实现在不同气象卫星数据之间共享信息和知识，从而提高单一气象卫星的云分类模型的泛化能力。这种方法可以帮助本文更好地利用气象卫星数据，提高气象卫星图像云分类的准确性和鲁棒性。

综上所述，本文的工作可以总结为以下几点：

1. 针对气象卫星数据特点，创新实现了接近实时的 10 类云分类。将云分类结果以可视化图片形式展示，提高了云分类结果的可读性，同时也为进一步的研究提供了数据基础和可视化分析手段。
2. 针对不同卫星之间通道缺省导致的域间差异现状，本文提取气象卫星的数据特征，通过对抗学习弱化域间差异，实现了风格一致性迁移，进而解决了目视解译难的实际问题。同时验证了气象卫星领域内域迁移的可行性，为本文构建最终的云分类域迁移模型提供了有力支持。
3. 与目视解译问题相比，云分类问题更为复杂，本文以风格一致性迁移为基础，加入内容一致性模块设计，提升云分类模型泛化能力，从而更好地利用气象卫星数据。

本文工作对气象卫星图像云分类和气象预报领域的研究和应用具有重要意义，为相关领域的进一步发展和应用提供了有力支持。

#### 1.4.2 组织结构

本文一共包括六章。结合研究内容，本文章节组织结构如图 1-2 所示：

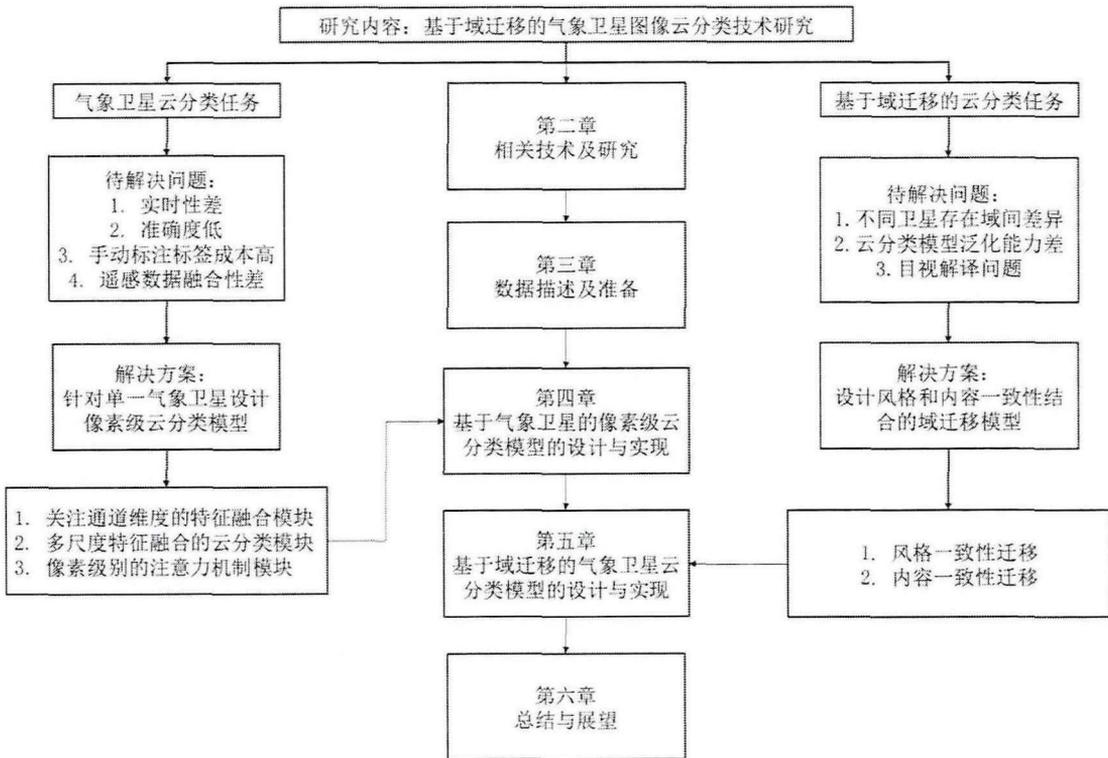


图 1-2 组织结构

第一章首先介绍本文的研究目的，并对目前国内外研究现状进行了综述，分析了其中待解决的问题，概括了本文为解决这些问题开展的主要工作。

第二章介绍相关技术及研究。分别对气象卫星图像云分类技术研究现状和域迁移技术研究现状进行详细分析。其中，气象卫星图像云分类技术目前可分为基于阈值、形态学处理、机器学习和深度学习的方法。域迁移技术中，又可细分为基于特征对齐、模型自适应、生成式和对抗式训练的方法，另外元学习的域迁移方法目前也有部分研究成果。在本章最后，对遥感气象领域的域迁移和云分类任务研究现状进行系统化讲解和阐述。

第三章对完成了对基于域迁移的气象卫星图像云分类的数据描述，分别详细介绍了日本的葵花 8 号（Himawari-8）气象卫星和我国自主研发的风云 4 号气象卫星，阐述了本文使用的卫星数据及标签的准备过程，且进行了数据可视化对比。

第四章介绍基于单一气象卫星数据的像素级云分类模型，以葵花 8 号气象卫星为例详细阐述该模型设计思路。设计的轻量模型 VecNet 包括整合多通道维度的特征融合模块、多尺度特征融合模块和像素级别注意力模块。通过与传统模型的对比实验以及消融实验，证明了 VecNet 的性能优越性。最后，实验结果进行可视化分析。

第五章介绍基于域迁移的气象卫星云分类模型的设计细节。首先，简要介绍了整体模型结构，然后详细介绍了风格一致性迁移和内容一致性迁移两个方面的气象卫星图像域迁移过程。在风格一致性方面，该方法采用特征编码器、共享权

重的源域分割网络/目标域特征提取网络和鉴别器等模块实现功能。其次，结合遥感气象卫星数据的具体分析，引入了基于 Patch 的内容一致性模块，用于保证迁移过程中语义内容的前后协同。再次，详细描述了实施细节和评估标准，对实验结果进行了分析，包括与传统模型的性能比较、气象卫星域迁移的可行性验证和内容一致性模块的消融实验。通过实验验证，解决了风云 4 号气象卫星目视解译困难的问题，证明了风格一致性迁移方法在气象卫星领域内的可行性。最后在消融实验中，通过模型可解释性的角度对模型效果进行分析，提出了一些特有的思考。第六章对全文进行总结，并对存在的问题和未来发展做出展望。

## 第二章 相关技术及研究

本章重点阐述基于域迁移的气象卫星图像云分类的相关技术及研究。分别对气象卫星图像云分类和域迁移两个研究方向技术进行归纳总结,并详细介绍二者在遥感领域内的交叉研究进展。

### 2.1 气象卫星图像云分类技术研究

根据国际卫星云气候学项目(ISCCP)的定义,目前云包括卷云、环云、深对流、高积云、高积云、积云、积云、层云和无云十种类型。目前基于单一地球静止卫星数据的云类型分类研究已经有一定研究基础,具体研究现状如下:

#### 2.1.1 基于阈值的传统云分类技术

##### 2.1.1.1 基于单一阈值的云分类

基于单一阈值的云分类是最简单的阈值法分类技术,其原理是根据图像灰度阈值将图像二值化,并将像素分为云和非云两类。该技术的优点是计算速度快,适用于对简单云层的分类。但对于复杂云层,由于其像素灰度值变化大,单一阈值难以准确地区分云层的不同部分,导致分类精度较低。

##### 2.1.1.2 基于多阈值的云分类

基于阈值法的传统云分类技术是气象学领域中最先应用的一种云分类技术。其基本思想是分析图像像素的阈值,利用多光谱的物理特性,对光谱的波段进行阈值定制,进而完成云分类任务。其基本处理思想如下:

1. 预处理:首先对气象卫星图像进行预处理,包括去除边界噪声、进行背景平均值的估计等操作。
2. 灰度化:将彩色气象卫星图像转换成灰度图像。
3. 阈值分割:根据预设的灰度阈值,将灰度值大于阈值的像素判定为云像素,再以云像素为基础,细化阈值区间,区别出不同的云种类。将灰度值小于阈值的像素判定为非云像素。
4. 后处理:对于分割结果中的小孔和小斑点进行去除,以及对云层的形态进行修正。

上述基于阈值法的传统云分类技术简单易懂,且计算效率较高,是气象卫星图像云分类中最早的一种技术。Bai<sup>[35]</sup>等人就利用此种思想,使用红外亮温和红外亮温差(BTDIR)阈值对云进行检测。红外亮温和红外亮温差阈值法是传统的云

检测技术之一，其基本原理是利用云层和地表的热辐射特性，通过设置阈值来区分云和非云像元。通过比较图像中每个像元的亮温值与预先设定的阈值，将像元分为云和非云两类。然而，该技术的准确性受到多种因素的影响，如云的形态、高度、温度等，同时由于红外亮温在云层与地面之间的反射和透过作用，以及大气吸收和发射等因素的影响，可能会导致像元的亮温值偏高或偏低，从而影响云检测的准确性。

进而使用了红外亮温差阈值法是对红外亮温阈值法的改进。通过计算两个红外波段的亮温差，即红外波段  $10.8\mu\text{m}$  和  $12.0\mu\text{m}$  之间的差值，来区分云和非云像元。由于云层的高度、温度等因素的影响，云层的 BTDIR 值通常较低，而地面的红外亮温差值通常较高，因此可以通过设置阈值来区分云和非云像元。然而，此种红外亮温差阈值法仍然存在着准确性低、对于复杂云层结构难以处理、需要手动设定阈值等缺点。

因此，此阈值法虽然在实践中应用广泛，但对于复杂的云层结构难以处理，且需要手动设定阈值，不同图像需要不同的阈值，操作复杂。

云类型检测的分窗算法(SWA)，是一种广泛应用于云类型检测的传统方法。SWA 的基本做法是根据热红外波段图像得到亮度温度(BT)和亮度温差(BTD)之间的二维散点图，然后根据经验确定几个阈值，将图像划分为代表不同云类型的区域。SWA 通常结合 13 波段 ( $10.4\mu\text{m}$ ) 和 15 波段 ( $12.4\mu\text{m}$ )，用于对葵花 8 号气象卫星<sup>[36]</sup>观察到的云图像进行分类。SWA 方法的可行性得到了多方面的印证。例如，美国国家航空航天局和法国国家空间研究中心共同合作完成的太阳轨道地球侦察卫星 CALIPSO，利用其处理后的数据与地面仪器数据和舰载观测数据<sup>[37,38]</sup>进行匹配结合，印证了 SWA 的云类型分类算法<sup>[36]</sup>的合理性。然而，SWA 方法的缺点也显而易见。首先，这些传统的云类型分类方法需要手工设计特征和精心选择分类阈值。其次，随着对遥感图像的像素要求越来越高，阈值法已经难以满足高分辨率和高精度的需求。此外，SWA 方法对于复杂的云层结构难以处理，且不同的云图像需要不同的阈值，操作复杂，时间和人力成本也极高。

### 2.1.2 基于形态学处理的传统云分类技术

随着理论体系的发展和现实需求的不断增长，使用阈值的传统技术已经不能满足实际应用。因此，基于形态学处理的云分类技术初见雏形。

此种云分类技术是一种利用形态学理论和技术对云图像进行特征提取和分类的技术。其将形态学处理技术应用于云图像中的像素点和像素点集合，通过提取和分析云的形态特征来实现云的分类。

形态学处理技术包括膨胀、腐蚀、开、闭、梯度等运算，这些运算可以改变云图像的形状和大小，并将云图像中的连通域进行分离。例如，膨胀运算可以使

云的边界更加平滑,使云的形状更加规则;腐蚀运算可以消除云中的小孔洞和小斑点,使云的轮廓更加清晰。和基于阈值的传统云分类技术比较,基于形态学处理的云分类技术一般包括以下基本思想:

1. 图像预处理:此步骤与上述基于阈值的云分类技术类似,包括去除噪声、图像增强等步骤。
2. 形态学处理:通过膨胀、腐蚀、开、闭、梯度等运算提取云图像的形态特征。
3. 特征提取及选择:基于形态学处理后的图像,提取云的特征,如云的形状、大小、纹理等。再根据上述所提取到的特征重要性,选择最具代表性的特征。
4. 分类器设计:利用传统方法设计出分类器对云进行分类。

基于形态学处理的云分类技术具备了传统阈值技术所不具备的优点:不需要手动设定阈值,避免了传统云分类技术中需要手动选择阈值的问题;能处理复杂的云层结构,对云的不规则形状、空洞、并联和重叠等情况能够有效地处理;能提取更多的云特征,对云的形状、大小、纹理等特征都有较好的提取效果。

但是,基于形态学处理的云分类技术也存在一些不足,由于在形态学处理时,膨胀、腐蚀、开、闭、梯度等运算是按照像素级别内容进行计算和选择,所以处理速度相对较慢,需要较高的计算资源和时间。

另外,由于是基于形态学的相关操作,所以对于图像的质量要求极高。存在着因为图像质量差而导致输出的效果波动问题,产生难以信赖的相关为题。另外,此技术对于图像中的噪点极为敏感,在像素与其他周围像素进行膨胀和腐蚀计算中,若存在难以判断出的噪点,将极大影响云分类的准确率。基于以上问题,该技术在气象卫星云分类领域中应用场景有限。

### 2.1.3 基于机器学习的气象卫星图像云分类技术

传统机器学习技术是指使用经典的监督学习算法进行训练和分类的技术,常见的算法包括支持向量机、决策树、朴素贝叶斯和随机森林等。这些算法通过对样本数据的学习,构建一个分类模型来对新的数据进行分类预测。在云分类领域,传统机器学习技术通常将遥感图像的像素作为特征,通过对不同云类型的气象卫星图像进行训练和分类,实现对云的自动分类。

C Vaduva<sup>[39]</sup>等在其研究中采用了贝叶斯推理来提取卫星图像的特征,并将其分配到基本语义中进行云分类。他们使用的数据包括多个波段的卫星图像,通过将这些波段的信息融合来增强分类效果。经过验证,相比于传统的云分类技术,基于贝叶斯推理的方法能够更准确地识别各种类型的云;在此基础上,基于支持向量机和随机森林来进行云分类技术也应运而生,利用卫星数据提取不同的特征,

如颜色、形状、纹理等，并通过这些特征来区分不同类型的云。研究表明，相比于基于阈值和形态学处理传统的云分类技术，基于随机森林的技术能够更好地处理复杂的云层结构和纹理信息，从而提高分类准确率。

除了传统的机器学习技术，一些改进算法也被应用到云分类中，例如 k 近邻方法。此技术在传统机器学习技术上取长补短，更进一步提升了云分类精度和效率。

k 近邻算法是一种基于实例的学习技术，其基本思想是对于一个新样本，通过计算其与训练样本集中 k 个最相似样本的距离，来确定其所属的类别。k 近邻算法在云分类中被广泛应用，其优点是简单易懂，适用于小样本数据。曾有工作理解 k 近邻算法思想，提出了一种基于光学厚度的云类型分类技术，但结果表明该技术的准确率较低，不足以支持实际使用；另外在此基础上，同样存在一些基于 k 近邻算法的卫星云图分类技术，通过将植被和云分开来，降低了分类错误的可能性，进而从新角度使得云分类更加准确。但是其缺点是需要保存大量的训练数据，计算复杂度较高，且对样本分布的依赖性较强。

综合来看，传统的机器学习技术在云分类中有着广泛的应用，这些技术通过提取和选择不同的特征来进行云分类，具有较好的分类效果。然而，这些技术需要人工设计和选择特征，缺乏自适应性和泛化能力，同时也难以处理高维数据和复杂的云层结构，因此在实际应用中存在一定的局限性。随着深度学习技术的发展，越来越多的基于深度学习的云分类技术得到了广泛的关注和研究。

#### 2.1.4 基于深度学习的气象卫星图像云分类技术

随着深度学习技术的发展，其在气象卫星图像云分类领域的应用也越来越广泛。传统的基于特征提取的云分类技术需要人工设计特征，而且特征提取过程可能会丢失一些重要信息。而深度学习是一种基于神经网络的机器学习技术，通过多层次的非线性变换学习输入数据的多维度信息，自动从原始数据中学习到最优的特征表示，大大提高了分类的准确性和效率。其次，深度学习技术具有很强的泛化能力和鲁棒性。气象卫星图像中的云的形状和颜色可能会受到气象条件、时间和空间等因素的影响，传统的机器学习技术可能无法适应这些变化，而深度学习可以自适应地处理这些变化。

因此，在气象卫星图像云分类领域，深度学习技术已经被广泛应用，并取得了很好的分类效果。

深度学习算法中最常用的是卷积神经网络。卷积神经网络是一种专门用于处理图像数据的神经网络，它可以自动学习图像的特征，从而实现图像的分类。Cheng 等人<sup>[40]</sup>提出了一种简单而有效的判别 D-CNNs (Discriminative Deep Convolutional Neural Networks) 学习技术，该技术通过对遥感图像进行特征学习

和分类学习,提高了遥感图像场景分类的性能。该技术将传统模型中的全连接层替换为判别层,从而提高了模型的判别性能。同时,该技术还采用了正则化技术来避免过拟合,并采用了动态学习率调整技术来提高训练速度和准确率。该技术在多个遥感数据集上都取得了较好的分类效果,证明了深度学习技术在云分类领域的有效性和实用性;Zhang 等人<sup>[41]</sup>使用葵花 8 号卫星数据训练了全卷积神经网络,并成功应用该网络完成了提取对流云的任务。在该研究中,作者通过将传统的卷积神经网络中的全连接层替换为全卷积层,实现了对不同大小的输入图像进行端到端的像素级分类。还采用了数据增强来避免过拟合,并使用了交叉熵损失函数来优化模型。实验结果表明,该技术在对流云的提取任务中取得了较好的效果,证明了全卷积神经网络在遥感领域及云分类任务中的应用前景。SCGID<sup>[42]</sup>中基于葵花 8 号卫星数据使用深度学习技术生完成了云分类,分类结果如图 2-1 所示(不同颜色代表该地理位置的不同云种类)。

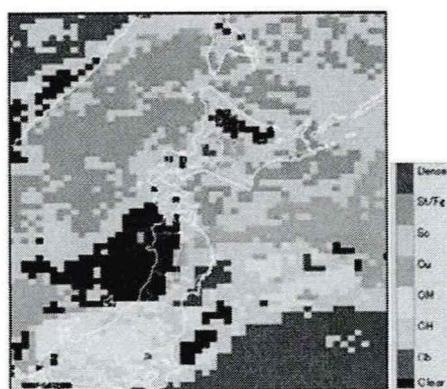


图 2-1 SCGID 云分类结果

从图 2-1 结果中不难发现,目前已有的深度学习技术生成的云分类结果中,云种类较少,精度和准确度较差。另外,一些现有的深度神经网络如 Fully Convolutional Networks<sup>[43]</sup>(FCN)使用葵花 8 号卫星数据,在精确度上进行了部分提升,实现云分类的表现与葵花 8 号卫星云分类产品图如图 2-2 所示:

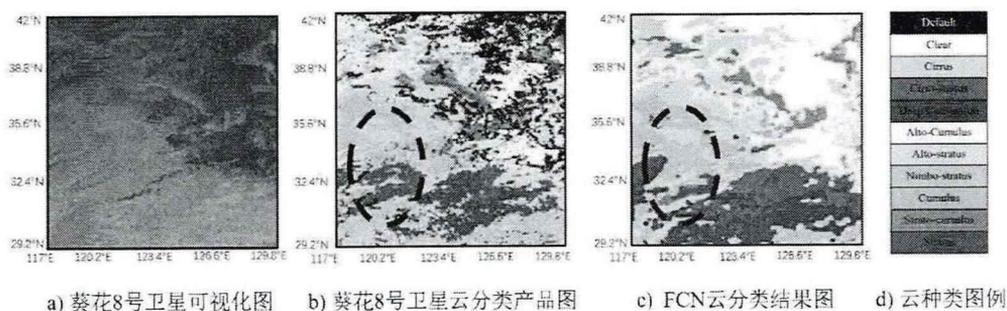


图 2-2 a)葵花 8 号卫星可视化图、b)葵花 8 号卫星云分类产品图(真值), c)Fully Convolutional Networks (FCN)云分类结果, d)云种类图例

图 2-2 黑色圈内，可明显发现 FCN 云分类结果分辨率较低，对于云类型细节分割极为模糊，且推理速度慢。由此不难得出，目前深度神经网络技术存在与遥感数据融合性差，参数量庞大，推理速度较慢，且分类精度低和泛化能力极弱等缺点。

除此之外，不同气象卫星观测数据间具有特征化、个性化和不兼容等特点。以风云 4 号卫星和葵花 8 号气象卫星数据可视化为例，由于风云 4 号卫星对比葵花 8 号气象卫星缺少关键的可见光通道，目视解译时造成可视化图片存在观感差，结果展示与实际观测存在较大差距，下游任务难以有效开展等问题。陈博洋<sup>[42]</sup>等人根据多通道扫描辐射成像仪反射通道的响应特点，在没有符合人眼红绿蓝响应通道的情况下，提出了新的真彩色图像合成方法，但其效果距离真实观测仍存在一定差距。

经调研，域迁移任务能够解决上述模型泛化能力不足，不同气象卫星数据特征域不兼容的问题，因此为将域迁移技术应用至云分类任务中，提升云分类模型的泛化能力，域迁移任务是不可缺少的一环。

## 2.2 域迁移技术研究

域迁移是指在机器学习和人工智能领域中，将从源域（source domain）中学习到的知识迁移到目标域（target domain）中，以达到在目标域上更好的泛化效果的技术。在深度学习领域，由于神经网络对数据的需求比较高，需要大量的标注数据进行训练，但实际应用中标注数据较为有限，因此域迁移技术在解决这一问题上具有很大的潜力。另外在实际应用中，数据的来源和分布可能会发生变化，导致在不同的域上出现不同的分布，从而影响深度神经网络的泛化能力。域迁移技术旨在通过将源域中学到的知识迁移到目标域中，以提高模型在目标域上的性能。其主要目的是解决由于数据分布变化而导致的数据偏移问题，进而提高模型的泛化能力。

目前，域迁移技术已被广泛应用于各个领域，例如自然语言处理、计算机视觉、机器人控制等。近年来，随着深度学习技术的不断发展，越来越多的研究者开始探索基于深度学习的域迁移技术，以解决数据分布变化问题。其中，基于特征对齐的域迁移技术、基于模型自适应的域迁移技术、基于对抗学习的域自适应技术和基于元学习的域迁移技术等方法已经被广泛研究和应用。

### 2.2.1 基于特征对齐的域迁移技术

基于特征对齐的技术是一种经典的域适应技术，其核心思想是通过对齐源域和目标域的特征分布，使得它们的特征空间尽可能相似，从而实现在目标域上的泛化能力。在实际应用中，由于不同域之间存在差异，会导致源域和目标域的特征分布存在较大差异，从而导致在目标域上的泛化性能较差。

为了解决这一问题，基于特征对齐的技术主要有两种实现方式，分别是最大均值差异化和对抗性自编码器。

#### 2.2.1.1 最大均值差异化 (Maximum Mean Discrepancy, MMD)

最大均值差异化技术是一种通过最小化源域和目标域之间的均值差异来实现域适应的技术。具体地，通过将源域和目标域的特征映射到一个共享的隐空间中，计算两个域之间的距离，并将其最小化，使得它们的分布尽量相似，从而实现域之间的对齐。与其他基于特征对齐的技术不同，MMD 技术不需要知道源域和目标域的具体分布，只需要知道它们的样本集合。此外，MMD 技术具有计算效率高、易于实现等优点。

在深度学习领域中，MMD 技术被广泛应用于任务中。例如，Long 等人在 2015 年<sup>[44]</sup>中提出了一种基于 MMD 技术的深度域适应技术。该技术通过将卷积神经网络的特征映射到一个共享的隐空间中，并使用 MMD 技术来对齐源域和目标域的特征分布，从而实现域之间的迁移。实验结果表明，该技术在多个图像分类数据集上均取得了较好的效果；后续<sup>[45]</sup>在 MMD 技术上进行改进，提出了一种新颖的深度域适应技术，与传统的域适应技术不同，该技术考虑到了源域和目标域之间的属性和身份信息之间的关系，并通过联合训练来实现域适应。具体地，TJ-AIDL 包括三个部分：一个共享的 CNN、一个特定于域的分类器和一个属性-身份的相关性学习模块。通过联合训练，TJ-AIDL 可以学习到可迁移的特征表示，从而实现源域到目标域的迁移。

然而，MMD 技术也有一些不足之处。其在计算 MMD 距离时需要知道源域和目标域的核函数，但在实际应用中这两个核函数通常是未知的，并且需要手动调整核函数的超参数。此外，当源域和目标域的分布差异较大时，MMD 技术的效果可能会受到影响。

#### 2.2.1.2 对抗性自编码器 (Adversarial Autoencoder, AAE)

AAE 技术是一种基于对抗学习的域适应技术，与上述最大均值差异化不同，其核心思想是通过对源域和目标域的特征进行编码和解码，通过引入一个对抗性的训练机制，使得源域和目标域的特征在隐空间中重合，并且训练一个判别器来区分源域和目标域的特征。

此技术中，与计算 MMD 距离并将其最小化不同的是，编码器和解码器被共同训练，通过最小化原始数据和解码器输出之间的差异，使得源域和目标域的数据在潜在空间中尽可能接近。然后，鉴别器被引入，来判断潜在向量是来自源域还是目标域。同时，编码器和解码器的训练目标变为最大化鉴别器的错误率，即让鉴别器无法准确地区分源域和目标域的潜在向量，从而实现域之间的特征对齐。通过对抗性训练的方式，使得不同域的特征在隐空间中重合，同时通过训练一个判别器来区分源域和目标域的特征，从而实现域之间的特征对齐。

随着深度学习技术的不断提升，Zhou 等人<sup>[46]</sup>提出了联合优化的 AAE，它将判别器和重构损失合并为一个目标函数进行联合优化，从而提高了训练的稳定性和收敛速度。同时，此技术还引入了门限激活函数，以增强编码器的表征能力。此外，Li 等人<sup>[47]</sup>提出了一种基于层次特征对齐的 AAE，它使用层次特征对齐来提高迁移效果。具体而言，其使用了多个对抗网络，每个对抗网络对应一个层次，将层次特征对齐和总体特征对齐相结合，从而增强了迁移性能。

总的来说，基于特征对齐的技术是一种比较流行的域适应技术，其主要优点是可以有效地对源域和目标域的特征进行对齐，从而提高在目标域上的泛化性能。在实际应用中，针对不同的问题和数据，可以选择不同的特征对齐技术，以获得更好的效果。

### 2.2.2 基于模型自适应的域迁移技术

此技术中，基本思路是精准设计出特征提取器。与基于特征对齐的方式不同，此设计出的特征提取器可以使得从源域和目标域提取的特征分布是一样的。通过调整源域和目标域之间的模型参数，使得模型能够更好地适应目标域的数据分布，从而提高模型的泛化能力。

<sup>[48]</sup>提出了一种自监督域自适应网络，用于域自适应目标检测。该技术通过自监督任务学习共享特征，再使用一个对抗性学习模块来迭代地更新模型。实验结果表明，该技术在目标检测任务上的性能优于其他基线技术；同样，为解决在源域和目标域差异较大的情况下效果不理想的问题，Long 等人<sup>[49]</sup>提出了一种基于深度自适应网络的迁移学习技术，旨在解决在目标域中缺乏标注数据的情况下，如何通过源域中已有的标注数据来提高目标域的分类准确率。其中提出了深度自适应网络 (Deep Adaptation Network, DAN)。其核心思想是通过调整源域和目标域之间的差异，从而实现在目标域上的分类任务。具体地，DAN 包含一个特征提取器和一个分类器。在特征提取器中，源域和目标域分别共享前面的层，但是后面的层是针对不同的域进行训练的。在分类器中，源域和目标域之间共享所有层的权重参数。通过训练调整特征提取器中的参数，使得源域和目标域的特征分布更加接近，从而实现在目标域上的分类任务。Long 等人在多个数据集上进行

了实验，实验结果表明，DAN 在目标域上的分类准确率明显高于其他传统的迁移学习技术，证明了 DAN 的有效性；在<sup>[50]</sup>中，Sohn k 等人提出一种基于自监督学习和模型自适应的技术，用于进行人脸识别的域迁移。该技术使用自监督学习来学习特征表示，同时使用模型自适应来适应到新的未见过的目标域。具体来说，该技术使用一个额外的辅助任务来学习特征表示，该任务不需要标注数据。然后，使用一个自适应模块来对特征表示进行调整，以适应目标域的分布。实验结果表明，该技术在多个人脸识别数据集上取得了优秀的表现。

### 2.2.3 基于生成式训练的域迁移技术

生成式训练 (GT) 技术主要关注外观的差异，如颜色和纹理。这些技术的目标是生成视觉上相似的图像，以便使用来自源域的标签来开发一个在目标域中也被采用的高性能模型。因此，生成技术的关键问题是如何在语义和约束的指导下生成假图像。此类技术可分为如下几个部分：

#### 2.2.3.1 目标域风格化迁移

目标域风格化技术的主要目的是将源域图像转换为与目标域图像风格相似的假图像，从而最大限度地保持数据和标签的语义一致性。

传统的目标风格化迁移技术主要是基于匹配技术，如直方图匹配及其变体<sup>[52,53]</sup>、图匹配<sup>[51]</sup>、颜色常量算法<sup>[54]</sup>、灰色环境<sup>[55]</sup>等。虽然这些技术可以快速实现转移，但在面对巨大的域转移和新数据时，它们是不够的；此外，在面对多目标域时，很难获得良好的性能。例如，随机直方图匹配 (RHM)<sup>[53]</sup>匹配从不同域随机选择的源-目标对的直方图，而不是将源的每个直方图与整个目标域数据进行匹配。

为了解决传统技术的局限性，近年来出现了许多基于深度学习的目标风格化技术。ColormapGAN<sup>[2]</sup>提出通过学习传输颜色特征来生成假的训练图像。与 GAN<sup>[56]</sup>不同的是，本文在生成器中没有任何卷积或池化层，其中生成器由一个元素级矩阵乘法和一个矩阵加法运算组成。通过对初始分类器、ColormapGAN 和微调的训练，实现了目标风格化迁移；SemI2I<sup>[3]</sup>引入了一种新的数据增强技术，通过使用样式转移技术，如 AdaIN<sup>[57]</sup>，将目标域数据的样式转移到训练数据中，而在 AdaIN 模块中， $\sigma$  和  $\mu$  携带两个域的样式信息。该技术可以同时保证风格相似性和语义一致性；BiFDANet<sup>[58]</sup>提出了一种基于双向图像到图像转换技术的无监督域适应技术，充分利用这两个领域，克服单向域适应导致的低性能。

#### 2.2.3.2 源域风格化迁移

目前同样有研究认为，将目标数据转换为源域样式可以使用更全面的源域特征。在翻译过程中，需要保留图像细节和语义一致性，因此一些研究经常使用如 AdaIN<sup>[57]</sup>来完成源域风格化。比如 FCAN<sup>[59]</sup>中，由外观适应网络和表示适应网络

两个主要组成部分组成,通过搜索中间源将不同域的外观转换为域不变量可以实现域自适应,源域风格迁移方式在多域自适应中表现良好。

## 2.2.4 基于对抗性训练的域迁移技术

此技术与 2.2.1 中基于特征对齐的对抗性自编码器技术类似,核心思想均为对抗学习。

但是自编码器技术中,更侧重于将源域和目标域的数据都映射到一个隐空间中,然后在这个隐空间中对自编码器进行对抗训练,使得源域和目标域之间的特征分布尽可能的相似,从而达到域适应的目的。

而对抗性训练(AT)技术中,目标是提取特征级或像素级或两个层次的信息,以减少不同领域之间的差异,源域和目标域的数据都经过一个共享的神经网络进行特征提取,并将提取出的特征分别输入到一个分类器和一个对抗网络中。AT 技术中,一些特征级域自适应技术的确成功缩小了源域和目标域之间的域差距,如对齐二阶统计量、对比域差异等。AT 技术又可以更详细的划分为特征级、像素级和多层次的对抗训练技术,国内外对此同样有着不少的研究成果:

### 2.2.4.1 特征级的对抗性训练技术

Tzeng<sup>[60]</sup>等人借助对抗思路,提出了一种基于对抗性训练的域自适应技术,通过对抗训练的方式,实现了从源域到目标域的特征对齐。该技术包含两个部分:一个特征提取器和一个域分类器,其中特征提取器用于学习源域和目标域的共享特征,域分类器则用于判别源域和目标域。与 DAN 方案类似,此技术最小化源域和目标域的分类误差和最大化域分类误差,实现了特征对齐和域分类器的训练,在多个数据集上取得了优异的迁移效果;除此之外,<sup>[61]</sup>等人在过去技术的基础之上,剖析特征级别的内在关系,利用生成对抗网络实现了特征增强。和过去技术不同的是,此技术在目标域的特征中嵌入了一个额外的噪声向量,并通过一个生成器网络将其从特征中分离出来。生成器网络和鉴别器网络共同组成了一个对抗学习框架,通过对抗训练使得目标域的特征更加具有区分性,从而提高了分类性能。

### 2.2.4.2 像素级的对抗性训练技术

与迁移表象差异的生成训练技术和适应语义差异的基于特征的对抗性训练技术不同,像素级域适应主要影响输出空间,以缩小每个像素从源域和目标域预测之间的差距。解决上述问题的直接技术是设计一个输出空间的域鉴别器,以判断输出来自源域或目标域,如 AdaptSegNet<sup>[62]</sup>。

另外,<sup>[63]</sup>使用全卷积分割网络作为生成器来提取语义特征,并利用鉴别器结构基于二值交叉熵损失将预测结果与目标域区分开来。此外,论文<sup>[64]</sup>在遥感数据

道路检测中采用了类似的 CLAN 技术<sup>[65]</sup>, 将元素加乘后的类别级特征定义为全局特征, 并通过协同训练实践确定了类别级特征在源和目标之间的对齐程度。

#### 2.2.4.3 多层次特征的对抗性训练技术

基于挖掘更有效信息的挖掘, 许多论文致力于实现多层次特征对抗训练, 包括图像、区域、像素或语义级。例如, TA<sup>3</sup>N<sup>[66]</sup>利用图像级和区域级的域区分特征来迁移域差异, 并增加了可转移的注意机制, 以更多地关注突出的对象, 而更少地关注背景。此外, 许多研究构建了基于距离和基于 GAN 的训练之间的结合, 以实现适应。CsDA<sup>[67]</sup>嵌入到一个协同训练的对抗性学习网络中, 使用非常高分辨率光学航空图像进行土地覆盖映射, 以强调调整类别一致性和全局域一致性的重要性。Med-CMDA<sup>[79]</sup>提出了一个无监督领域适应框架与对抗学习图像分割模型, 该模型基于一个扩展的全卷积网络进行像素级预测。在不使用任何目标域标签的情况下, 将目标输入映射到与源域特征空间对齐的特征, 并取得了非常有前景的结果。

最近三年来, 越来越多的论文从特征层面和像素层面考虑了不同层次的融合, 如 CyCADA<sup>[68]</sup>、AdaptSegNet<sup>[62]</sup>等。此外, 在分割输出水平的转移之后, 也有许多检测任务使用多层次对抗训练策略来实现无监督域自适应。

基于对抗学习的域自适应技术优势非常明显, 通过对抗学习的方式让模型学习到源域和目标域之间的差异, 极大提升了模型的泛化能力。并且可以通过只利用源域数据进行训练, 在目标域中完成分类任务, 无需标注目标域数据, 避免了人工标注的成本和时间。换角度而言, 由于可以自适应地对不同的数据分布进行建模, 此技术可以处理非平稳的数据分布。

但同样, 目前国内外基于对抗学习的域迁移的研究中也暴露出一些问题。对抗过程中其实需要同步训练两个网络, 容易出现梯度消失和梯度爆炸的问题, 而且对抗学习技术中需要调整多个参数, 如生成器和判别器的学习率、权重衰减系数等, 需要耗费大量的时间和精力进行调试。

#### 2.2.5 基于元学习的域迁移技术

元学习技术目前在域迁移领域也同样有着一定的应用, 其基本原理是利用元学习算法来学习一个通用的特征表示, 然后在目标领域中进行自适应以提高模型的泛化能力。Sun 等人<sup>[69]</sup>发表了一种基于元学习的源域适应技术, 在元学习阶段, 模型通过学习多个任务的经验来构建一个通用的特征表示, 使得该特征表示对于不同任务的输入数据具有较好的鲁棒性和泛化性, 然后通过利用多个源域中的信息, 学习出通用的特征表示, 并且在目标领域中进行自适应

与 2.2.3 中对抗性训练的域迁移技术相近, 基于元学习的域迁移技术通常需要设计复杂的模型结构和优化算法来处理多个任务之间的关系。这些复杂的模型

结构和优化算法可能会增加模型的计算复杂度和训练时间,同时也会增加模型的难以理解和调试的复杂性。

### 2.3 遥感气象领域中域迁移的研究

随着遥感监测和计算机视觉技术的快速发展,上述技术中,尤其是深度学习相关技术在实现地球观测、气候变化甚至空间探索等应用方面取得了很大进展。但是,利用现有数据训练的模型不能直接用于处理新的遥感数据,而且标注新数据的标签也存在耗时多、效率低、劳动密集和准确率欠佳等问题。

无监督域迁移是上述问题的较好解决方案,其将有标签数据域定义为源域、无标签数据域定义为目标域,基本目的是在源域获取一个训练有素的模型,通过最小化两个领域之间的差异,使该模型在目标域中同样保持良好性能,进而解决由数据分布差异导致的模型泛化能力差的问题。国内外目前有许多基于自然数据的无监督域迁移技术,域迁移技术也借此在遥感气象领域也有了一定的应用:Jeon等人<sup>[70]</sup>应用了卷积神经网络传输学习(CNN-TL)模型来识别具有不同波段组合的海雾。徐等人<sup>[71]</sup>采用无监督的域迁移方式实现了不同波段卫星数据的海雾检测。目前还有工作<sup>[72]</sup>等通过对遥感卫星数据加入像素级别的域迁移技术,完成了端到端的语义分割网络。王<sup>[73]</sup>等人通过使用无监督的域迁移完成了图像分类目标。并且,在遥感卫星数据道路提取任务<sup>[74]</sup>中,域迁移任务同样取得了良好表现。

本文中的域迁移问题可进一步归结为上述的无监督域迁移问题。如何在解决单一气象卫星图像云分类的基础上,利用对抗训练的方式完成无监督的域迁移,是本文后续介绍的重点内容。

### 2.4 本章小结

本章重点阐述了基于域迁移的气象卫星图像云分类的相关技术及研究,分别对气象卫星图像云分类和域迁移两个研究方向技术进行归纳总结。对于气象卫星图像云分类技术而言,传统的阈值和基于形态学处理方法逐渐被机器学习和深度学习方法所替代。在域迁移技术中,详细介绍了基于特征对齐、模型自适应、生成式训练和对抗性训练等域迁移方法,它们共同构成了域迁移的主要技术手段。另外,通过对遥感气象领域中域迁移的技术分析,可将本文的域迁移问题归结至遥感领域内的无监督域迁移问题,后续章节将围绕此问题展开。

## 第三章 数据描述及准备

本章将对本研究中使用到的各类数据进行细致描述,介绍各卫星和十类云分类标签数据信息,完成可视化对比,并介绍了卫星数据及标签的准备和处理过程。

### 3.1 数据描述

#### 3.1.1 葵花 8 号 (Himawari-8) 气象卫星数据

葵花 8 号是一颗由日本气象厅运营的静止气象卫星,该卫星于 2014 年发射并包含 16 个探测波段,是一颗极为重要的气象卫星。葵花 8 号卫星具有静止轨道的特点,距离地球大约 3.6 万公里,覆盖范围从亚洲到澳大利亚的大部分地区。相比于运动轨道的卫星,其可以提供更为连续和稳定的观测数据,使得观测数据质量更高、覆盖范围更广,并且可以实现更为精细的时间序列分析。

葵花 8 号包含 16 个探测波段:3 个可见光波段,3 个近红外波段和 10 个热红外波段。不同的探测波段具有不同的分辨率,对应的空间分辨率为 0.5~2km,每 10 分钟进行一次探测。可见光波段用于观测云的形态、结构、运动和日地变化等,近红外波段用于观测云的温度和水汽分布,而热红外波段用于观测云的温度和水汽分布以及地表温度和地表特征。

首先是可见光波段,包括了波长为 0.47-0.52 微米的蓝光、0.52-0.60 微米的绿光和 0.63-0.69 微米的红光。这些波段可以用来观测地表反射的太阳光,从而获取云、海洋和陆地等表面的颜色、形状、纹理等信息。

其次是近红外波段,包括了波长为 0.86-0.87 微米的第一近红外波段、1.60-1.62 微米的第二近红外波段和 2.26-2.30 微米的第三近红外波段。这些波段可以用于监测地表植被覆盖、火山喷发等自然灾害、城市热岛效应等。另外近红外波段还可以用于大气中的气溶胶、二氧化碳和臭氧含量的检测,这些参数对于全球气候变化的研究有着重要意义。而且,这三个近红外波段可以用来观测地表和云层的反射率和发射率,对于区分云种类和地表等目标具有较好的效果。

再次是热红外波段,包括了波长为 3.48-3.90 微米的第一热红外波段、6.07-6.43 微米的第二热红外波段、6.88-7.02 微米的第三热红外波段、8.44-8.67 微米的第四热红外波段、9.54-9.72 微米的第五热红外波段、10.4-10.7 微米的第六热红外波段、11.2-11.4 微米的第七热红外波段、12.3-12.5 微米的第八热红外波段、13.2-13.4 微米的第九热红外波段和 13.8-14.0 微米的第十热红外波段。

其中需要关注的是,在热红外波段中的6个中红外波段(3.9、6.2、7.3、8.6、9.6和10.4微米)是最常用于卫星云检测的波段。由于大气层中的云层会吸收和反射辐射,这些波段可以检测到云层的温度和高度。另外,2个水汽波段(6.9和7.3微米)可用于检测大气层中的水汽含量,便于进行天气预测和防灾减灾。由于水汽是云层形成的原材料,水汽波段的数据可以帮助气象学家更准确地预测降水的可能性和时间。换言之,水汽波段也是判别云种类的一个重要维度信息。同时,它们还可以用于监测大气中的水汽含量,便于预测天气变化。这些波段可以用来观测云层和地表的辐射温度,从而推断出温度、湿度和云高等气象参数。

因为葵花8号数据的完备通道,该卫星可以用于研究热带气旋、海洋温度、火山活动、大气气溶胶等。通过观测热带气旋的形态和运动,可以预测其路径和强度,为相关地区的防灾减灾提供科学依据。

具体的通道信息如表3-1所示:

表3-1 葵花8号气象卫星通道信息

通道	波段	物理性质	
1	0.46 $\mu\text{m}$	植被、气溶胶 蓝光	可见光
2	0.51 $\mu\text{m}$	植被、气溶胶 绿光	
3	0.64 $\mu\text{m}$	低云,雾 红光	
4	0.86 $\mu\text{m}$	植被、气溶胶	近红外
5	1.6 $\mu\text{m}$	云相态	
6	2.3 $\mu\text{m}$	颗粒大小	
7	3.9 $\mu\text{m}$	低云、雾、森林火灾	红外
8	6.2 $\mu\text{m}$	中上层湿度	
9	6.9 $\mu\text{m}$	中层湿度	
10	7.3 $\mu\text{m}$	中上层湿度	
11	8.6 $\mu\text{m}$	云相态,二氧化硫含量	
12	9.6 $\mu\text{m}$	臭氧含量	
13	10.4 $\mu\text{m}$	云图像、云顶信息	
14	11.2 $\mu\text{m}$	云图像、海表温度	
15	12.4 $\mu\text{m}$	云图像、海表温度	
16	13.3 $\mu\text{m}$	云顶高度	

总而言之,葵花8号气象卫星数据在气象和遥感各领域中有极为广泛的应用,在云分类方面更是如此。

由于葵花 8 号气象卫星图像数据具有成熟的可视化界面、符合国际方法标准,而且可见光波段和红外波段都具有较高的分辨率和灵敏度,能够提供更为准确的云图信息。在此基础上可以通过对云分类数据的分析,可以了解云的类型、形态、高度、密度等特征,进而将云分类应用于气象灾害预测、农业生产、环境保护等领域。所以,葵花 8 号数据在云分类识别任务中具有显著的优势,因此在该研究中被选作源域数据。

### 3.1.2 风云 4 号气象卫星数据

风云 4 号气象卫星是中国气象卫星第四代星系的代表,于 2016 年 6 月 11 日发射升空。该卫星是中国气象卫星的第一颗全自主研发的定量遥感气象静止卫星,主要任务是提供高质量的气象、海洋、环境监测和气象服务。例如,可以用于气象预报、自然灾害监测和气候变化研究等,并且可以用于监测和预报热带气旋、暴雨、洪涝灾害、雪灾、沙尘暴、大雾等天气灾害,为公众提供准确、及时的预警信息;除此之外还可以用于海洋气象监测,包括海面温度、海面风速、海面高度、海流等参数的测量,为海事、渔业、航运等行业提供重要信息。更为重要的是,作为我国的第一颗全自主研发卫星,风云 4 号气象卫星为我国的云预测和云分类任务奠定了基础。

与 3.1.1 中的葵花 8 号气象卫星相比,风云 4 号气象卫星也是静止气象卫星,可以提供高时间和空间分辨率的观测数据,以支持我国气象预报、环境监测、自然灾害监测等领域。

但不同的是,与葵花 8 号气象卫星 16 个探测波段不同,风云 4 号气象卫星采用了国产高分辨率成像光谱仪,可实现光学和热红外高空间分辨率的观测,探测波段包括 2 个可见光波段,4 个近红外波段,6 个热红外波段和 2 个水汽波段。每 15 分钟进行一次探测。其中,可见光波段主要用于观测云、水汽等大气参数,近红外波段主要用于气溶胶和云检测,热红外波段主要用于测量地表温度和探测云高度,水汽波段则用于监测大气水汽含量和湿度变化等。具体的通道信息如表 3-2 所示:

表 3-2 风云 4 号气象卫星通道信息

通道	波段	
1	0.45~0.49 $\mu\text{m}$	可见光& 近红外
2	0.55~0.75 $\mu\text{m}$	
3	0.75~0.90 $\mu\text{m}$	
4	1.36~1.39 $\mu\text{m}$	短波红外
5	1.58~1.64 $\mu\text{m}$	
6	2.10~2.35 $\mu\text{m}$	
7	3.5~4.0 $\mu\text{m}$ (High)	中波红外
8	3.5~4.0 $\mu\text{m}$ (Low)	
9	5.80~6.70 $\mu\text{m}$	水蒸气
10	6.90~7.30 $\mu\text{m}$	
11	8.0~9.0 $\mu\text{m}$	长波红外
12	10.3~11.3 $\mu\text{m}$	
13	11.5~12.5 $\mu\text{m}$	
14	13.2~13.8 $\mu\text{m}$	

风云 4 号气象卫星的可见光和近红外通道包括了三个波段,分别为 VIS-0.6、VIS-0.8 和 VIS-0.4。其中, VIS-0.6 波段的波长范围为 0.55-0.75 微米,对应着绿色和黄绿色光; VIS-0.8 波段的波长范围为 0.75-0.90 微米,对应着红色和近红外光; VIS-0.4 波段的波长范围为 0.45-0.49 微米,对应着蓝色光。可见光通道数据可以用于云的监测,通过可见光通道数据,可以获取云的分布、类型、高度、厚度等信息,为天气预报、气候研究提供重要的观测数据。但是由于其成像光谱仪的原因,风云 4 号卫星与葵花 8 号卫星相比缺少一个可见光通道,在可见光图像的生成(使用前三个可见光波段进行合成生成彩色图像)过程中,无法准确地反映地表反射率的颜色差异,导致生成的彩色图像与实际地表颜色存在偏差,对比度低,难以准确反映地表的真实颜色。特别是在云、水体等场景下,可能会出现颜色失真的情况,使得可见光图像的反演结果不如其他卫星,同时也难以与实际观测进行精确的对比。因此,在对此卫星进行目视解译时,常常需要结合其他波段信息进行判断。

风云 4 号气象卫星的红外波段与葵花 8 号卫星类似,波段覆盖范围为 1.36-13.8 微米。在目前的数据分析中,我国将风云 4 号气象卫星的红外波段更详细的划分为短波红外、中波红外、水蒸气和长波波段四种波段。其中短波红外覆盖了 3 个波段,分别为 1.6-2.2 微米, 3.5-4.0 微米和 4.0-4.5 微米。风云 4 号气象卫

星在此波段的特点是温度灵敏度高，可以探测到地表和云顶的微小温度差异，被广泛应用于云和温度分析。

本文的研究中，由于葵花 8 号卫星包含了手动标注的像素级标签，因此它被用作源领域，而风云 4 号卫星没有像素级标签，因此它被用作域迁移的目标域数据。本文主要关注黄海和渤海的部分海域，这些海域云类型丰富，非常具有代表性。经度范围在  $116^{\circ}$  E 至  $141.6^{\circ}$  E 之间，纬度范围在  $19.4^{\circ}$  N 至  $45^{\circ}$  N 之间。

### 3.1.3 基于葵花 8 号的云分类标签数据

为研究全球云覆盖的变化和影响，国际卫星云气候学项目（ISCCP）是由国际气象组织发起的一个项目。在这个项目中，对云的分类标准被定义为了 ISCCP 标准。

按照国际云分类学标准，云可以被分为十种不同类型。其中，卷云、环云、深对流云、高云、中云、低云、积云、层云、层积云等九种类型是传统的云的分类，它们主要是根据云的形态、高度、组织形式等特征来划分的。这九类云以及无云情况共同构成了国际卫星云气候学项目（ISCCP）中的十种云类型。

具体来说，卷云是由薄透明的丝状云层组成，一般高度在 6 千米以上；环云是薄而广的云层，一般覆盖整个天空；深对流云是由气流上升形成的巨大云状物，可高达 15-20 千米；高云是白色薄片状云层，一般高度在 6 千米以上；中云是由平均高度在 2-6 千米之间的云层组成，可以覆盖整个天空；低云是形状较小的、由白色薄片状云层组成的云；积云是形态为球状或圆柱状的、密集的云团，一般高度在 2 千米以下；层云是水平延伸很大的云层，通常厚度较小；而无云则指天空中几乎没有云的情况。详细对比如表 3-3 所示：

表 3-3 云十种不同类型

云名称	高度范围	描述	
卷云	Cirrus	7公里以上	高层云，薄透明的丝状云层，白色或淡蓝色
环云	Cirro-stratus	6公里以上	高层云，比卷云更厚，呈现出一层均匀的薄云层
深对流云	Deep Convection	4公里以上	庞大而垂直的云，形成雷暴和降水
高云	Alto-Cumulus	6公里以上	包括卷云、环云和深对流云
中云	Alto-stratus	2-6公里	由平均高度在2-6千米之间的云层组成
低云	Nimbo-stratus	2公里以下	包括层云、积云和层积云
积云	Cumulus	2公里以下	独立的白色云，形状类似于棉花糖
层云	Stratus	2公里以下	水平延伸的云，通常形成一层灰色云层
层积云	Strato-cumulus	2公里以下	层云基础上，有一些独立的积云
无云	Clear	无固定高度	天空中几乎没有云的情况

在本文中，使用了标注于日本航空航天研究开发局（JAXA）P-Tree 系统的云分类标签，该云分类标签基于葵花 8 号气象卫星数据标注，符合 ISCCP 标准，且原始数据时间分辨率为 10 分钟，空间分辨率为 5km，符合本文使用需求。

另需要注意的是，在某些情况下可能会提供具有较低置信度的标签，本文在处理数据和后续模型训练过程中，注意了此类云标签的去除。

### 3.1.4 数据可视化对比

以 2020 年 2 月 6 日 05: 00（标准时间 08: 00 北京）收集的卫星图像为例，使用可见光通道合成彩色图像和葵花 8 号气象卫星 16 通道图像可视化结果如图 3-1 所示：

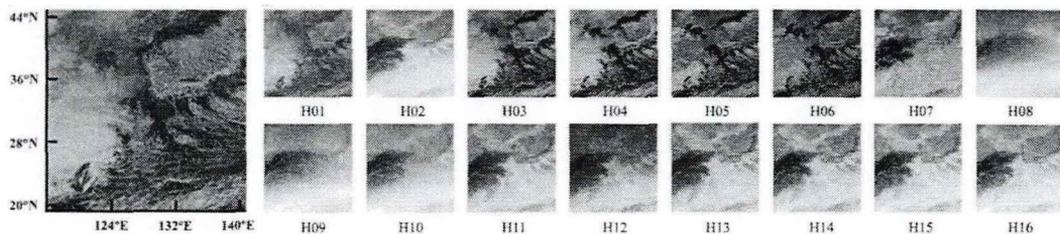


图 3-1 葵花 8 号气象卫星可见光图像及 16 通道图像可视化结果

由于风云 4 号气象卫星缺少一个可见光通道，因此图 3-2 仅展示同一时刻的风云 4 号气象卫星 14 通道图像可视化结果，不难发现两卫星之间的确存在着域间差异：

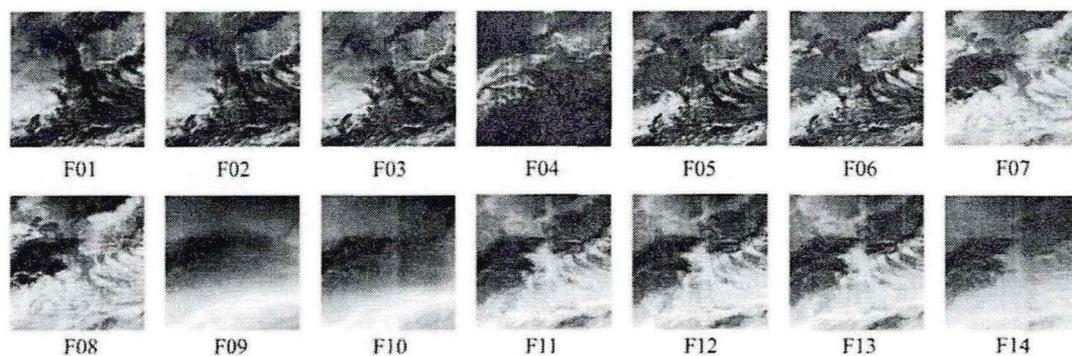


图 3-2 风云 4 号气象卫星 14 通道图像可视化结果

另外,由葵花 8 号气象卫星官网,下载并预处理同一时刻的十类云分类标签,可视化结果如图 3-3 所示:

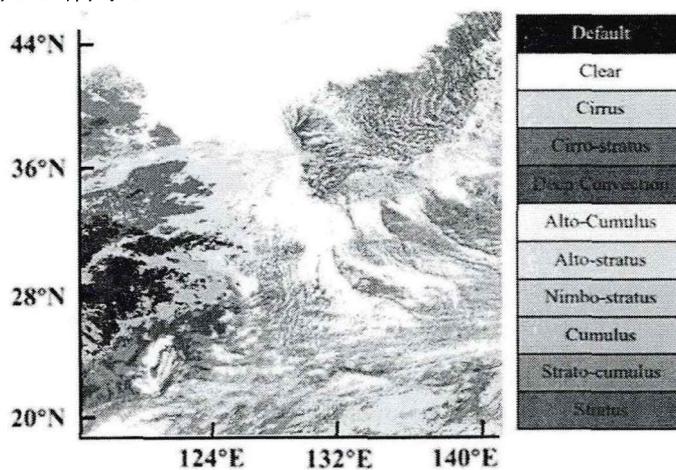


图 3-3 十类云分类标签可视化结果

### 3.2 数据准备

本文在实验开始前对收集到的气象卫星数据图像进行了预处理。为解决卫星图像的采集区域不均匀的问题,本文使用 NumPy 库中的函数,分别对葵花 8 号和风云 4 号气象卫星数据进行裁剪和对齐,并缩放到 512\*512 分辨率,以便在模型训练过程中进行比较和分析。同时,按照 4:1 的比例将数据集划分为训练集和验证集,确保数据样本的随机性和可靠性的同时,避免过拟合和欠拟合问题,从而提高模型的泛化能力。

本文云分类标签来自于 2020 年葵花 8 号卫星对 116°E-141.6°E, 19.4°N-45°N 区域的标注结果,其结果符合国际卫星云气候学项目 (ISCCP) 的云类型定义,并符合本文实验需求。为对齐于气象卫星图像数据,本文同样对云分类标签数据进行了裁剪和缩放,最终得到了 512\*512 像素的云分类标签,确保模型能够处理

足够的数 据，并保持了较高的空间分辨率。表 3-4 列出了卫星数据和云分类标签的详细信息，包括经纬度范围、时间间隔和图像大小等。

表 3-4 卫星数据的详细信息

数据	经纬度范围	分辨率	时间间隔	通道数	训练集	验证集
Himawari-8	116-141.6E	512×512	30min	16	1728	430
FY-4	19.4-45N			14	1524	325
标签	经纬度范围	分辨率	时间间隔	通道数	训练集	验证集
十分类云标签	116-141.6E 19.4-45N	512×512	30min	1	1728	430

### 3.3 本章小结

本章对本技术研究所使用到的各类数据进行了详细阐述，分别介绍了葵花 8 号气象卫星数据、风云 4 号气象卫星数据和作为标签的十类云分类数据。阐明各气象卫星数据特点，详细了解每个卫星的气象遥感器，接收地球及其大气层的可见光、红外和微波辐射频段。为清晰展示，本章对各类数据进行了可视化对比，并简明扼要介绍了数据处理和准备过程，为后续模型设计相关章节奠定基础。

## 第四章 基于气象卫星的像素级云分类模型的设计与实现

本章重点介绍了气象卫星数据像素级云分类模型的设计原理和实现思路。对各模块进行了消融实验，并将实验结果与经典模型的性能进行了对比总结。

### 4.1 像素级云分类模型设计(VecNet)

对于遥感图像，尤其是葵花 8 号等类似的多光谱气象卫星图像，在进行图像解译和下游任务使用时必须考虑光谱特征。例如，2.1.1 中曾介绍的 SWA 算法使用来自热红外波段图像的亮度温度(BT)和亮度温度差(BTD)进行云类型检测。BT 和 BTD 便是具有物理意义的光谱特征。因此，与传统的 RGB 图像不同，气象卫星数据具有更多的通道信息，因此需要更充分地提取通道间的联系。在对遥感图像进行云类型分类时，不能盲目地应用传统的深度学习网络，而必须考虑网络对光谱特征的敏感性。

基于 2.1 中对于气象卫星图像云分类技术的研究分析，遥感图像中所谓的光谱特征实质上是使用多个波段的数据执行单个函数操作以获取指标。换言之，传统方法大部分都是通过单个函数来实现对于光谱特征的计算和融合。目前已有的深度神经网络模型在处理气象卫星数据时往往无法充分利用通道间的关系，导致云分类效果不佳。

在本研究中，提出了一种深度卷积神经网络体系结构 VecNet，该结构可用于卫星图像的端到端像素级云分类。它不仅显著地简化了传统冗杂的过程，如复杂预处理，以及用于分析的人工干预，并且可以从每个卷积步骤中生成的一系列特征图中自动提取出识别出云类型所需的关键特征、亮度温度差、反射率阈值等参数，详细结构如图 4-1 所示：

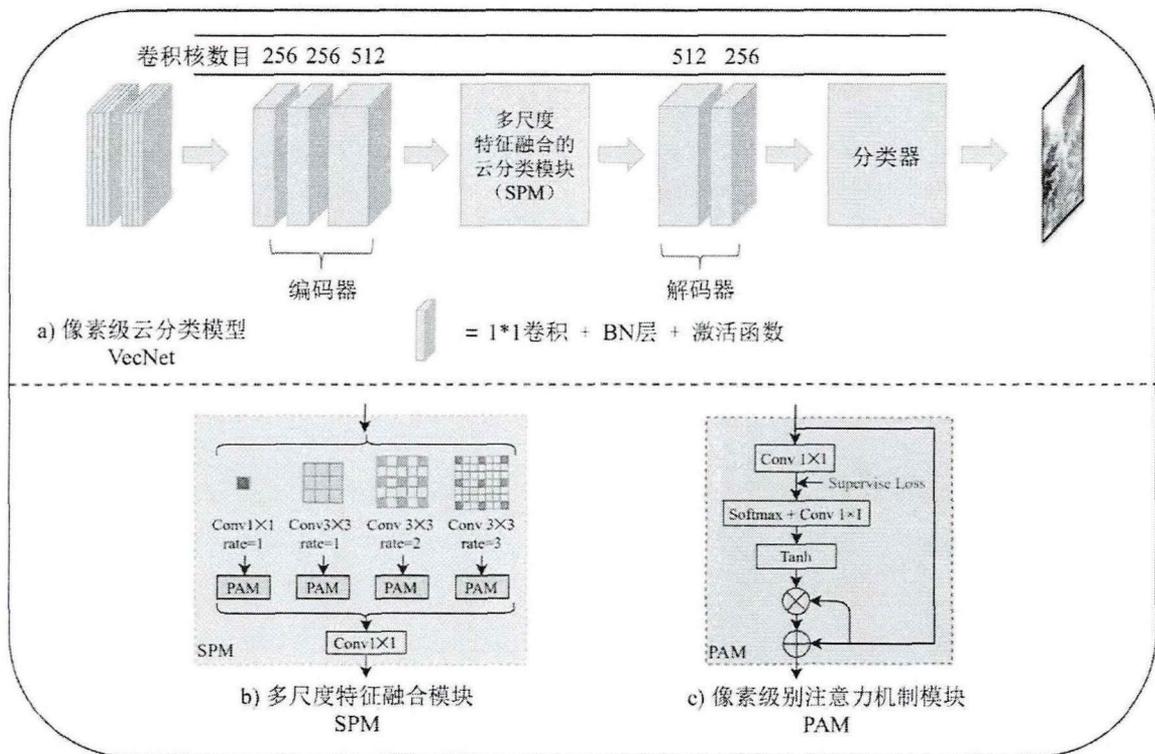


图 4-1 a)像素级云分类模型 VecNet、b)多尺度特征融合模块、c) 像素级别注意力机制模块

如图 4-1a)所示, 本模型设计时整体采用了图像分割经典模型的“编码器-解码器”结构, 并使用  $1*1$  卷积核来完成通道维度上的光谱信息整合和特征融合。此外, 该模型还使用了多尺度特征融合和像素级别的注意力机制模块来解决空间信息利用不够的问题, 并使用跳跃连接来提高粒度信息和分辨率。

“编码器-解码器”结构是图像分割任务中常见的模型结构, 它可以将输入图像进行特征提取和编码, 并将编码后的特征进行解码和重构, 最终得到与原始图像相同大小的分割结果。与常见分割模型中的  $3*3$ 、 $5*5$  卷积核不同, 本模型在“编码”和“解码”阶段使用了  $1*1$  卷积核完成通道维度上的光谱信息跨带整合。依据此通道维度的特征融合模块的设计, 即通过大量堆叠  $1*1$  卷积, 使得模型能在通道维度上更深入理解气象卫星多通道数据。另外,  $1*1$  卷积是在每个像素的通道维度上的一个可学习的线性组合, 通过构建足够的神经元和神经层可以适应任何功能需求。因此, 本模型使用了两个或两个以上的  $1*1$  卷积层可以提取非线性光谱特征。

在“编码器-解码器”中心部分中, 为解决空间信息利用不够的问题。本模型设计出了多尺度特征融合的云分类模块, 如图 4-1b)所示。通过使用空间金字塔结构, 在模型中心部分从空间层面理解气象卫星图像, 以不同尺度的空洞卷积来完成更为全面和深刻的图像理解。

额外需要提及的是, 本文注意到云的空间结构具有极大的特殊性。出了具备极为明显的空间分异性之外, 很多细粒度的云对于模型的实验结果起到了极大的

影响作用。具体而言,在使用空间金字塔结构后,周围像素点提取到的特征信息对中心点的云分类未起到辅助性作用,甚至是消极作用。因此本文在大量实验之后,引入了像素级别的注意力机制模块,用于辅助实现空间金字塔结构。通过输入权重的方式,更为合理的完成多尺度云分类任务。

此外,为提升粒度信息和分辨率,本文还添加了跳跃连接来补偿结构信息。跳跃连接是语义分割模型中的常见结构,它的主要作用是将不同层次的特征进行融合,以提高模型的性能。另外,本文在经过试验后引入3层跳跃连接,通过在模型中引入短路路径的方式,将高分辨率的特征图直接传递给解码层,以便更好地保留原始图像中的信息。

综上所述,本文采用了关注通道维度的特征融合模块、多尺度特征融合模块、像素级别注意力机制、跳跃连接等方法,深入调整了传统模型结构和方式,构建出适用性强、针对性高的信息特征提取方法,成功地解决了基于单一气象卫星的像素级云分类问题,本章后续将对每个模块进行具体介绍。

## 4.2 关注通道维度的特征融合模块设计

由本文3.1节可知,气象卫星观测数据具有数据特殊性。葵花8号气象卫星是日本气象厅运营的一颗新的地球静止卫星,其将Himawari成像仪作为传感器,提供了16个波段的数据,包含3个可见光(VIS),3个近红外(NIR)和10个热红外(TIR)波段。

与常规RGB三通道图像不同,气象卫星数据在一个像素点上拥有16个通道数据。每个数据为不同波段中提取到的重要信息,分别对应不同物理意义。但因此,相比目前已有的深度神经网络模型,本部分研究内容需要充分提取通道间关系,考虑采用多个 $1 \times 1$ 卷积或者通道间添加权重方式实现面向云分类任务的针对性改变。

$1 \times 1$ 卷积在深度学习中的应用不仅仅限于降低模型的维度和计算量,还可以实现通道信息的扩增和融合。在由于均为探测同一个地理位置的内容信息,所以16个通道数据间必然存在固有联系。因此如何在通道维度上进行深层次信息融合显得尤为关键,融合效果也将直接影响到云分类的最终精度和可信度。这时, $1 \times 1$ 卷积的作用就显得尤为重要。 $1 \times 1$ 卷积将通道信息扩增到高维表示,使气象卫星多通道数据实现更为深刻的通道信息融合。在卷积神经网络中, $1 \times 1$ 卷积可以看作是通道数为1的卷积核,它只能在通道维度上对输入数据进行卷积,对空间维度上的像素点没有影响。因此, $1 \times 1$ 卷积能够有效地实现通道之间的信息融合,而不会改变空间分辨率,从而避免了信息丢失。

## 4.3 多尺度特征融合的云分类模块设计

### 4.3.1 云分布呈现空间分异性

云是大气中水汽凝结形成的物质团块，其在空间中的分布具有明显的空间分异性。这些空间格局是由大气中的气流和温度等因素所引起的，同时还受到地形、季节和气候等因素的影响。

经调研，不同类型的云会形成不同的云系或云团，呈现出不同的空间格局。例如，锋面云通常呈线状或波浪状排列，气旋性云则常常呈环状或斑块状分布。这些云系或云团的形成和演化通常与大气中的气流和温度场的变化密切相关。此外，云的空间格局还会受到地形的影响。在山地地区，由于地形的影响，云会呈现出延伸状。类似地，在海洋和湖泊等水域地区，水体的影响也会对云的空间分布产生一定的影响。

综上所述，云分布的空间分异性是气象学研究中一个重要的方面，不仅能够反映大气中气流和温度等因素的变化，对于本文所研究的云分类具有极为重要的参考意义。

### 4.3.2 多尺度特征融合的云分类模块

神经科学实验已经证实，在人类视觉系统中，视网膜中央凹附近分布着大量具有不同尺寸感受区域的视锥细胞，这系列不同感受区域的细胞负责实现人眼的高清成像功能，也使得人类对一些细小的空间变化十分敏感。

同样，在空间分异性如此之强的云分类任务中，多尺寸的上下文信息往往对应着更好的分割效果。目前，这种多尺度感受野融合的方式在语义分割领域中已经受到了广泛研究。在云分类任务中，相比于单尺度的图像处理，空间金字塔结构具有以下优点：

1. 多尺度表示能够捕捉物体的多个尺度特征。由于不同云在卫星图像中的尺度不同，采用单尺度处理容易丢失一些重要的信息，而空间金字塔结构可以通过不同尺度的图像表示，从而捕捉到云的多个尺度特征，提高物体检测和识别的准确率。

2. 减少云位置不确定性。由于云在图像中位置不确定，而且不同尺度的云可能存在不同的位置和大小，使用空间金字塔结构可以减少物体位置不确定性的影响。通过对多个尺度的云进行处理，可以获得对物体位置和大小具有不变性的特征表示，提高云分类的稳定性和鲁棒性。

3. 提高计算效率。空间金字塔结构可以通过对图像进行分解，减少计算量和内存消耗，从而提高计算效率和处理速度。此外，空间金字塔结构还可以并行处

理多个尺度的图像，提高处理效率。通过调整模型结构的方式，使网络能够更好地整合语义信息。

受此启发，本文尝试在网络中融合多种感受野尺寸的特征图，借鉴语义分割中融合特征的方式，并根据云分类任务进行适应性改进，以提升网络提取图像特征的能力。使用空间金字塔结构以使得网络能够更好的捕捉到各类云之间细微的区别，从而提升云分类模型的效果。设计出的多尺度特征融合的云分类模块如图 4-2 所示：

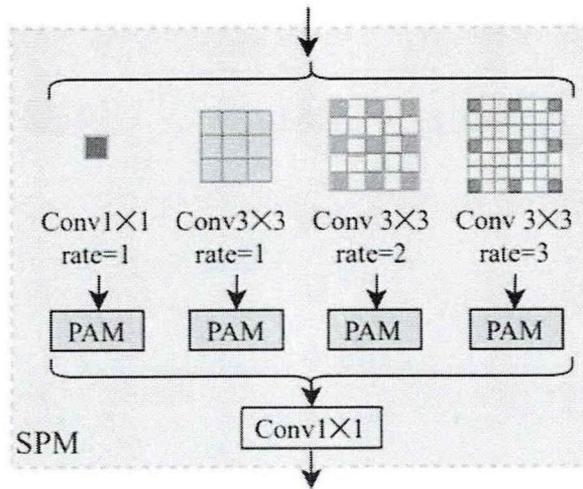


图 4-2 多尺度特征融合的云分类模块

图中可见，除  $1 \times 1$  卷积核外，额外采用 3 种独特的  $3 \times 3$  卷积核搭建出空间金字塔基本结构，空洞率分别为 1, 2 和 3。在不同尺度上，完成对于多种感受野的信息采集，并行送入到后续“解码器”模块之中。

## 4.4 像素级别的注意力机制模块设计

### 4.4.1 注意力机制

注意力机制是一种模仿人类视觉注意力机制的技术，用于在输入数据中选择和集中关注于特定区域或特征，以便更好地完成任务。此机制最早应用于自然语言处理领域中，常规的编码方法，无法体现对一个句子序列中不同语素的关注程度，在自然语言中，一个句子中的不同部分是有不同含义和重要性的，因此自然语言处理引入注意力机制本质上为一种基于深度神经网络模型的自动加权操作，将两个想要联系起来的不同模块，通过加权的进行联系，完成对不同重要程度的衡量和判别。

由于注意力机制在自然语言处理领域中的高效使用，计算机视觉领域内的注意力机制同样成为研究热点。在图像分类任务中，注意力机制可以帮助模型更好

地关注到图像中重要的局部区域，从而提高分类准确率。例如，一些基于注意力机制的分类方法可以在卷积神经网络中添加一些注意力模块，以便模型可以自适应地学习图像中重要的特征，从而提高分类性能。

受此启发，本文创新性提出云分类任务背景下的注意力机制模块。

#### 4.4.2 像素级别的注意力机制模块

像素级别的注意力机制模块设计可以帮助提高图像分割、分类等任务的性能，特别是在需要关注局部信息的任务中。在云类型分类中，每个像素点的云类型分类结果可能会受到周围像素点的影响，因此需要考虑周围像素点的权重分配，以更准确地对当前像素点进行分类。

本文注意到云的空间结构具有极大的特殊性。除了具备极为明显的空间分异性之外，很多细粒度的云对于模型的实验结果起到了极大的影响作用。具体而言，在使用空间金字塔结构后，周围像素点提取到的特征信息对中心点的云分类未起到辅助性作用，甚至是消极作用。因此本文在大量实验之后，引入了像素级别的注意力机制模块，用于辅助实现空间金字塔结构。通过输入权重的方式，更为合理的完成多尺度云分类任务。

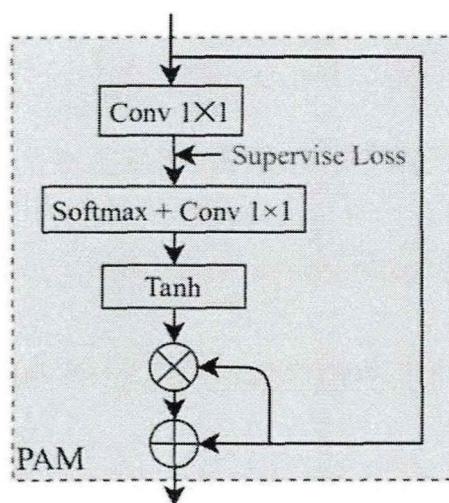


图 4-3 像素级别的注意力机制模块

如图 4-3 所示，为了实现云空间结构的细粒度应用，在多尺度特征融合的基础上引入了像素级别的注意力机制。具体而言，该模块可以通过以下步骤实现：

- 1.对于输入的图像，使用尺度特征融合的云分类模块提取特征。对于每个像素点，使用不同的卷积核对周围的像素点进行卷积操作，得到周围像素点的特征表示。

- 2.当前像素点和周围像素点，分别使用  $1 \times 1$  卷积，得到升维后的结果。与此同时，引入监督损失 (Supervise Loss)，完成辅助训练。接着，计算不同云像素

点之间的相似度，并将相似度作为权重来度量周围像素点的重要性。并用激活函数对权重进行归一化，以确保所有权重之和为 1。

3.通过围像素点的特征表示与对应的权重进行加权求和，得到一个聚合的特征。将聚合的特征表示与当前像素点的特征表示进行拼接，再通过后续的  $1 \times 1$  卷积层操作来提取更高层次的特征表示。

4.最后输入至全连接层中，并引入 Tanh 激活函数对当前像素点注入重要性权重，进而实现云类型的辅助分类。

通过引入像素级别的注意力机制，可以让周围像素点以不同的权重来帮助当前像素点的云类型分类，从而提高云类型分类的准确率。同时，由于该模块考虑了多尺度特征融合和周围像素点的重要性度量，因此能够在一定程度上提高模型的鲁棒性和泛化能力。

## 4.5 实验细节与评估指标

### 4.5.1 实验细节

为了进行数据增强，本文采用了随机水平翻转、竖直翻转和旋转的方法对训练数据进行一系列随机变换，有效地扩增数据集，增强模型的鲁棒性和泛化性能。

同时，使用了随机梯度下降（SGD）优化器来更新模型参数，其中设置了权重衰减（weight decay）为 0.0001 和动量（momentum）为 0.9。这些超参数的设置对于模型的收敛速度和泛化性能具有重要影响。最后，本文将每个 batch 的大小设置为 32，以充分利用 GPU 并行计算的能力，提高模型的训练效率。

本文使用学习率调度策略，具体公式如公式（4-1）所示：

$$lr = lr_{base} \times \left(1 - \frac{iter}{total\ iter}\right)^{power} \quad (4-1)$$

其中， $lr_{base}$  设置为 0.01， $power$  设置为 0.9， $iter$  和  $total\ iter$  分别为当前迭代次数和迭代总次数。在训练过程中，本文使用 Dice 损失函数和交叉熵损失函数进行训练，设计如公式（4-2）所示：

$$LOSS_{cloud} = LOSS_{Dice} + LOSS_{CE} \quad (4-2)$$

其中， $LOSS_{Dice}$  是一种基于 Dice 系数的损失函数，Dice 系数是用于计算两个样本点相似度的集合相似度测量函数，有利于涉及正、负样本的极端不平衡的图像分割。如果 Dice 系数更大，则集合更相似，损失更小。具体公式如下所示，

其中,  $y_{in}$  是  $c$  类中的真实标注,  $\hat{y}_{in}$  是由分割网络输出的分割结果,  $C$  是标签类别总数, 本实验中即为所有云分类的类别数量 10。具体公式如公式 (4-3):

$$Loss_{Dice} = 1 - \sum_{c=1}^C \frac{2 \sum_{i=1}^I y_{in} \hat{y}_{in}}{C(\sum_{i=1}^I y_{in} + \sum_{i=1}^I \hat{y}_{in})} \quad (4-3)$$

另外, 使用交叉熵损失函数来指导点引导注意模块中的点引导注意图的生成, 交叉熵损失可简化表示为公式 (4-4):

$$Loss_{CE} = - \sum_{c=1}^C \hat{y}_{in} \log(y_{in}) \quad (4-4)$$

#### 4.5.2 评估指标

作为一个气象卫星图像领域的语义分割任务, 本文自然引入了语义分割任务中最为常见的, 平均交-并比 (mIOU) 作为评价度量, 其中  $i$  为真实类别,  $j$  为模型预测类别,  $p_{ij}$  表示真实类别为  $i$ , 被预测类别为  $j$  的像素数量。设计如公式 (4-5):

$$mIOU = \frac{1}{C} \sum_{i=0}^C \frac{p_{ii}}{\sum_{j=0}^C p_{ij} + \sum_{j=0}^C p_{ji} - p_{ii}} \quad (4-5)$$

### 4.6 实验结果与对比分析

#### 4.6.1 消融实验

本部分对于此方法的几种变体进行了消融实验, 以评估每个组件。具体的实验结果如表 4-1 所示:

表 4-1 消融实验对比结果

基础VecNet	多尺度特征融合模块	像素级别注意力机制模块	跳跃连接	mIOU(%)
√				65.2 (-2.7%)
√	√			66.5 (-1.4%)
√	√	√		67.7 (-0.2%)
√	√	√	√	67.9

实验发现, 基本的 VecNet 模型便可以实现 65.2% 的 mIOU。这意味着该模型在气象卫星背景下的语义分割任务中表现良好, 但仍有提高的空间。接下来, 本

文依次添加了多尺度特征融合模块和像素级别注意力机制模块,通过实验评估了它们的效果。

多尺度特征融合模块可以显著提高模型的性能,使 mIOU 提高了 1.3%。这表明语义金字塔模块可以提高模型捕获多尺度特征的能力。在气象卫星图像中,不同尺度的云可能会有不同的特征,此实验结果也印证了捕获多尺度特征是提高气象卫星像素级云分类性能的重要因素。金字塔结构通过将图像分解为不同尺度的子图像,并在每个子图像上运行网络来捕获多尺度特征,从而提高了模型的性能。

此外,像素级别注意力机制模块也提高了 VecNet 模型的性能,mIOU 在上部分基础之上又提高了 1.2%。像素级别注意力机制模块可以帮助网络学习更多的区别特征表示,帮助区分图像中相似但不同类别的物体。例如,两种云可能具有相似的形状表示,但在轮廓细节上可能有所不同。使用空间金字塔结构后,周围像素点提取到的特征信息对中心点的云分类未起到辅助性作用,甚至是消极作用。像素级别注意力机制模块使网络更加关注这些细节,并通过引入监督损失,有效提高区分细划类别的能力。

最后,基于上述模型结构,又在三个不同层次的特征图之间设计了跳跃连接,使模型更好地利用原始图像中的细节和上下文信息,从而提高模型的准确性和鲁棒性。格外需要强调的是,通过跳跃连接,低层次的特征可以直接传递给高层次的特征,这有助于减少梯度消失和爆炸问题,在该次消融实验中,定性的发现训练速度具有一定程度的提升。

#### 4.6.2 经典模型性能对比

本文还在其他经典的分割架构上进行了实验,包括 FCN-8s<sup>[76]</sup>、Unet<sup>[77]</sup>和 Deeplabv3+<sup>[78]</sup>来评估本文方法。对比实验结果如表 4-2 所示,

表 4-2 经典模型性能对比

方法	参数量 (M)	FPS (s)	mIOU (%)
FCN-8s	134.3	58.75	47.3 (-20.6%)
Deeplabv3+	54.7	54.95	46.9 (-21.0%)
Unet	17.3	140.67	66.2 (-1.7%)
VecNet	4.0	42.31	67.9

实验结果表明,VecNet 作为针对气象卫星数据设计的模型,云分类任务中的表现优于其他经典模型,并在准确性和参数量方面具备显著优势。在 mIOU 指标上,Unet 相对优秀,而 DeepLabv3+和 FCN 性能略逊,但是相对于这三个经典模型,VecNet 的准确度最高,可达到 21.0%的提升。

与经典模型相比，VecNet 使用大量的  $1 \times 1$  卷积核代替传统卷积核，并降低了网络深度，因此使用的参数数量要少得多。FCN 作为传统的全连接深度神经网络，拥有最深的网络结构和最大的模型规模。尽管 DeepLabv3+ 和 Unet 在 FCN 基础上通过模型剪枝减少了参数量，但仍具有接近两千万和五千万级别的网络参数。本文设计的 VecNet 经过大量消融实验和模型裁剪，设计出了轻量高效的模型，仅四百万的模型参数极大降低显卡资源负担。

另外，与使用较多的阈值法和现有成熟的云产品相比，本文能够以几乎实时的速度完成单张推理。经测试，VecNet 最快可在 0.024 秒内完成单张气象卫星图像的云分类推理，远快于传统阈值法和延时 30 分钟生成的成熟云产品。总而言之，高性能和轻量化是 VecNet 的突出优点。

### 4.6.3 可视化结果分析

本部分旨在展示定性比较模型结果。

#### 4.6.3.1 经典模型可视化结果对比

本文通过图 3-7 中的结果可视化将本方法与几种常用方法进行比较，为更清晰说明，本实验结果切取了输出结果图的典型部分进行对比，每一行为同一时间点不同方法的推理结果。

第一列为葵花 8 号气象卫星图像的可视化结果 (True-color Image)，第二列为十类云分类标签数据，即真实值 (GT)。由图中三个不同时刻的黑色虚线圆圈区域可看出，“VecNet + SPM + PAM” 相比于 FCN-8s 和 Deeplabv3+ 有显著的改进，通过引入了多尺度特征融合的云分类模块，VecNet 对于云的空间结构信息有更为深入的理解，进而在云种类分类有更为优异的表现。对于 UNet，本模型额外添加的像素级别注意力机制和更关注通道维度的设计使得模型在细节方面同样表现更好。具体而言，优点对比如下：

#### 1. 离散点云识别准确

VecNet 能够更好地识别离散点云。如图第二行所示，作为面积较小、分布离其他种类云很近的云情况，VecNet 堆叠的  $1 \times 1$  卷积设计将气象卫星的细节信息发挥到极致，更加细致化、精准化的对每个气象卫星图像像素点进行计算，最终得到了第二行虚线框中的优异表现。

#### 2. 密集云区域识别准确

VecNet 在密集云区域的预测结果也比经典方法更加准确。如第三行所示，对于多种云密集分布在有限区域内的情况，精心设计出的多尺度模块和像素级注意力机制起到了极为关键的作用，从特征层面增加了不同云的区分度，使得在云密集区域中的预测更符合实际，效果良好。

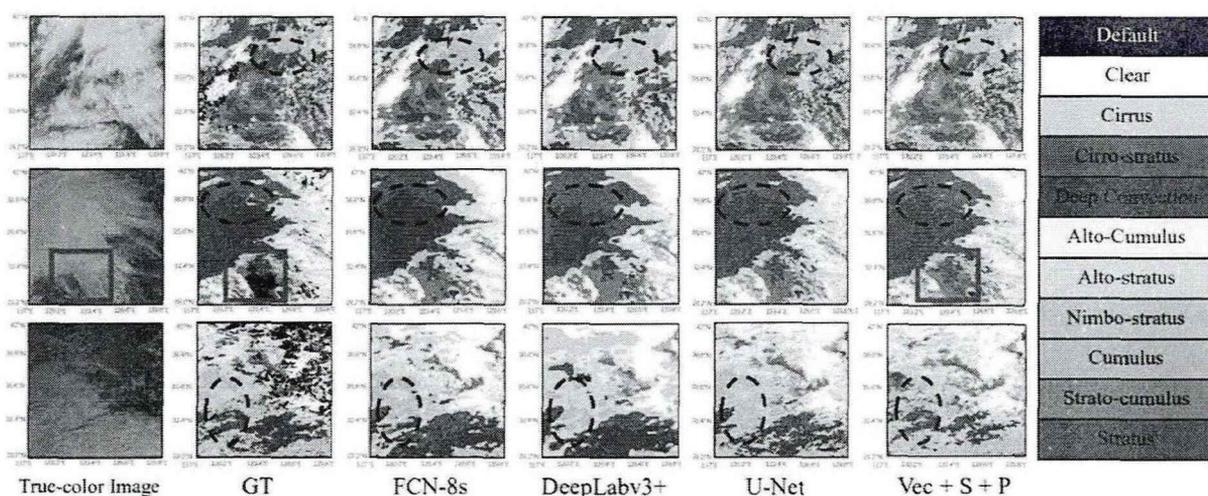


图 4-4 经典模型可视化结果对比

#### 4.6.3.2 消融实验可视化结果对比

如图 4-5, “VecNet + SPM + PAM” 相比于 “VecNet” 和 “VecNet + SPM” 有显著的改进。如图中黑色虚线所圈, 虽然 “VecNet” 能够很好地分类离散像素, 但对于某些连续云层表现平平。“VecNet + SPM” 在一定程度上能够缓解这个问题。引入像素级注意力机制后, “VecNet + SPM + PAM” 学习到了更为可识别的特征, 获得了更准确的预测结果。此外如第二行红色框中所示, VecNet 可以对传统阈值法难以确定的点云给出高置信度的种类分类。

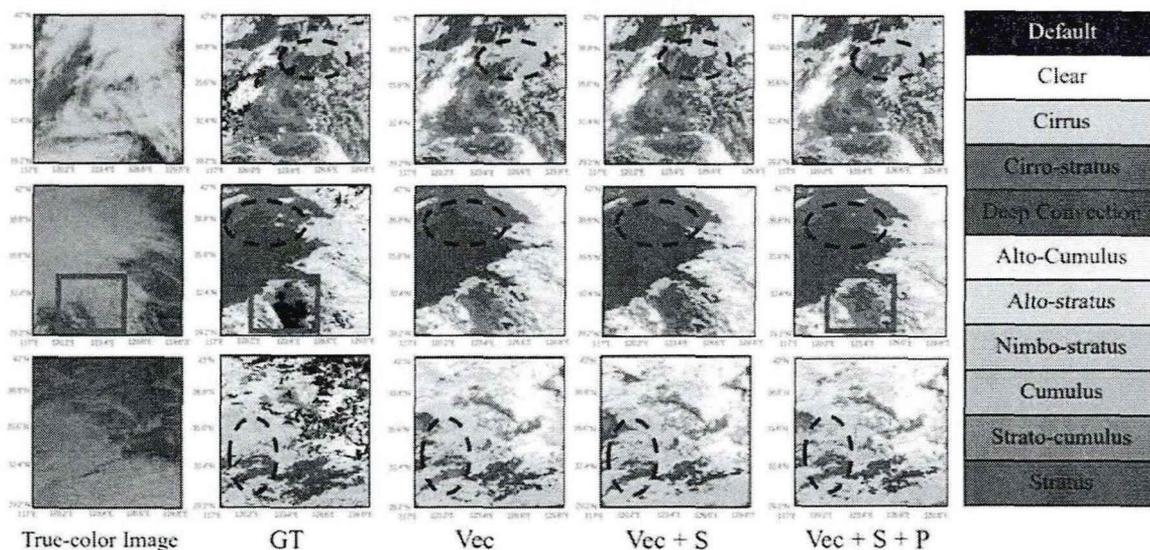


图 4-5 消融实验可视化结果对比

## 4.7 本章小结

本章完成了对基于域迁移的气象卫星图像云分类的数据描述,分别详细介绍了日本的葵花 8 号气象卫星和我国自主研发的风云 4 号气象卫星,并讲解了作为模型训练标签的云分类产品数据,且进行了数据可视化对比。

以葵花 8 号气象卫星为例,设计出了基于单一气象卫星图像的云分类模型。所设计的轻量模型 VecNet 通过整合多通道维度的特征融合模块、多尺度特征融合模块和像素级别注意力模块,使得预测准确率 mIOU 达到 67.9%,在气象卫星图像云分类领域,性能表现明显优于经典分割模型。另外最快可在 0.024 秒内完成单张气象卫星图像的云分类推理,速度远快于传统阈值法和延时 30 分钟生成的成熟云产品。

结果表明,基于单一气象卫星数据的像素级云分类模型是有效的,深度学习方法在云类型研究中具有很大的潜力。

## 第五章 基于域迁移的气象卫星云分类模型的设计与实现

本章首先对基于域迁移的气象卫星图像云分类模型进行系统性概述,然后依次剖析风格一致性和内容一致性迁移的设计原理和实现思路,最后阐明实验细节和实验结果。

### 5.1 基于域迁移的气象卫星图像云分类模型设计

本章在第四章基础之上,提出了一种基于无监督域迁移的气象卫星云分类模型,该架构不需要人工标注的云分类标签。由 3.1 数据描述章节所示,本章使用有云分类产品作为标签的葵花 8 号气象卫星数据为源域,无完备云产品标签的风云 4 号卫星数据为目标域。通过两个卫星共享的相同语义空间,建立了由分割模型、目标域特征提取模型和域鉴别器组成的对抗学习网络。

旨在解决两个卫星之间通道数量的差异和数据分布差异的问题。总体而言,本文在学习两个域的数据分布的基础上,提取域不变特征,然后通过鉴别器来减少域间差异。

当模型输入时,本文首先设计了编码器来解决卫星数据通道差异的问题。接着,借鉴了 2.2.3 域迁移技术中常用的对抗性训练方法思想,有目的性设计出特征提取器提取出域不变特征,并相对应的使用鉴别器来区分提取出特征的来源。方法充分利用特征提取器和域鉴别器之间的对抗关系来优化这两个模块,直到提取器能够输出合格的、难以被鉴别器判别来源的特征图。此对抗学习的过程充分保证源域和目标域的风格一致性,完成了域迁移方法的初步设计。

另外,和传统域迁移方法不同的是,本文综合了气象卫星图像数据的特点,创新性引入了基于 Patch 的交叉熵损失函数,额外完成内容上一致性的约束,实现了对目标域上的云种类的识别。

整体网络模型如图 5-1 所示:

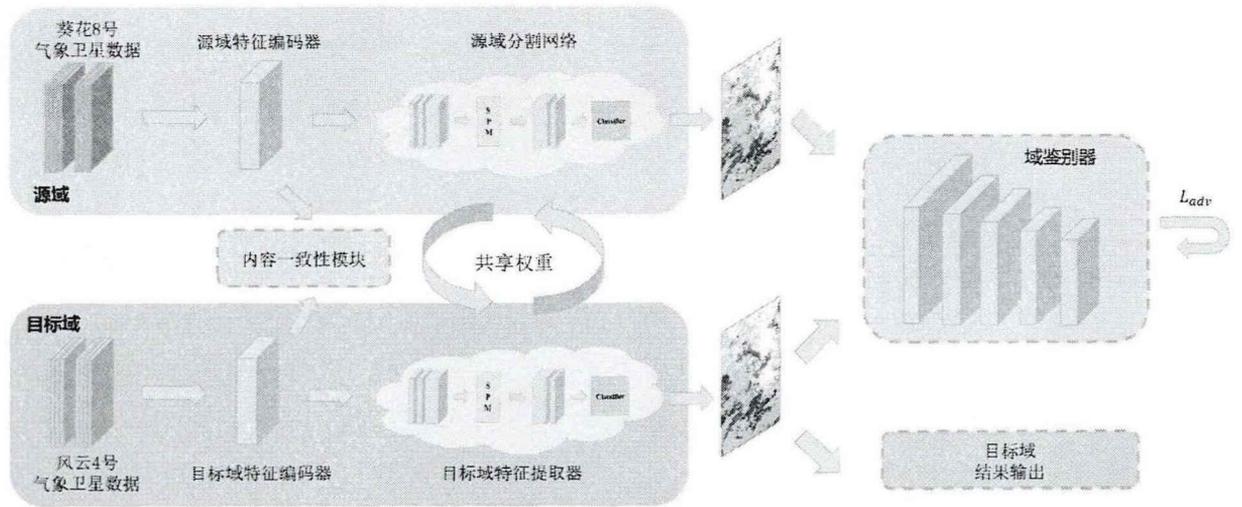


图 5-1 基于域迁移的气象卫星云分类模型

具体而言，为了完成目标域和源域之间的无监督域自适应，本模型设计出了由四部分组成的网络，分别为：特征编码器、基于 Patch 的内容一致性模块、源域分割网络/目标域特征提取器和域鉴别器。为更清晰说明模块作用，本章将从风格一致性迁移和语义一致性迁移两个角度完成对于上述四部分的介绍。

## 5.2 风格一致性迁移

风格一致性是一种常用的域迁移方法，它的基本原理是在源域和目标域之间建立一种“风格”的联系，将源域的样式特征迁移到目标域上。具体来说，它通过建立一个从源域到目标域的映射，将源域的风格特征转移到目标域，从而实现域适应。经过 2.2 节域迁移技术研究现状的调研，本文使用对抗性训练的方式实现风格一致性。

在训练的早期阶段，本文首先将源域数据输入到模型上方，将目标域数据输入到模型下方。在它们各自的特征编码器中输入后，它们会在共享权重的源域分割/目标域特征提取网络中计算，并受分割损失的限制。

### 5.2.1 特征编码器设计

本文的特征提取器借助于 ResNet Block 构建，ResNet Block 是 ResNet 的核心模块之一，是一种具有残差连接的卷积神经网络模块。它一般由两个或三个卷积层组成，每个卷积层后面跟着一个批量归一化层和激活函数。其中，最后一个卷积层的输出会与输入进行残差连接，然后再经过激活函数输出。这种残差连接的设计有效避免深度神经网络中的梯度消失问题，从而使得神经网络更容易训练。ResNet Block 作为特征提取器，可通过堆叠多个 ResNet Block 构建非常深的神经网络，并在保持较高准确率的同时减少训练时间和参数量。

针对气象卫星数据的特点,本文分别设计了 16 通道和 14 通道输入的特征编码器来适应本任务,使得不同气象卫星数据在通道维度上完成了初步的一致化。接着,在输入了各自的特征编码器后,在共享权值分割/特征提取网络中进行计算,并受到分割损失的约束。

### 5.2.2 源域分割网络/目标域特征提取器设计

在本文中,选用 VecNet 作为域迁移任务中的基础 backbone 骨架,分别搭建出源域分割网络和目标域特征提取器,提取出葵花 8 号和风云 4 号气象卫星数据域中的特征信息。

根据第三章讲述,本技术所设计的轻量模型 VecNet 通过整合多通道维度的特征融合模块、多尺度特征融合模块和像素级别注意力模块,使得预测准确率 mIOU 达到 67.9%,在气象卫星图像云分类领域,性能表现明显优于经典分割模型。因此选用 VecNet 作为基础框架完成云分类任务。

相对应的,目标域的特征提取器与源域分割网络通过训练得到的权值共享,将特征提取器的输出结果输入到域鉴别器上进行判断。

### 5.2.3 域鉴别器设计

为了减少源域和目标域之间的域差异,本文采用了一种鉴别器设计,它通过与分割模型/特征提取模型输出的分割结果进行连续训练,以区别出分割结果的正确来源。传统的鉴别器通常将分割结果映射为一个实际的数字,即整张分割结果图像来自于源域的概率,用此单一的输出作为最终评价值。但在实验中发现,本文使用的分割结果图分辨率较高,不同区域间区分度大,因此单一评价值不能全方位反映出整张分割结果是否来源于源域。为解决这个问题,本文借鉴了 PatchGAN<sup>[75]</sup>的设计,设计了一种更加细粒度的鉴别器,对每个图像块进行评价,并将评价结果整合成一个值。此方法能够更准确地评价分割结果的来源,并提高对抗训练的性能。



图 5-2 域鉴别器结构

如图 5-2 所示, 本文提出的鉴别器网络由多个卷积层和激活函数堆叠而成, 其输入为源域分割网络/目标域特征提取器输出的分割结果, 输出为一个  $16 \times 16$  的矩阵。在该矩阵中, 每个点都代表输入图像中一个小区域的评价值, 即图像中接受域的一部分, 将整个  $16 \times 16$  矩阵的平均值作为鉴别器的最终输出。通过这种方式, 域鉴别器可以考虑到输入图像中不同部分的影响, 从而使输出结果更有可信度。

最终的鉴别器网络通过与分割模型/特征提取模型的对抗性更新不断迭代更新, 并受到对抗性损失的限制。通过使用对抗性训练的方式, 本部分实现了不同气象卫星数据域之间的风格一致性转换。这种方法可以帮助解决气象卫星图像云分类问题中的域迁移问题, 从而提高模型的性能和稳定性。

## 5.3 内容一致性迁移

### 5.3.1 内容一致性意义

内容一致性的主要意义在于进行域迁移时, 需要确保在源域和目标域之间进行迁移的语义内容和基本形态上保持一致性, 以便于能够将在源域中学到的知识迁移到目标域中。换言之, 虽然数据来源于不同的气象卫星数据域, 但表征的是同一地理位置的相同信息, 因此源域和目标域的输入图像必定有着同样的结构和相同的语义信息, 经过特征编码器后的特征空间也必然存在着对应的联系。如果源域和目标域之间的语义内容不一致, 那么即使在源域中有很好的性能, 也无法保证在目标域中能够有良好的表现。因此, 确保内容一致性是域迁移中非常关键的一步。

### 5.3.2 基于 Patch 的内容一致性模块设计

受到 2.2.4.1 节中特征及对抗训练方法的启发, 本文引入并适当性改造出了基于 Patch 的内容一致性模块, 具体结构如图 5-3 所示。

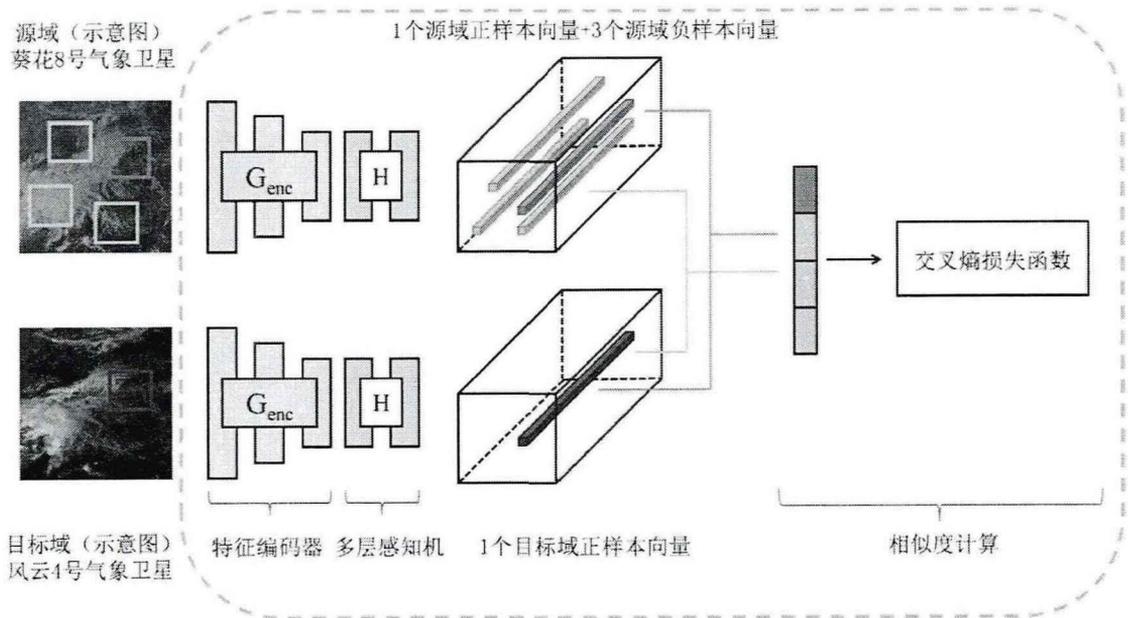


图 5-3 基于 Patch 的内容一致性模块

由图 5-3 可见，本模块的设计思路如下：

1. 本模块首先从源域气象卫星图像中随机选取 4 个无重叠位置作为源域的待处理 Patch，并从这些 Patch 中随机选取一个作为源域正样本，并记录此 Patch 在整个图像中的位置信息待用。除此之外，其余 3 个 Patch 均设定为源域负样本。
2. 接着，从目标域气象卫星图像中，选取出源域正样本相同位置的 Patch，将此目标域待处理 Patch 作为目标域正样本。
3. 将所得到的源域待处理 Patch 和目标域待处理 Patch 分别输入 4.2 中所提到的特征编码器之中，再分别经过本模块额外引入的多层感知机将所得特征图缩放到 1 维向量。此时，得到了源域待处理 Patch 提取出的 4 个 1 维向量（1 个源域正样本向量  $v^+$ ，3 个源域负样本向量  $v^-$ ）和目标域待处理 Patch 提取到的 1 个 1 维向量（1 个目标域正样本向量  $\hat{v}$ ）
4. 使用交叉熵损失函数，拉近源域正样本向量和目标域正样本向量的距离，拉远源域负样本向量和目标域正样本向量的距离。目的就是让正样本 Patch 和负样本 Patch 形成鲜明对比，借此方式来实现相同语义内容在特征空间上的拟合，保证内容一致性的成功实现。将上述文字表述以函数形式可表示为公式 (5-1)：

$$l(\hat{v}, v^+, v^-) = -\log \left[ \frac{\exp\left(\hat{v} \cdot \frac{v^+}{\tau}\right)}{\exp\left(\hat{v} \cdot \frac{v^+}{\tau}\right) + \sum_{n=1}^N \exp\left(\hat{v} \cdot \frac{v^-}{\tau}\right)} \right] \quad (5-1)$$

其中,  $\tau$  为超参数, 常被称作温度系数, 可用来调整正样本被选中的概率。

## 5.4 实施细节和评估指标

### 5.4.1 实验细节

本部分实验与 4.5.1 中实验细节接近, 同样使用随机梯度下降优化器 (公式 4-1) 更新模型参数, batch 设置为 32, 优化器的权重衰减为 0.0001,  $lr_{base}$  设置为 0.01,  $power$  设置为 0.9, 完成整体训练。

不同的是, 本部分使用分割损失  $Loss_{Seg}$  来约束分割训练的效果, 设计如公式 (5-2):

$$Loss_{Seg} = Loss_{Dice} + Loss_{CE} + Loss_{PatchNce} + Loss_{adv} \quad (5-2)$$

其中,  $Loss_{Dice}$  和  $Loss_{CE}$  与 4.5 节  $Loss_{cloud}$  使用的 Dice 损失函数和交叉熵损失函数相同, 具体公式可见公式 (4-5) 和公式 (4-6)。为缓解域迁移的影响减少域间差异, 本文使用对抗损失  $Loss_{adv}$  来约束域自适应, 具体设计如公式 (5-3):

$$Loss_{adv} = -\frac{1}{n_s} \sum_{s=1}^{n_s} (\ln D(M_s(\hat{y}_i^s))) - \frac{1}{n_t} \sum_{t=1}^{n_t} (1 - \ln D(M_t(\hat{y}_i^t))) \quad (5-3)$$

值得提及的是,  $D(X)$  表示鉴别器的输出,  $M_s(\hat{y}_i^s)$  表示源域分割网络输出的集合,  $M_t(\hat{y}_i^t)$  表示目标域特征提取器输出的集合。另外, 基于 Patch 的内容一致性损失  $Loss_{PatchNce}$  由公式 (5-1) 演化而来, 具体公式如公式 (5-4) 所示:

$$Loss_{PatchNce} = \sum_{r=1}^R \sum_{q=1}^Q l(\hat{z}_r, z_r^q, z_r^{Q/q}) \quad (5-4)$$

- 其中  $r$  表示所在层数,  $r \in \{1, 2, 3, \dots, R\}$ ;  $q$  表示 patch 数 ( $q$  属于  $\{1, 2, \dots, Q\}$ )
- 如公式 (5-5),  $z_r$  表示经过了特征编码器  $G_{enc}$  和感知机  $H$  后产生的第  $r$  层特征,  $z_r^q$  表示在第  $r$  层中, 源域第  $q$  个 Patch 经过特征编码器和多层感知机后所对应的特征向量。

$$z_r = H(G_{enc}^l(x)) \quad (5-5)$$

- $\hat{z}_r$  表示第  $r$  层里, 目标域中 Patch 经过目标域特征编码器和多层感知机后所对应的特征向量。
- $z_r^{Q/q}$  表示第  $r$  层里, 所有 Patch 除去第  $q$  个 Patch 后的剩余特征向量。

## 5.4.2 评估指标

本文使用 mIOU 和整体准确率  $Acc_{all}$  作为指标。对于云多分类问题，存在类别分布不均衡的问题，比如，深对流云面积相对较大，深对流云像素出现次数也远高于其他云种类。因此设计整体准确率如公式 (5-6)，修正类别分布不均导致的影响。 $m_c$  是第  $c$  类云的预测准确率， $n_c$  为预测结果中第  $c$  类云所占像素数量， $N$  是预测结果中像素总数。

$$Acc_{all} = \sum_{c=1}^C \frac{m_c \times n_c}{N} \quad (5-6)$$

平均交-并比 (mIOU) 作为次级评价度量，与公式 (4-5) 保持一致，在此不再赘述。

## 5.5 实验结果与对比分析

在本节中，首先完成了本实验方法与其他方法的性能对比，紧接着通过两个阶段的实验分别完成了对于风格一致性迁移和内容一致性迁移模块的验证。成功解决了目视解译难的问题，并且证明了本域迁移气象卫星云分类模型的有效性。

### 5.5.1 模型性能对比

本文采用无监督对抗训练方式，实现了基于域迁移的气象卫星图像云分类模型。同时，使用风云 4 号卫星数据和葵花 8 号云分类标签数据，以全监督方式训练了经典模型 Unet<sup>[77]</sup>。实验结果表明，本文提出的基于域迁移的气象卫星图像云分类模型准确率可达 57.3%，接近于全监督训练的效果，并且预测准确率显著优于同类域迁移模型 Med-CMDA<sup>[79]</sup>。尽管在积云、低云等少样本类别中，本模型输出准确度较低，但整体准确率已能接近全监督情况，且明显高于同类域迁移方法。这证明在无监督情况下，成功地弱化了风云 4 号和葵花 8 号卫星数据域间差异，使得基于葵花 8 号标签训练出的云分类模型在风云 4 号数据域中仍能保持较高性能，增强了模型的泛化能力，为后续遥感领域内的域迁移工作提供了有力的支持。

表 5-1 模型性能对比

方法/云种类		无云 0	卷云 1	环云 2	深对流云 3	高云 4	中云 5	低云 6	积云 7	层云 8	层积云 9	mIOU	All-Acc
全监督 云分类 模型	Unet	84.3	44.1	66.1	68.8	28.4	51.0	59.8	37.0	57.3	49.2	54.6	65.3
无监督 域迁移 云分类 模型	Med-CMDA	32.1	31.7	48.2	15.1	25.6	47.3	32.4	10.2	24.9	40.4	30.8	48.7
	本文	78.2	44.5	52.3	49.7	18.5	42.1	31.8	23.5	42.6	39.7	42.3	57.3 (+8.6)

## 5.5.2 相关消融实验

### 5.5.2.1 气象卫星域迁移的可行性验证

本论文 1.3.3 中曾提到风云 4 号气象卫星的目视解译难问题。如图 5-4 所示，风云 4 号气象卫星由于缺少一个可见光通道，生成出的可视化图片对比葵花 8 号气象卫星来说不符合观感、影响下游任务使用这一现状，目前还没有比较明确且简易有效的解决方案。

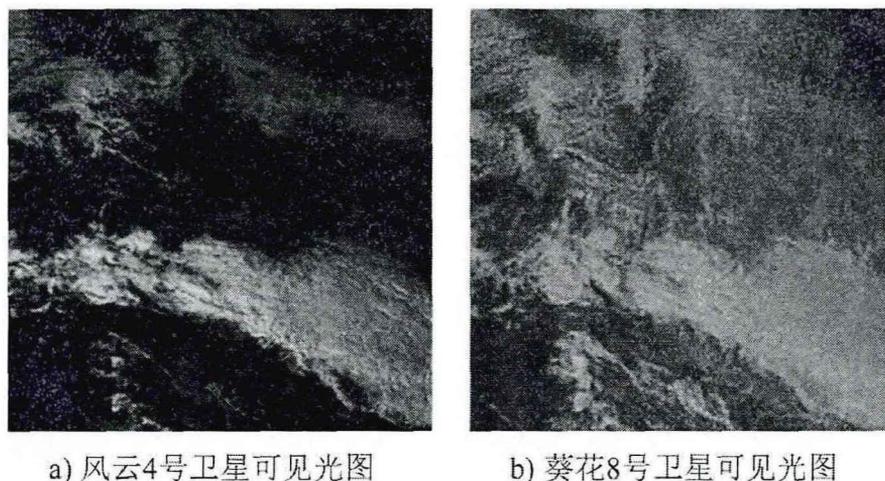


图 5-4 风云 4 号与葵花 8 号气象卫星可见光对比图

本部分实验面向目视解译难实际问题，旨在通过消融实验测试风格一致性迁移效果，印证气象卫星领域中域迁移技术的可行性，为本文构建最终的云分类域迁移模型奠定基础。实验内容如下：

剥离出主模型的目标域特征编码器和域鉴别器，先将特征编码器的输入通道数固定为 3，再分别输入葵花 8 号和风云 4 号气象卫星的前三个通道（可见光通道），通过与鉴别器的对抗训练，完成对于风格一致性迁移的可行性验证。作为主模型的一部分，具体实验模型如图 5-5 所示。

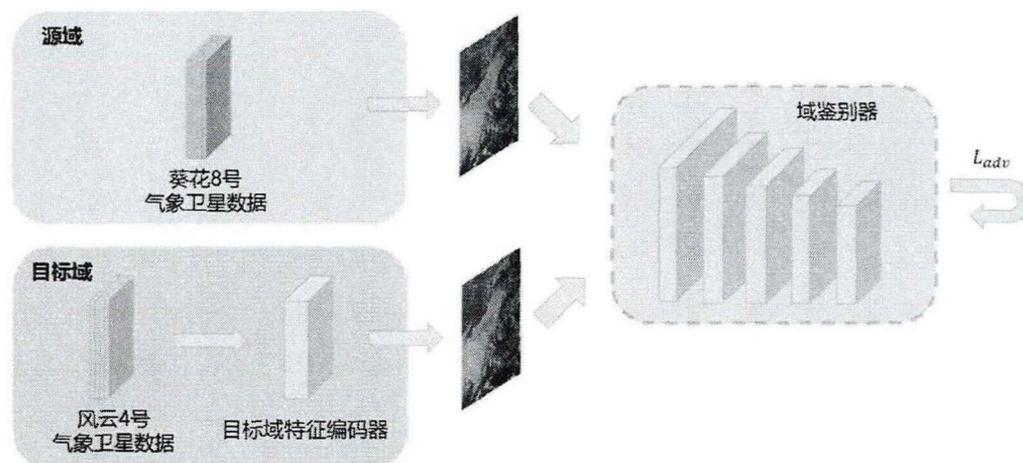


图 5-5 风格一致性模型结构

与云分类实验不同,源域葵花 8 号气象卫星的可见光图像就是风格域迁移的目标,因此无需源域特征提取器和共享权重的源域分割/目标域特征提取网络。本文仅使用目标域特征提取器和域鉴别器来完成对抗训练,检验风格一致性迁移在气象卫星领域内的可行性。

另外,为更为直观且侧重的展现域迁移前后的风格一致性程度,本消融实验使用常见的弗雷歇距离 FID 作为度量指标,对应于本实验中具体而言,通过计算葵花 8 号卫星源域样本高斯分布的均值 $\mu_{H8}$ 和方差 $\sigma_{H8}$ ,以及风云 4 号卫星目标域生成样本 $\mu_{FY4}$ 和方差 $\sigma_{FY4}$ ,再计算两个高斯分布之间距离,此距离即可衡量出域迁移后风格一致性程度,且与风格一致性程度成正比。即 FID 值越小,高斯分布越接近,迁移前后的风格一致性越高。具体公式如公式(5-7)所示:

$$FID = \|\mu_{H8} - \mu_{FY4}\| + Tr(\sigma_{H8} + \sigma_{FY4} - 2(\sigma_{H8}\sigma_{FY4})^{\frac{1}{2}}) \quad (5-7)$$

经过 50 轮 epoch 迭代, FID 最终可达到 25.2462, 印证了在气象卫星领域内进行域迁移的可行性,为第二阶段更为复杂的云分类域迁移任务奠定了重要基础。此外,对本实验的输出结果进行了可视化输出,对比结果如图 5-6 所示。

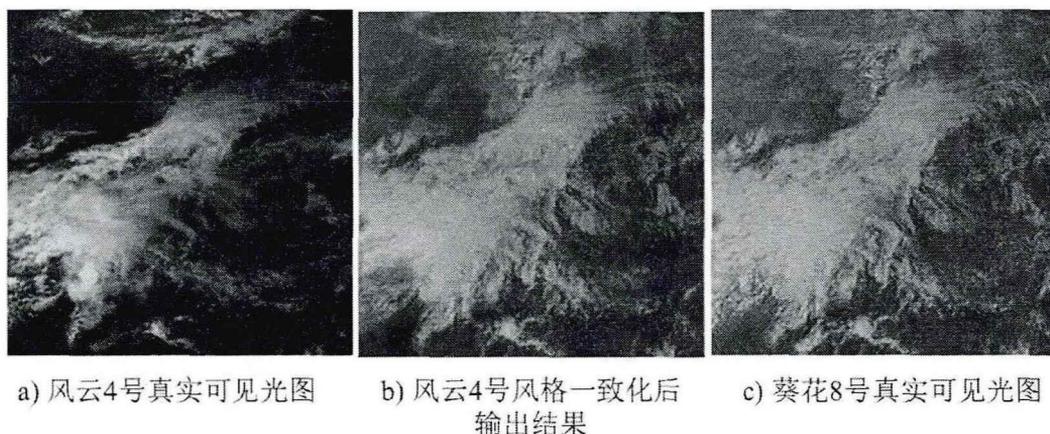


图 5-6 风格一致化输出与真实可见光图对比

不难发现,风云 4 号气象卫星经过风格域迁移后,所输出的可见光图片从风格上更为符合实际,虽然与葵花 8 号气象卫星可见光图仍存在一定颜色差异,但已经符合正常观感,实际方便于下游任务的使用,成功完成了对于目视解译难题的初步解决,证明了风格一致性迁移及相关设计模块的有效作用。

#### 5.5.2.2 基于 Patch 的内容一致性模块性能实验

另外,本文对基于 Patch 的内容一致性模块进行了更为细致的实验,以找到更适合气象卫星图像的模块尺寸。经实验,具体的实验结果如表 5-2 所示:

表 5-2 内容一致性模块性能实验结果

方法/云种类	无云 0	卷云 1	环云 2	深对流云 3	高云 4	中云 5	低云 6	积云 7	层云 8	层积云 9	m-Acc	All-Acc
未引入基于Patch的内容一致性模块	67.7	34.1	50.9	38.2	14.7	28.9	31.7	15.7	38.7	28.2	48.3	55.8
引入基于Patch的内容一致性模块	Patch大小 8*8	63.0	34.4	51.8	39.0	13.3	29.6	31.0	15.3	29.8	48.7 (+0.4)	56.9 (+1.1)
	Patch大小 16*16	68.2	32.5	52.3	39.7	14.5	30.1	31.8	17.1	32.6	49.5 (+0.9)	57.3 (+1.5)

经过实验数据对比分析，本文发现引入基于 Patch 的内容一致性模块后，无论采用哪种方案，模型的准确度都有一定程度的提升。特别是在气象卫星领域内的域迁移任务中，Patch 大小为 16\*16 的内容一致性模块表现更佳。

此外，通过模型的可解释性分析，发现引入基于 Patch 的内容一致性模块后，模型在第 3 类深对流云的分类表现最优。深对流云是一种庞大而垂直的云，通常以大面积、连续云的形式存在。引入 Patch 在约束语义一致性信息时，通过空间结构信息的形式提取了更为准确的特征，使得模型对此类大规模云种类更为敏感。实验数据还表明，使用 Patch 的面积越大，获得的空间信息越多，因此 16\*16 的 Patch 方案在深对流云分类的准确度上比 8\*8 的 Patch 方案表现更佳。

综上所述，引入基于 Patch 的内容一致性模块不仅可以提高模型的准确度，而且在处理大规模云种类时表现更为优异，这对于气象卫星领域内的域迁移任务具有重要意义。

### 5.5.3 可视化结果分析

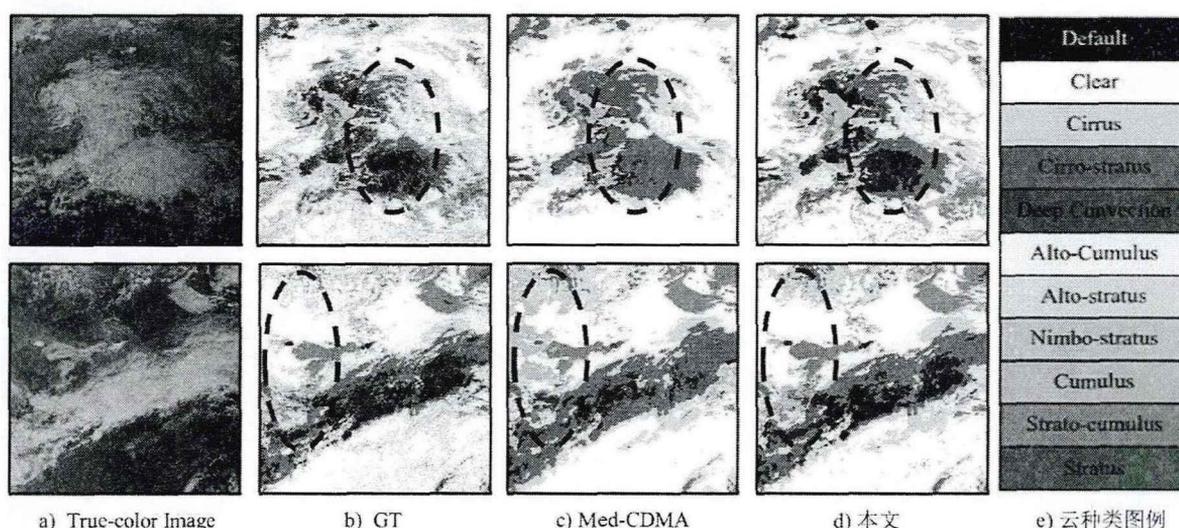


图 5-7 域迁移模型可视化结果对比

本文对各域迁移模型的可视化结果进行了对比展示。图 5-7 中，第一列为葵花 8 号气象卫星图像的可视化结果 (True-color Image)，第二列为真实值 (GT)，第三列和第四列分别为 Med-CDMA<sup>[79]</sup>方法结果和本文的域迁移结果。

通过图中第一行黑色虚线所圈出的区域，可以明显地看出本文的域迁移云分类模型在云聚集区域的判别准确度和细粒度方面表现明显优于同类域迁移模型。同时，第二行虚线圈出的区域也体现出本模型在无云和有云分类上区分度极高，表现出色。成功印证了本文可以在气象卫星领域无标签监督下完成域迁移任务，使得基于葵花 8 号标签训练出的云分类模型在风云 4 号数据领域中仍能保持较高性能。

## 5.6 本章小结

本章介绍了基于域迁移的气象卫星云分类模型的设计与实现，重点介绍了风格一致性迁移和内容一致性迁移两方面的气象卫星图像的域迁移过程。在风格一致性方面，采用了特征编码器、共享权重的源域分割网络/目标域特征提取网络和域鉴别器三个主要模块，通过对抗训练完成了气象卫星域迁移的可行性验证。在云分类问题更为复杂的情况下，增加了基于 Patch 的内容一致性模块，保证迁移过程中语义内容的前后协同，提升了云分类模型的泛化能力。实验结果包括对传统模型性能比较、气象卫星域迁移的可行性验证和内容一致性模块的消融实验，从模型可解释性的角度对模型效果进行了分析。通过本文所制定的各项内容，成功完成了域迁移和云分类结合任务，解决了现实存在的遥感气象领域实际问题。

## 第六章 总结与展望

### 6.1 论文总结

本文基于域迁移领域内的问题，针对性完成气象卫星数据的域迁移工作，并将云分类作为主要切入点，最终实现了基于域迁移的气象卫星云分类任务。

为解决上述问题，本文将研究内容细分为两大类：气象卫星云分类研究和域迁移内容研究。首先本文对国内外研究现状进行了细致的调研，对遥感领域内的云分类常见方法以及域迁移技术的前沿研究方法都分别进行了阐述，然后对遥感气象领域中域迁移已有手段进行了总结。

第三章对本文所使用到的各类数据进行了详细阐述，分别介绍了葵花 8 号气象卫星数据、我国自主研发的风云 4 号气象卫星数据和作为标签的十类云分类数据。阐明各气象卫星接收地球及其大气层的可见光、红外和微波辐射频段。为清晰展示，对各类数据进行了可视化对比，并简明扼要介绍了数据处理和准备过程。

第四章以葵花 8 号气象卫星为例，设计出了基于单一气象卫星图像的云分类模型。所设计的轻量模型 VecNet 通过整合多通道维度的特征融合模块、多尺度特征融合模块和像素级别注意力模块，使得预测准确率和推理速度均优于目前已有方法。

第五章在现有单一气象卫星云分类模型的基础上，进一步设计了基于域迁移的气象卫星云分类模型。通过深度学习和域适应方法，解决了不同气象卫星图像之间的域差异，针对通道不匹配和气象卫星目标域无标签等问题，提出了遥感气象卫星域迁移任务。本章从风格一致性和内容一致性两方面进行了模型设计，通过完成气象卫星域迁移的可行性验证，解决了风云 4 号气象卫星目视解译困难的问题，同时印证了风格一致性迁移方法在气象卫星领域内的可行性。在此基础上，引入了基于 Patch 的内容一致性模块，进一步提升了域迁移在云分类任务中的效果。本章的研究成果成功地将域迁移和云分类任务结合起来，为遥感气象领域实际问题的解决提供了新的思路和方法。

综上所述，本文完成了基于域迁移的气象卫星图像云分类技术研究，将研究生以来所学深度学习知识落地应用，解决了遥感领域内的实际问题，避免了需要大量手动多维参数的选取和人工标注的干预处理，以接近实时的速度，输出高置信度的云分类推理结果。

## 6.2 未来工作展望

究其本源，深度学习是数据驱动的方法，数据的质量直接决定了模型训练的效果。在本文中，清洗和处理气象卫星数据花费了很多时间精力。考虑到计算资源和时间成本，本文主要采用了一整年的气象卫星数据完成各类实验，未来如果有工作引入更大量、更丰富的训练数据一定能进一步提升模型的性能。

另外，本文中域迁移任务是将我国的风云 4 号气象卫星作为目标域进行实验。风云 4 号气象卫星作为中国气象卫星的第一颗全自主研发的定量遥感气象静止卫星，已经为我国各行业提供了高质量的气象、海洋、环境监测和气象服务，称得上是每个中国遥感人的骄傲。但对于卫星数据的深层次挖掘仍有很多可以工作开展，如何能够充分发挥我国的气象卫星性能，多方位、多角度开发卫星数据将是未来可以研究和发展的方向。



## 参考文献

- [1] Zhang X, Wang T, Chen G, et al. Convective clouds extraction from Himawari-8 satellite images based on double-stream fully convolutional networks[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 17(4): 553-557.
- [2] Tasar O, Happy S L, Tarabalka Y, et al. ColorMapGAN: Unsupervised domain adaptation for semantic segmentation using color mapping generative adversarial networks[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(10): 7178-7193.
- [3] Tasar O, Happy S L, Tarabalka Y, et al. SemI2I: Semantically consistent image-to-image translation for domain adaptation of remote sensing data[C]//IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2020: 1837-1840.
- [4] Benjdira B, Bazi Y, Koubaa A, et al. Unsupervised Domain Adaptation using Generative Adversarial Networks for Semantic Segmentation of Aerial Images[J]. Remote Sensing, 2019, 11(11):1369.
- [5] Li Y, Shi T, Chen W, et al. Unsupervised Style Transfer via Dualgan for Cross-Domain Aerial Image Classification[C]//IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2020: 1385-1388.
- [6] Fu H, Gong M, Wang C, et al. Geometry-consistent generative adversarial networks for one-sided unsupervised domain mapping[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 2427-2436.
- [7] Zhao D, Yuan B, Gao Y, et al. UGCNet: An Unsupervised Semantic Segmentation Network Embedded with Geometry Consistency for Remote-Sensing Images[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 19: 1-5.
- [8] Li Z, Wang R, Pun M O, et al. Inverse Domain Adaptation for Remote Sensing Images Using Wasserstein Distance[C]//2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS. IEEE, 2021: 2345-2348.
- [9] Cai Y, Yang Y, Zheng Q, et al. BiFDANet: Unsupervised bidirectional domain adaptation for semantic segmentation of remote sensing images[J]. Remote Sensing, 2022, 14(1): 190.
- [10]Tasar O, Tarabalka Y, Giros A, et al. StandardGAN: Multi-source domain

- adaptation for semantic segmentation of very high resolution satellite images by data standardization[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. 2020: 192-193.
- [11]Tasar O, Giros A, Tarabalka Y, et al. Daugnet: Unsupervised, multisource, multitarget, and life-long domain adaptation for semantic segmentation of satellite images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 59(2): 1067-1081.
- [12]Tzeng E, Hoffman J, Zhang N, et al. Deep Domain Confusion: Maximizing for Domain Invariance[J]. Computer Science, 2014.
- [13]Gill, R. Mastering English Literature [M]. 2th ed. London: Macmillan, 1985: 42-45.
- [14]Sejdinovic D, Sriperumbudur B, Gretton A, et al. Equivalence of distance-based and RKHS-based statistics in hypothesis testing[J]. Annals of Stats, 2013, 41(5):2263-2291.
- [15]Arjovsky M, Chintala S, L, et al. Wasserstein generative adversarial networks[C]// International Conference on Machine Learning. PMLR, 2017.
- [16]Ganin Y, Lempitsky V. Unsupervised domain adaptation by backpropagation[C]//International conference on machine learning. PMLR, 2015: 1180-1189.
- [17]Tzeng E, Hoffman J, Saenko K, et al. Adversarial discriminative domain adaptation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 7167-7176.
- [18]Tsai Y H, Hung W C, Schulter S, et al. Learning to adapt structured output space for semantic segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 7472-7481.
- [19]Luo Y, Zheng L, Guan T, et al. Taking a closer look at domain shift: Category-level adversaries for semantics consistent domain adaptation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 2507-2516.
- [20]Liu W, Su F. Unsupervised adversarial domain adaptation network for semantic segmentation[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 17(11): 1978-1982.
- [21]Lu X, Zhong Y. A Nov AI Global-Local Adversarial Network for Unsupervised Cross-Domain Road Detection[C]//2021 IEEE International Geoscience and

- Remote Sensing Symposium IGARSS. IEEE, 2021: 2775-2778.
- [22] Chen J, Chen G, Fang B, et al. Class-Aware Domain Adaptation for Coastal Land Cover Mapping Using Optical Remote Sensing Imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 11800-11813.
- [23] Hu J, Tuo H, Wang C, et al. Unsupervised satellite image classification based on partial transfer learning[J]. Aerospace Systems, 2020, 3: 21-28.
- [24] Cao Z, Long M, Wang J, et al. Partial transfer learning with selective adversarial networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 2724-2732.
- [25] Panareda Busto P, Gall J. Open set domain adaptation[C]//Proceedings of the IEEE international conference on computer vision. 2017: 754-763.
- [26] Saito K, Yamamoto S, Ushiku Y, et al. Open set domain adaptation by backpropagation[C]//Proceedings of the European conference on computer vision (ECCV). 2018: 153-168.
- [27] Zhao S, Li B, Yue X, et al. Multi-source domain adaptation for semantic segmentation[J]. Advances in Neural Information Processing Systems, 2019, 32.
- [28] Lu X, Gong T, Zheng X. Multisource compensation network for remote sensing cross-domain scene classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 58(4): 2504-2515.
- [29] Ji S, Wang D, Luo M. Generative adversarial network-based full-space domain adaptation for land cover classification from multiple-source remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 59(5): 3816-3828.
- [30] Zheng J, Wu W, Fu H, et al. Unsupervised mixed multi-target domain adaptation for remote sensing images classification[C]//IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2020: 1381-1384.
- [31] Luo M, Ji S. Cross-spatiotemporal land-cover classification from VHR remote sensing images with deep learning based domain adaptation[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 191: 105-128.
- [32] Nyborg J, Pelletier C, Lefèvre S, et al. TimeMatch: Unsupervised cross-region adaptation by temporal shift estimation[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 188: 301-313.

- [33]Li Y, Shi T, Zhang Y, et al. Learning deep semantic segmentation network under multiple weakly-supervised constraints for cross-domain remote sensing image semantic segmentation[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 175: 20-33.
- [34]Iqbal J, Ali M. Weakly-supervised domain adaptation for built-up region segmentation in aerial and satellite imagery[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 167: 263-275.
- [35]J. Bai, H. Wang, and Z. Tao, "Recognition and tracing of severe convective cloud from ir images of gms," J. Tropical Meteor, vol. 3, no.1, pp. 192- -201, 1997.
- [36]Purbantoro B , J Aminuddin, Manago N , et al. Comparison of Cloud Type Classification with Split Window Algorithm Based on Different Infrared Band Combinations of Himawari-8 Satellite[J]. 遥感技术进展 (英文) , 2018, 7(3):17.
- [37]Huang Y, Siems S, Manton M, et al. Evaluating Himawari-8 cloud products using shipborne and CALIPSO observations: Cloud-top height and cloud-top temperature[J]. Journal of Atmospheric and Oceanic Technology, 2019, 36(12): 2327-2347.
- [38]Purbantoro B, Aminuddin J, Manago N, et al. Evaluation of Cloud Type Classification Based On Split Window Algorithm Using Himawari-8 Satellite Data[C]//IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2019: 170-173.
- [39]Vaduva C , Gavati I , Datcu M . Deep learning in very high resolution remote sensing image information mining communication concept[C]// Signal Processing Conference. IEEE, 2012.
- [40]Cheng G , Yang C , Yao X , et al. When Deep Learning Meets Metric Learning: Remote Sensing Image Scene Classification via Learning Discriminative CNNs[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018:2811-2821.
- [41]Zhang X , Wang T , Chen G , et al. Convective Clouds Extraction From Himawari-8 Satellite Images Based on Double-Stream Fully Convolutional Networks[J]. IEEE Geoscience and Remote Sensing Letters, PP(99):1-5.
- [42]陈博洋, 吴琼, 冯绚,等. FY-4A 多通道扫描辐射成像仪评价与图像合成[J]. 红外与毫米波学报, 2018, 37(4):5.
- [43]Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 3431-3440.

- [44] Long M, Cao Y, Wang J, et al. Learning transferable features with deep adaptation networks[C]//International conference on machine learning. PMLR, 2015: 97-105.
- [45] Wang J, Zhu X, Gong S, et al. Transferable joint attribute-identity deep learning for unsupervised person re-identification[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 2275-2284.
- [46] Zhou Q. Deep embedded clustering with adversarial distribution adaptation[J]. IEEE Access, 2019, 7: 113801-113809.
- [47] Li H, Pan S J, Wang S, et al. Domain generalization with adversarial feature learning[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 5400-5409.
- [48] Achituve I, Maron H, Chechik G. Self-supervised learning for domain adaptation on point clouds[C]//Proceedings of the IEEE/CVF winter conference on applications of computer vision. 2021: 123-133.
- [49] Long M, Cao Y, Wang J, et al. Learning transferable features with deep adaptation networks[C]//International conference on machine learning. PMLR, 2015: 97-105.
- [50] Sohn K, Liu S, Zhong G, et al. Unsupervised domain adaptation for face recognition in unlabeled videos[C]//Proceedings of the IEEE International Conference on Computer Vision. 2017: 3210-3218.
- [51] Tuia D, Munoz-Mari J, Gómez-Chova L, et al. Graph matching for adaptation in remote sensing[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 51(1): 329-341.
- [52] Rakwatin P, Takeuchi W, Yasuoka Y. Restoration of Aqua MODIS band 6 using histogram matching and local least squares fitting[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 47(2): 613-627.
- [53] Yaras C, Huang B, Bradbury K, et al. Randomized histogram matching: A simple augmentation for unsupervised domain adaptation in overhead imagery[J]. arXiv preprint arXiv:2104.14032, 2021.
- [54] Agarwal V, Abidi B R, Koschan A, et al. An overview of color constancy algorithms[J]. Journal of Pattern Recognition Research, 2006, 1(1): 42-54.
- [55] Buchsbaum G. A spatial processor model for object colour perception[J]. Journal of the Franklin institute, 1980, 310(1): 1-26.
- [56] Creswell A, White T, Dumoulin V, et al. Generative adversarial networks: An overview[J]. IEEE signal processing magazine, 2018, 35(1): 53-65.
- [57] Huang X, Belongie S. Arbitrary style transfer in real-time with adaptive instance

- normalization[C]//Proceedings of the IEEE international conference on computer vision. 2017: 1501-1510.
- [58]Cai Y, Yang Y, Zheng Q, et al. BiFDANet: Unsupervised bidirectional domain adaptation for semantic segmentation of remote sensing images[J]. Remote Sensing, 2022, 14(1): 190.
- [59]Zhang Y, Qiu Z, Yao T, et al. Fully convolutional adaptation networks for semantic segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 6810-6818.
- [60]Tzeng E, Hoffman J, Saenko K, et al. Adversarial discriminative domain adaptation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 7167-7176.
- [61]Ganin Y, Ustinova E, Ajakan H, et al. Domain-adversarial training of neural networks[J]. The journal of machine learning research, 2016, 17(1): 2096-2030.
- [62]Tsai Y H, Hung W C, Schuler S, et al. Learning to adapt structured output space for semantic segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 7472-7481.
- [63]Deng X, Yang H L, Makkar N, et al. Large scale unsupervised domain adaptation of segmentation networks with adversarial learning[C]//IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2019: 4955-4958.
- [64]Lu X, Zhong Y, Zheng Z, et al. Cross-domain road detection based on global-local adversarial learning framework from very high resolution satellite imagery[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 180: 296-312.
- [65]Luo Y, Zheng L, Guan T, et al. Taking a closer look at domain shift: Category-level adversaries for semantics consistent domain adaptation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 2507-2516.
- [66]Yang J, Chen H, Xu Y, et al. Domain adaptation for degraded remote scene classification[C]//2020 16th International Conference on Control, Automation, Robotics and Vision (ICARCV). IEEE, 2020: 111-117.
- [67]Fang B, Kou R, Pan L, et al. Category-sensitive domain adaptation for land cover mapping in aerial scenes[J]. Remote Sensing, 2019, 11(22): 2631.
- [68]Hoffman J, Tzeng E, Park T, et al. Cycada: Cycle-consistent adversarial domain adaptation[C]//International conference on machine learning. Pmlr, 2018: 1989-

- 1998.
- [69]Sun Q, Liu Y, Chua T S, et al. Meta-transfer learning for few-shot learning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 403-412
- [70]Zhao S, Wang G, Zhang S, et al. Multi-source Distilling Domain Adaptation[J]. 2019.
- [71]Luo Y, Zheng L, Guan T, et al. Taking a closer look at domain shift: Category-level adversaries for semantics consistent domain adaptation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 2507-2516.
- [72]Jeon H K, Kim S, Edwin J, et al. Sea Fog Identification from GOCI Images Using CNN Transfer Learning Models[J]. Electronics, 2020, 9(2): 311.
- [73]Mengqiu X U, Ming W U, Jun G U O, et al. Sea fog detection based on unsupervised domain adaptation[J]. Chinese Journal of Aeronautics, 2021.
- [74]Shi L, Wang Z, Pan B, et al. An end-to-end network for remote sensing imagery semantic segmentation via joint pixel-and representation-level domain adaptation[J]. IEEE Geoscience and Remote Sensing Letters, 2020.
- [75]Isola P, Zhu J Y, Zhou T, et al. Image-to-image translation with conditional adversarial networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 1125-1134.
- [76]Long J, Shelhamer E, Darrell T. Fully Convolutional Networks for Semantic Segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4):640-651.
- [77]Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[C]//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.
- [78]Chen L C, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//Proceedings of the European conference on computer vision (ECCV). 2018: 801-818.
- [79]Dou Q, Ouyang C, Chen C, et al. Unsupervised cross-modality domain adaptation of convnets for biomedical image segmentations with adversarial loss[J]. arXiv preprint arXiv:1804.10916, 2018.