



中国科学院大学
University of Chinese Academy of Sciences

博士学位论文

基于大数据的太阳暗条自动提取的方法研究

作者姓名: _____ 祝高飞

指导教师: _____ 王东光 高级工程师(正研级)

_____ 中国科学院国家天文台

学位类别: _____ 理学博士

学科专业: _____ 天文技术与方法

培养单位: _____ 中国科学院国家天文台

2020 年 12 月

Research on automatic extraction method of solar filaments
based on big data

A dissertation submitted to the
University of Chinese Academy of Sciences
in partial fulfillment of the requirement
for the degree of
Doctor of Natural Science
in Astronomical techniques and methods

By

Zhu gaofei

Supervisor: Professor Wang dongguang

National Astronomical Observatories, Chinese Academy of Sciences

December, 2020

中国科学院大学 学位论文原创性声明

本人郑重声明：所呈交的学位论文是本人在导师的指导下独立进行研究工作所取得的成果。尽我所知，除文中已经注明引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的研究成果。对论文所涉及的研究工作做出贡献的其他个人和集体，均已在文中以明确方式标明或致谢。本人完全意识到本声明的法律结果由本人承担。

作者签名：

日 期：

中国科学院大学 学位论文授权使用声明

本人完全了解并同意遵守中国科学院大学有关保存和使用学位论文的规定，即中国科学院大学有权保留送交学位论文的副本，允许该论文被查阅，可以按照学术研究公开原则和保护知识产权的原则公布该论文的全部或部分内容，可以采用影印、缩印或其他复制手段保存、汇编本学位论文。

涉密及延迟公开的学位论文在解密或延迟期后适用本声明。

作者签名：

日 期：

导师签名：

日 期：

摘 要

太阳暗条是一种低温高密度的等离子体结构，当它出现在日面的边缘时，也可以称为日珥。它在色球望远镜的观测下，由于其是在太阳日面的投影，所以一般呈现的是暗黑色不规则条状物，其通常沿着磁场极性的反转线出现。研究表明，暗条的形成、发展和演化与太阳磁场的变化有密切的关系，而且暗条的爆发也与其他太阳活动(例如耀斑和日冕物质抛射)的产生有着潜在关系。因此，对暗条进行个例研究以及统计分析都具有重要的意义，如何在天文观测海量数据中快速有效地得到研究人员感兴趣的信息是目前天文数据处理的一个亟待解决的难题。

本研究课题是以百年的全日面 $H\alpha$ 的基础数据作为支撑，提出一种满足大数据需求的更为普适、高效、方便的暗条特征识别的方法，并且能够满足批量自动化处理的要求。在处理海量的历史数据资料时，遇到的问题有：由于地面观测过程中视宁度、散射光、高空云层等的影响，或者图像的对比度等都会对观测的图像质量有影响，以及各种因素导致图像中出现异常，这些都是会影响后期的自动化批量处理过程的，所以需要提出一种完整的算法流程能够从这些海量数据中自动化筛选出优质 $H\alpha$ 全日面数据，进而进行太阳暗条的识别和参数的提取。

针对多台站、长周期和大批量的历史 $H\alpha$ 太阳色球数据，我们提出了获取太阳圆盘圆心坐标、半径和太阳暗条识别的系统方法。该方法可以采用完全自动化的对历史大数据进行太阳圆盘的提取，并可以准确的计算其圆心坐标和半径，这对后续的临边昏暗去除的好坏以及暗条经纬度等参数的提取起到至关重要的作用；该方法还可以以自动化的方法在海量的历史数据中，可以高效、方便的实现太阳暗条的识别以及参数的计算，这些对后续的针对长周期的太阳暗条的统计分析工作起到关键的作用。

由于传统方法具有一定的局限性，特别是针对历史数据而言，存在各种各样的图像质量问题，不得不事先根据太阳圆盘特征设定一系列的算法步骤来应对图像质量造成的问题，所以我们提出使用基于卷积神经网络的新方法，可以自动的学习太阳圆盘的特征，并回归出太阳圆盘的数值化数据，即：圆心坐标

和半径。通过使用深度学习直接从 $H\alpha$ 图像中回归出数值化信息，也可以在天文领域进行更多的研究。

由于传统方法在进行太阳暗条识别，会在初步识别结果中带入大量的噪点存在，不得不根据面积、长宽比等条件来进行噪点排除，这可能会导致大暗条周围的小暗条一起被排除，所以我们提出基于全卷积神经网络的新方法，该方法的具有的很大的优势是可以从 $H\alpha$ 图像中直接识别出太阳暗条，而不会带入大量的噪点。通过对该方法再不断的改进，将会具有很好的前景。

关键词： 太阳暗条,太阳圆盘,历史大数据,卷积神经网络,全卷积神经网络,深度学习

Abstract

The solar filament is a kind of plasma structure with low temperature and high density. When it appears at the edge of the solar surface, it can also be called a prominence. Under the observation of chromospheric telescope, because of its projection on the solar surface, it usually presents a dark black irregular strip, which usually appears along the reversal line of magnetic polarity. It is generally believed that the formation, development and evolution of filaments are closely related to the changes of the solar magnetic field, and the breakout of filaments is also potentially related to the generation of other solar activities (such as flares and coronal mass ejections). Therefore, the case study and statistical analysis of the filament have important practical significance. How to get the information that researchers are interested in quickly and effectively from the massive astronomical observation data is an urgent problem to be solved in astronomical data processing.

This research project is based on the basic data of a century's full-disk $H\alpha$ solar images, which can provide a more universal, efficient and convenient method for solar filament feature recognition and parameter extraction of big data as far as possible, and can automatically process the full-disk $H\alpha$ data of big data automatically. When processing massive historical data, the problems encountered are: due to the influence of the visual tranquility, various scattered light, high-altitude clouds, etc. in the process of ground observation, even some inaccurate flat field correction or image contrast, saturation, etc., will have an impact on the quality of the observed image, and some practical factors will cause various anomalies in the image. This paper proposes a complete algorithm process, which can automatically screen out the high-quality $H\alpha$ data, and then identify the solar filaments and extract the parameters.

In view of the historical $H\alpha$ solar chromosphere data with multiple stations, long period and large quantities, we propose a systematic method to obtain the coordinates, radius and filaments of the solar disk. This method can extract the sun disk from the historical big data automatically, and can accurately calculate its center coordinates and

radius, which plays an important role in the subsequent limb darkening removal and the extraction of parameters such as the longitude and latitude of the solar filaments. The method can also be used in the massive historical data with automatic method, which can be realized efficiently and conveniently. The identification of solar filaments and the calculation of parameters play a key role in the subsequent statistical analysis of long period solar filaments.

Due to the limitations of traditional methods, especially for historical data, there are a variety of image quality problems, so we have to set a series of algorithm steps according to the characteristics of the solar disk to deal with the image quality problems. Therefore, we propose a new method based on convolution neural network, which can automatically learn the characteristics of the solar disk and regression. The numerical data of the solar disk, i.e. the coordinates and radius of the circle center. Through the use of deep learning, we can directly retrieve the numerical information from the $H\alpha$ image, and we can do more research in the field of astronomy.

Since the traditional method will bring a lot of noise in the preliminary recognition results, we have to eliminate the noise according to the area, aspect ratio and other conditions, which may lead to the exclusion of the small solar filaments around the large one. Therefore, we propose a new method based on the fully convolution neural network, which can directly identify the small solar filaments from the $H\alpha$ image. It will not bring in a lot of noise. Further improvement of this method will have a good prospect.

Keywords: solar filaments, solar disk, historical big data, convolution neural network, fully convolution neural network, deep learning

目 录

第1章 引言	1
1.1 太阳和太阳活动	1
1.2 太阳暗条	5
1.3 研究背景与意义	7
1.4 太阳圆盘和暗条自动识别算法概述	8
1.5 已有方法的分析	9
1.6 本文概述	10
第2章 相关技术基础	13
2.1 基础数字图像处理	13
2.2 神经网络的发展	20
2.3 卷积神经网络的使用分类	21
2.4 卷积神经网络的基本原理	22
2.4.1 单层感知机和图像卷积	22
2.4.2 卷积神经网络基本原理	25
第3章 基于历史大数据的太阳暗条识别	31
3.1 数据获取	32
3.2 太阳圆盘的圆心坐标和半径的获取	34
3.2.1 改进传统方法的算法	34
3.2.2 结果分析	36
3.3 全日面H α 图像预处理	40
3.3.1 太阳临边昏暗和不均匀性的去除	40
3.3.2 太阳暗条的增强	40
3.4 太阳暗条识别	43
3.4.1 改进的传统方法	43
3.4.2 结果分析	46
3.5 太阳暗条参数提取	50
第4章 基于卷积神经网络的圆心坐标和半径的回归	53
4.1 数据获取	53
4.2 建议的CNN网络模型	55
4.3 结果分析	62

第5章 基于全卷积神经网络的太阳暗条识别	67
5.1 数据获取	68
5.2 改进的U-Net网络模型	69
5.3 结果分析	73
第6章 全文总结与展望	77
6.1 工作总结	77
6.2 进一步工作展望	79
附录 A 附录	81
A.1 不均匀性去除	81
参考文献	83
发表的学术论文与研究成果	89
致谢	91

图形列表

1.1 太阳结构示意图。·····	2
1.2 几种典型的太阳活动。(a)中黑色区域是太阳黑子；(b)是太阳耀斑；(c)是日珥爆发；(d)是带有明显扭转运动的日珥。图片来源：NASA···	3
1.3 几种太阳观测数据。(a)全日面磁图；(b)全日面 $H\alpha$ 图；(c)131 Å图；(c)335 Å图；图片来源：solarmonitor.org·····	4
1.4 太阳黑子活动具有明显的周期性。图片来源：NASA·····	7
1.5 整个研究任务的技术方案。·····	10
2.1 (a)表示为一个 3×3 ，标准差为1的高斯核的数值；(b)是随机产生的一个 30×30 ，标准差为5的卷积核的可视化；(c)是(b)图中卷积核的三维直观效果。·····	15
2.2 一个图像分割的例子。左图是一只大牛和两只小牛；右图是将左图中的三只牛标记分割出来。图片来源：(Chen 等, 2017)·····	16
2.3 Sobel算子和Prewitt算子的常用模板。(a)、(b)分别是Sobel算子在 x 轴方向的横向模板和 y 轴方向的纵向模板；(c)、(d)分别是Prewitt算子在 x 轴方向的横向模板和 y 轴方向的纵向模板；·····	18
2.4 膨胀和腐蚀操作的示意图。(a)代表原图像，蓝色表示特征；(b)表示 3×3 的结构单元，形状为十字型；(c)表示用结构单元(b)对原图像膨胀的结果，绿色部分为膨胀区域；(d)表示用结构单元(b)对原图像腐蚀的结果，绿色部分为腐蚀掉的区域；·····	19
2.5 人体神经元被抽象成数学模型感知机的发展过程。上图：代表人体神经元的示意图；中图：神经元工作的抽象化表示；下图：由神经元抽象出来的数学模型感知机。·····	23
2.6 三种激活函数的图像。·····	24
2.7 一个基本的卷积层计算单元模型。 G_j^l 特征图和上一层的每个特征图都有关系。·····	25
2.8 AlexNet网络结构，由5个卷积层、3个池化层和3个全连接层组成。图片来源：Krizhevsky 等 2012·····	26
2.9 一个基本的卷积神经网络的工作原理。·····	29
2.10 一个基本的针对完整的训练集的训练过程。·····	30
3.1 一张来自怀柔观测基地(HSOS)的全日面 $H\alpha$ 太阳图像。图像中能观察到几种太阳活动现象，比如耀斑，黑子，暗条等。·····	31
3.2 历史数据中几种数据质量不符合要求的图像的示例。实际数据中会包含各种各样的质量不好的图像，大致可分为两类，一是不存在完整太阳圆盘；二是太阳日面非正常状态。·····	33

3.3 太阳圆盘的识别提取算法。包含判断太阳圆盘是否存在、是否满足要求、保存圆心和半径。·····	38
3.4 用Hough变换对缩小的图像进行初步圆定位，然后从原图像粗略的切割出来。·····	39
3.5 对大概切割出来太阳圆盘进行处理分割出太阳圆盘。·····	39
3.6 图像经过临边昏暗和不均匀性的去除。(a)表示获取太阳圆盘圆心坐标和半径，并且置于图像中心的原图像；(b)是从原图像中拟合出来的临边昏暗图像；(c)是拟合出来的不均匀性的图像；(d)是扣除临边昏暗和不均匀性的图像，呈现出相对均匀的强度分布。·····	41
3.7 采用低帽变换对图像的较暗区域进行有选择的增强。(a)临边昏暗和不均匀性去除后的图像；(b)采用低帽变换得出来的图像；(c)增强以后的图像，可以看出太阳暗条有明显的增强。·····	42
3.8 左：临边昏暗和不均匀性去除后的图像和它的直方图；右：采用低帽变换增强的图像和它的直方图。·····	44
3.9 太阳暗条的识别分割结果。(a)表示增强后的图像；(b)是它的直方图；(c)是带有噪点的太阳暗条分割结果；(d)是去除噪点和黑子的太阳暗条的识别分割结果。·····	45
3.10 一个三个台站对比的例子，它们都是CCD相机获取到、来自2013年1月4日同一天的数据。(a)表示预处理的数据；(b)是它们的直方图，拟合得到的均值和标准差分别是 $2.1873e+04$ 、 $2.1872e+04$ 、 $2.7196e+04$ 和 $1.8320e+03$ 、 $1.7132e+03$ 、 $2.1626e+03$ ；(c)是三个台站的识别分割结果。·····	46
3.11 一个来自NSO的1967年1月1日的例子，它的原始数据记录在照相底片/胶卷，然后扫描数字化的数据。(a)表示原始记录的数字化的图像和它的统计直方图，后面的(a)-(d)都是一样；(b)是排除其他干扰，P角矫正之后，太阳圆盘置于图像中间；(c)是临边昏暗去除的图像；(d)是不均匀性去除的图像和呈现正态分布的直方图，它的均值为 $3.1642e+04$ ，标准差为 $2.3192e+03$ ；(e)(左)是识别分割结果；(右)去除各种噪点之后的识别结果。·····	49
4.1 一个数据增强的例子。(a)表示一张仅随机了圆心坐标，没有噪声的图像；(b)是一张随机了圆心坐标，噪声密度为0.01的图像；(c)是一张随机了圆心坐标，噪声密度为0.04的图像；(d)是一张随机了圆心坐标，噪声密度为0.09的图像；·····	55
4.2 建议的CNNs回归模型的网络结构。整个模型总共有13层，其中包含10个卷积层和3个全连接的层。输入是 512×512 分辨率的单通道图像，输出为三个正实数，是太阳圆盘的中心坐标和半径。·····	59
4.3 整个任务的示意图。整个过程由数据和模型两部分组成。蓝色矩形表示任务处理顺序。·····	60
4.4 由建议的CNNs模型产生的特征图。(a)第一块中卷积层的特征图；(b)第四块卷积层的部分特征图。·····	60

4.5 一个训练过程的学习率曲线。	61
4.6 训练集和验证集的MSE损失曲线和R-square曲线。在训练过程中，训练集和验证集上模型的损失可以快速收敛，通过R-square表征拟合的程度也迅速提高。	62
4.7 太阳圆盘圆心坐标和半径的回归值和每幅图像的真实值。蓝色虚线表示回归值等于真值。大多数样本都穿过蓝色虚线。有一些偏离点是由于云污染、原始误差和不完整的圆造成的。	63
4.8 不同噪声密度下真实值与回归结果的差异。直线代表真值。太阳圆盘的圆心坐标和半径保持稳定的回归结果。	65
4.9 模型回归的可视化结果。白色圆圈表示结果：(a)原始图像，(b)无噪声的结果，(c)噪声密度为0.04的结果，(d)噪声密度为0.09的结果。 ...	66
5.1 利用传统图像处理方法进行太阳暗条识别的例子。太阳圆盘中存在大量的噪声点，这些噪声点是右侧面板上分散、孤立的黄色散射点所表示的。	67
5.2 全卷积网络结构。整个网络由卷积层组成，没有全连接层。FCN结合了粗略、高层和细致、低层的特征信息。	70
5.3 改进的网络结构。包含用蓝色框显示的收缩路径和用绿色框显示的扩展路径。每个方框下面的数字表示通道数。方框的左右两侧提供了特征图的尺寸大小。每个框内包含更多操作，如图5.4所示。	71
5.4 图5.3中每个彩色框的结构。蓝色虚线框包含两个卷积层、一个Dropout层和一个最大池化层。绿色虚线框由上采样层、卷积层、合并层和两个卷积层组成。卷积核的大小为 3×3 。每个卷积层后面都有一个激活函数。Dropout层以50%的概率丢弃神经元。上采样层使用最近邻域插值代替反卷积。合并操作用于连接每个下采样框中的第二卷积层和每个对应的上采样框中的上采样层。	72
5.5 训练集和验证集的Loss和Accuracy曲线。	74
5.6 使用改进的U-Net网络识别太阳暗条的例子。(a)表示预处理的 $H\alpha$ 太阳图像；(b)表示真值；(c)表示概率图；(d)表示新方法的分割结果；(e)是传统方法的识别结果，需要后续进行噪点排除。	76

表格列表

3.1 5个台站的数据概况。	32
3.2 长周期、多台站的太阳圆盘识别随机抽样结果。	37
3.3 每个台站的有效识别率。	47
3.4 长周期、多台站的太阳暗条识别随机抽样结果。	48
4.1 每个部分的样本数量。	57
4.2 250个样本的不同相对误差的比例。	64
4.3 在典型不同噪声密度下模型的真值和回归结果。	64
5.1 改进网络的数据增强的参数。	69
5.2 100个随机样本的识别结果。	74

符号列表

缩写

HSOS	怀柔观测基地
BBSO	美国大熊湖观测站
NSO	美国国立天文台
KSO	Kanzelhöhe太阳天文台
KODA	印度天文台
CCD	电荷耦合元件
CME	日冕物质抛射
H α	Hydrogen Alpha
SOHO	Solar and Heliospheric Observatory
TRACE	Transition Region and Coronal Explorer
Solar-B	Solar-B
STEREO	Solar TERrestrial RELations Observatory
SDO	Solar Dynamics Observatory
AIA	Atmospheric Imaging Assembly
EVE	EUV Variability Experiment
HMI	Helioseismic and Magnetic Imager
ASO-S	先进天基太阳天文台
FMG	全日面矢量磁象仪
OTSU	天津算法
ROI	局部感兴趣区域
CNN	卷积神经网络
ANN	人工神经网络
SVM	支持向量机
LSTM	长短期记忆人工神经网络

ReLU	Rectified Linear Units
MSE	均方误差
RMSE	均方根误差
Adam	Adaptive Moment Estimation
FDHA	Full-Disk H-alpha Patrol Telescope
FCN	全卷积神经网络

第1章 引言

1.1 太阳和太阳活动

当我们来到这个世界之后，无论是对于地球上的一切，还是宇宙的浩瀚，都会在脑海中产生各种各样的好奇。无数人类不畏艰难险阻一代又一代地去揭开这些神秘，都只为寻找那些终极答案：我们是谁？我们为什么存在？我们的归属又是什么？宇宙中是否还有其他高等生命？正是由于人类特有的这份好奇心，我们一直都在不停歇的去探索未知的一切。而这其中太阳又是决定地球上是否有生命存在的关键因素。漫漫的人类历史长河中，经过人类的不断的观测研究，我们渐渐对太阳有了一些基本的认知(林元章, 2000)。

太阳是一颗离地球平均距离为 $1.496 \times 10^8 \text{Km}$ 的恒星。由于地球环绕太阳的旋转轨道是椭圆，日地的最大距离为 $1.521 \times 10^8 \text{Km}$ ，最小距离为 $1.471 \times 10^8 \text{Km}$ 。由于其“适中”的距离，对地球上的生命存在起着至关重要的作用。正因为地球围绕太阳公转，以及地球本身地轴与公转轨道的 $66^\circ 34'$ 的交角，导致地球表面受到的辐射热量的变化，产生了地球的四季交替。太阳的质量约为 $1.989 \times 10^{30} \text{Kg}$ ，平均密度约为 $1.408 \times 10^3 \text{Kg/m}^3$ ，半径约为 $6.963 \times 10^5 \text{Km}$ ，其主要是由氢元素构成，其能量的产生主要是源于核聚变。

从结构上看，太阳从内向外分为内部结构和大气结构，而内部结构又分为核心层(又称日核)，辐射层，对流层；大气结构分为光球层、色球层和日冕层。如图1.1，其中核心层是太阳核聚变反应的区域，其本身具有非常高的温度和密度，并且不断的向外辐射出能量。辐射层主要是将日核产生的辐射能向外传递出去，其温度和密度是向外逐渐减少。对流层由于内部的氢的不断电离，引起流体静力学平衡的破坏，造成了气体不断的升降，形成对流。光球层位于太阳大气的最低层，也是我们可以使用白光观测到的太阳表面，通常太阳半径就是以光球层的外边界定义的，光球层的厚度不过几百公里，但是我们地球所看到的太阳可见光基本上是由它发出来的。色球层在光球层之上，密度更低，更稀薄，但温度反而更高，它的表面被针状物所覆盖。太阳最外层大气就是日冕层，它的形状非常不规则，温度却相比光球层和色球层都要高，达 10^6K 。由于太阳与地球的距离太远，所以我们对太阳的认知基本来源于望远镜观测和理论计算等

手段。而对于太阳的观测，我们可以通过选择适当的观测谱线，对太阳大气中不同层次的太阳活动进行观测。

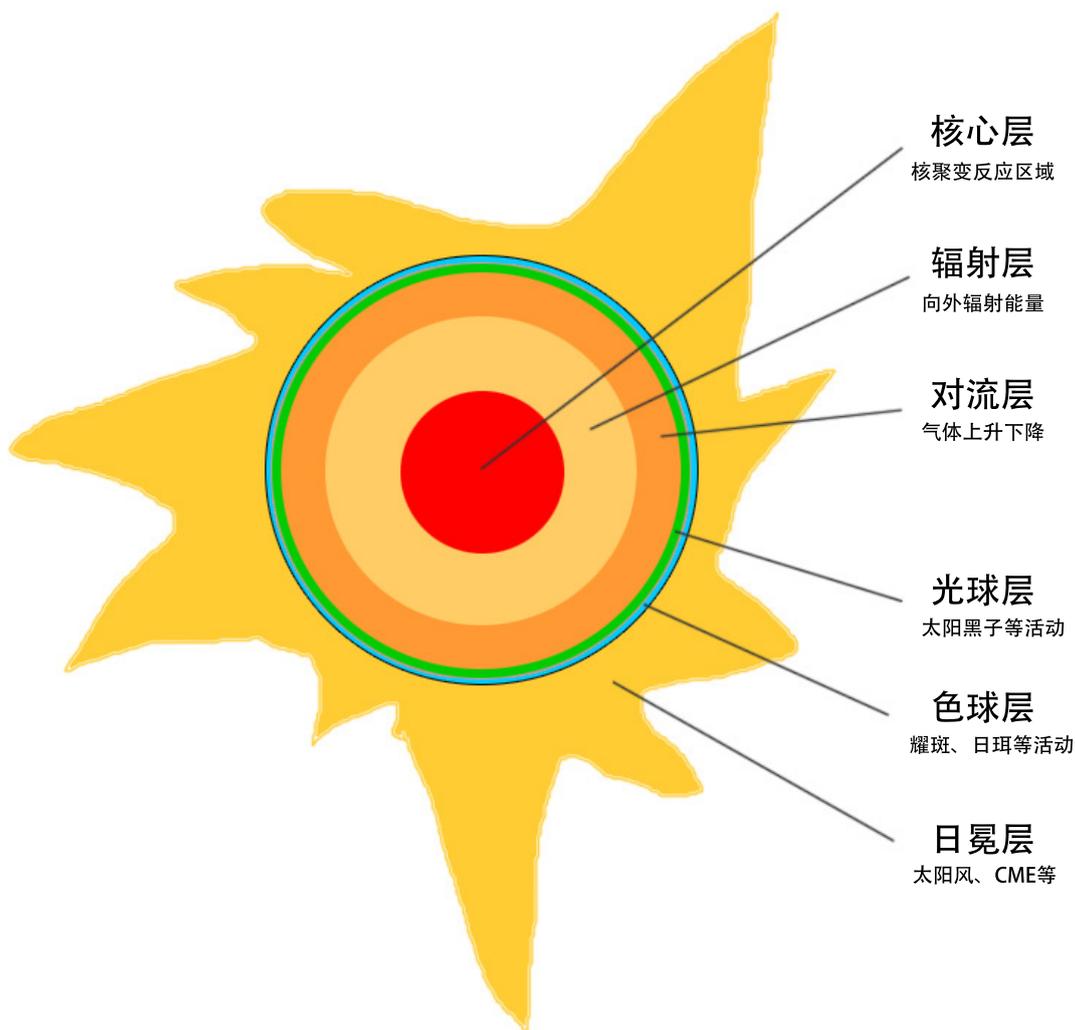


图 1.1 太阳结构示意图。

Figure 1.1 Schematic diagram of the structure of the sun.

太阳活动主要是太阳大气中各种活动现象的概括。在太阳大气中不同层有不同的特有的太阳活动，但是它们又是相互联系的。光球层的主要特征物包括太阳黑子、光斑，有时也会出现白光耀斑；色球层常常会发生剧烈的耀斑爆发，暗条(在日面边缘时又称日珥)和谱斑是色球上的典型特征物；日冕层通常会出 现日冕物质抛射(Coronal Mass Ejection:CME)、太阳风等。图1.2展示一些典型的太阳活动。太阳黑子主要是在光球表面呈现出暗黑色斑点，通常这个区域具有非常强的磁场，导致它的温度一般都低于日面的其他区域，所以才导致黑子看起来呈现暗黑色。而且对于较大型的发展成熟的黑子，中心区域具有更深的

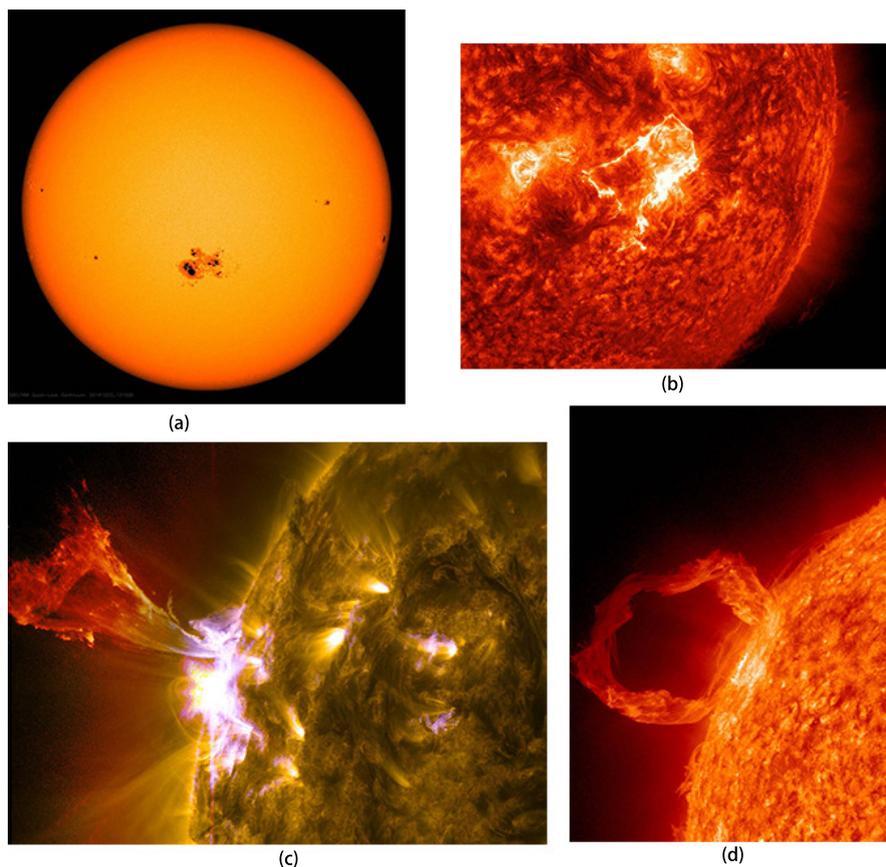


图 1.2 几种典型的太阳活动。(a)中黑色区域是太阳黑子；(b)是太阳耀斑；(c)是日珥爆发；(d)是带有明显扭转运动的日珥。图片来源：NASA

Figure 1.2 Several typical solar activities. (a) the sunspot; (b) the solar flare; (c) the prominence burst; (d) the prominence with obvious twisting motion. Source:NASA

黑色，称为本影；在本影周围的淡黑色区域，称为半影。黑子生存周期通常几天到几十天不等，最长可达几个月。经过长期的观测发现，黑子的数量的变化具有11年的周期性，被称为太阳黑子活动周。太阳耀斑是太阳活动中最为剧烈的活动现象之一，起初人们主要是通过氢的 $H\alpha$ 线(波长为 6562.8\AA)对其进行单色光成像，发现在太阳的色球层上谱斑区域会突然的增亮，也称为色球爆发。增亮的区域会在短时间内比周围的谱斑区域增亮几倍或者几十倍，在随后几十分钟或者1~2小时内慢慢恢复到原来的亮度。通常耀斑的爆发会朝外释放大量的能量，这其中包含各种电磁波和高能粒子。太阳暗条(日珥)同样可以在太阳的色球层通过 $H\alpha$ 线观测到，它主要是日珥在色球层投影形成的暗黑色狭长的条状物，当在日面边缘时呈现出不规则的喷发状。暗条的温度通常比周围日面要低，所以也是以暗黑色呈现出来。日冕物质抛射(CME)是太阳在一定时间内向外抛射

一团日冕物质，一般呈现出巨大的扩散环状，但是由于CME是动态变化的，其形态结构非常复杂多变。而且CME的爆发通常与其他的太阳活动有千丝万缕的关系，所以对CME的研究一般会同其他太阳活动关联起来。

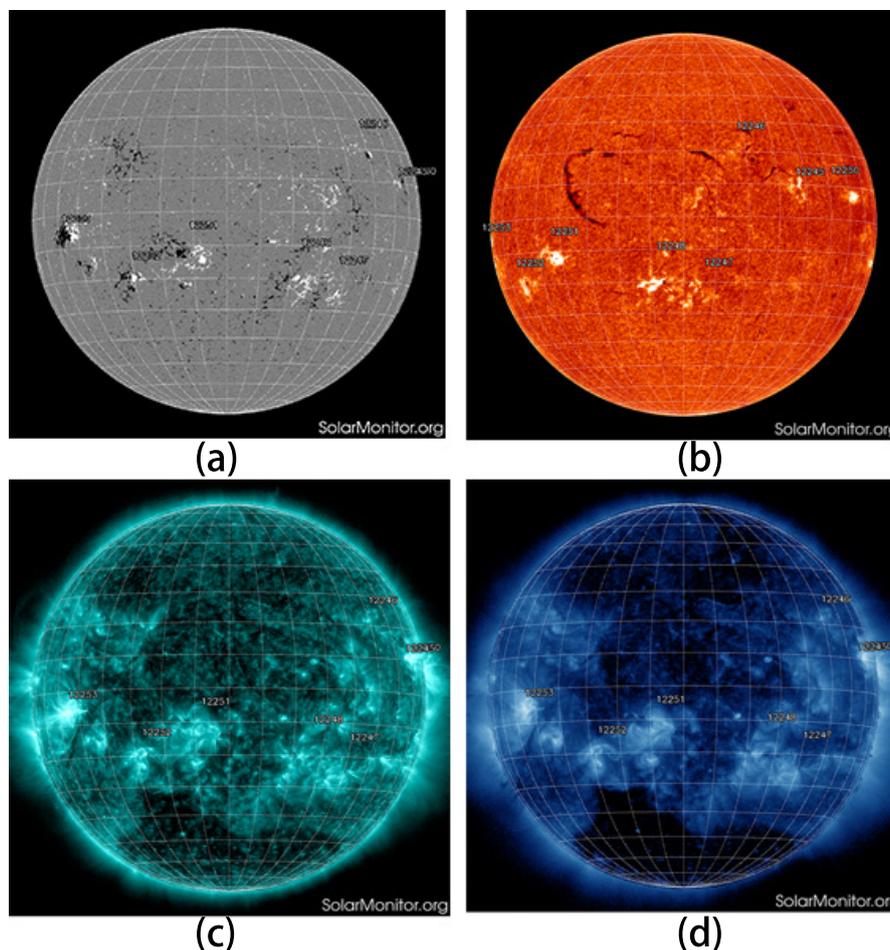


图 1.3 几种太阳观测数据。(a)全日面磁图；(b)全日面 $H\alpha$ 图；(c) 131 \AA 图；(c) 335 \AA 图；图片来源：solarmonitor.org

Figure 1.3 Several solar observations. (a) full-disk magnetic map; (b) full-disk $H\alpha$ solar image; (c) 131 \AA image; (c) 335 \AA image; source: solarmonitor.org

对太阳的观测，从观测位置来分，分为地面观测和空间观测。地面观测因为受到地面大气窗口的限制，仅限于可见光、部分红外、和射电波段的观测。空间观测则没有观测波段的限制，比较典型的有欧美合作研制的“太阳和日球天文台” (Solar and Heliospheric Observatory, 简称 SOHO)、美国研制的“过渡区和日冕探测器” (Transition Region and Coronal Explorer, 简称 TRACE)、多国联合研制的“Hinode”以及美国研制的“日地关系天文台” (Solar TERrestrial RELations Observatory, 简称 STEREO)。目前较近期的太阳观测卫星是2010年2月11日

在美国发射的“太阳动力学天文台”(Solar Dynamics Observatory,简称 SDO),它主要包括Atmospheric Imaging Assembly (AIA)、EUV Variability Experiment (EVE)、Helioseismic and Magnetic Imager (HMI)三个科学实验设备。国内目前正在研制空间项目先进天基太阳天文台(ASO-S)等设备,其中搭载了全日面矢量磁象仪(FMG)等科学仪器,以及地面的用于太阳磁场精确测量的中红外观测系统(AIMS)等项目。现在针对太阳的观测已经有非常多的数据种类,包括全日面 $H\alpha$ 太阳图像、全日面(局部)磁图,还有很多其他波长的观测数据,例如: 94\AA 、 131\AA 、 171\AA 、 304\AA 、 335\AA 、 1600\AA 等等,如图1.3。

1.2 太阳暗条

我国认为早在公元前1400年就已经在甲骨卜辞记载了发生在日全食的日珥现象(方成等,2008)。而欧洲人认为第一次发现这个现象是在公元1239年Muratori在一次日食的过程中观测到一个“燃烧洞(burning hole)”,并且很有可能就是“日珥”(Tandberg-Hanssen, 1995)。第一次半科学描述它们是在1733年5月2日的日食之后, Vassenius在瑞典哥德堡(Gothenburg, Sweden)看到三、四个“突起物”。在随后的1735年、1778年也观察到类似的现象。但在很长一段时间内这些观测被遗忘了。直到1842年在法国和意大利, Bailey、Airy、Struve和Schidlofscky、Arago等人再一次观测到这种现象,并且非常疑惑和惊讶他们所看到的,但仍然错误的认为那些“凸起”是太阳上的山脉(Tandberg-Hanssen, 1995)。所以对于日珥的认知,大致可以分为三个阶段,1860年以前的“猜测”期、1860~1960年的“光谱测量”期、以及1960以后的“偏振测量”期。虽然到现在为止对日珥的认识仍然存在很多不理解的地方,但是随着观测研究不断的发展,人们渐渐地向日珥有了更科学的认知。

太阳暗条就是日珥在日面上投影出的呈现暗黑色条状物,当日珥出现在日面边缘时,会出现明显喷发状的结构,图1.2(c)(d)。由于日珥是一个动态喷发的过程,它呈现出来的形态非常的多样和复杂,如果能从不同角度去观测它,更是有可能出现不同的形态特征。暗条在历史上有过多种分类法,典型的分类主要是从生存周期上和运动特性上来分。从生存周期看,主要分为短生存期、长生存期和中间类;从运动特性来分,主要分为活动区暗条、宁静区暗条和中间类(Engvold, 1998)。活动区的暗条一般具有强磁场,它的变化非常剧烈,往往

伴随在耀斑发生期间，且生存周期很短；宁静区的暗条一般形态较大，生存周期一般较长且变化相对缓慢；中间类暗条一般形成于活动区和衰减的单极区之间(郝奇, 2015)。无论是用哪种分类方式，这些特征信息可以为寻找更本质的太阳暗条的成因提供基础。

太阳暗条是一种高密度低温度的等离子体，通常认为太阳暗条在变化的过程中，存在着磁场力对其变化产生作用。有一些的研究(Kippenhahn 和 Schlüter 1957, Kuperus 和 Raadu 1974)指出存在向上的洛伦兹力导致暗条在下落的过程变得缓慢，通常被称为磁凹陷(dip)。而且通过大量的观测研究(Colloquium 等 1998, Martin 等 1994)，太阳暗条特征包含暗条主轴、暗条分叉、暗条通道，以及与磁螺度相关的暗条手征性，主要反映暗条上方冕拱的磁场旋转方向。和黑子一样，暗条同样也存在大约11年左右的周期。黑子一般存在随时间向赤道方向漂移的趋势，通过长周期的统计，它会形成非常明显的“蝴蝶图”(Maunder 1913, 图1.4)，暗条在日面上分布更广，从极区到赤道附近都有可能暗条的存在，同样经过长时间的统计也会形成“蝴蝶图”。此外，暗条的主轴、走向和手征性等也存在一定的规律性(Heinzel 等 2007, Hundhausen 等 1981, Lin 等 2008)。太阳暗条的数量和位置分布具有南北半球不对称性(Newton 和 Milsom 1955)。而且越来越多的研究表明太阳暗条与耀斑、CME等的发生有着很多相关性，一般耀斑的爆发会引起活动区的暗条周围的磁场结构发生变化，从而导致暗条发生相应的改变(Martin 等 1972, Tang 1986)。CME的爆发和暗条也同样存在联系(Munro 等 1979, Webb 和 Hundhausen 1987, Gilbert 等 2000, Gopalswamy 等 2003)，有可能它们有着共同的磁场结构。

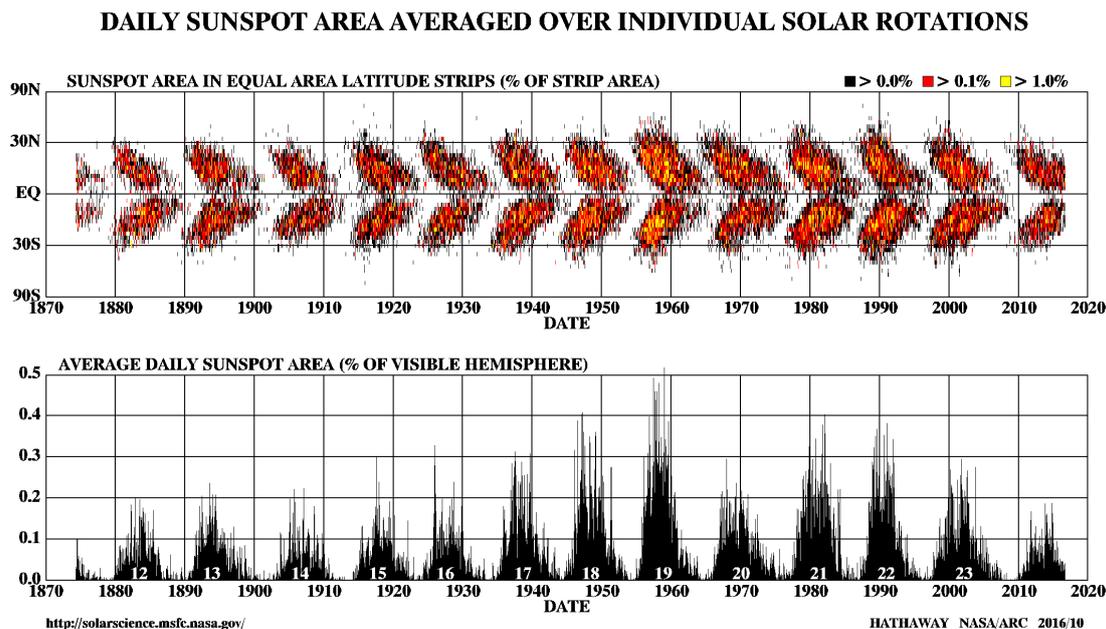


图 1.4 太阳黑子活动具有明显的周期性。图片来源：NASA

Figure 1.4 The sunspot activity has obvious periodicity. Source: NASA

1.3 研究背景与意义

本文研究的太阳暗条主要是来自全日面 $H\alpha$ 太阳图像，它主要通过太阳色球望远镜观测得到，通常使用 $H\alpha$ 谱线(波长为 6562.8\AA)作为透过波长，滤光器半宽一般为 $0.25 \sim 0.75\text{\AA}$ 。目前全世界仍有非常多的天文台使用色球望远镜对太阳进行常规观测，平均1-5min一张太阳色球图像，可以持续记录太阳上的活动现象。

我们目前收集到了多个观测站的全日面 $H\alpha$ 太阳图像数据(详细请见3.1)，其中我们选取了5个台站的数据用于太阳暗条识别的方法研究，它们分别是怀柔观测站(HSOS)，大熊湖观测站(BBSO)，Kanzelhöhe太阳天文台KSO，美国国立太阳观测站(NSO)，印度Kodaikanal天文台(KODA)。时间跨度达百年之久，数据存储量达数十TB，文件数量约为千万张图像。这里面有些早期数据是通过照相底片/胶卷数字化的数据，有些是电荷耦合元件(CCD)拍摄获得的。基于如此海量的 $H\alpha$ 全日面大数据，需要提出更为普适、高效、方便的暗条特征识别方法，并且能够满足批量自动化处理的要求。在处理海量历史数据资料时发现，由于地面观测过程中视宁度、散射光、高空云层等的影响，或者图像的对比度等都会对观测的图像质量有影响，以及各种因素导致图像中出现异常，这些都是会影

响后期的自动化批量处理过程的，所以需要提出一些自动化算法以满足大数据的普适性要求，以及尝试提出一些新的方法可以为以后更为可靠高效的处理提供思路。

1.4 太阳圆盘和暗条自动识别算法概述

太阳圆盘的圆心坐标和半径的确定是后续处理必要且关键的步骤，它们的准确度影响后续的操作和暗条参数的计算，比如临边昏暗去除、暗条的位置信息等。对于太阳圆盘的识别并获取其圆心坐标和半径，主要有几个发展阶段，Denker 等 (1999)从图像的X、Y方向扫描遇到出现明显强度变化的地方，通过对其相应坐标做简单运算来获取。这种方法的局限性是遇到图像中存在噪声或者边缘存在日珥都会造成结果的不准确。Joshi 等 (2010)通过在图像的左右上三个方向确定三个强度突变的点，根据三个不共线的点确定一个圆，这个方法同样也存在前面一样的局限性。Yuan 等 (2011)引入了级联Hough圆检测(cascading Hough circle detector)来计算太阳圆盘的圆心坐标和半径，将图像先缩小，再使用Hough变换检测圆，然后再将相应的结果放大。这种方法可以很好的克服图像中存在的噪声问题，但是由于Hough变换巨大的计算量，所以需要缩小图像降低计算量，这样会造成一定的精度损失。Hao 等 (2015)结合最小二乘圆拟合和级联Hough圆检测对于太阳圆盘进行提取，当两种方法的计算结果计算结果的差异在一定的像素数范围内即认为是合格的，这里面存在一些权衡的问题，首先Hough变换计算量大，图像越小速度越快，但是精度会降低；另外，当两种方法比较时选择的阈值过大，取哪一个作为最后的结果将是一个问题；而最小二乘拟合对噪声敏感，需要事先得到一个干净、光滑的圆盘边缘。所以对于大批量的历史数据，设计一个可以全自动、高准确度的太阳圆盘识别的算法是非常必要的。

在计算机蓬勃发展以前，对于太阳暗条识别分析，主要是采用人工的方式进行识别检测。Wang 等 (1998)分析了1991-1994年消失的暗条，并做了两个统计分析，其中针对统计中的活动事件主要是采用人工的方式检测的。随着望远镜和计算机的不断发展，产生了越来越多的数据，而且无论是时间分辨率还是空间分辨率都得到了很大的提高，慢慢的开始使用计算机对太阳活动自动的识别检测。Gao 等 (2002)采用结合阈值和区域生长的方式识别太阳暗条，先用全

图的中值的一半作为全局阈值，将图像初步分割成二值图，然后采用区域生长的方法将满足条件的区域标记成暗条。Shih 和 Kowalski (2003)提出局部和全局阈值两种方式，首先用局部阈值滤波器来进行暗条识别，但是效果不是很理想，所以又提出一种经过一些预处理之后使用一个固定全局阈值并运用形态学滤波来进行暗条的识别。Bernasconi 等 (2005)采用Shih 和 Kowalski (2003)的第二种方式进行同样的工作。Fuller 等 (2005)是在采用图像增强之后，使用区域增长进行暗条的识别分割，并且使用击中-脱靶变换(HitOrMiss transform)识别暗条的主轴。Qu 等 (2005)采用自适应阈值方案，先从0到全图的中值循环算出一个全局阈值，然后使用局部阈值实现暗条的分割。Zharkova 和 Schetinin (2005)采用的是由两个隐藏神经元和一个输出神经元组成的人工神经网络(artificial neural network, ANN)对事先已经从全日面图像切割出来的太阳暗条进行识别研究。Joshi 等 (2010)采用的是自适应局部阈值方法，主要是让局部区域的中值与设置的上限值和下限值比较，确定相应的可变的阈值，然后对每个像素的强度值与可变阈值对比识别暗条。Yuan 等 (2011)提出一种针对多台站的自适应阈值算法，通过循环检测所有候选阈值，找出一个满足某个要求的全局阈值识别暗条。Hao 等 (2013)、Hao 等 (2015)从最开始采用的固定阈值到后面采用基于改进的大津算法(OTSU; Otsu 1979)进行暗条提取，里面包含通过测试数百张图像得出的调整系数。Chatterjee 等 (2017)在综合图中进行长周期的暗条相关参数统计，采用的是半自动的识别方式，需要人工在综合图中标出种子点，然后用区域增长的方式实现暗条的识别。

1.5 已有方法的分析

通过前文的介绍，早期获取圆心坐标和半径的方法具有比较明显的局限性，不太适合大批量的历史数据使用。而后期采用的Hough变换和最小二乘拟合同时使用时会存在权衡问题，所以对于长周期的数据来说我们更希望的是能够结合两种方法的优势设计一个更合适的算法。针对全日面H α 太阳图像的暗条识别研究，由于暗条在日面上具有非常显著的强度特征，具有低强度值，呈现暗黑色的狭长不规则形状，主要的识别方法还是集中在通过阈值实现太阳暗条与其他非相关特征的分。主要分为全局和局部阈值、固定和可变阈值，以及配合区域增长等方法，随着识别算法的不断改进，不同的方法得到阈值的方式，

由最开始的原图像中获取，发展到经过一系列处理之后的图像中获取；处理的数据从最开始的实验性质的少量数据，到后面的可以对多台站的跨几个太阳活动周的 $H\alpha$ 数据进行识别研究。无论是固定阈值还是可变的自适应阈值，除了Yuan 等 (2011)和Hao 等 (2015)，其他研究工作大多针对单一台站，数据量相对偏少。Yuan 等 (2011)需要循环所有候选阈值进行阈值确定；Hao 等 (2015)中改进的OTSU算法需要经过数百张测试得出不同台站各自的调整系数，普适性存在局限。所以我们希望对于大批量、多台站、长时间的数据能够提出更为普适快速的方法。

1.6 本文概述

我们面对的是多台站、长周期、大批量的数据，这其中的数据质量又参差不齐。通过大量调研，我们制定了如图1.5的技术方案：

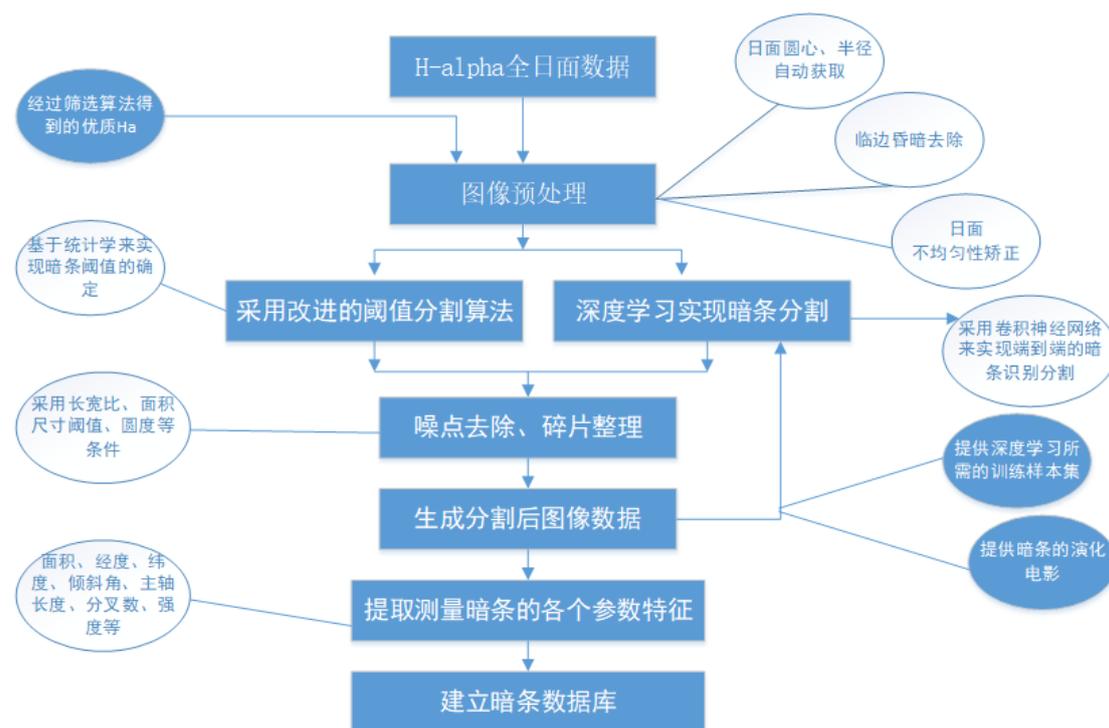


图 1.5 整个研究任务的技术方案。

Figure 1.5 The technical scheme of the whole research task.

首先我们对全日面 $H\alpha$ 太阳图像进行预处理，这同时也是筛选优质 $H\alpha$ 的步骤，其中包括太阳圆盘确定、是否符合要求、获取圆心坐标和半径，太阳圆盘临边昏暗去除，不均匀性的去除；然后改进传统方法，提出基于统计学实现太

阳暗条阈值的确定；并且进一步提出基于深度学习的太阳暗条的识别；对于传统方法的识别结果需要进一步的噪点等干扰去除，通过设定长宽比、面积尺寸阈值、圆度等条件来完成，最后计算太阳暗条相关的参数。

这其中针对历史大数据，我们改进了太阳圆盘的圆心坐标和半径的获取方法，改进了太阳暗条的识别方法，并进一步分别提出了基于深度学习的新方法。

本文的组织结构如下：第二章我们介绍了工作中用到的数字图像处理技术和卷积神经网络的相关基本理论，并且阐述了卷积神经网络与传统数字图像处理之间的联系；第三章介绍了改进传统方法的太阳暗条识别技术的具体工作；第四章阐述了基于深度学习的太阳暗条的识别相关工作；最后一章进行了全文的总结和进一步的工作展望。

第2章 相关技术基础

2.1 基础数字图像处理

数字图像处理技术是信息技术发展中一个重要的技术分支，虽然它属于计算机学科领域，但随着它的不断发展完善，如今已经在医学、生物、天文等诸多领域得到了广泛的应用，使得各学科交叉融合得到了很好的发展。

数字图像通常由扫描仪、摄像机、数码相机等设备来获取，天文学中使用望远镜来获取图像，它们都有个共同点，大部分通常是由电荷耦合元件(简称：CCD)来接收图像。而早期的天文数据通常是由胶卷等设备保存的，然后通过现代的扫描仪形成数字化的图像，这样可以方便处理和保存。通常我们进行数字化的图像处理主要有几个目的：改善或退化图像质量、提取图像中某些特征、图像的编码与压缩、计算图像中的特征参数。数字化的图像通常是矩阵形式，即数字阵列表示图像，所以我们可以通过一些数学运算对数字化的图像进行相对方便的处理。

数字图像处理一般包含图像变换、增强、复原、分割、描述、编码和压缩、分类、重建等内容(冈萨雷斯等, 2010)。介绍本节主要有两个目的：一个是我们的研究任务中会涉及数字图像处理的相关内容；第二个是数字图像处理技术作为计算机视觉领域重要的学科，也是卷积神经网络的重要的基础。所以我们选取了数字图像处理的一些常用技术方法在本节进行简单的阐述。

图像增强

图像增强就是突出原有图像整体或某些细节信息，达到让人或者机器更容易观看或者分析的目的。通常情况图像增强分为在空域空间和频域空间进行处理。空域空间表示在图像的像素级空间下进行处理，其中又分为针对每个像素点的点操作和针对周围像素的邻域操作。频域法是将原图像从空域空间变换到频域空间，可以有针对性的对高频或者低频信息进行处理。因为本文所研究对象的需要，我们仅对空域空间下的邻域操作的一些方法进行介绍。

对一幅灰度图像中某个像素点按固定大小窗口区域里的像素强度进行排序，取其中的中值作为该点的新的强度值，将该操作从左至右，从上到下依次进行，这个过程就叫做中值滤波(Huang 等 1979)。该方法是一种非线性的平滑技术，对

于椒盐等噪声具有非常好的抑制效果。对于二维图像数据的表达式为:

$$n(i, j) = \text{median} \{o(i - N, j - N), \dots, o(i, j), \dots, o(i + N, j + N)\} \quad (2.1)$$

其中 (i, j) 代表图像中像素点的坐标位置, $2N \times 2N$ 是扫描窗口的尺寸大小。

均值滤波(Koo 和 Park 1991)和中值滤波非常相似, 只不过获取的是窗口区域内的亮度信息的均值。均值滤波是线性的平滑技术, 它可以把图像中尖锐的特征变得平滑, 甚至模糊。针对二维数据的数学公式为:

$$n(i, j) = \frac{1}{MN} \left(\sum_{w=-a}^a \sum_{h=-b}^b o(i + w, j + h) \right) \quad (2.2)$$

其中 $M \times N$ 为窗口尺寸的大小, a , b 分别为 $M/2$, $N/2$, 通常情况我们称窗口大小的矩阵为算子或者核(kernel), 而且一般核的尺寸大小是相等的。然而均值滤波还可以表示为一个二维矩阵和一个核加权平均, 又可以被称为卷积操作。同时, 卷积神经网络(Convolutional Neural Networks, CNN)中的卷积就是最基本的运算操作, 可以抽象化为:

$$G = g \otimes f \quad (2.3)$$

其中 f 代表卷积核, 具体内容我们将在下一节详细介绍,

高斯滤波(Young 和 Van Vliet 1995)同样和均值滤波非常相似, 不同于均值滤波的是它的核矩阵的值不再是相同的数值, 而是具有高斯分布(又称为正态分布)的高斯核。高斯滤波同样也是一种线性平滑技术, 与均值滤波同属于低通滤波, 对高斯噪声的去除具有显著的效果。一维高斯分布的函数为:

$$G(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} \quad (2.4)$$

而针对二维数据的高斯函数表示为:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.5)$$

其中 σ 代表标准差。如图2.1

高斯滤波对图像的平滑程度取决于 σ 的大小, σ 越大, 高斯滤波器的宽度越宽, 也就是图2.1(b)白色区域的范围越大, 图2.1(c)中凸出的区域越平坦, 图像的平滑程度越好; σ 越小, 所有情况则相反。

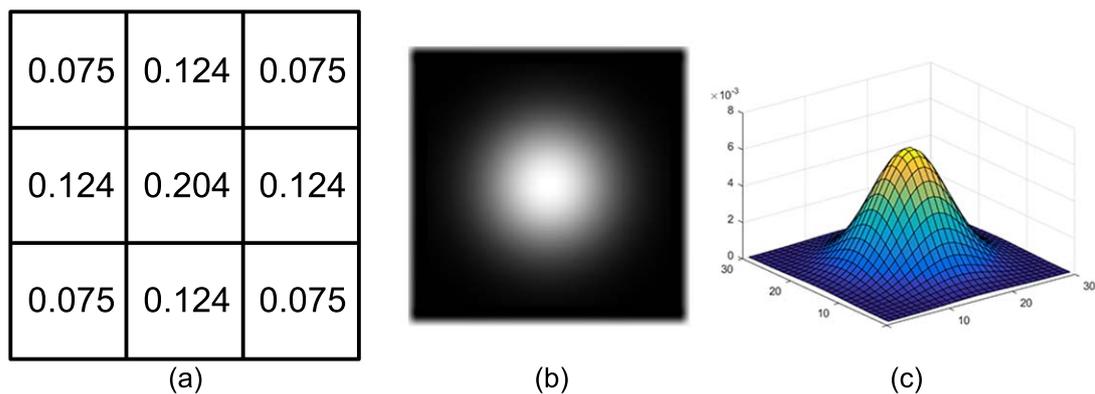


图 2.1 (a)表示为一个 3×3 ，标准差为1的高斯核的数值；(b)是随机产生的一个 30×30 ，标准差为5的卷积核的可视化；(c)是(b)图中卷积核的三维直观效果。

Figure 2.1 (a) The value of a Gaussian kernel with the size of 3×3 and standard deviation of 1; (b)The visualization of randomly generated convolution kernel with the size of 30×30 and standard deviation of 5; (c) It is the three-dimensional visual effect of convolution kernel in (b).

图像分割

图像分割的目的主要是从图像中分离出包含某些相似特征的感兴趣区域(ROI)(冈萨雷斯等, 2010)。通常情况我们是根据需求将原图像划分成若干块不同的区域，具体就是将图像中的像素逐个的标记，归类为不同的所属，如图2.2。目前图像分割方法主要分为以下几类：基于灰度阈值的分割法、基于区域的分割法、基于边界检测的分割法和一些其他方法。根据我们的研究内容，本节我们主要介绍一下第一种方法。

基于灰度阈值的分割方法主要应用于目标物体和背景具有显著差异的灰度图。具体就是通过某种方式找到一个合适的阈值，将图像中每个像素强度与阈值进行比较，小于阈值的设置为0，大于阈值的设置为1，变成二值图。通常阈值分割又分为局部阈值和全局阈值，局部阈值法还需要加入图像中局部区域的特征作为参考，可以用函数表示为：

$$T = Thr [x, y, l(x, y), o(x, y)] \quad (2.6)$$

其中 (x, y) 为像素坐标， $l(x, y)$ 为局部区域灰度值， $o(x, y)$ 表示原图像素灰度值。



图 2.2 一个图像分割的例子。左图是一只大牛和两只小牛；右图是将左图中的三只牛标记分割出来。图片来源：(Chen 等, 2017)

Figure 2.2 An example of image segmentation. Left panel: contains a cow and two calves. Right panel: the result of segmentation of three cows.

当确定了阈值以后，我们需要按照如下公式进行分割：

$$g(x, y) = \begin{cases} 1, & f(x, y) \geq T \\ 0, & f(x, y) < T \end{cases} \quad (2.7)$$

其中 T 就是代表所需的阈值。对于多类的分割，通常需要设置多个阈值，相应的会对不同的类别的像素进行不同的标记设置。而对于如何确定合适的阈值又是图像分割是否成功的关键，对于单一的全局阈值，比较经典的是通过观察图像的灰度直方图，在两个峰之间的谷底，就是所需要的全局阈值，虽然此方法比较简单，但是需要人为参与，灵活性不够。还有就是采用迭代的方式去搜索候选阈值，当阈值满足某种条件后，则认为当前候选为所需阈值。自适应阈值算法是可以针对图像中不同的特征强度自动确定合适的阈值，其中大津算法(Otsu 1979; OTSU)为经典的自适应阈值算法，也叫最大类间方差法，将图像分为目标和背景两部分，当它们的类间方差最大时，则认为当前阈值为所需。然而，在实际领域应用的过程中，所有的阈值方法如果直接应用在原图像中都有局限性，往往需要在应用阈值法之前，对原有图像先处理掉干扰的因素，再采用阈值方法会起到事半功倍的效果。

边缘检测

边缘检测是数字图像领域非常重要的研究内容，在非常多的研究任务中具有铺垫作用(Deriche 1987; Touzi 等 1988; Harris 等 1988)，比如特征提取之类的，越适合的边缘检测方法会让后续的研究任务变得方便可行。边缘检测，顾名思义，就是检测图像中明亮程度具有阶跃的地方，又称边缘，往往在图像中表现为某个目标物体的轮廓特征。而在实际的检测过程中我们往往是需要查找图中梯度变换明显的地方。在微积分中，二维的连续函数，可以通过求偏导获取梯度：

$$\frac{\partial f(x,y)}{\partial x} = \lim_{\gamma \rightarrow 0} \frac{f(x+\gamma,y) - f(x,y)}{\gamma} \quad (2.8)$$

$$\frac{\partial f(x,y)}{\partial y} = \lim_{\gamma \rightarrow 0} \frac{f(x,y+\gamma) - f(x,y)}{\gamma} \quad (2.9)$$

而在实际的数字图像中，是以二维离散化的像素点的形式存在的，所以不需要在图像中求导或者偏导数，而是通常只需要在x轴、y轴方向上进行简单的加减运算。梯度大的地方就是灰度变化明显的地方，也就是通常我们需要找的边缘。

在实际的边缘检测过程中，我们通常会使用滤波器(也可以像前文所称：算子或核)对原图像进行滤波(加权平均)。通常滤波器有：Sobel算子(Kittler 1983)、Canny算子(Ding 和 Goshtasby 2001)、Prewitt算子(Neuvo 等 1987)和Laplacian算子(Berzins 1984)。像前文所述，对图像的滤波就是原图像和算子从左到右、从上到下遍历做点积运算(像素点相同位置相乘然后再相加)。不同的滤波器只有算子里面的数值不同。如图2.3展示两种算子模板。我们可以看出不同的滤波器由不同的算子构成，它们有各自的优缺点，比如Sobel算子对噪声不敏感，对边缘具有良好的感知能力。Prewitt算子和Sobel算子具有类似的特点，从图2.3也能看出，只有细微变化。Laplacian算子对噪声敏感，还可能会出现双像素边界，少用于边缘检测。Canny算子相对其他三种，一般效果较好，它能有效的抑制噪声，原因是它会先对图像进行高斯滤波，还会对结果进行非最大值抑制，最后还会进一步连接边缘。

数学形态学

数学形态学(Haralick 等 1987)在数字图像处理中，就是使用一些具有某种形状的结构单元(Structuring Elements)，对原图像的特征进行某些形态上的改

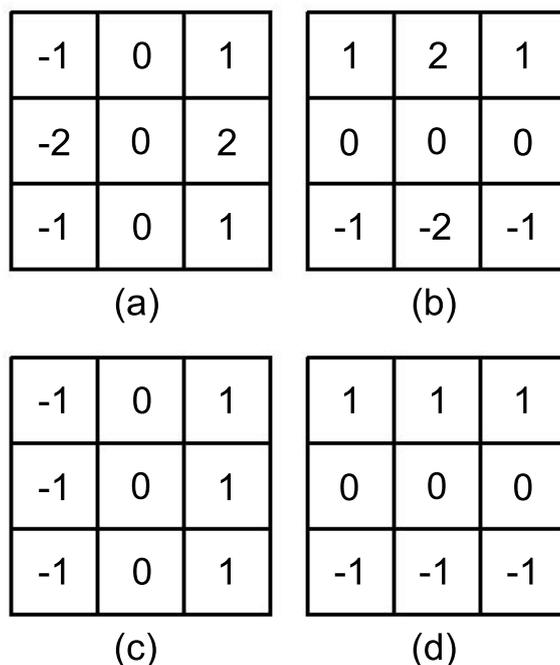


图 2.3 Sobel算子和Prewitt算子的常用模板。(a)、(b)分别是Sobel算子在x轴方向的横向模板和y轴方向的纵向模板；(c)、(d)分别是Prewitt算子在x轴方向的横向模板和y轴方向的纵向模板；

Figure 2.3 Common templates of Sobel operator and Prewitt operator. (a)、(b) are the horizontal template of Sobel operator in the direction of x and the vertical template of Sobel operator in the direction of y axis, respectively; (c)、(d) are the horizontal template of Prewitt operator in the direction of x and the vertical template of Prewitt operator in the direction of y axis, respectively;

变。一般结构单元都是由0和1组成的，由1构成不同的形状。膨胀(Dilation)和腐蚀(Erosion)是形态学中最基本的两个操作。膨胀操作是将结构单元在原图上从左到右，从上到下依次扫描，取原图中对应结构单元为1的点的强度最大值设置为目标点的值，可表示为：

$$n(x, y) = \max_{\{(x', y') : e(x', y')\}} \{o(x + x', y + y')\} \quad (2.10)$$

其中 $n(x, y)$ 是改变之后的值， $o(x, y)$ 是原图像的值， (x', y') 是结构单元中为1的点相对于目标点的偏移量。可以简单记为：

$$N = O \oplus e \quad (2.11)$$

而对于腐蚀运算则相反：

$$n(x, y) = \min_{\{(x', y') : e(x', y')\}} \{o(x + x', y + y')\} \quad (2.12)$$

同样也可简记为:

$$N = O \ominus e \quad (2.13)$$

图2.4是膨胀和腐蚀操作的一个示意图, 图中使用的结构单元的形状是十字型, 它还有多种形状结构, 比如菱形(diamond)、圆盘形(disk)、线形(line)、八角形(octagon)、矩形(rectangle)等, 在实际使用过程, 可以根据需要选择相应的结构单元的形状。另外, 在形态学基本操作之上, 还有膨胀和腐蚀的复合运算, 比如开运

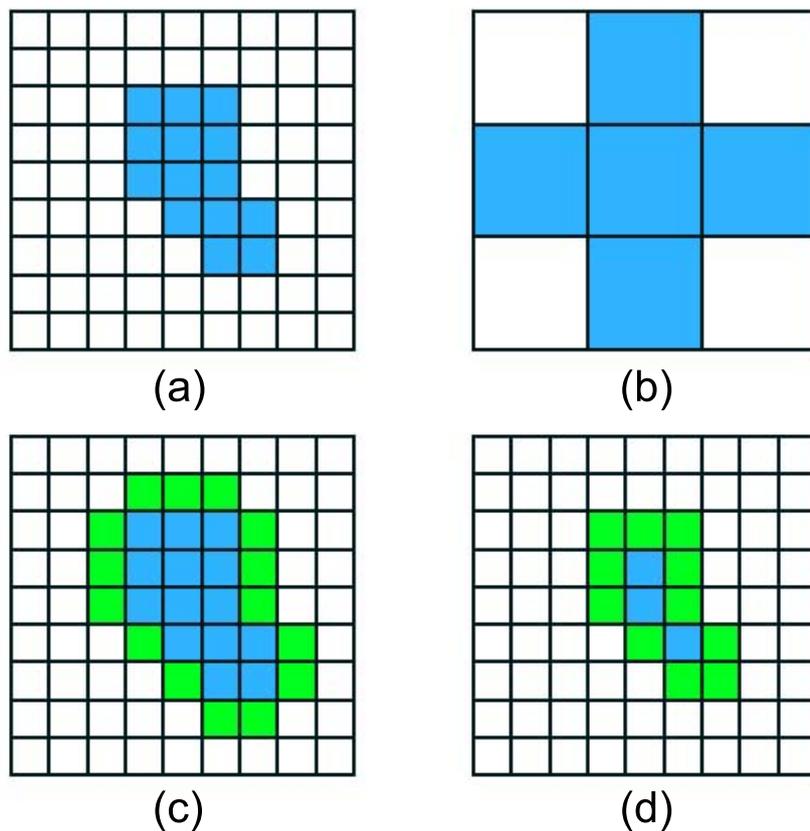


图 2.4 膨胀和腐蚀操作的示意图。(a)代表原图像, 蓝色表示特征; (b)表示 3×3 的结构单元, 形状为十字型; (c)表示用结构单元(b)对原图像膨胀的结果, 绿色部分为膨胀区域; (d)表示用结构单元(b)对原图像腐蚀的结果, 绿色部分为腐蚀掉的区域;

Figure 2.4 Schematic diagram of the dilation and erosion operation. (a) represents the original image, and blue represents the feature; (b) represents the structural element with 3×3 , and its shape is cross shaped; (c) represents the result of the dilation of the original image with structural element (b), and the green part is the dilation area; (d) represents the result of the erosion of the original image with structural element (b), and the green part is the erosion area;

算(Opening)和闭运算(Closing)。开运算是用同一个结构单元进行先

腐蚀再膨胀，而闭运算则相反。开运算可表示为：

$$N \circ e = (O \ominus e) \oplus e \quad (2.14)$$

它可用于消除图像中的较小区域。而闭运算可表示为：

$$N \bullet e = (O \oplus e) \ominus e \quad (2.15)$$

它的作用是对图像中的小空洞区域进行填充。

在开、闭运算基础之上，还包含白色顶帽变换(top-hat transformation; Bai 和 Zhou 2010)和黑色低帽变换(bottom-hat transformation; Baek 和 Lee 2016, Wang 等 2019)。白色顶帽变换使用原图像减去开运算结果，它可表示为：

$$T_{top} = O - (O \circ e) \quad (2.16)$$

它能够将原图像较亮的区域分离出来。黑色低帽变换是将闭运算的结果减去原图像，表示为：

$$T_{bot} = (O \bullet e) - O \quad (2.17)$$

它能将图像中较暗的区域分离出来。顶帽和低帽变换可以配合其他方法应用于不均匀性去除、图像增强等。

2.2 神经网络的发展

神经网络的发展经历过几个关键时期，并且发展过程中有起有落，慢慢才建立起来神经网络在当前人工智能领域决定性的作用。最早在1943年，神经学家McCulloch和数学家Pitts提出对神经元的数学描述和结构，给出了MP神经元模型(McCulloch 和 Pitts 1943)，这给后来的发展奠定了基础。生理学家Hebb在1949年的《行为组织：一个神经心理学理论》一书中提出神经元间的权值调整规则，并且信息存储在权值之中，这一思想依然在现代的神经网络结构中被采用(Hebb 1949)。1958年，Rosenblatt提出了“感知器(Perceptron, 或称感知机)”的概念，定义了一个单层计算单元的神经网络结构(Rosenblatt 1958)，提出一种类似于人类的学习过程的理论，这算是建立起人工神经网络(Artificial Neural Network, ANN)的雏形。自此，神经网络发展进入了第一个小高潮，然而到1969年，Minsky 和 Papert (1969)给本来正有起色的神经网络泼了一盆冷水，他们在《感知器：计

算几何导论》一书中指出简单的单层感知器的神经网络只能处理线性问题，不能解决线性不可分问题，如异或(XOR)。并且更多的感知器简单堆叠连接并不能处理非线性问题(Minsky 和 Papert 1969)，这无疑让当时的神经网络发展出现了停滞。直到1986年，Rumelhart、Hinton和Williams 提出多层感知器的新误差反向传播方法，不断调整权重让实际的网络输出和预期的输出之间的误差最小，被称为BP(back propagation)算法(Rumelhart 等 1986)，也是目前比较普遍的权重学习算法的基础，自此，神经网络进入了第二次发展高潮。1989-1998年，经过LeCun等人的不断努力，终于成功的设计出7层结构的卷积神经网络LeNet，并成功的应用于手写字符的识别(Lecun 等 1998)。随后的近20年，又有很多方法被提出来，例如决策树(Quinlan 1986)、支持向量机(SVM)(Cortes 和 Vapnik 1995)、LSTM模型(Hochreiter 和 Schmidhuber 1997)、随机森林(Breiman 2001)等，虽然他们都属于机器学习，然而除了LSTM模型其它的都不能严格的算是神经网络，虽然LSTM模型属于神经网络，但是由于当时硬件条件有限、神经网络缺乏严格的数学证明，神经网络的发展又进入低潮期。2006年，Hinton等人提出了深层次网络结构梯度消失的解决方案(Hinton 等 2006)，深度学习概念被提出。但直到2011年，ReLU(Rectified Linear Units)激活函数被提出来更好的用于解决梯度消失问题(Glorot 等 2011)，然后在2012年，Hinton等人在Imagenet图像识别大赛中使用其设计的带有ReLU激活函数的深度卷积神经网络(DCNN)AlexNet一举获得冠军，深度学习再次爆发研究热潮。至今又有非常多的基于卷积神经网络的研究成果，如ResNet(Wang 等 2012)、ZFNet(Zeiler 和 Fergus 2014)、VGGNet(Simonyan 和 Zisserman 2014) 和 GoogleNet(Szegedy 等 2015)等等。

2.3 卷积神经网络的使用分类

卷积神经网络属于深度学习(属于机器学习)，不仅在计算机视觉的图像领域取得很大的发展，同时也在如自然语言处理、语音识别等领域有着非常多的研究成果。它在学习方式上面可以分为有监督学习、无监督学习和弱监督学习。有监督学习需要给网络提供已经做好标记的或者是真实值的数据，让网络可以自动的朝着真值方向学习；无监督学习是指网络能够根据未经标记的数据集中的数据找出潜在的某种规律或模式，原生的生成对抗网络(GAN; Generative Adversarial Networks)是其典型的代表；弱监督学习就是要学习的数据中有部分已

经做好标记，或者一些标记不确切和不精确，有条件的生成对抗网络(Condition GAN)就是典型的代表。从卷积神经网络不断发展的过程看，它可以应用到分类、回归、聚类、识别等各种任务上。下一节我们将从有监督学习角度介绍卷积神经网络的基本原理。

2.4 卷积神经网络的基本原理

通过对神经网络的发展史的了解，我们知道最开始形成比较完整的卷积神经网络是LeCun等人提出的LeNet-5，用于手写字符的识别。随后Hinton等人的AlexNet网络更是让卷积神经网络的发展上了一个新的台阶，此后各种网络结构层出不穷。它的发展很大程度上有赖于硬件和数据的发展，在图像处理领域得到了很好的施展空间。

2.4.1 单层感知机和图像卷积

神经网络的发展主要是模拟人类的学习过程，通常认为神经元是人类学习过程的基本单位，通过我们人类的输入设备，比如眼睛、耳朵，然后经过预处理之后变成电信号作为神经元的输入，然后经历或简单或复杂的处理之后，输出给别的神经元或最后输出电信号，转变成人的各种反应。人类把这个过程通过数学模型抽象出来，叫做“感知机(Perceptron, 或称感知器)(Rosenblatt 1958)”。如图2.5展示的是人体神经元被抽象成数学模型感知机的发展过程(王旭等 2007)。图2.5(上)是人体神经元的构成的简易图示，它通过分支较多的树突接收来自其他神经元的电脉冲信号或化学物质，然后经过细胞体内的一系列处理变化，最后再通过突触将电信号或化学物质传递出去。图2.5(中)人们把它们抽象成一个包含输入、输出和中间处理过程的计算单元。图2.5(下)是进一步用数学模型抽象神经元的工作过程，称为“感知机(Rosenblatt 1958)”。感知机的输入可以包含多个输入，即： $x_1、x_2、\dots、x_n$ ，也可以用向量 X 表示。对于每个输入 x_i 都有对应的权重 w_i ，每个输入和权重相乘，再把所有结果求和，最后再加上偏置 b ，为了能够解决非线性的问题，最后又需要使用一个激活函数来添加非线性因素。它的数学表示为：

$$y(x) = f\left(\sum_{i=1}^n x_i w_i + b\right) \quad (2.18)$$

其中 f 代表激活函数，通常激活函数有Sigmoid函数、tanh函数、ReLU函数(Nair

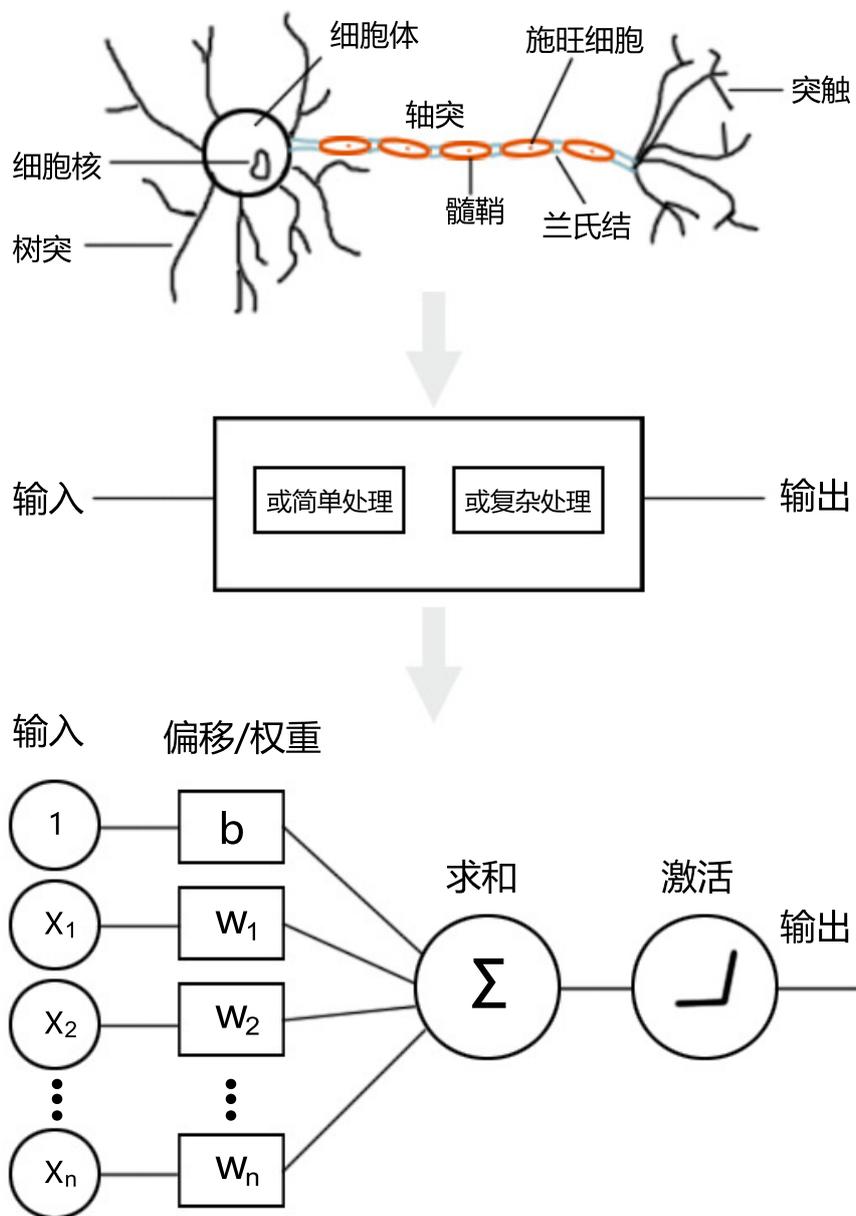


图 2.5 人体神经元被抽象成数学模型感知机的发展过程。上图：代表人体神经元的示意图；
 中图：神经元工作的抽象化表示；下图：由神经元抽象出来的数学模型感知机。

Figure 2.5 The development process that human neurons are abstracted into mathematical models-perceptron. Top panel: represents schematic diagram of human neurons; Middle panel: the abstract representation of neuron operation; Bottom panel: a mathematical model perceptron abstracted from neurons.

和 Hinton 2010)等。它们的数学表达式分别为：

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.19)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.20)$$

$$f(x) = \max(0, x) \quad (2.21)$$

它们的图像如图2.6，由于前两种激活函数存在梯度消失的问题，目前最常用的激活函数是ReLU函数(Nair 和 Hinton 2010)。

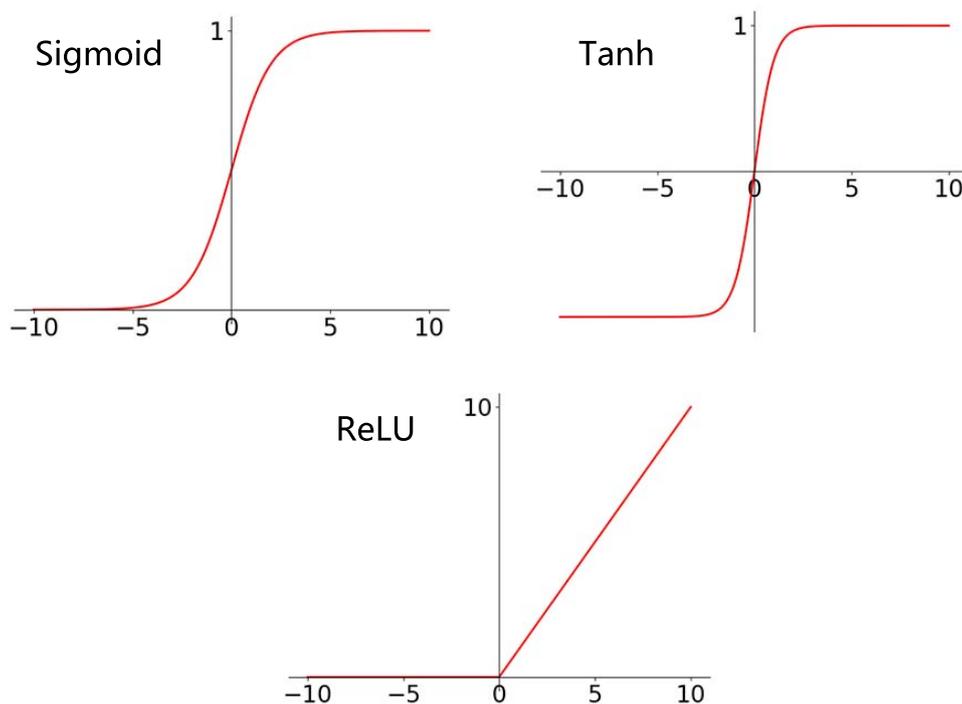


图 2.6 三种激活函数的图像。

Figure 2.6 Three activation functions.

感知机是根据人类神经元结构简单的数学抽象，不同于神经元内部复杂的电化学反应，单层的感知机只能做一些“与、或”这样的简单布尔运算，两个感知机连接就可以处理“异或”这类相对复杂点的逻辑运算(Minsky 和 Papert 1969)，用更多的感知机组成一个网络结构，就具有更好的拟合能力，可以处理更复杂的问题。

对感知机有了基本了解之后，就是如何将这些思想应用于实际问题当中。应用这些思想最成功的领域就是计算机视觉，人们首先将这个思想和图像卷积

相结合，产生了卷积神经网络思想。图像卷积的过程和前文所述的图像的滤波是一样的操作原理，只不过卷积会先把卷积核(前文称：算子)顺时针旋转180°。然后再用原图像和卷积核点积，一般表示为：

$$G = g \otimes w \quad (2.22)$$

其中 g 是原图像， w 是卷积核。所以原图像和卷积核从左到右、从上到下扫描点积，分别再加上偏置，然后经过激活函数的过程，就是感知机的模型思想。然而在实际使用过程中，我们每一层的图像(特征图)往往不止一张，每一张特征图都要和卷积核做卷积然后再叠加。相应地，卷积神经网络的基本计算公式是：

$$G_j^l = f\left(\sum_{i=1}^N g_i^{l-1} \otimes w_{ij}^l + b_j^l\right) \quad (2.23)$$

其中 f 是激活函数， g 代表第 $l-1$ 层的特征图(feature map)， w 代表第 l 层卷积核(权重)， b 代表偏置。如图2.7 主要表示某一层的所有特征图分别和卷积核点积加上

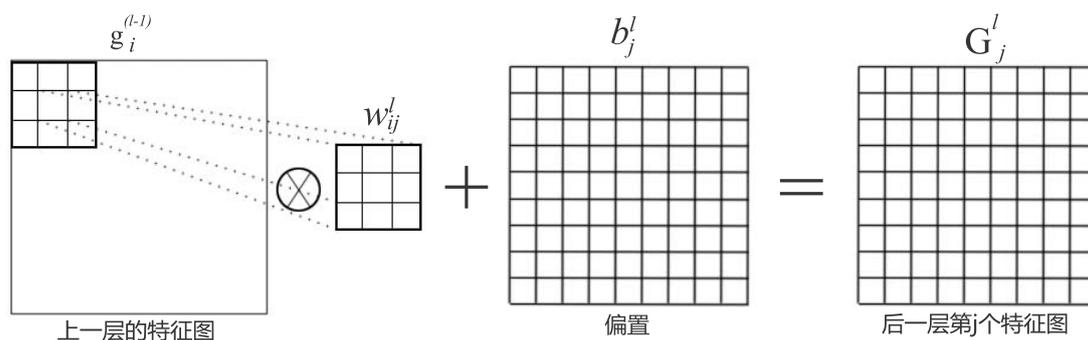


图 2.7 一个基本的卷积层计算单元模型。 G_j^l 特征图和上一层的每个特征图都有关系。

Figure 2.7 A basic computational element model of convolution layer The feature map of G_j^l is related to each feature map of the previous layer.

偏置之后的叠加，这样才计算得出它后一层的某个特征图。从上面可以看出，不同于感知机模型，卷积神经网络的权重是共享的(不变)，所以在点积的过程中卷积核是不变的，很好的降低了网络的复杂程度，同样需要加入激活函数，来添加非线性因素，去解决更多的非线性问题。

2.4.2 卷积神经网络基本原理

一个典型的卷积神经网络(CNN)的基本构成有(Lecun 等 1998, Krizhevsky 等 2012): 卷积层(Convolutional layer)、激活函数(Activation function)、池化层(Pooling

layer)、全连接层(Full connected layer)。卷积层的主要目的是为了提取图像中的特征信息，上节阐述了一个基本的卷积层的计算过程，然而在实际的卷积神经网络中，卷积层往往还包含很多的卷积核，每一个卷积核都能提取到本层的不同的特征信息，相当于特征提取器，不同于前文所述的图像滤波的算子是固定的，卷积核是动态学习调整的。激活函数同前文所述。池化层(又称：下采样层)的主要目的是降低前一层特征图的尺寸大小，减少网络的复杂度，常用的池化方法有平均池化(Average Pooling; Wang 等 2012)和最大池化(Maximum Pooling; Ranzato 等 2007, Yang 等 2009, Boureau 等 2010,)，平均池化是在图像中局部区域(通常 2×2)取一个平均值，然后在图像中滑动，生成一个新的图像，通常它的尺寸相比原先减小一半。最大池化是在局部区域内取最大值，通常情况下我们选择最大池化作为缩小图像的手段，第 l 层池化层位置为 (i, j) 的值可表示为：

$$m_{ij}^l = \max(m_{ab}^{l-1}), \quad i \leq a, b \leq i + 2 \quad (2.24)$$

其中 (a, b) 为第 $l - 1$ 层卷积层的相应位置。池化层能够起作用主要依赖于平移不变性(translation invariance)、旋转不变性(rotation invariance)和尺度不变性(scale invariance)。全连接层主要目的是连接前面卷积层和池化层提取到的特征信息，然后交给分类器(如Sigmoid函数)。具体就是将前面的特征经过连接拉成一个一维的特征向量，丢掉位置信息，然后交给分类器去做判断。一个可用的卷积神经网络，往往是由多个卷积层和激活函数，以及多个池化层和全连接层构成的，有的网络结构甚至达到了上百层。如图2.8是AlexNet的网络结构。

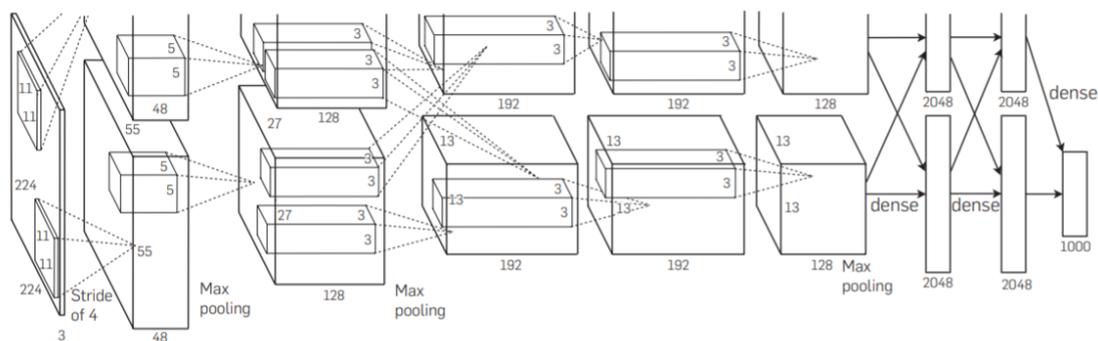


图 2.8 AlexNet网络结构，由5个卷积层、3个池化层和3个全连接层组成。图片来源：[Krizhevsky 等 2012](#)

Figure 2.8 Alexnet network structure is composed of 5 convolutional layers, 3 pooling layers and 3 fully connection layers.

当一个神经网络的构成基本确定以后，另外一个重要的事情，是确定一个损失函数(Loss Function)，它的主要作用是判断CNN学习得出来的结果和真实的结果之间的差异程度。最简单的损失函数就是感知机里面的0-1损失函数，预测结果和真实结果相等为0，不等为1，由于条件严苛目前基本很少使用。预测结果和真实结果之差，取绝对值或平方的绝对值损失函数(Absolute Loss Function)和平方损失函数(Quadratic Loss Function)。还有一些其它的比如对数损失函数(Logarithmic Loss Function)和指数损失函数(Exponential Loss Function)。以上的函数主要是针对单个样本间的误差。如果针对一批数据的误差，我们就需要把每个样本间的误差再求平均，通常我们把它称为代价函数(Cost Function)。常用的代价函数有均方误差(Mean Square Error)、均方根误差(Root Mean Square Error)、平均绝对误差(Mean Absolute Error)和交叉熵函数(Cross Entry Function)。比如均方根误差的表达式为：

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t^{(i)} - p^{(i)})^2} \quad (2.25)$$

其中 i 表示第几个样本， t 表示真实值， p 表示预测值。还有一个更广泛的概念是目标函数，它在代价函数的基础上，添加一定的惩罚项(又称：正则化函数)，主要目的是避免模型出现过拟合的现象，可表示为：

$$Obj = cost + \lambda\Phi(u) \quad (2.26)$$

虽然这三个概念有一些差异，但是通常我们相互混用，依然不影响理解。在网络模型结构相同的情况下，选择或设计一个好的损失函数(目标函数)，会取得事半功倍的效果。另外，在计算损失的时候，也需要一个评估函数，来评估当前预测值和真实值之间的匹配程度，比如，平均绝对误差(Mean Absolute Error)和R方(R Squared)等等。然而在有些问题当中，损失函数既可以作为损失函数也可以作为评估函数，比如均方误差(MSE)等。

当我们知道了预测结果和真实结果存在的差异之后，下一步就是根据差异自动调整参数(权重)进行下一次的预测。前面所述的求差异(误差)的过程，就是神经网络学习的正向传播过程(Forward propagation)。得到误差之后，需要将得到的误差反向带回网络进行计算，去更新权重(卷积核) w 和偏置 b ，这个过程叫做反向传播(Back propagation; Rumelhart 等 1986)。当有足够的样本量，真实

值 t 和预测值 p 之间的误差是权重 w 和偏置 b 的函数。所以，如果能求得该函数的最小值，就相应的得到了或者学习到了我们需要的最优的权重 w 和偏置 b 。而求这个函数极值的方法有很多，像早期的梯度下降法(Gradient Descent)，和后来改进的随机梯度下降法(Stochastic Gradient Descent, SGD, Bottou 2010)等。梯度下降法就是找一条路径最快的下降到函数的最低点，对权重 w 的更新可表示为：

$$w_n = w_o - \eta \frac{\partial(Obj)}{\partial(w_o)} \quad (2.27)$$

其中 Obj 表示目标函数， w_o 表示当前权重， η 表示学习率(learning rate)或步长， w_n 表示更新后的权重。它的含义就是我们在函数的 w_o 点求偏导，找出这个点下降最快的方向，也就是梯度的反向，然后乘以一个学习率，就可以将权重从 w_o 调整到 w_n ，实现了权重的更新操作，而对于偏置 b 的更新是同样的道理。因此学习率就成了权重更新的关键性因素，然而过大的学习率有可能会错过函数的最低点，导致震荡，过小的学习率会导致下降过慢，造成学习时间过长。所以人们进一步优化梯度下降法，提出动量(Momentum)梯度下降的技术(Qian 1999)，在更新公式2.27的权重之前先引入一个速度 v ，可表示为：

$$v_t = \beta v_{t-1} + (1 - \beta) \frac{\partial(Obj)}{\partial(w_o)} \quad (2.28)$$

其中 β 就是需要人为指定的动量参数，通常会被设置为0.9或相近。然后再更新权重：

$$w_n = w_o - \eta v_t \quad (2.29)$$

这样做的好处就是可以使网络加速收敛，减少震荡，使得收敛过程更稳定。后面随着改进的不断深入，有的是可以针对参数设置自适应的学习率，有的是针对参数设置自适应的动量，最终形成了目前使用较多的Adam方法(Adaptive Moment Estimation; Kingma 和 Ba 2014)，并且在实际使用过程中效果良好。如图2.9展示一个基本的卷积神经网络的运作原理。

上文所述的卷积神经网络的正向传播和反向传播各一次就是一次完整的参数更新的过程，后面会迭代更新参数，直到我们认为它满足某种条件之后才会结束，得到的参数就是训练好的模型。然而，在实际的训练(学习)过程中，往往由于训练样本集过大，导致计算机内存/显存不足，所以无法一次性对所有样本同时学习一次，进而更新一次参数。所以通常的做法是将样本集拆分成若干个

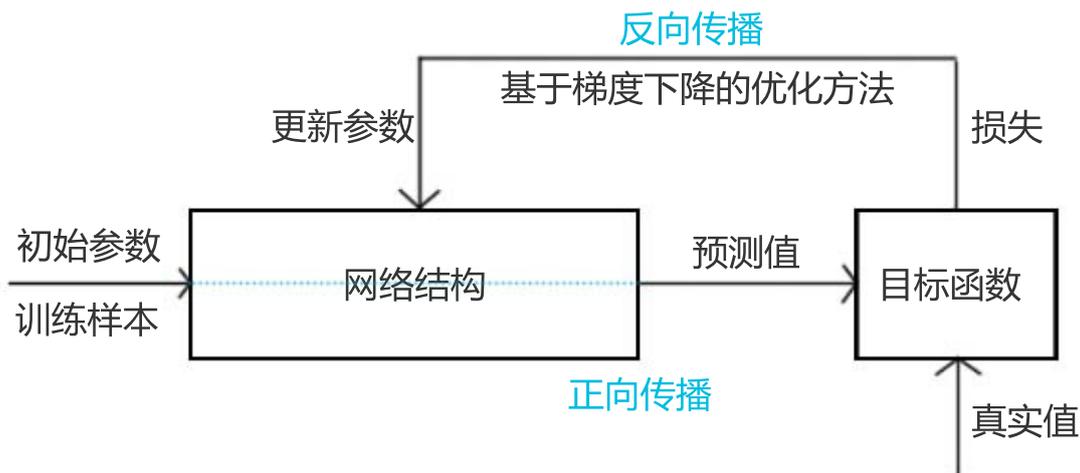


图 2.9 一个基本的卷积神经网络的工作原理。

Figure 2.9 The operation principle of a basic convolution neural network.

批次(Batch)，每个批次中的样本数一般叫“批尺寸(Batch Size)”。一次送入一个小批量(Batch)数据进行训练，每个Batch里面的所有样本各经历一次正向和反向传播，一般对每个样本计算出来的参数(先不更新)求完平均之后再更新参数(一个Batch训练一次称为一次迭代：iteration)；后面的每个Batch会在上一个Batch更新完之后的参数基础上，继续再训练(更新参数)，直到最后一个Batch训练完，就算完成一次Epoch(所有样本完成一次训练)。它们可以表示为：

$$Sample = \{x_1, x_2, \dots, x_N\} \quad (2.30)$$

$$Batch = \{x_1, x_2, \dots, x_n\}, \quad n \leq N \quad (2.31)$$

其中 N 表示样本集中样本的数量， n 表示“批尺寸(Batch Size)”，所以Batch是样本集(Sample)的真子集。一个Epoch由多个迭代次数组成(=Batch的个数)，可表示为：

$$iteration = \frac{N}{n} \quad (2.32)$$

如图2.10 展示一个基本的针对完整的训练集的训练的运作过程。通常训练的过程中，数据会被打乱再送入训练。

在整个实际的训练过程中，网络会不断的对所有样本集进行学习训练(不断的Epoch)，需要满足损失收敛(最小)，评估指标最好的情况，才算网络对当前样本集可以很好的拟合。但是当前训练出来的模型，是否应用在其他的数据集中

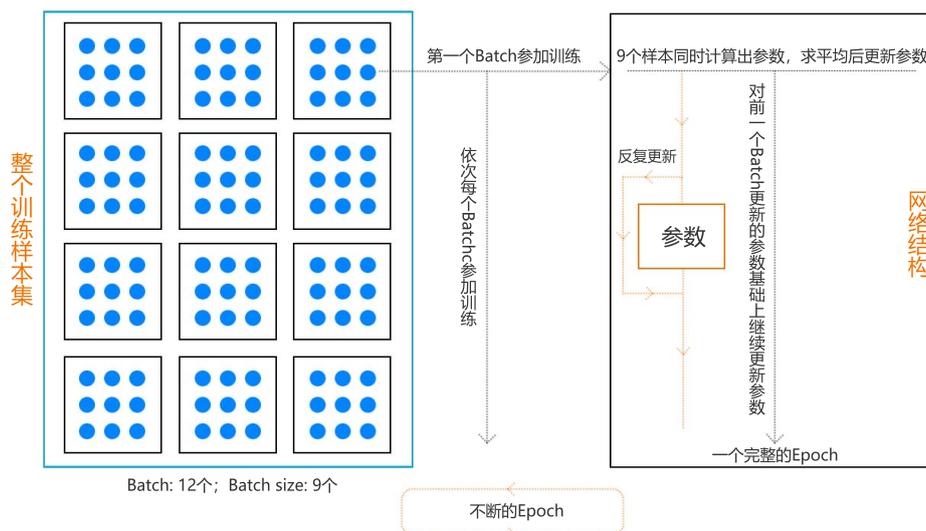


图 2.10 一个基本的针对完整的训练集的训练过程。

Figure 2.10 A basic training process for a complete training set.

也可以有很好的预测结果，我们是不清楚的。这就需要在对训练集训练的过程中，每经过一个Epoch之后，再用一个验证集去根据当前更新的参数计算相应的损失和评估，这样就可以大概判断卷积神经网络的学习能力的好坏。另外，还可以根据验证集的损失和评估的指标，大概判断在何时我们需要结束训练，所以可以根据观察来设置固定的Epoch数，或者根据训练集或验证集的损失不再下降作为终止训练的条件。

第3章 基于历史大数据的太阳暗条识别

针对全日面 $H\alpha$ 太阳图像，太阳暗条在图像中呈现的是暗黑色不规则条状物，如图3.1所示，可以看出图中的太阳暗条形态各异，且分布非常广泛和零散，虽然颜色呈现暗黑色，但依然有很多较小的暗条颜色很淡，由于周围各种活动和大气等的影响，如果直接识别很难有好的效果。特别针对大批量的历史数据而言，由于历史上各种原因会导致历史数据的质量参差不齐，所以我们需要提出一个可以针对长周期、多台站的历史数据的太阳暗条识别方案。由于历史数据质量的复杂性，首先我们需要从图像中确定是否有太阳圆盘，如果存在，然后再计算出太阳圆盘的圆心和半径。然后我们需要在太阳暗条识别之前做一些预处理的工作，一是保证经过预处理的数据是质量相对好的；二是经过预处理排除一些干扰，为下一步的识别工作做好铺垫。最后，在前面的工作基础之上，对图像内的太阳暗条进行识别分割。

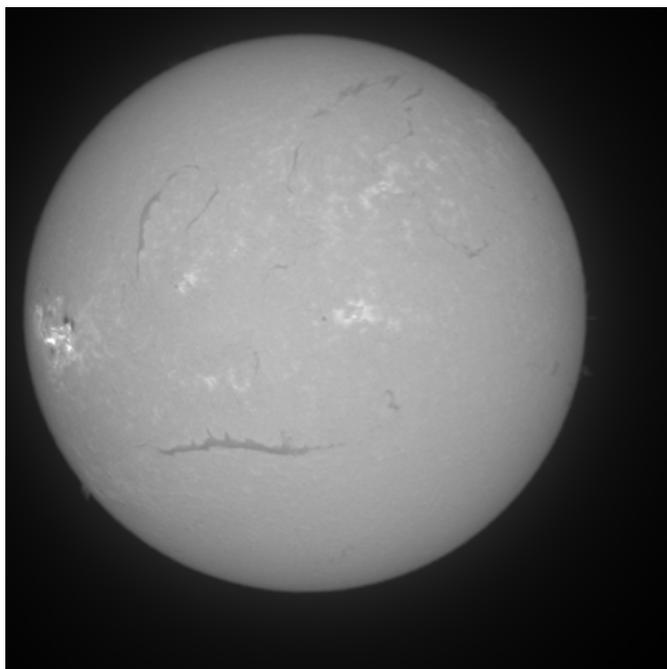


图 3.1 一张来自怀柔观测基地(HSOS)的全日面 $H\alpha$ 太阳图像。图像中能观察到几种太阳活动现象，比如耀斑，黑子，暗条等。

Figure 3.1 A full-disk $H\alpha$ solar image from Huairou observation station. Several solar activities, such as flares, sunspots and streaks, can be observed in the image.

表 3.1 5个台站的数据概况。

Table 3.1 Data statistics of 5 stations.

台站名	时间跨度	文件数量	存储大小(压缩后)
HSOS	2000–2018	1,088,914	8.1 TB
BBSO	1988–1994, 2000–2017	454,923	2.1 TB
NSO	1973–2015	7,299,490	5.1 TB
KSO	1963–2003	1,046,085	30 TB
KODA	1912–1973	18,313	680 GB

3.1 数据获取

我们收集到了来自世界上5个台站的全日面 $H\alpha$ 太阳图像的原始数据，分别是HSOS(怀柔观测基地)、BBSO(美国大熊湖天文台)、NSO(美国国立天文台)、KSO、KODA(Kodaikanal Observatory of India)，总时间跨度将近100年，总数据量将近50TB。如表 3.1，其中有些数据早期是从电影或底片数字化出来的数据，后期是用CCD(电荷耦合器件)获取到的数据。由于各种台站数据资料的不同，我们对它们进行了初步融合、比如统一文件名、目录、压缩等(Lin 等 2020)。由于NSO数据文件的Header中缺失观测时间这一首要关键字，而是在图像中的左或右两侧以图片的形式存在(时间戳)，所以在真正使用之前，又使用卷积神经网络和人工校验的方式(Zhang 等 2019)，将时间戳信息提取出来，解决了NSO缺少观测时间信息的问题。

由于收集到的是历史数据，所以整个数据的质量不稳定，会有各种各样的问题存在，如图3.2展示了几种图像质量不好的示例，大致可分为两类：一个是图像中不存在完整的太阳圆盘；二是有完整圆盘存在，但是圆盘内不存在正常的太阳日面。为了能够针对大批量数据自动化的挑选合适的图像，并且对其进行有效的太阳暗条识别，步骤是判断太阳圆盘是否存在、是否满足要求、计算圆心和半径，之后进行一些预处理的工作，最后完成太阳暗条的识别和参数的计算。

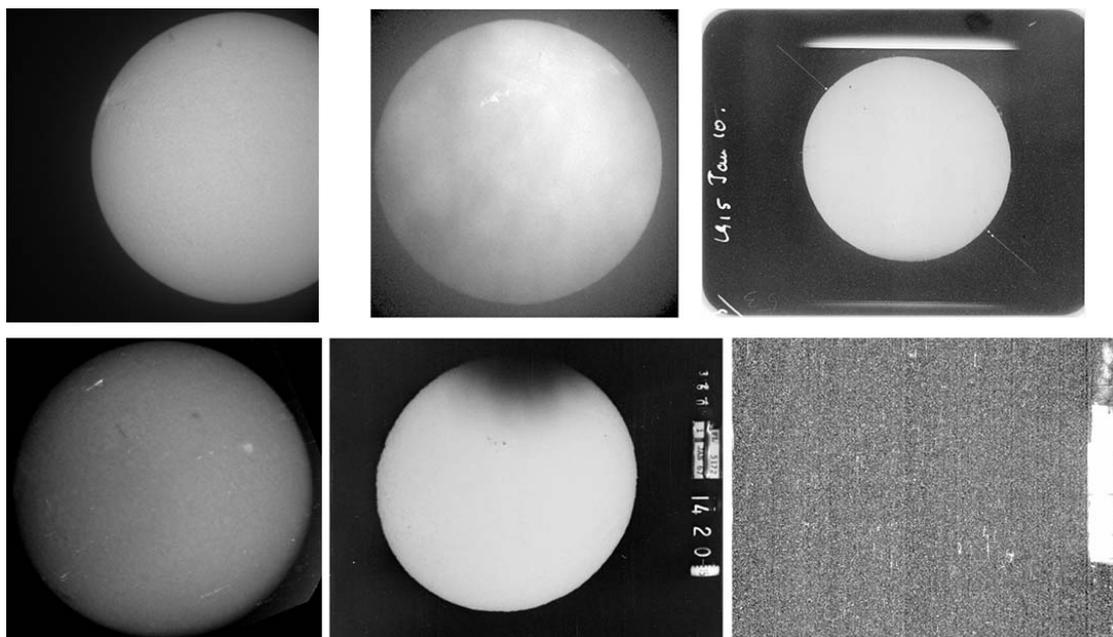


图 3.2 历史数据中几种数据质量不符合要求的图像的示例。实际数据中会包含各种各样的质量不好的图像，大致可分为两类，一是不存在完整太阳圆盘；二是太阳日面非正常状态。

Figure 3.2 Examples of several images in historical data whose data quality does not meet the requirements. The actual data will contain a variety of bad quality images, mainly in two aspects: one is that there is no complete solar disk; the other is the abnormal state of the sun's surface.

3.2 太阳圆盘的圆心坐标和半径的获取

3.2.1 改进传统方法的算法

通过我们对历史数据的观察，发现其中存在非常多的干扰因素，而且形式多种多样，这就需要我们提出一种能够处理大批量历史数据的全自动太阳圆盘识别算法。对此，我们算法会涉及Hough变换、最小二乘和大津算法(OTSU)等内容。下面对其作简要的介绍：

Hough变换最早由Paul Hough在1962年提出，用来检测图像中的直线，随着后来的改进，它不仅可以检测直线还可以检测圆形等任意的形状。主要原理是将二维图像的笛卡尔坐标系转变成极坐标系，将需要检测的形状的函数式用极坐标形式表示，然后将每个待计算的像素点代入函数式，一般在极坐标系中最多曲线的交点即为求解出来的形状的极坐标函数式，也可以再转化成笛卡尔坐标的函数式。如直线方程和圆方程的极坐标形式：

$$\rho = x \cos \theta + y \sin \theta \quad (3.1)$$

$$\begin{cases} x = x_0 + r \cos \theta \\ y = y_0 + r \sin \theta \end{cases} \quad (3.2)$$

其中 ρ 表示原点到直线的距离， θ 表示角度， (x_0, y_0) 表示圆心， r 表示半径。从原理也可以看出图像越大、越复杂，检测出来的边缘点越多，Hough变换的计算量就会越大；一般最后结果会有一堆候选项，一般选择投票最多(极坐标系中曲线交点最多的点)的结果，当图像中出现多层同心圆的情况，有可能我们需要的圆的投票不是最高的，这需要人工去做选择；而且通常在检测圆的时候，还需要为它的半径设置一个查找范围和查找步长，这些也关乎最后的运算速度。所以在使用的時候先缩小图像，再进行检测，这会造成精度降低，但是由于其对噪声很好的鲁棒性，可以用其进行初步的太阳圆盘的定位。

最小二乘(least square method)是通过最小化误差平方和(SSE)，来用给定的样本点拟合目标函数方程。比如我们存在一个光滑的边缘点集合 (X_i, Y_i) ，待拟合的圆的函数为：

$$R^2 = (x - A)^2 + (y - B)^2 \quad (3.3)$$

其中 (A, B) 和 R 就是需要拟合出来的圆心坐标和半径。将所有点集合带入得:

$$g_i^2 = (X_i - A)^2 + (Y_i - B)^2 \quad (3.4)$$

它们的误差平方和为:

$$\begin{aligned} Q(a, b, c) &= \sum \delta_i^2 \\ &= \sum (g_i^2 - R^2)^2 \\ &= \sum [(X_i - A)^2 + (Y_i - B)^2 - R^2]^2 \\ &= \sum [X_i^2 + Y_i^2 + aX_i + bY_i + c]^2 \end{aligned} \quad (3.5)$$

我们只要求得系数 a, b, c 使 $Q(a, b, c)$ 的值最小即可。最后相应的圆心坐标 (A, B) 和半径 R 为:

$$\begin{cases} A = -\frac{a}{2} \\ B = -\frac{b}{2} \\ R = \frac{1}{2}\sqrt{a^2 + b^2 - 4c} \end{cases} \quad (3.6)$$

由上面可知, 最小二乘方法拟合的好坏, 完全取决于所获得的边缘点, 所以对噪声会非常敏感。如果事先排除掉过多的噪声点和其他干扰, 得到干净光滑的边缘点, 再来拟合圆就会得到好的结果, 而且速度很快。

大津算法(OTSU)是由日本人大津于1979年提出的, 它主要是求出图像中使得前景和背景类间方差最大的全局阈值, 所以又称最大类间方差法。通过循环阈值 T , 将图像分为前景 f 和背景 b , 然后使下面类间方差最大:

$$\delta^2 = P_f \times (Q_f - \eta)^2 + P_b \times (Q_b - \eta)^2 \quad (3.7)$$

其中 η 表示整个图像的平均值, Q_f, Q_b 代表前景和背景的平均值, P_f, P_b 分别表示前景和背景的每个灰度级的概率之和。它的局限性是只能分割图像中具有明显区分度的目标, 而且只适合二分类分割, 不太适合多个目标的情况。它的优点是计算简单快速。

我们发挥上面各个方法的优势, 提出具有强鲁棒性的太阳圆盘识别算法, 如图3.3, 步骤如下:

1. 首先我们需要先对圆盘有一个基本的判断, 图像内是否存在圆盘。我们采用Hough变换检测圆, 得出一个最有可能的圆心坐标和半径, 鉴于图像内的干

扰和噪声，以及Hough变换对于大尺寸的图像计算速度非常慢，我们先把图像缩小后应用Hough变换，然后把可能存在的太阳圆盘从原图像粗略的切割出来，初步排除掉其他多余的大的干扰。如图3.4。

2. 然后对上面切出来的太阳圆盘图像，提高太阳圆盘和背景的对比度，使圆盘产生过曝的效果，将背景置0，使用大津算法(OTSU)分割出太阳圆盘，排除掉日珥等因素的干扰。如图3.5，然后对其进行边缘检测，根据边缘计算圆度，当圆度小于0.9则认为当前图像不符合要求跳过；否则，进入下一步。

3. 对上面边缘检测的结果，计算每个连通域像素构成数量，最大的连通域就是太阳边缘，删除由其他噪声构成的小的连通域。然后将边缘进行形态学膨胀，再骨骼细化，就得到一个干净太阳边缘像素集合。

4. 对上面的太阳边缘集合进行最小二乘拟合圆，得到相应的圆心坐标和半径。此时的太阳圆盘并非在图像中心所以我们根据现在的圆心坐标和半径，对太阳圆盘进行进一步的切割，让其处于图像的中心，然后将圆外置0。为了验证结果是否正确，我们需要再重复进行一次2-3步，当两次的半径相等(或在1个像素误差以内)，则认为我们识别的太阳圆盘的结果是符合要求的。

5. 最后保存圆心坐标和半径，供参数计算使用。

3.2.2 结果分析

为了验证我们提出的方法的可靠性，我们将本方法应用在HSOS、BBSO、KSO、NSO四个台站的全日面数据，时间跨度为1963-2018年、大约5个太阳活动周。由于数据量巨大，我们采用随机抽样，然后人工检查的方法进行评估。印度KODA数据的质量问题，在很多情况下日面中没有任何有效的太阳活动特征，人工难以判断，虽然有些数据依然可以使用我们建议的方法，为了结果的客观和有效，暂不考虑它的抽样分析。我们从每一年的数据中随机抽取10张图像，进行人工的验证是否符合要求，结果列出如下表3.2，从统计结果看出，我们提出的改进的方法，平均准确率达到了98.55%，说明我们改进的方法可以以全自动化的方式并且以非常高的准确率完成太阳圆盘的识别。

虽然我们的改进的算法可以达到很高的准确率，越高的准确率越利于后面进一步的处理，但依然会存在一定的错误发生，而它一般是满足我们设定的一些条件的巧合性存在，从而导致错误发生，所以对于所得结果是否正确，仍然无法100%的判断，这样侧面说明对于传统方法获得圆心坐标和半径，如果不可

视化出来，再以人工方式校验，对所得结果是否正确仍是无法准确判断的，而造成错误结果都是由于图像质量的问题。所以在下一章我们进一步提出新的思路和方法，来提供更多的可能性。

表 3.2 长周期、多台站的太阳圆盘识别随机抽样结果。

Table 3.2 The results of random sampling for long period and multi station solar disk identification are presented.

年份	所属台站	正确识别	错误识别	正确率	年份	所属台站	正确识别	错误识别	正确率
1963	NSO	10	0	100%	1992	KSO	10	0	100%
1964	NSO	10	0	100%	1993	KSO	10	0	100%
1965	NSO	10	0	100%	1994	KSO	10	0	100%
1966	NSO	10	0	100%	1995	KSO	10	0	100%
1967	NSO	9	1	90%	1996	KSO	10	0	100%
1968	NSO	9	1	90%	1997	KSO	8	2	80%
1969	NSO	10	0	100%	1998	KSO	10	0	100%
1970	NSO	10	0	100%	1999	KSO	10	0	100%
1972	NSO	10	0	100%	2000	KSO	10	0	100%
1973	NSO	10	0	100%	2001	KSO	10	0	100%
1974	NSO	10	0	100%	2002	KSO	10	0	100%
1975	NSO	10	0	100%	2003	KSO	10	0	100%
1976	NSO	10	0	100%	2004	BBSO	10	0	100%
1977	NSO	9	1	90%	2005	BBSO	10	0	100%
1978	NSO	10	0	100%	2006	KSO	10	0	100%
1979	NSO	10	0	100%	2007	KSO	10	0	100%
1980	NSO	10	0	100%	2008	BBSO	10	0	100%
1981	KSO	10	0	100%	2009	BBSO	10	0	100%
1982	KSO	10	0	100%	2010	BBSO	10	0	100%
1983	KSO	10	0	100%	2011	BBSO	10	0	100%
1984	KSO	10	0	100%	2012	BBSO	10	0	100%
1985	KSO	10	0	100%	2013	BBSO	9	1	90%
1986	KSO	10	0	100%	2014	HSOS	9	1	90%
1987	KSO	10	0	100%	2015	HSOS	10	0	100%
1988	KSO	10	0	100%	2016	HSOS	10	0	100%
1989	KSO	10	0	100%	2017	HSOS	10	0	100%
1990	KSO	10	0	100%	2018	HSOS	9	1	90%
1991	KSO	10	0	100%					

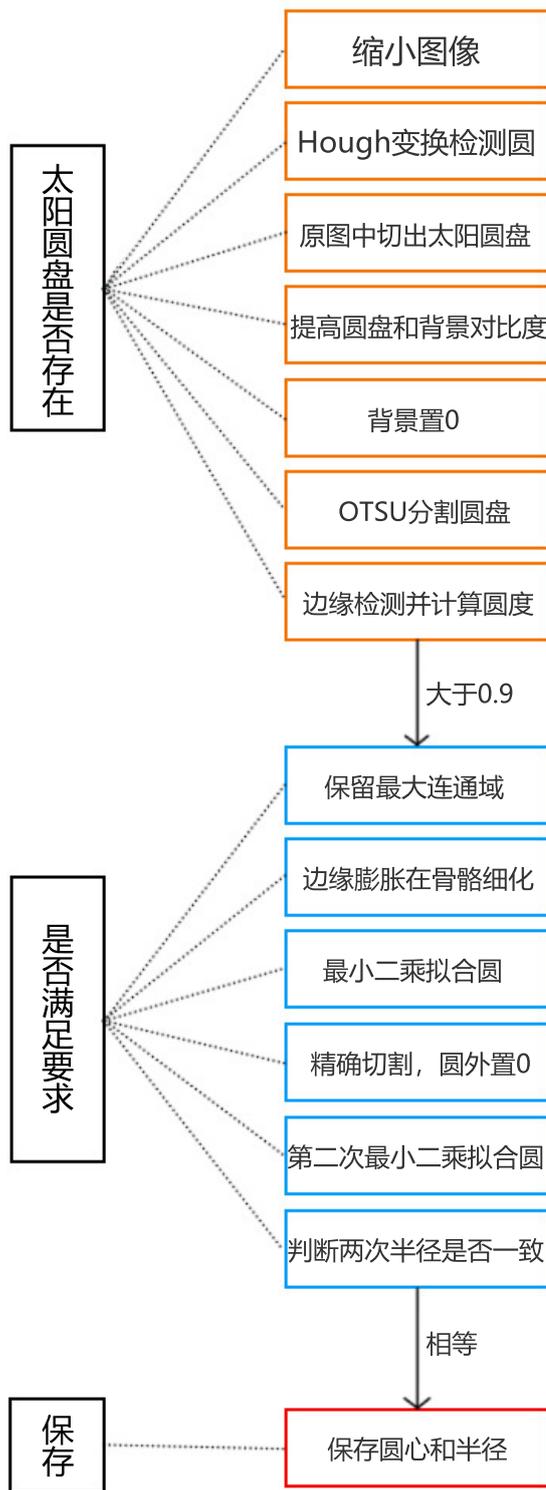


图 3.3 太阳圆盘的识别提取算法。包含判断太阳圆盘是否存在、是否满足要求、保存圆心和半径。

Figure 3.3 Recognition and extraction algorithm of solar disk. It includes whether the solar disk exists, whether it meets the requirements, and saves the center and radius of the circle.

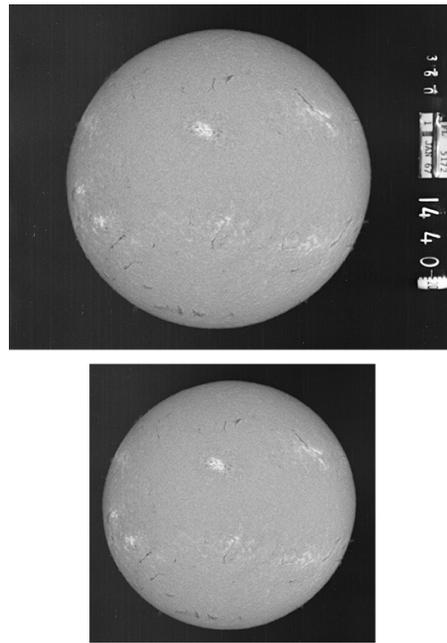


图 3.4 用Hough变换对缩小的图像进行初步圆定位，然后从原图像粗略的切割出来。

Figure 3.4 Hough transform is used to locate the circle of the reduced image, and then the original image is roughly cut out.

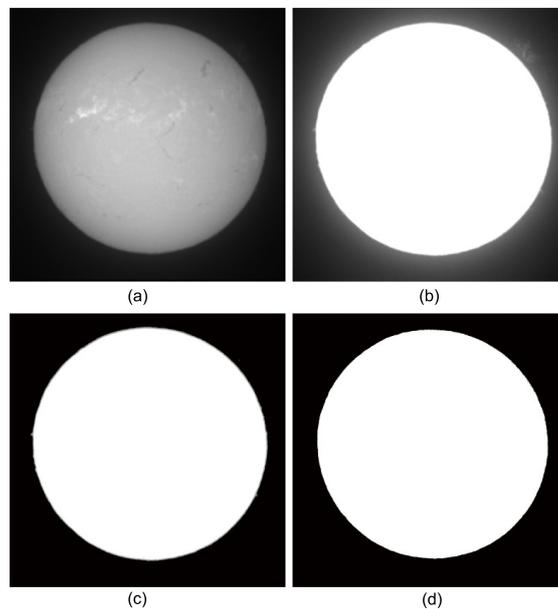


图 3.5 对大概切割出来太阳圆盘进行处理分割出太阳圆盘。

Figure 3.5 For the roughly cut out of the sun disc, further processing, segmentation of the sun disk.

3.3 全日面H α 图像预处理

3.3.1 太阳临边昏暗和不均匀性的去除

经过上面的处理过后，我们得到了一个排除了所有干扰和噪声的仅存在太阳圆盘的图像。然而此时的太阳圆盘内存在临边昏暗现象(Ozhogina 2009)即从圆盘中心到太阳边缘会逐渐变暗。为了获取强度分布更均匀的图像，需要进行临边昏暗的去除，主要采用的方式是借助上文计算出来的圆心坐标和半径，将图像从笛卡尔坐标系转为极坐标系，然后从所有临边昏暗曲线(Denker 等 1999, Csizmadia 等 2013)中取中值(径向方向取中值)，得到一条新的临边昏暗曲线，然后经过平滑处理，再从极坐标将它转化到笛卡尔坐标系，最后将其从原图中扣除(Zharkova 等 2003)。临边昏暗去除之后图像中往往还是存在强度分布不均匀的现象，我们采用多项式面拟合技术(Bernasconi 等 2005, Yuan 等 2011；可参考附录1)进行去除，用加权的最小二乘方法拟合四阶二元多项式来表示图像中不均匀的地方，它的表达式为：

$$g(x, y) = \alpha_0 + \alpha_1x + \alpha_2y + \alpha_3x^2 + \alpha_4y^2 + \alpha_5xy + \alpha_6x^3 + \alpha_7y^3 + \alpha_8x^2y + \alpha_9xy^2 \quad (3.8)$$

其中 α_i 是需要我们拟合出来的结果，然后再从临边昏暗去除后的图像扣除拟合出来的不均匀性，就得到了一个强度相对均匀的全日面太阳图像。如图3.6。

3.3.2 太阳暗条的增强

上面处理过后的图像，虽然日面的强度相对均匀，但是为了后续更好的进行太阳暗条的识别，需要进一步对图像进行增强处理，强化太阳暗条特征。由于太阳暗条在图像中的强度值低，呈现的是暗黑色，我们采用形态学中的低帽变换(bottom-hat transformation；公式2.17)来增强太阳暗条，它能将图像中较暗的区域分离出来，再使用原图像与低帽变换的图像之差，将图像中较暗的区域进行有选择的增强，可表示为：

$$T = T_p - T_{bot} \quad (3.9)$$

其中 T_p 表示临边昏暗去除后均匀的图像， T_{bot} 表示对 T_p 进行低帽变换的图像，如图3.7。

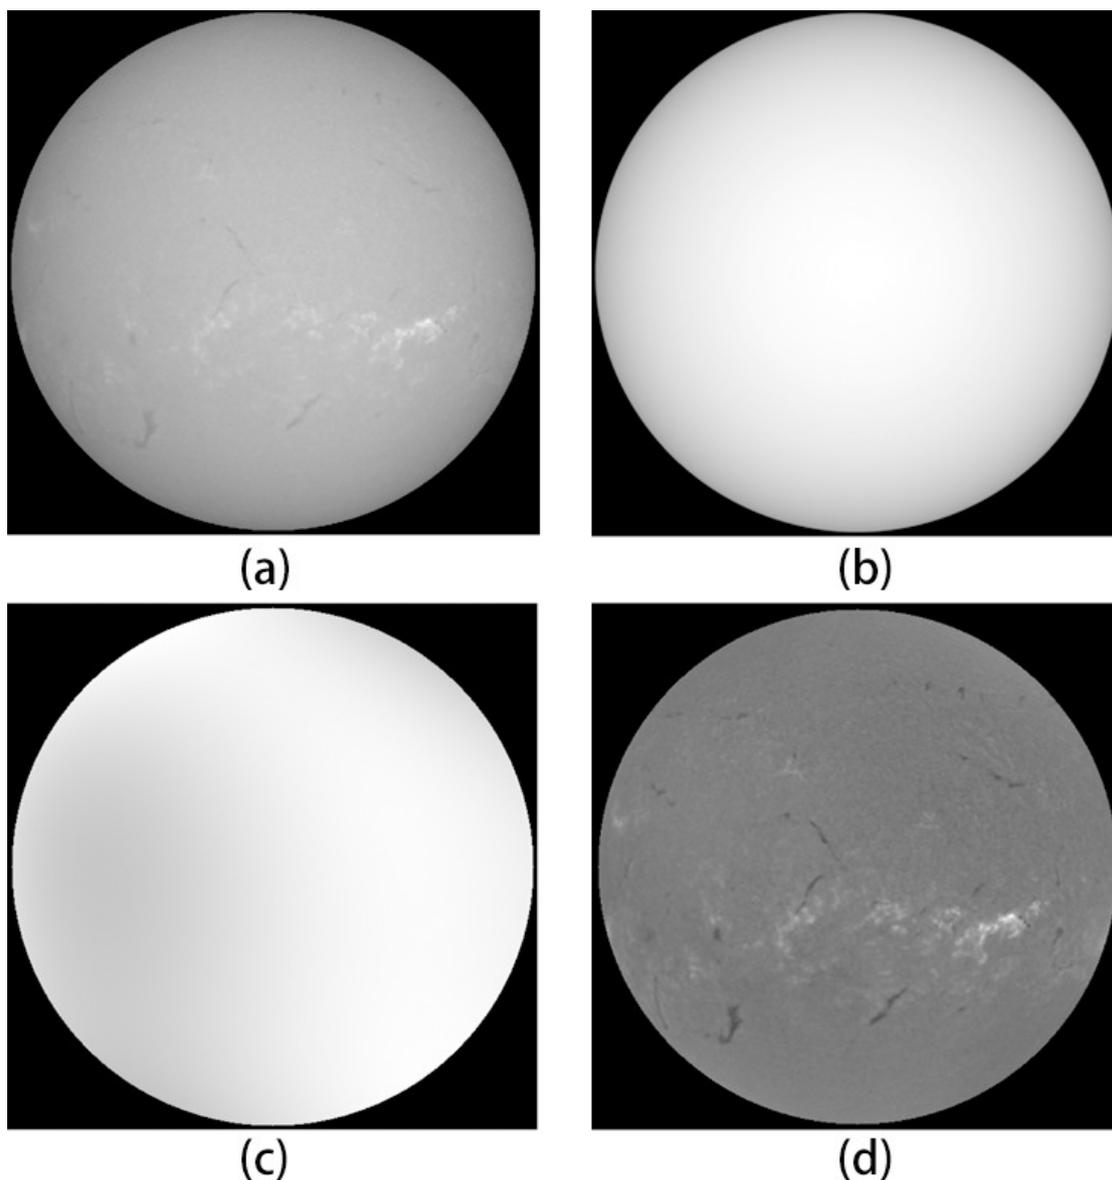


图 3.6 图像经过临边昏暗和不均匀性的去除。(a)表示获取太阳圆盘圆心坐标和半径, 并且置于图像中心的原图像; (b)是从原图像中拟合出来的临边昏暗图像; (c)是拟合出来的不均匀性的图像; (d)是扣除临边昏暗和不均匀性的图像, 呈现出相对均匀的强度分布。

Figure 3.6 The image after removing limb darkening and non-uniformity. (a) It refers to the original image and placed in the center of the image; (b) the limb darkening image fitted from the original image; (c) the non-uniformity image fitted from the original image; (d) the image with relatively uniform intensity after deducting the limb darkening and non-uniformity.

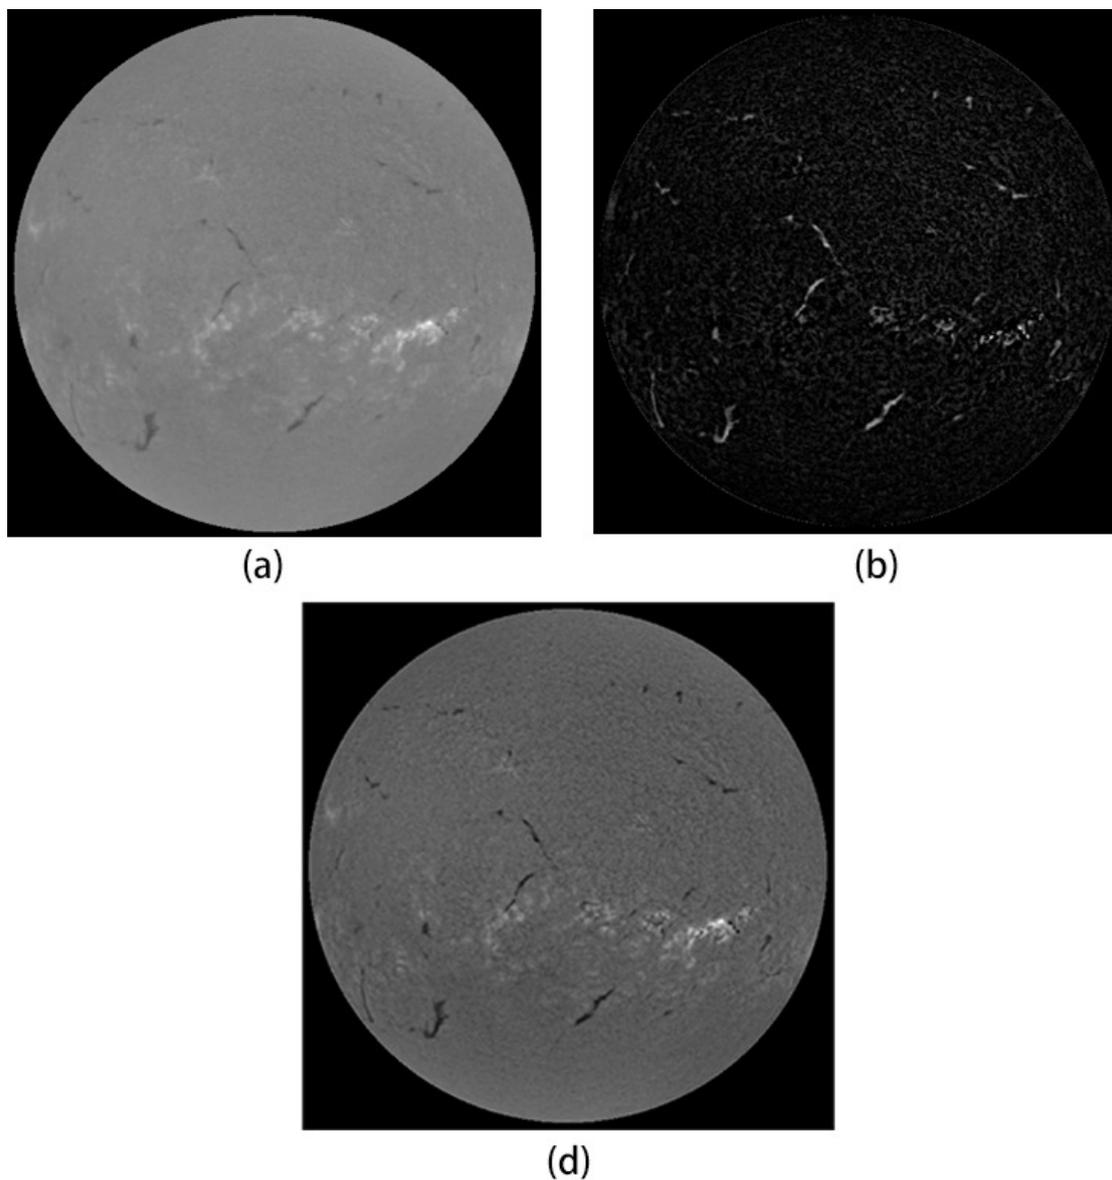


图 3.7 采用低帽变换对图像的较暗区域进行有选择的增强。(a)临边昏暗和不均匀性去除后的图像；(b)采用低帽变换得出来的图像；(c)增强以后的图像，可以看出太阳暗条有明显的增强。

Figure 3.7 The bottom-hat transform is used to enhance the dark region of the image selectively. (a) The results show that the limb darkening and nonuniformity are removed; (b) the image applied to the bottom-hat transform; (c) the enhanced image shows the obvious enhancement of the solar filament.

3.4 太阳暗条识别

3.4.1 改进的传统方法

经过上面的预处理，太阳圆盘的强度分布相对来说就比较均匀了，如果只考虑太阳圆盘内的像素强度，会发现一个有趣的现象，圆盘内的像素强度会呈现正态分布(Normal distribution;又称高斯分布)，这也是大自然界非常常见的一个分布。直观的角度来讲，就是圆盘内的强度分布总是处于中间的数量最多，高强度或低强度总是最少，从太阳圆盘的视觉上也能看得出来，圆盘的整体状态是不存在太阳活动的地方总是占大多数的，其他无论是强度低的太阳暗条或者黑子，还是强度高的谱斑或者耀斑都是相对来说数量偏少。

我们可以画出它的直方图，然后可以看出图像的曲线是呈现一个正态分布的形状，我们就可以利用统计学的知识，使用单高斯函数去拟合这个曲线，得到相应的均值 μ 和标准差 σ 。它的表达式为：

$$f(x) = \frac{1}{\sqrt{2\sigma}} e^{-\frac{(x-\mu)}{2\sigma^2}} \quad (3.10)$$

由于我们想要识别的太阳暗条是呈现暗黑色低强度的像素区域，它们的强度值会处于高斯函数曲线的左侧区域，而对于高斯函数有一个“ 3σ ”原则：

$$T = \mu - 3\sigma \quad (3.11)$$

就可以很容易的得到我们想要的合适的阈值，然后对图像进行太阳暗条的分割操作。

如图3.8(左)，可以看出当太阳圆盘的临边昏暗和不均匀性去除之后，它的直方图的曲线就是呈现正态分布，但是整体的曲线宽度不够宽，说明太阳圆盘内的强度值的最大最小值相差比较小，从图像上看就是图像整体的对比度偏低。所以采用低帽变换对图像进行增强，从图3.8(右)中可以看出太阳暗条被明显的增强，它的直方图的宽度也被拉宽，说明太阳圆盘内的像素最大最小的强度值相差变大，整体图像的对比度增强。

图3.9是我们对直方图进行单高斯函数拟合，对拟合的R-square指标进行条件限制，设置为大于0.988，然后获得均值和标准差，采用“ 3σ ”原则，得到所需的阈值，对图像进行太阳暗条识别分割的结果。从图中可知太阳暗条可以被有效的分割出来，但是由于传统方法的局限性，在暗条分割出来的同时会伴随

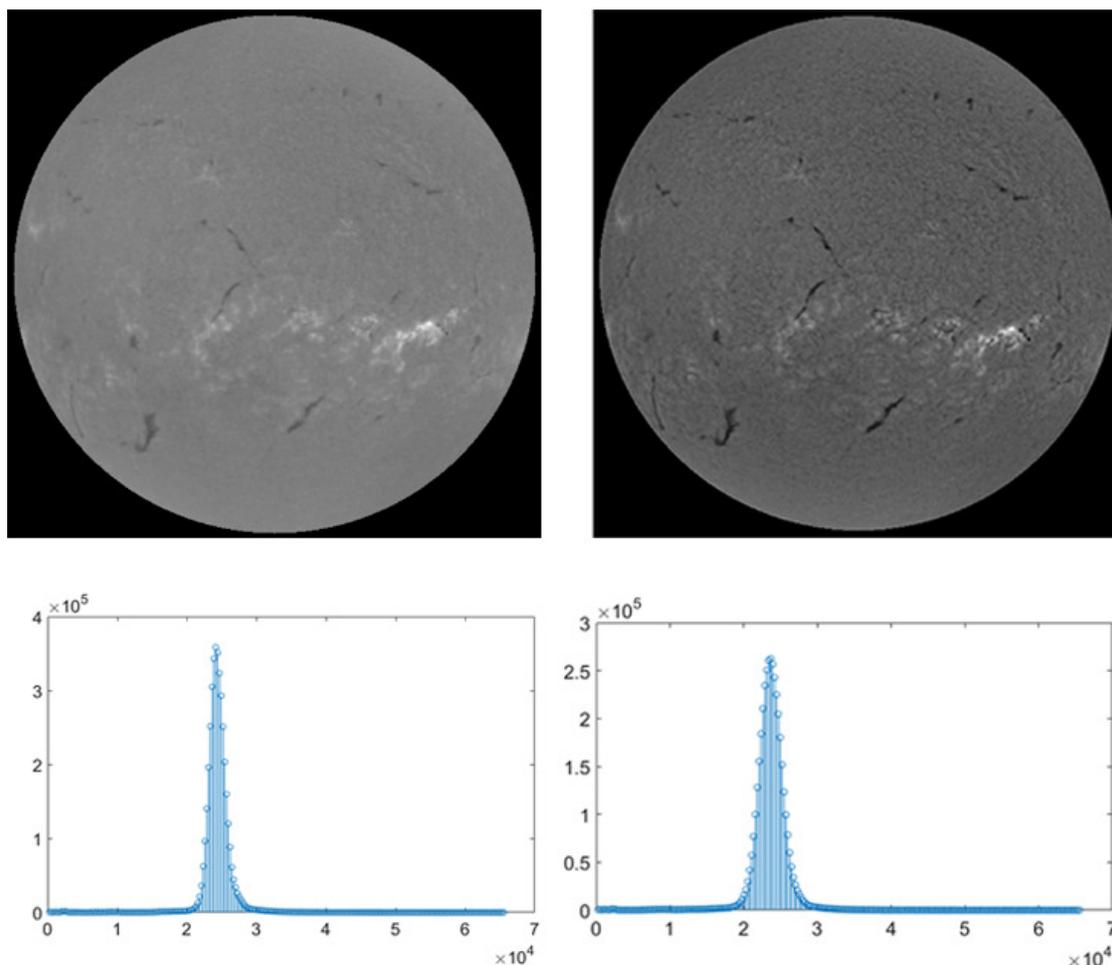


图 3.8 左：临边昏暗和不均匀性去除后的图像和它的直方图；右：采用低帽变换增强的图像和它的直方图。

Figure 3.8 Left panel: the image after the limb darkening and non-uniformity removal and its histogram ; right panel: the image enhanced by bottom-hat transformation. and its histogram

一些噪点，我们需要对分割出来的二值图进行连通域统计标注，通过面积、长宽比等条件进行排除。除此之外，还有黑子也会被分割出来，我们通过它的圆度、面积等的限制条件，把黑子也排除在外，然后就得到了只剩下太阳暗条的识别分割结果。

我们建议的这个方法不仅可以针对单一台站，还可以针对多台站的全日面太阳数据，如图3.10，我们把BBSO、HSOS和KSO的三个台站同一天的数据进行对比，它们都是使用CCD获取到的数据，发现它们的直方图都呈现出很好的正态分布，通过“ 3σ ”原则也可以有效的将太阳暗条识别分割。

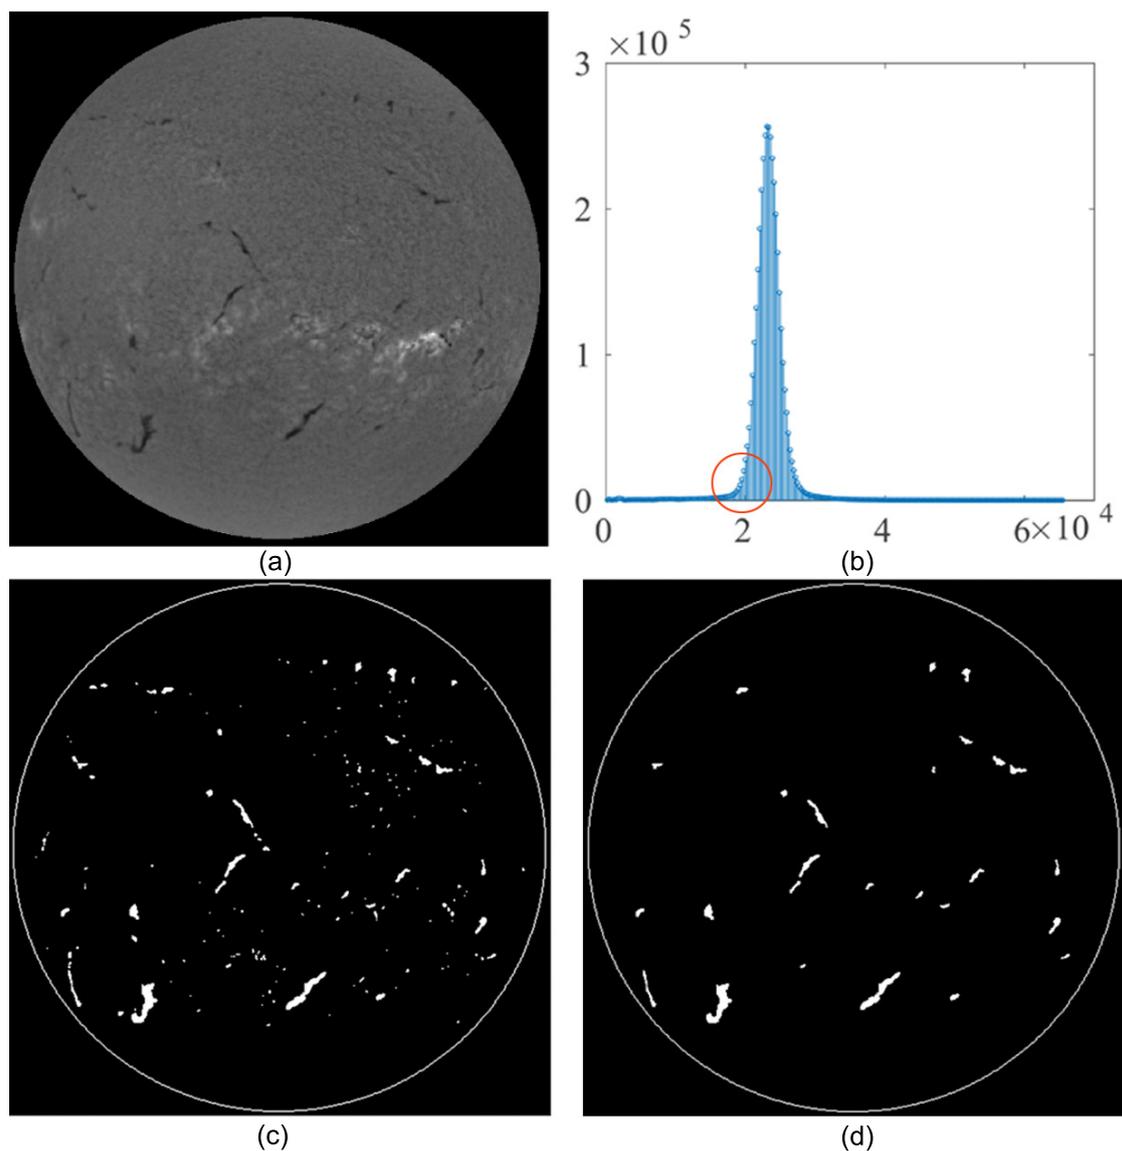


图 3.9 太阳暗条的识别分割结果。(a)表示增强后的图像；(b)是它的直方图；(c)是带有噪点的太阳暗条分割结果；(d)是去除噪点和黑子的太阳暗条的识别分割结果。

Figure 3.9 The result of recognition and segmentation of solar filaments. (a) Represents the enhanced image; (b) is its histogram; (c) is the segmentation result of solar filaments with noise and sunspots; (d) is the recognition and segmentation result of solar filaments without noise and spots.

建议的算法不仅可以针对从CCD获取到的全日面 $H\alpha$ 太阳图像，还可以针对来自照相底片/胶卷，然后经过扫描数字化的数据，如图3.11，可以看出针对扫描的数字化的历史数据，经过一步一步排除掉噪声和干扰之后，太阳圆盘内呈现出正态分布，同样最后给出太阳暗条识别分割结果。

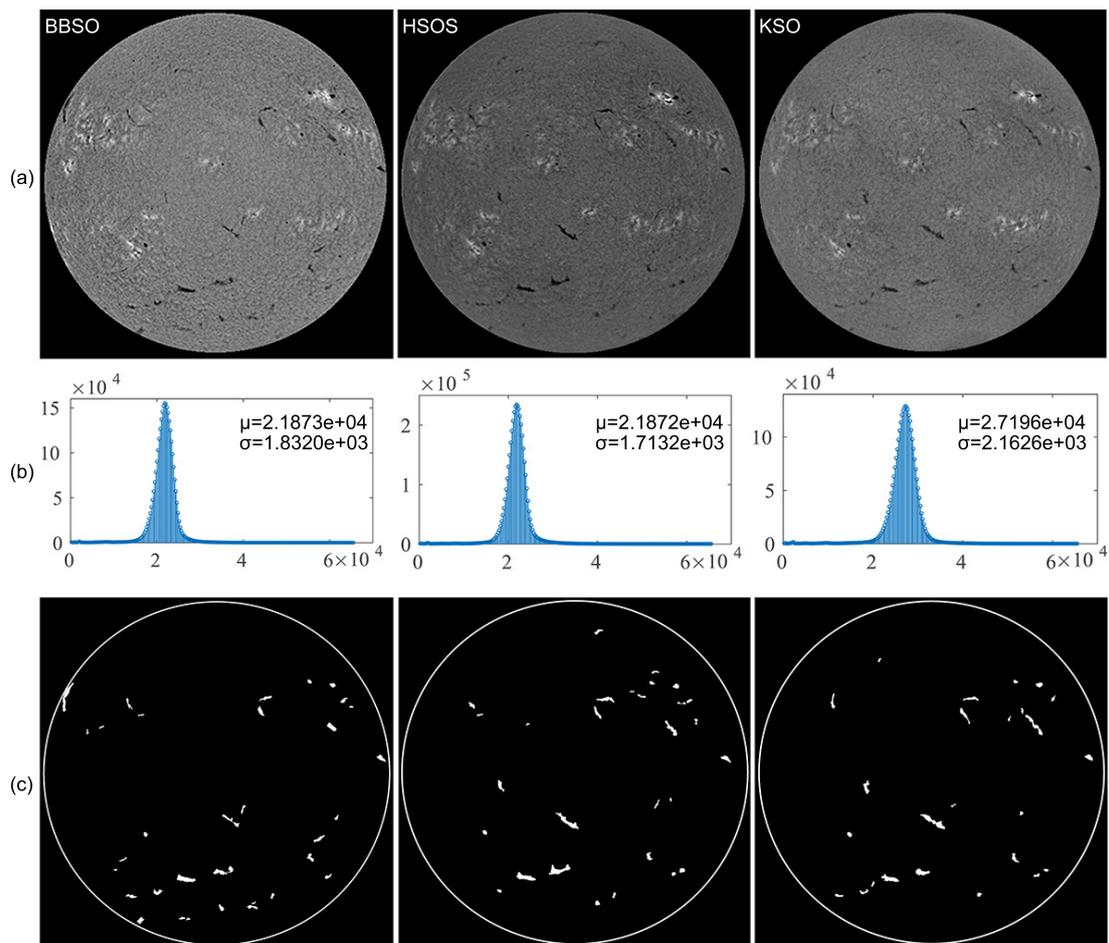


图 3.10 一个三个台站对比的例子，它们都是CCD相机获取到、来自2013年1月4日同一天的数据。(a)表示预处理的数据；(b)是它们的直方图，拟合得到的均值和标准差分别是 $2.1873e+04$ 、 $2.1872e+04$ 、 $2.7196e+04$ 和 $1.8320e+03$ 、 $1.7132e+03$ 、 $2.1626e+03$ ；(c)是三个台站的识别分割结果。

Figure 3.10 A comparative example on 2013 January 4. The data were all acquired with CCD cameras. (a) the pre-processed images; (b) the histograms of the above images with curve means are $2.1873e+04$, $2.1872e+04$, and $2.7196e+04$, and standard deviations are $1.8320e+03$, $1.7132e+03$, and $2.1626e+03$, respectively; (c) the recognition results

3.4.2 结果分析

为了验证我们方法的可靠性，同样地，我们对前文各个台站每年随机选出的10张图像进行人工验证，结果如表3.4和3.3所示，对于整体数据的抽样的平均有效识别率为86.55%，相对来说还是比较可靠。我们发现在这些台站中，KSO台站的相对有效识别率是最低的，为82%，很多年份都存在错误识别的情况，针对这个问题，我们在人工核对KSO台站的原始数据发现，该台站的原始

数据大部分都存在质量不佳的情况。而对于时间更早期的NSO来说，有效识别率88.82%，比KSO的相对高一些，也说明NSO的图像质量相较于KSO来说更好些。有效识别率最高的是BBSO的，达到93.75%，其次是HSOS的，为90%。这里的错误识别还包括前文中的太阳圆盘识别有误造成的太阳暗条识别不可信。通过观察抽样样本，造成错误识别主要两个原因：1.是日面中存在各种各样问题造成的暗黑色的区域，它不属于暗条特征，但是会混淆在有效识别的太阳暗条中；2.图像中存在非常严重的不均匀性污染，由于其复杂性过高，难以通过高阶多项式完美拟合来去除。而且我们发现越是早期的数据有效识别率越低，越是近期的有效识别率越高，近期的图像相对于早期的图像质量更好一些，所以干扰以及噪声相对来说较少，所以结果更好。

表 3.3 每个台站的有效识别率。

Table 3.3 The effective recognition rate of each station.

所属台站	总数	有效识别数量	错误识别数量	有效识别率
NSO	170	151	19	88.82%
KSO	250	205	45	82%
BBSO	80	75	5	93.75%
HSOS	50	45	5	90%
ALL	550	476	74	86.55%

表 3.4 长周期、多台站的太阳暗条识别随机抽样结果。

Table 3.4 The results of random sampling for long period and multi station solar filament identification are presented.

年份	所属台站	有效识别	存在错误识别	有效识别率	年份	所属台站	正确识别	存在错误识别	有效识别率
1963	NSO	8	2	80%	1992	KSO	8	2	80%
1964	NSO	9	1	90%	1993	KSO	5	5	50%
1965	NSO	10	0	100%	1994	KSO	6	4	60%
1966	NSO	9	1	90%	1995	KSO	8	2	80%
1967	NSO	8	2	80%	1996	KSO	7	3	80%
1968	NSO	8	2	80%	1997	KSO	6	4	60%
1969	NSO	9	1	90%	1998	KSO	9	1	90%
1970	NSO	9	1	90%	1999	KSO	10	0	100%
1972	NSO	9	1	90%	2000	KSO	8	2	80%
1973	NSO	10	0	100%	2001	KSO	10	0	100%
1974	NSO	10	0	100%	2002	KSO	10	0	100%
1975	NSO	9	1	90%	2003	KSO	10	0	100%
1976	NSO	8	2	80%	2004	BBSO	10	0	100%
1977	NSO	8	2	80%	2005	BBSO	9	1	90%
1978	NSO	9	1	90%	2006	KSO	10	0	100%
1979	NSO	9	1	90%	2007	KSO	10	0	100%
1980	NSO	9	1	90%	2008	BBSO	9	1	90%
1981	KSO	9	1	90%	2009	BBSO	10	0	100%
1982	KSO	10	0	100%	2010	BBSO	9	1	90%
1983	KSO	8	2	80%	2011	BBSO	10	0	100%
1984	KSO	7	3	70%	2012	BBSO	9	1	90%
1985	KSO	6	4	60%	2013	BBSO	9	1	90%
1986	KSO	8	2	80%	2014	HSOS	8	2	80%
1987	KSO	6	4	60%	2015	HSOS	10	0	100%
1988	KSO	8	2	80%	2016	HSOS	10	0	100%
1989	KSO	7	3	70%	2017	HSOS	10	0	100%
1990	KSO	10	0	100%	2018	HSOS	7	3	70%
1991	KSO	9	1	90%					

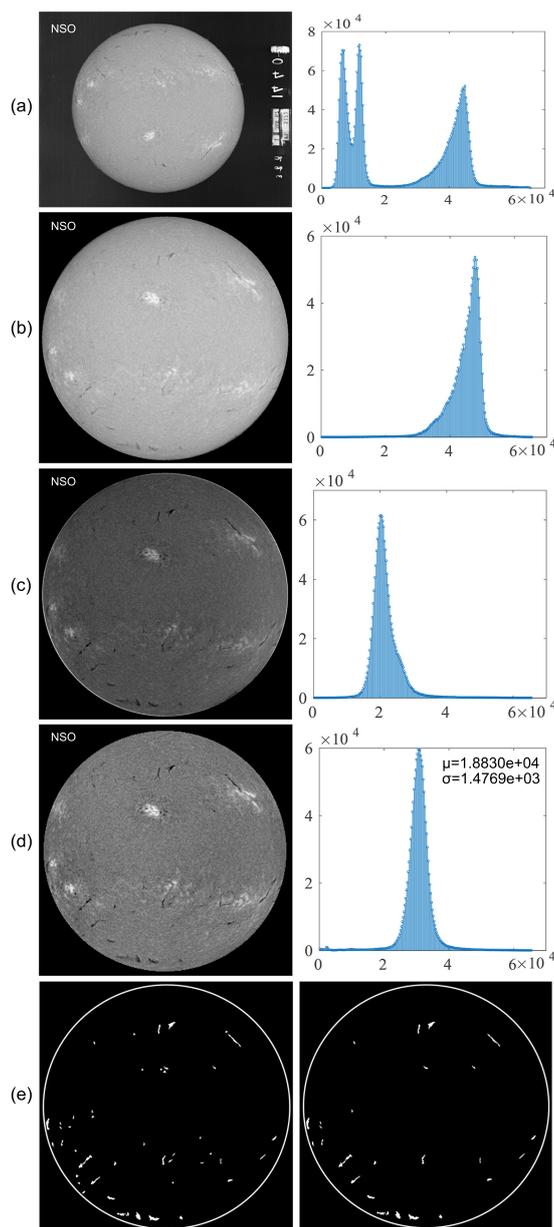


图 3.11 一个来自NSO的1967年1月1日的例子，它的原始数据记录在照相底片/胶卷，然后扫描数字化的数据。(a)表示原始记录的数字化的图像和它的统计直方图，后面的(a)-(d)都是一样；(b)是排除其他干扰，P角矫正之后，太阳圆盘置于图像中间；(c)是临边昏暗去除的图像；(d)是不均匀性去除的图像和呈现正态分布的直方图，它的均值为 $3.1642e+04$ ，标准差为 $2.3192e+03$ ；(e)(左)是识别分割结果；(右)去除各种噪点之后的识别结果。

Figure 3.11 An NSO example on 1967 January 1. Its data were originally recorded in photographic plates/films and scanned into a digital image. (a) The plate/film image and its statistical histogram; the same is shown for the panels (a)-(d). (b) The digitalized image with a P-angle correction. (c) The image with limb darkening being further removed. (d) The image with an uneven background being removed as well and its histogram showing a normal distribution, in which the curve mean is $3.1642e+04$ and the standard deviation is $2.3192e+03$. (e) Left panel: the recognition result; right panel: the recognition result with the noisy points being removed.

3.5 太阳暗条参数提取

通过太阳暗条的识别之后，可以进行相关参数的提取。目前我们对以下参数进行了提取工作：

1. **面积：** 太阳暗条的面积我们主要通过统计二值结果图中相应的连通域相应的像素数表示：

$$m = N \left(\frac{D}{2R} \right)^2 \quad (3.12)$$

其中 N 代表像素数， D 代表太阳实际的直径大小，单位公里， R 表示图像太阳圆盘的半径，单位个。面积一般可以表征暗条发生的范围大小，通常可以与时间、纬度等参数联合统计其变化情况。

2. **周长：** 通过对太阳暗条的边缘检测，统计相应的边缘点像素数获得。周长一般也可以表征暗条发生的范围大小。

3. **位置：** 通过获取太阳暗条的质心像素坐标，然后转换为相应的经纬度坐标：

$$\begin{cases} L_{lat} = -\arcsin\left(\frac{y-c_y}{r}\right) \times \frac{180}{\pi} \\ L_{lon} = \arcsin\left(\frac{x-c_x}{\sqrt{r^2-(y-c_y)^2}}\right) \times \frac{180}{\pi} \end{cases} \quad (3.13)$$

其中 (x, y) 表示太阳暗条质心的像素坐标， (c_x, c_y) 表示太阳圆盘的圆心坐标，原点在图像的左上角， r 表示太阳像素半径。位置一般可以表征暗条发生的地点，使用其纬度信息，与观测时间一起，可生成暗条的蝴蝶图。

4. **主轴长度：** 先把暗条骨骼细化，然后将骨架的像素点按照从上到下，从左往右的顺序依次编号，对应找出骨架的各个端点。然后按照无向图的方式，计算出两两端点之间的距离，选出最长的作为暗条的主轴，相应的两端点作为主轴的两个端点，相应的像素点的个数作为主轴长度。主轴长度一般可以表征暗条发生时的长度特征。

5. **倾斜角：** 与暗条主轴具有相同标准二阶中心矩的椭圆的长轴与赤道的交角(度)。倾斜角一般可以与时间、纬度等参数联合研究其南北对称性问题。

6. **分叉的角度：** 就是暗条与Barbs的交角，先将暗条骨架按照二叉树的方式，保存下暗条的骨架坐标，以及每个分叉的坐标，然后分别对骨架和各个分支拟合直线，相应计算每个分叉与主轴之间的夹角，得出相应分叉的角度。分叉的角度一般可以和磁图联合研究暗条的手征性。

7. **平均宽度：** 先将暗条的骨架分成若干段，按照每段的位置坐标求相应的

法线，法线与暗条重合的部分作为相应段的暗条宽度，将每段暗条宽度累加之后求平均。

8. **骨架始尾欧氏距离：**暗条主轴始尾点的直线距离；可以和主轴长度联合研究其弯曲程度。

第4章 基于卷积神经网络的圆心坐标和半径的回归

通过我们对传统获取太阳圆心坐标和半径的方法的改进，目前改进的算法可以针对大批量的历史数据去挑选太阳圆盘符合要求的数据。虽然有很高的正确率，但是由于传统方法的局限性，依然存在一定的错误率。所以使用传统方式获取的太阳圆心坐标和半径，不用人工的方式可视化观察，我们无法判断所得的结果是否正确，而导致计算错误的往往都是图像质量的问题，我们尝试探索新的方式，如果能不仅判断当前图像的质量是否合格，若合格同时获取太阳圆盘的圆心坐标和半径，这将会极大的提高工作效率。但是在这之前，证明是否能够从图像中回归出数值型的数据(圆心坐标和半径)就显得尤为关键，这将有两个好处，一个是太阳圆盘圆心坐标和半径的获取有新的思路；另一个是如果新方法证明可行，它将可以在天文领域更多的方向上做图像回归数值的尝试。

通过不断的尝试，我们提出了使用卷积神经网络回归太阳圆盘圆心坐标和半径的方法，它可以将全日面 $H\alpha$ 太阳图像作为输入，然后直接输出三个数值型的数据。本节分为三个部分进行阐述，第一小结介绍数据的来源和数据的增强等内容；第二小节介绍我们建议的CNN网络模型和一些网络训练的细节；最后一节介绍结果。

4.1 数据获取

由于针对这项研究没有现存的数据集可用，所以我们从中国科学院国家天文台怀柔观测基地(HSOS)获取了近100,000张全日面 $H\alpha$ 太阳图像作为我们数据集。HSOS是现在世界上观测太阳的主要站点之一，提供多种局部区域和全日面的日常观测数据，比如磁图(magnetograms)、单色像(filtergrams)和多普勒速度图(dopplergrams)。2006年以前，太阳多通道望远镜的其中一个单通道望远镜(Ai 和 Hu 1986, Deng 等 1997)，14厘米口径光学望远镜，通过可调的 $H\alpha$ 滤光片(带宽 0.5\AA 的 -32\AA - $+32\text{\AA}$)和柯达MegaPlus 4.2i相机观测全日面。2006年以后，一个新的20厘米口径望远镜投入使用继续全日面 $H\alpha$ 观测(Zhang 等 2007)，它是太阳磁活动望远镜的其中一个通道。它的波长是 6562.81\AA ，带通是 0.25\AA ，滤光器中心波长在线心 $\pm 2\text{\AA}$ (Liu 2020)。空间分辨率、曝光时间、全日面 $H\alpha$ 探测器大小分别

是2角秒、1-5分钟、 2712×2712 。

我们构造的数据集包含两部分，一部分是全日面 $H\alpha$ 太阳图像的原始数据；另一部分是存储在“txt”文件中数值型的圆心坐标和半径。我们使用Hough变换和最小二乘自动计算出来未被验证的圆心坐标和半径，然后将它们可视化在原始图像上，把偏离的样本都删除。由于实验的1070Ti GPU的内存限制，我们不得不把原始图像的尺寸缩小到 512×512 进行实验。

在常规观测中，太阳圆盘并不总是处于图像的中间，而且它在某些时期会有倾向性的位置，不总是随机出现。所以为了增加网络模型的泛化性，我们采取了随机太阳圆盘圆心位置的策略。填充或裁剪图像的边缘，并且保持太阳圆盘处于图像中没有被裁剪。

数据增强是一种常用、有效的方法提高模型的泛化能力和鲁棒性，它可以同时增加训练数据和噪声数据。目前有一些常用的数据增强的方式，翻转、旋转、缩放、裁剪、平移和噪声。特别是针对图像分类任务，一个模型通常会同时使用它们中的几种方式。大气和云层通常是地面观测的主要干扰因素，会导致不理想的图像质量，由于它们的复杂性，我们的模型训练的过程中没有考虑这些因素，但是为了论证我们方法在图像中有效信息被可接受的污染之后，模型仍然可以有效的回归出所需要的参数，我们在训练的过程中给图像添加了噪声。我们对每个Batch的数据添加噪声密度上限是0.1，步长是0.01。图4.1表示不同噪声密度的例子。这能够使模型在有噪声存在的时候也能获得有效的圆心坐标和半径。

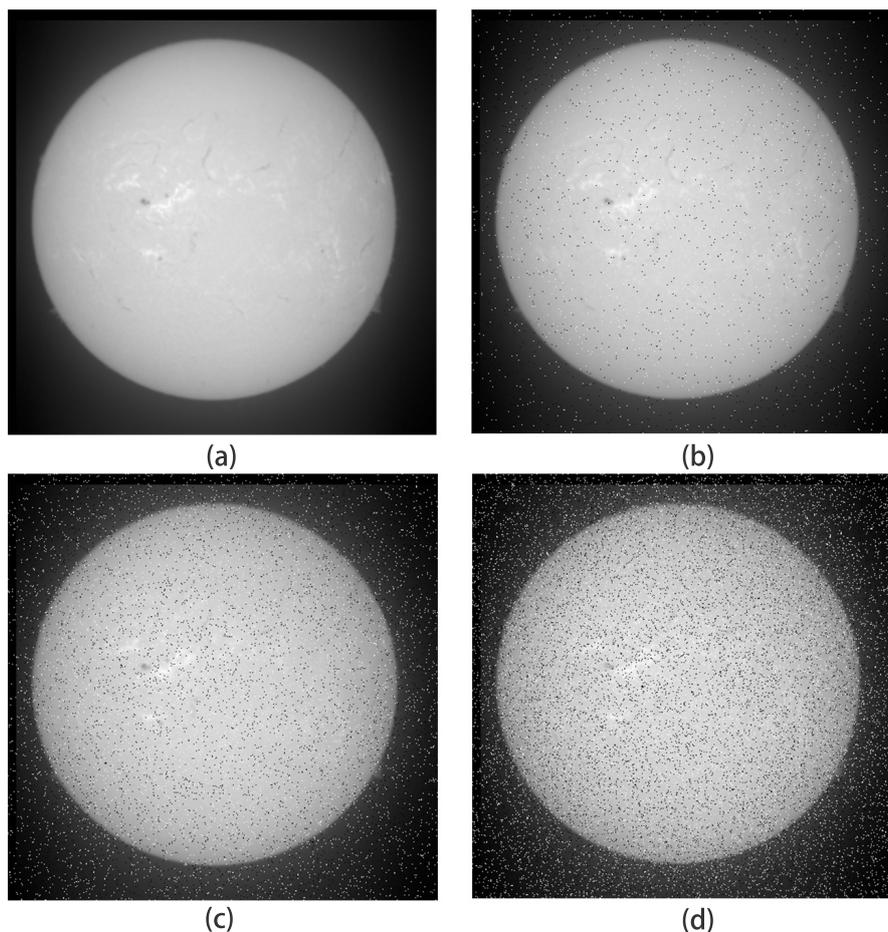


图 4.1 一个数据增强的例子。(a)表示一张仅随机了圆心坐标，没有噪声的图像；(b)是一张随机了圆心坐标，噪声密度为0.01的图像；(c)是一张随机了圆心坐标，噪声密度为0.04的图像；(d)是一张随机了圆心坐标，噪声密度为0.09的图像；

Figure 4.1 An example of data augmentation. (a) Only an image of randomized center coordinates without any noise. (b) An image of randomized center coordinates with a noise density of 0.01. (c) An image of randomized center coordinates with a noise density of 0.04. (d) An image of randomized center coordinates with a noise density of 0.09.

4.2 建议的CNN网络模型

卷积神经网络(CNNs)自从被提出以来，在各个科学领域都展现出来强大的生命力，包括在天文物理领域，也展示出它的自动学习特征的巨大优势。CNNs可以在不需要任何先验知识的情况下，从大批量的原始数据中自动的学习特征，而传统的图像处理需要事先对图像有一定的理解。传统图像处理经常需要设计描述子用以提取不同的特征，比如边缘、角点和区域等。然而，CNNs可以从样本中自动学习特征分类器。它已经在非常多的问题上取得惊人的结果，特别是

对图像分类、目标检测和分割等任务上。

我们提出一个CNNs结构能够从全日面H α 太阳图像的原始数据中回归太阳圆盘的圆心坐标和半径，这个网络结构的灵感来自于VGGNet网络模型(Simonyan和Zisserman 2014)。VGGNet是2014年图像大规模视觉识别挑战(ImageNet挑战)的亚军。VGGNet的网络深度包含11层到19层不等，包含三个全连接层和其他的卷积层，到目前为止，它仍然是很多模型的特征提取重要的组成部分。

由于原VGGNet网络模型不能被直接在当前任务中使用，我们对VGGNet模型做了一些改进，特别是对VGGNet-13。我们建议的CNN模型由5个块组成，总共13层，如图4.2，其中前三个块和VGGNet-13的相同。前三个块中每个块包含2个卷积层和一个池化层(用于减少特征图的维度和减少计算量)，第一个块的前2个卷积层使用64 \times 3 \times 3的卷积核，随后块的卷积核的尺寸分别是128 \times 3 \times 3，256 \times 3 \times 3，512 \times 3 \times 3。与VGGNet-13不同的是在第四个块中使用4个卷积层，并且后面没有池化层。最后一个块有三个全连接层，前两个全连接层分别有256和16个通道，并且对核权重使用L2正则化处理过拟合，它的表达式为：

$$H = H_0 + \alpha \sum_w w^2 \quad (4.1)$$

其中 w 是权重矩阵， α 代表正则化因子，在建议的CNN模型中， α 被设置为0.01。不像在大多数解决分类问题的CNN模型中使用的softmax函数，我们模型的最后一个全连接层使用的是恒等函数。因此，最后输出不是一个概率值，而是3 \times 1的正实数矩阵，分别代表太阳圆盘的圆心坐标和半径。我们使用单通道的图像(灰度图)代替VGGNet中使用的三通道的彩色图，最大池化层的尺寸是2 \times 2。

我们的网络模型中还有些其它的配置参数。为了避免特征图的尺寸在卷积之后变小，我们设置“padding”为“same”，这样可以使卷积层的输入和输出的尺寸保持一致。而且每层的初始的卷积核权重为高斯分布初始化(He等2015，可以参考图2.1)，初始的偏置为0张量。

整个网络的训练过程如图4.3。在模型输入之前，我们需要预处理和增强数据。然而数据集分割是另一个重要的事情，通常，我们把数据集分为训练集、验证集和测试集。训练集主要是用于模型的训练，用来拟合参数(权重等)；验证集主要是调整参数(超参等)；测试集用来评估整个模型的性能。整个数据集包含93686幅图像，这些图像分为三个子集部分，比例为8:1:1(表4.1)。此外，为了

平衡数据集的分布，我们将数据集分成N/10部分，每个部分的前8个样本作为训练集，第9个样本作为验证集，第10个样本作为测试集。由于实验的硬件限制，Batch大小设为8。此外，样本顺序还会被打乱。

表 4.1 每个部分的样本数量。

Table 4.1 Number of Samples in Each Part.

构成	比例	数量
全部	1	93686
训练集	0.8	74948
验证集	0.1	9368
测试集	0.1	9368

如图4.3，整个CNN网络在训练过程中需要朝着一个目标(损失函数)前进。我们建议的网络的损失函数是均方误差(MSE)，可表示为：

$$MSE = \frac{1}{M} \sum_{m=1}^M (y_m - \hat{y}_m)^2, \quad (4.2)$$

其中 y_m , \hat{y}_m 分别代表真值和预测值。模型的评估指标是R-square，它主要与回归平方和(SSR)和总平方和(SST)有关，它的表达式为：

$$R^2 = \frac{SSR}{SST} = \frac{\sum_{m=1}^M w_m (\hat{y}_m - \bar{y}_m)^2}{\sum_{m=1}^M w_m (y_m - \bar{y}_m)^2} = 1 - \frac{\sum_{m=1}^M (\hat{y}_m - y_m)^2}{\sum_{m=1}^M (\bar{y}_m - y_m)^2} \quad (4.3)$$

其中 \hat{y}_m 是预测值， \bar{y}_m 是均值， y_m 是真值。整个模型的训练过程要求MSE尽可能低，R-square尽可能接近1。

我们选择“Adam”作为优化器(Kingma 和 Ba 2014)，它具有可变的學習速率(learning rate)，可以使损失尽可能的低。初始学习率设置为 10^{-4} 。如果每隔8个周期后“val_loss”不降低，则学习率将降低1/10，最小学习率为 10^{-8} 。

为了了解整个模型的学习过程，图4.4显示了第一块和第四块中卷积层的特征图。如图4.4(a)所示，该层主要提取图像的整体特征和一些不同对比度的图像

特征。在图4.3(b)中, 该层提取了不带太阳圆盘内部特征的白化和灰化特性。随着层数的加深, 该模型能自动获得原始太阳圆盘的基本特征。通过不断调整各层的权值和偏移量, 最终建立特征与结果的映射关系。

我们CNN模型采用的是可变的学习率, 图4.5展示了我们模型的学习速率衰减曲线。我们的衰减策略是每8个Epoch后, 如果“*val_loss*”值损失不减少, 则学习率下降1/10。初始学习率为 10^{-4} , 在大约25个Epoch之后, 第一次衰退开始, 并且下降到 10^{-5} 。第二次下降大约在37个Epoch之后。然后随着训练时间的延长和学习率的不断下降, 模型损失和R-square均没有明显变化, 此时停止训练。最终的学习率停止在 10^{-7} 。

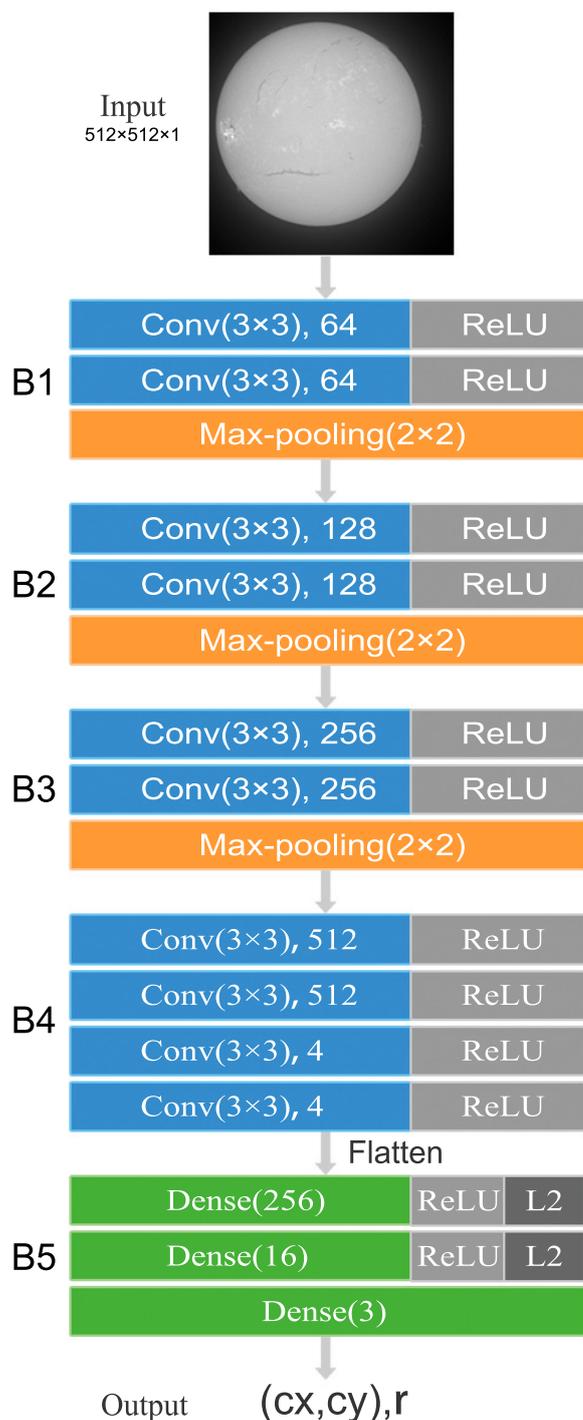


图 4.2 建议的CNNs回归模型的网络结构。整个模型总共有13层，其中包含10个卷积层和3个全连接的层。输入是512×512分辨率的单通道图像，输出为三个正实数，是太阳圆盘的圆心坐标和半径。

Figure 4.2 Architecture of the proposed CNNs regression model. The whole model consists of 13 layers with ten convolutional layers and three fully connected layers. The input is a single-channel image of 512×512 and the output is three positive real numbers, which are the center coordinates and radius of the solar disk.

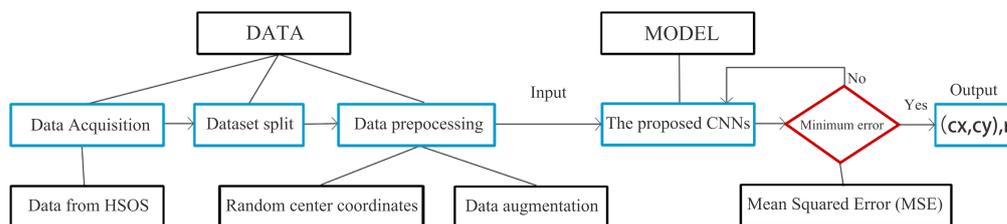


图 4.3 整个任务的示意图。整个过程由数据和模型两部分组成。蓝色矩形表示任务处理顺序。

Figure 4.3 Schematic diagram of the entire task. The whole process consists of two parts: data and model. The blue rectangle represents the task processing order.

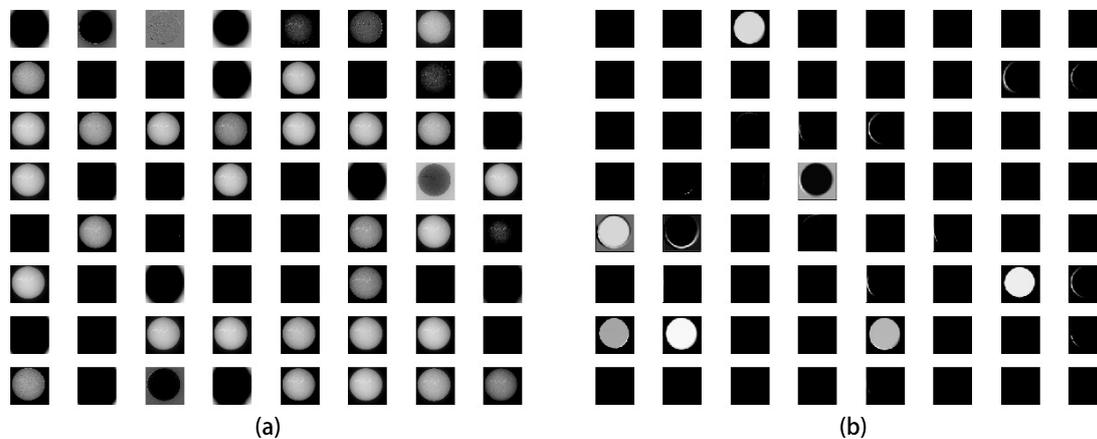


图 4.4 由建议的CNNs模型产生的特征图。(a)第一块中卷积层的特征图；(b)第四块卷积层的部分特征图。

Figure 4.4 Feature maps of the proposed CNNs model. (a) The feature maps of the convolutional layer in the first block. (b) Part of the feature maps of the convolutional layer in the fourth block.

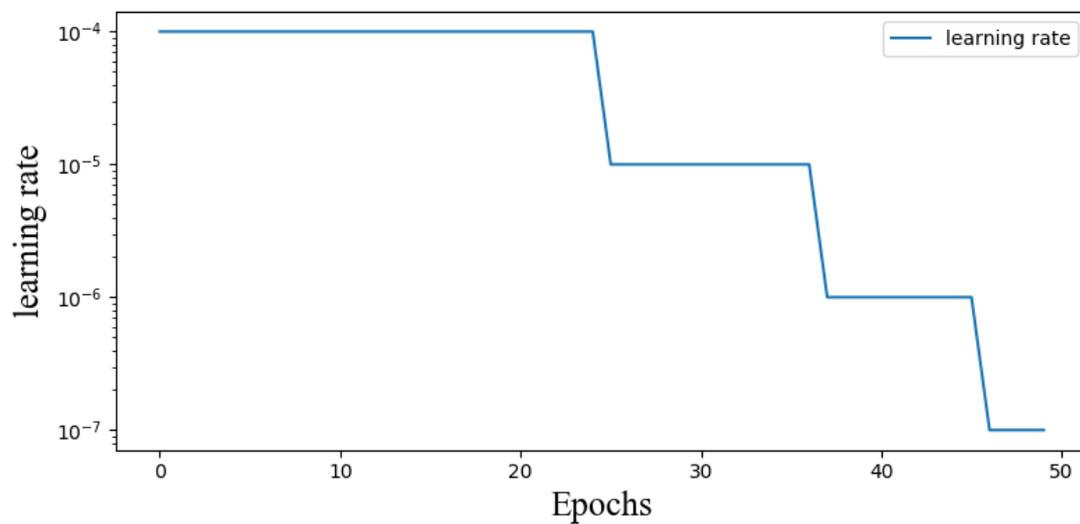


图 4.5 一个训练过程的学习率曲线。

Figure 4.5 Learning rate curve of one training process.

4.3 结果分析

CNNs具有较强的自学习能力，能够根据所提供的数据集自动提取特征，并在问题与结果之间建立非线性映射关系。在这项研究中，我们使用所提出的CNNs模型从全日面H α 图像中回归太阳圆盘的圆心坐标和半径。在图4.6的左面板中，训练损失在前6个Epochs急剧减少，验证损失在前10个Epochs开始急剧下降。训练损失的最终收敛约为0.28，验证损失的最终收敛约为1.6。在图4.6的右侧面板中，训练和验证的R-square分别在几乎相应的位置急剧上升。它们都稳定在0.99以上，训练R-square相对较高。此外，我们的模型在测试集上的平均损失为1.75，平均R-square为0.9974。这说明我们的模型具有良好的学习能力。

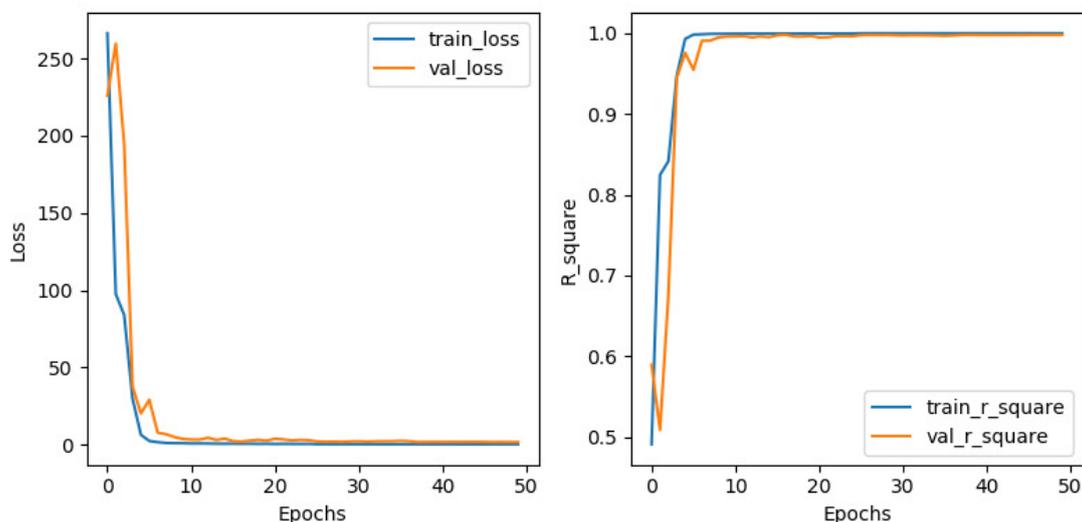


图 4.6 训练集和验证集的MSE损失曲线和R-square曲线。在训练过程中，训练集和验证集上模型的损失可以快速收敛，通过R-square表征拟合的程度也迅速提高。

Figure 4.6 Curves of MSE loss and R-square for the training set and validation set. During the training process, the loss of the model on the training set and the validation set can be quickly converged, and the degree of fitting through R-square characterization has also rapidly improved.

为了证明我们的模型更具通用性，我们不仅在测试集上评估我们的模型，而且在一个由250个图像组成的独立测试集上评估我们的模型，而这个测试集不是来自先前的数据集。在理想状态下，回归值应等于真值，如图4.7中蓝色虚线所示。“真”值由Hough变换和最小二乘法获得，然后手工验证。彩色圆圈代表独立测试集中的250个样本。在图4.7(a)中，只有几个圆圈的异常值，它们都位

于蓝色虚线的左上方，这意味着回归的 x -center(cx)坐标值比真值更高。绝大多数样本都是很好的通过蓝色虚线。在图4.7(b)中，只有很少的离群值，它们主要集中在蓝色虚线上。这意味着回归的 y -center(cy)坐标值很紧密的围绕着真值周围。在图4.7(c)中，大多数样本位于蓝色虚线周围，有少量的异常值。造成上述异常值的原因如下：(1)数据集中不可避免地存在不确定性，可能由于色球边缘不清晰，造成我们的模型也学习了这种不确定性；(2)这里的异常值是由于存在厚的云层污染造成的，但模型训练过程中并没有学习云层的特征；(3)一些数据中存在不完整的太阳圆盘会导致相对较大的计算误差。其中后两种原因是由于数据质量相对不好，一般会在后面的科学研究中予以删除。

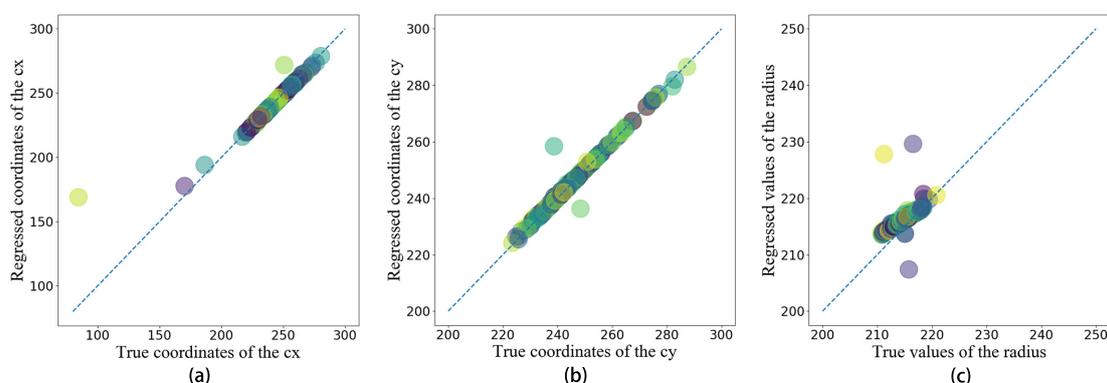


图 4.7 太阳圆盘圆心坐标和半径的回归值和每幅图像的真实值。蓝色虚线表示回归值等于真值。大多数样本都穿过蓝色虚线。有一些偏离点是由于云污染、原始误差和不完整的圆造成的。

Figure 4.7 Regressed values and the true values of each image for the center coordinates and the radius of the solar disk. The blue dashed line represents that the regressed values equal the true values. Most samples run through the blue dotted line. There are a few outliers because of cloud pollution, original errors, and incomplete circles.

此外，我们还计算了太阳圆盘的回归值与真值之间的相对误差，

$$\delta = \frac{|T-P|}{T}, \quad (4.4)$$

其中 T 表示真值， P 代表预测值。表4.2显示了不同相对误差的比例。圆心 cx 坐标在0.01以下的相对误差为98.4%，相对误差在0.01和0.1之间的比例为1.2%。如上所述，有一些异常值的相对误差小于1%。对于圆心 cy 的坐标而言，不存在相对误差大于0.1的样本。99.2%的相对误差小于0.01。对于太阳圆盘半径，65.2%的样本的相对误差控制在0.01以下，34%的样本在0.01-0.04之间。只有0.8%的样本

在0.04和0.1之间，尽管半径的相对误差不如圆心坐标，它的相对误差仍然相对较低。此外，用一台标准PC的CPU计算每个图像的中心坐标和半径平均需

表 4.2 250个样本的不同相对误差的比例。

Table 4.2 Proportion of Different Relative Errors of 250 Samples

相对误差	$\delta < 0.01$	$0.01 \leq \delta < 0.1$ (0.04)	$(0.04)0.1 \leq \delta < 0.2$ (0.1)	$\delta \geq 0.2$ (0.1)
cx坐标	246 (98.4%)	3 (1.2%)	0 (0%)	1 (0.4%)
cy坐标	248 (99.2%)	2 (0.8%)	0 (0%)	0 (0%)
半径	163 (65.2%)	85 (34.0%)	2 (0.8%)	0 (0%)

要0.953s，特别是，一台带有1070Ti GPU的标准PC平均只需要0.024s就可以完成相同的任务。

我们还分析了在不同噪声密度下训练好的模型的性能。我们将模型用于10幅含有噪声的图像来测试太阳圆盘被污染之后仍能有效的回归出所需的参数，这些图像是从250幅图像中随机选取的。每个图像的噪声密度为0–0.1(不包括右端点)，其步长为0.01。表4.3显示了典型不同噪声密度下模型回归结果与真实值的比较。通过比较发现，在不同的噪声密度下，太阳圆盘的中心坐标差仍然很小，

表 4.3 在典型不同噪声密度下模型的真值和回归结果。

Table 4.3 The True Values and the Regressed Results of the Model Under Typical Different Noise Densities.

(cx,cy),r	真值	0	0.04	0.09
1	(243.19, 241.11), 217.77	(242.76, 241.21), 217.92	(242.87, 241.15), 217.96	(242.76, 241.17), 217.95
2	(232.17, 240.12), 217.24	(231.84, 240.31), 217.69	(231.88, 240.11), 217.69	(231.86, 240.15), 217.66
3	(238.03, 238.17), 216.64	(237.78, 238.54), 217.18	(237.76, 238.42), 217.22	(237.88, 238.48), 217.19
4	(228.54, 246.64), 215.55	(228.18, 246.83), 216.62	(228.20, 246.77), 216.64	(228.25, 246.78), 216.64
5	(240.70, 255.58), 215.37	(240.04, 255.81), 216.46	(240.08, 255.80), 216.53	(240.18, 255.78), 216.51
6	(231.15, 243.96), 211.52	(230.43, 244.78), 214.20	(230.43, 244.71), 214.19	(230.42, 244.75), 214.18
7	(236.26, 243.64), 211.04	(235.30, 244.56), 213.76	(235.22, 244.44), 213.72	(235.25, 244.49), 213.71
8	(235.80, 248.70), 211.76	(235.04, 249.19), 214.28	(235.09, 249.12), 214.34	(235.12, 249.21), 214.34
9	(235.35, 235.77), 213.52	(234.49, 236.49), 215.31	(234.45, 236.47), 215.36	(234.57, 236.40), 215.38
10	(237.81, 237.99), 219.43	(237.67, 238.06), 219.77	(237.55, 238.07), 219.82	(237.72, 238.07), 219.64

最大为1个像素，半径的最大差约为2-3个像素。图4.8描述了表4.3中第一个样本的真实值和回归结果之间的差异。这表明，在部分太阳图像受到污染后，该模

型仍能稳定地回归到预期结果。图4.9是其回归的可视化结果。

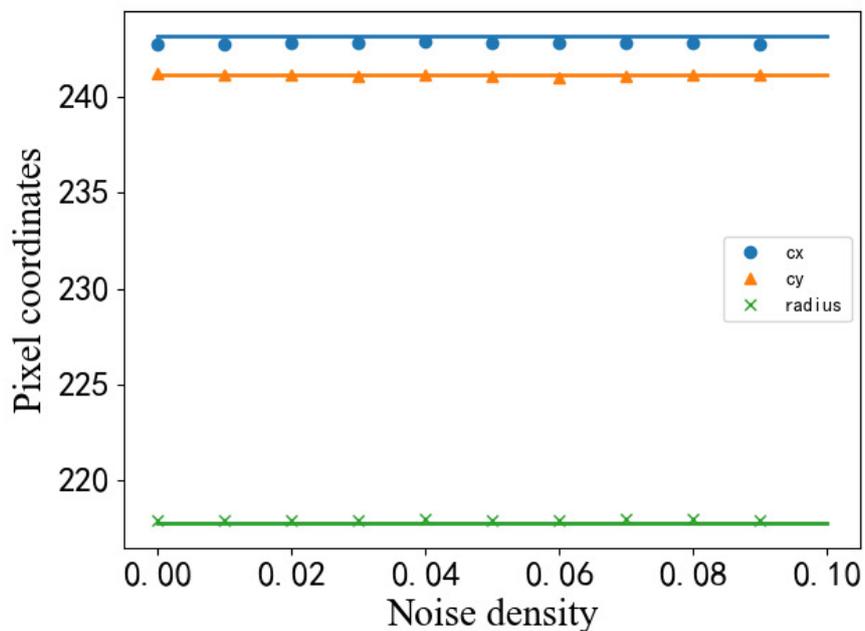


图 4.8 不同噪声密度下真实值与回归结果的差异。直线代表真值。太阳圆盘的圆心坐标和半径保持稳定的回归结果。

Figure 4.8 Difference between true values and results under different noise densities. The line represents the true values. The center coordinates and radius of the solar disk maintain stable regression results.

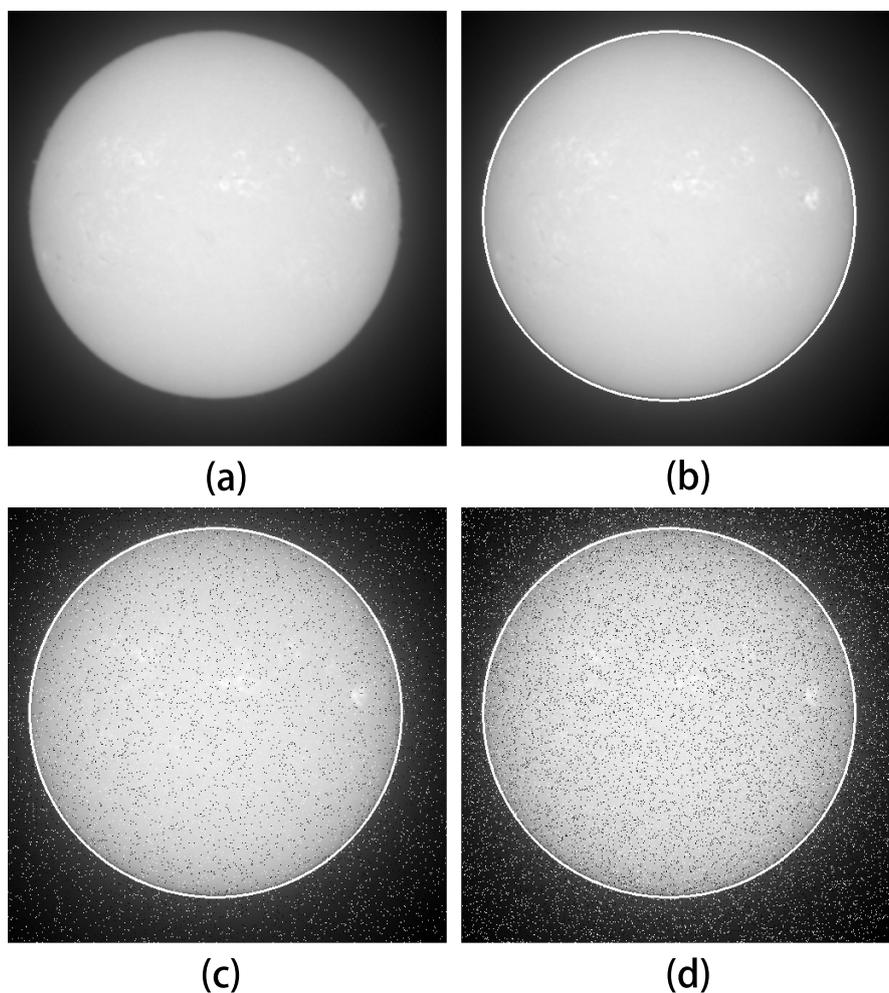


图 4.9 模型回归的可视化结果。白色圆圈表示结果：(a)原始图像，(b)无噪声的结果，(c)噪声密度为0.04的结果，(d)噪声密度为0.09的结果。

Figure 4.9 A visualization results of model regression. The white circles represent the results: (a) the original image, (b) a result without noise, (c) a result with a noise density of 0.04, and (d) a result with a noise density of 0.09.

第5章 基于全卷积神经网络的太阳暗条识别

通过我们提出的改进的传统方法进行太阳暗条的识别分割，通过论证虽然可以有效的进行暗条的识别工作，但是由于传统方法的局限性，我们在进行太阳暗条的识别工作的时候，总是会存在或多或少的噪点同时存在于暗条的识别结果中，如图5.1，所以我们不得不通过连通域的面积、长宽比等条件来进行进一步的排除操作，不可避免会存在将暗条同时被排除可能性，所以我们尝试使用新的方法直接去识别太阳圆盘内的暗条，而不引入过多的噪点。所以我们尝试使用基于深度学习的方式来进行实验，通过实验表明该方法能够有效的直接进行太阳暗条的识别。

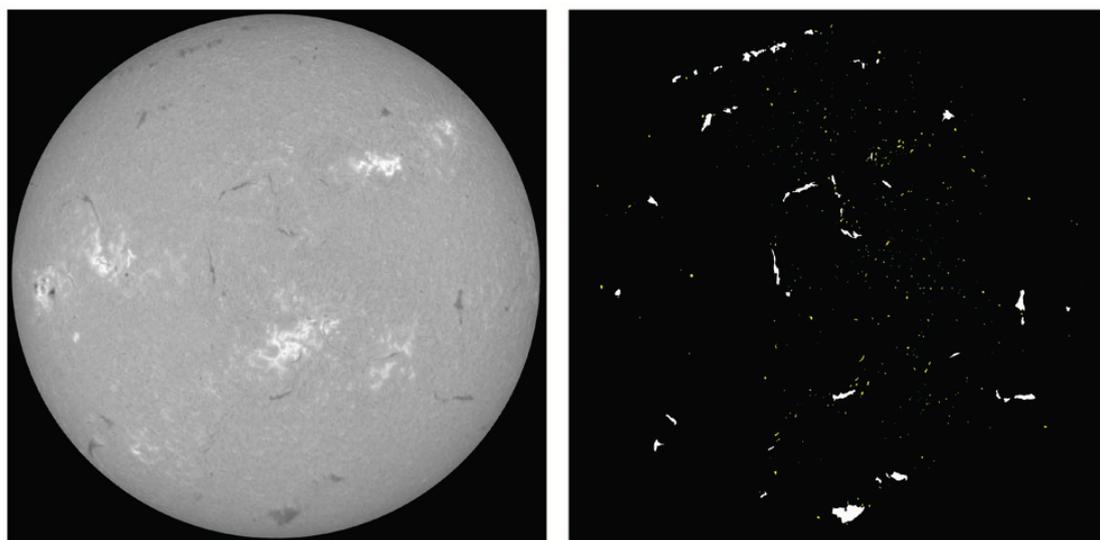


图 5.1 利用传统图像处理方法进行太阳暗条识别的例子。太阳圆盘中存在大量的噪声点，这些噪声点是右侧面板上分散、孤立的黄色散射点所表示的。

Figure 5.1 One example of filament recognition using traditional image processing method. There are a lot of noise points in the solar disk, which are represented by the scattered and isolated yellow dispersion points in the right panel.

本节的组织如下：第一小节介绍数据的来源和数据增强扩充等内容；第二小节介绍全卷积神经网络和改进的U-Net网络模型；第三小节介绍最后的结果。

5.1 数据获取

由于没有针对太阳暗条识别现存直接可用的数据集，所以我们从BBSO的FDHA(Full-Disk H-alpha Patrol Telescope)中获取全日面 $H\alpha$ 太阳数据，并且制作成数据集。FDHA是BBSO主要用于全日面 $H\alpha$ 常规观测的主要设备，它的滤波器带通为Zeiss Lyot Filter 0.025 nm，可调滤波器范围为 $\pm 0.30\text{nm}$ ，摄像机为JAI PULNIX TM4200GE Camera，探测器为柯达KAI 4021，分辨率为 2048×2048 。在BBSO上获得的 $H\alpha$ 全日面图像的典型曝光时间为30ms。

我们制作了由数万张全日面图像组成的数据集，由于两个原因我们暂时只取其中太阳暗条特征典型的30张数据作为我们的训练集，一个是我们建议的网络的训练暂时不需要大批量的数据即能够学习到对应的目标特征信息，二个是我们需要对选取的训练集进一步采用人工的方式进行标签的矫正处理，对于大批量的数据的人工矫正是一个巨大的工作量。所以我们暂时用少量的数据作为训练集，下文会介绍使用数据增强扩充数据，然后再将其他的数据作为实际的测试之用。同时，我们又选取了20张数据作为验证集，目的是作为网络模型训练的参考。

数据集包含两部分，一个是全日面 $H\alpha$ 太阳图像，另一个是对应的太阳暗条的二值图，图中只包含0和1，其中1代表暗条区域，0代表非暗条区域。为了验证我们想法的可行性，减少噪声和不可预见的因素，需要对全日面 $H\alpha$ 太阳图像事先去除临边昏暗，并且将太阳圆盘以外的地方设置为灰色，然后对二值图进一步用人工的方式进行矫正处理，以便让网络学习到正确的太阳暗条特征。

由于我们选取少量图像作为训练集，为了让网络依然能够学习到太阳暗条更本质的特征，我们采用数据增强的方式进行数据扩充。在前文我们已经介绍了数据增强的多种方式，在本实验中，我们使用了翻转、旋转、缩放、裁剪、平移等策略进行数据的增强，如表5.1。经过不断的数据增强处理，最后生成了6000多张数据供训练使用。

表 5.1 改进网络的数据增强的参数。

Table 5.1 Parameters of data enhancement of the improved network.

方法	范围
旋转	0.2°
平移	0.5 (水平和垂直方向)
裁剪	0.05
缩放	0.05
水平翻转	50% 概率
垂直翻转	50% 概率
填充模式	最近邻域

5.2 改进的U-Net网络模型

我们建议的U-Net网络是基于全卷积神经网络(FCN; Long 等 2015)。FCN也是基于卷积神经网络(CNNs)的一种新的网络结构,与典型的CNNs网络不同的是,FCN网络中没有全连接层,整个网络都由卷积层和池化层构成。在FCN网络提出之前,如何在图像中实现端到端学习的像素级分割仍然是一个难题。大多数的研究集中在使用CNNs进行图像分类等任务。这是首次采用全卷积层代替全连接层实现像素级图像分割。此外,Long等人的另一个重要贡献是定义了跳跃结构,它可以将来自深层的粗略信息与来自浅层的细致信息相结合。与CNNs对图像进行分类不同,FCNs可以对图像中的每个像素点进行分割以实现图像识别分割。

FCN将经典的由五个卷积层和三个全连接层构成的CNNs分类网络全部改为全卷积层的网络结构(图5.2)。它分别将不同的卷积层和倒数第二层卷积层进行反卷积的结果相融合得到相应的分割结果,每一个方式分别称为:FCN-8s、FCN-16s、FCN-32s。虽然FCN可以有效的学习到图像中每个像素的分类信息,从而进行语义分割操作,但是整个分割结果仍然是比较粗糙的,因此有很多研究都围绕着提高分割的精确度。主要分为两个方向,一个是使用空洞卷积(dilated convolution; Yu 和 Koltun 2016)或进一步改进空洞卷积(Chen 等 2014, Chen 等 2016);另一个是建立更多、或者不同位置的跳跃结构,比如DeconvNet(Noh

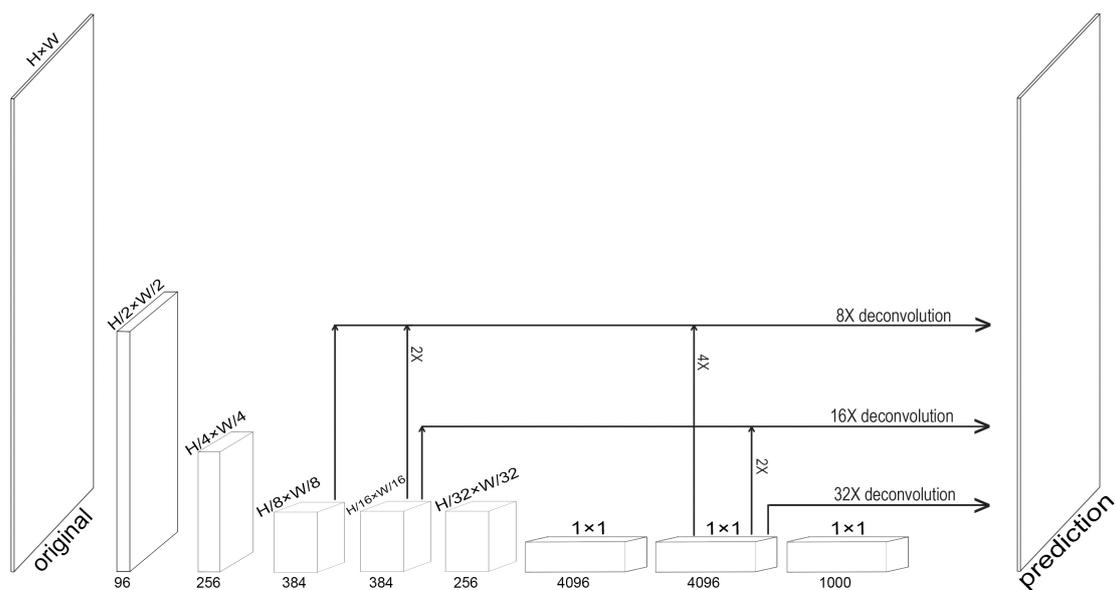


图 5.2 全卷积网络结构。整个网络由卷积层组成，没有全连接层。FCN结合了粗略、高层和细致、低层的特征信息。

Figure 5.2 Architecture of the fully convolutional networks (FCN). The entire network is composed of convolutional layers without any fully connected layer. The FCNs combine coarse and high layer information with fine and low layer information.

等 2015)、SegNet(Badrinarayanan 等 2017)、U-Net(Ronneberger 等 2015)等。由于U-Net网络的高效和精确，我们将它用于太阳暗条的识别分割中。而且，我们需要进一步的改进来更好的满足我们的需求。

U-Net是基于FCN网络的，其作者对网络框架进行了修改和扩展，使其能够使用非常有限的训练图像来获得更准确的识别结果。它的网络结构由一条收缩路径和一条扩展路径组成，在收缩路径中，特征图通过池化层减少尺寸；在扩展路径中，特征图通过反卷积进行升采样然后和收缩路径中相应位置的特征图相结合(Ronneberger 等 2015)。网络中可以包含有几个下采样块和上采样块。

通常情况下，太阳暗条在太阳圆盘上所占的面积很小，直接利用U-Net很难对其进行有效的分割。因此，基于经典的U-Net，我们引入了Dropout层(Srivastava 等 2014)在前四个下采样块的两个卷积层后面。此外，在上采样块中，我们使用了最近邻域插值方法代替反卷积进行上采样操作(图5.3)。引入的Dropout层的公式可表示为：

$$\tilde{y}^l = B(p) \times y^l, \quad (5.1)$$

其中 p 代表丢弃神经元的概率，通常设置为0.5， B 函数是随机产生0或者1。其中

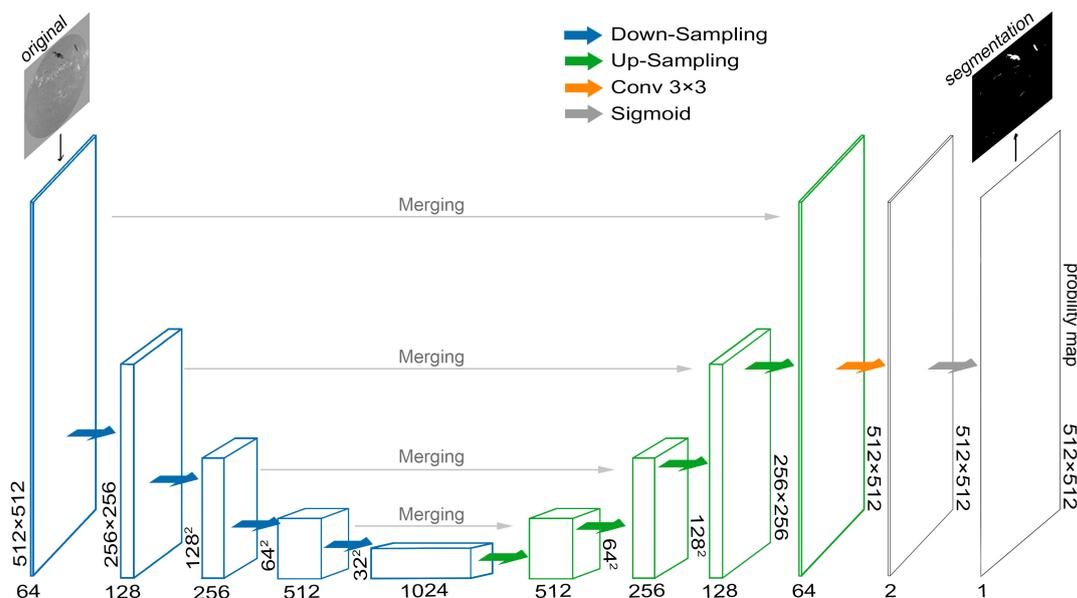


图 5.3 改进的网络结构。包含用蓝色框显示的收缩路径和用绿色框显示的扩展路径。每个方框下面的数字表示通道数。方框的左右两侧提供了特征图的尺寸大小。每个框内包含更多操作，如图5.4所示。

Figure 5.3 Architecture of the improved network. It contains a contracting path shown with blue and an expansive path with green. The number below each box represents the number of channels. The size of feature maps is provided at the left and right sides of the box. Each box contains more operations as shown in Figure 5.4.

在 $(l + 1)$ 层神经元 y_i 可以这样计算：

$$y_i^{(l+1)} = f \left\{ w_i^{(l+1)} \tilde{y}^l + b_i^{(l+1)} \right\}, i = 1, 2, \dots, N. \quad (5.2)$$

这样设计的目的就是会以50%的概率丢弃当前的神经元。

在上采样块中，我们使用最近邻域插值代替反卷积来调整图像大小，可以在保证结果可靠性的同时提高训练速度(图5.4)。由于特征的尺寸不变性，这个可靠性来源于对原特征进行插值方式来近似的调整。原始图像的宽度和高度为 w_1 和 h_1 ，缩放图像的宽度和高度分别是 w_2 和 h_2 。缩放图像的坐标可以表示为：

$$\begin{cases} w = \frac{w_1}{w_2}, w_2 \neq 0 \\ h = \frac{h_1}{h_2}, h_2 \neq 0 \\ x_0 = \text{int}(x * w) \\ y_0 = \text{int}(y * h) \end{cases}, \quad (5.3)$$

其中缩放图像中的 (x_0, y_0) 等于原始图像中的 (x, y) 。

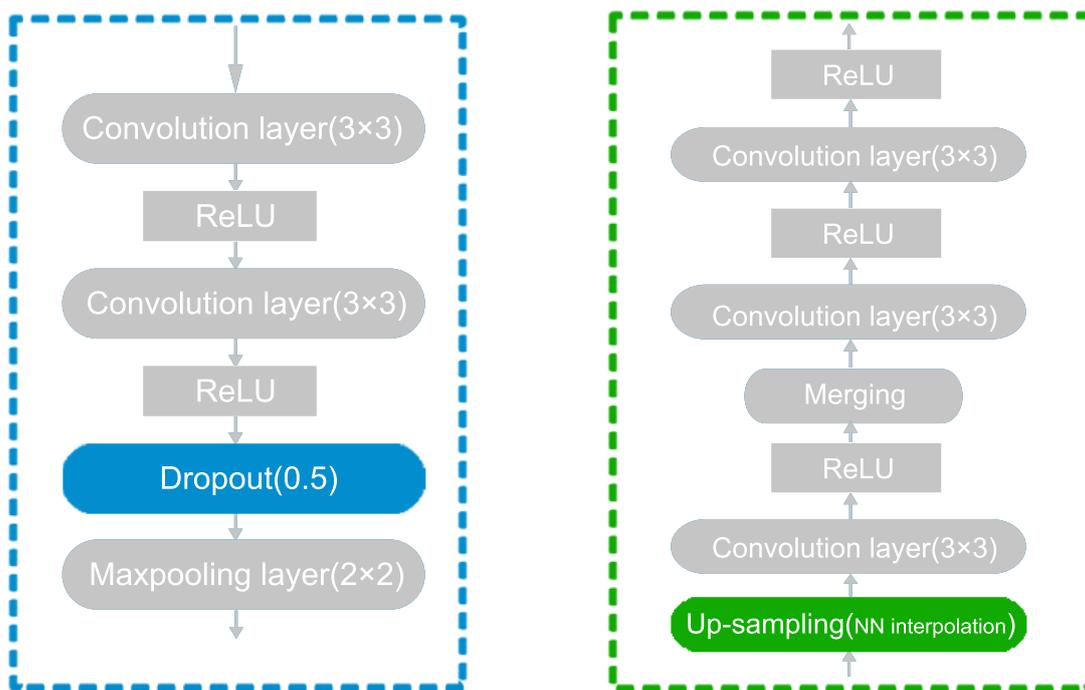


图 5.4 图5.3中每个彩色框的结构. 蓝色虚线框包含两个卷积层、一个Dropout层和一个最大池化层。绿色虚线框由上采样层、卷积层、合并层和两个卷积层组成。卷积核的大小为3×3。每个卷积层后面都有一个激活函数。Dropout层以50%的概率丢弃神经元。上采样层使用最近邻域插值代替反卷积。合并操作用于连接每个下采样框中的第二卷积层和每个对应的上采样框中的上采样层。

Figure 5.4 Architecture of each colored box as shown in Figure 5.3. The blue dashed box contains two convolution layers, one dropout layer, and one max-pooling layer. The green dashed box consists of an up-sampling layer, a convolutional layer, a merging layer, and two convolutional layers. The size of convolution kernels is 3×3 . Each convolution layer is followed by an activation function. The dropout layer discards neurons at a 50% probability. The up-sampling layer use the nearest-neighbor interpolation instead of deconvolution. Merging operation is used to connect the second convolution layer in each down-sampling box and the up-sampling layers in each corresponding up-sampling box.

由于我们实验的硬件条件的限制，数据集的图像尺寸都不得不调整尺寸为512×512。Batch大小设置为2，我们选择Adam作为优化器(Kingma 和 Ba 2014)，学习率设置为 10^{-4} ，所有的卷积核的初始化还是正态分布(He 等 2015)，所有的偏置初始化为0张量。整个网络除了最后一层，其他层的激活函数都是“ReLU”函数，最后一层采用的是“sigmoid”函数，可表示为：

$$S(x) = \frac{1}{1 + e^{-x}}, \quad (5.4)$$

其中 x 表示前面网络的处理的结果值。它将结果值映射到0-1之间，它越接近1表示越接近于目标。网络采用的损失函数是二元交叉熵(binary cross-entropy)，可表示为：

$$\text{loss} = - \sum_{i=1}^n \hat{y}_i \log y_i + (1 - \hat{y}_i) \log(1 - y_i), i = 1, 2, \dots, N, \quad (5.5)$$

其中 y_i 表示预测结果， \hat{y}_i 表示真值。评估函数使用准确率(Accuracy)，针对二分类的问题，就是预测正确的像素个数占实际像素数的比例，其表达式为：

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5.6)$$

其中 TP 、 TN 、 FP 和 FN 分别表示真阳率(True Positive Rate)、真阴率(True Negative Rate)、假阳率(False Positive Rate)、假阴率(False Negative Rate)。

5.3 结果分析

如图5.6，可以看出使用深度学习得到的结果能直接对太阳图像中的暗条特征进行识别分割，而不会像传统方法引入大量的噪点，具有明显的优势。图5.5展示所建议的网络训练的Loss和Accuracy曲线，虽然从图中看出val_loss并没有和loss一样收敛，val_acc也并没有像acc一样收敛，这在很大程度上是由于验证集数量过少，不如训练样本采用了图像增强的样本量大，但是其并不参与训练过程，只是作为参考。图5.5左边所示前5个Epochs网络快速收敛，并在20个Epochs左右，在0.005左右不再继续下降。而相应的accuracy在前5个Epochs迅速提升，并且在20个Epochs左右在0.998稳定下来，这说明我的网络可以快速的进行学习训练。

最初我们选取了10张图像作为我们的测试集，这只能论证我们的方法是具有可行性，为了进一步论证我们的方法具有普适性，我们随机选取100张图像组成独立数据集对模型进行测试。由于太阳暗条具有复杂的形态特征，而且很多非常小的暗条肉眼有时都难以判断，所以我们采用的评估是通过人工的方式判断最后的结果是否“有效”的识别出来即可，而是否有效根据人工观察是否将明显的太阳暗条识别出来为判断标准，而评价分为三个等级：完全有效的识别(R1)、带有轻微误识别的有效识别(R2)、完全错误识别(R3)。表5.2 通过我们对100个随机的样本进行人工验证分析可知，本方法可以几乎对所有的样本图像中的太阳暗条进行有效的识别，其中有77个样本是可以有效的针对太阳暗条识

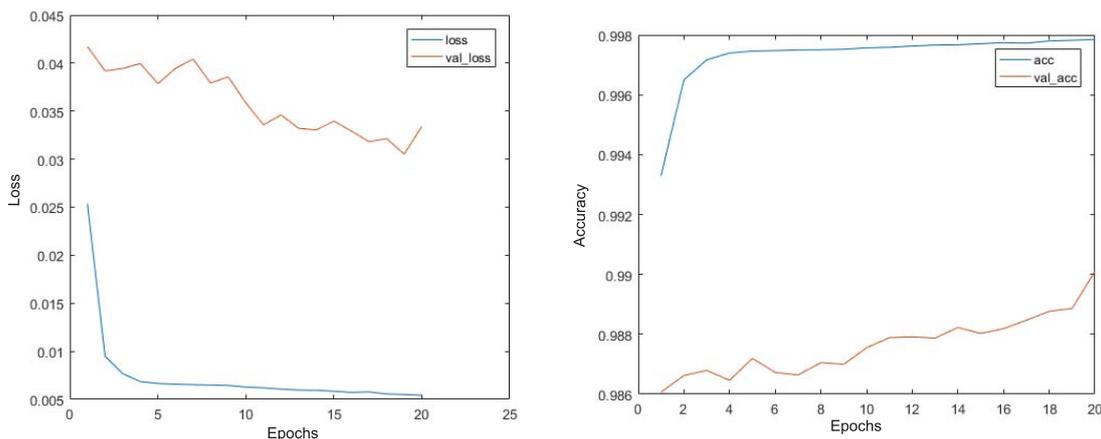


图 5.5 训练集和验证集的Loss和Accuracy曲线。

Figure 5.5 Loss and accuracy in the training process of the proposed network using a training set.

表 5.2 100个随机样本的识别结果。

Table 5.2 Results of the recognition of 100 random samples.

结果分类	完全有效的识别(R1)	带有轻微误识别的有效识别(R2)	完全错误识别(R3)
数量	77(77%)	23 (23%)	0 (0%)

别正确，还有23个样本虽然可以将图像中的暗条识别正确，但是会带有一定的“误”识别，而这个“误”识别分几种情况：1. 大部分集中在会将太阳圆盘边缘呈现暗黑色的区域也当做是暗条，这其中有些也确实确实是太阳暗条在日面边缘的情况，也不能真正的认为是“误”识别；2. 有些是由于其他原因导致日面边缘会存在暗黑色区域，造成真正的误识别，这个很难避免；3. 就是日面上存在明显的不均匀性，造成日面会存在很多暗黑色非暗条区域，而造成误识别。通常情况下太阳边缘的识别结果我们不考虑，所以对于1和2两种情况的问题如果排除掉的话，有效识别率可达96%以上。通过结果说明我们建议的方法可以对太阳暗条进行有效的学习，而且我们发现它学习到的就是图像中暗黑色区域的强度特征，所以才有可能将图像带有暗黑特征的区域判断成太阳暗条，而这类的问题可以和图像质量问题一并考虑去改善模型结构。

虽然我们建议的网络可以完成很好的预期结果，但是网络也存在一定的局限性，首先当日面中存在严重的不均匀时，由于其学习到的强度特征，有可能会将暗黑色的区域也识别成暗条；其次是所建议的网络存在陷入局部最优的风

险，如果这样就不得不重新训练模型，因为采用的是固定学习率，也尝试过采用可变学习率来改善，可以减少发生的几率，但目前仍然没有有效的解决这个问题，下一步可以尝试更多的可变学习率的方案。

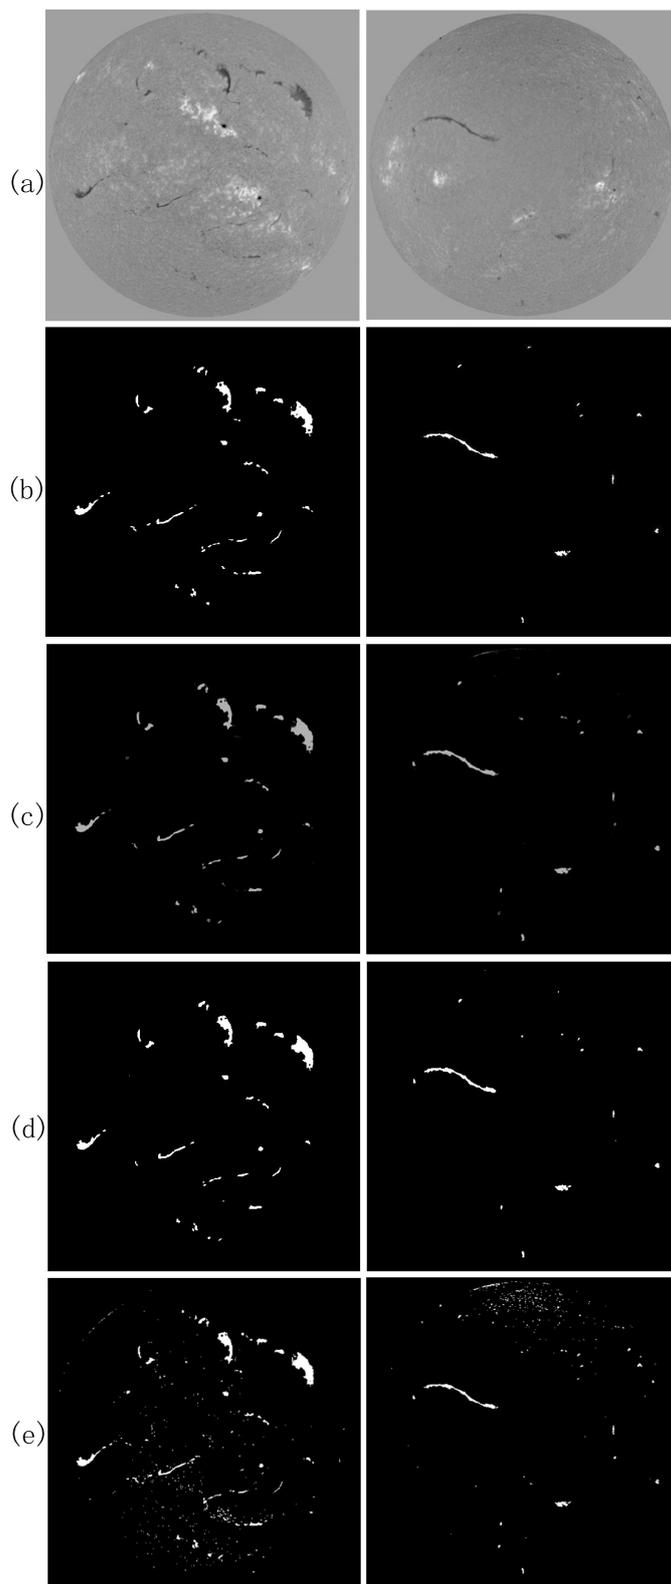


图 5.6 使用改进的U-Net网络识别太阳暗条的例子。(a)表示预处理的 $H\alpha$ 太阳图像；(b)表示真值；(c)表示概率图；(d)表示新方法的分割结果；(e)是传统方法的识别结果，需要后续进行噪点排除。

Figure 5.6 One example of segmentation results using the improved U-Net network. (a) The preprocessed $H\alpha$ images. (b) The ground truths. (c) The probability maps. (d) The segmentation results. (e) The segmentation result using traditional image processing.

第6章 全文总结与展望

6.1 工作总结

太阳暗条是一种低温高密度的等离子体，我们通过 $H\alpha$ 色球望远镜观测到的全日面图像中，它通常呈现出暗黑色的狭长的不规则，具有低温高密度的特性，它的发生通常会与耀斑、CME等太阳活动有千丝万缕的关系，目前世界上有非常多的台站都在对太阳进行日常 $H\alpha$ 观测，并且保存了大量的全日面 $H\alpha$ 太阳数据，所以针对太阳暗条的各种研究具有非常重要的意义。

我们目前收集到了多个台站、具有长周期的全日面 $H\alpha$ 太阳历史图像，这些数据有些是来自照相底片/胶卷记录的，然后通过扫描成数字化的数据为了能够长期保存，有些是通过新的CCD等技术获取到的。为了有效的发挥这些珍贵的历史数据的作用，首要做的工作就是对这些数据中的太阳暗条进行有效的提取，所以需要提出一种能够针对多台站、长周期的大数据进行太阳暗条的自动识别方案。

由于我们收集到的数据体量巨大，而且数据混乱复杂，需要做很多前期工作，对数据进行基本的标准化处理工作，这里面包含了非常多人的辛勤的付出。这其中比如数据存在翻转问题，需要把所有的数据做成电影，用人工的方式来判断翻转的方式；还有NSO台站的数据没有数字化的时间，它是存在图像中以时间戳的形式存在，需要经过自动识别之后经过数十人几个月的人工校验，以确保数据的正确可用。还有非常多类似的前期工作，对此表示真挚的感谢(具体人名在致谢中列出)。

通过充分的调研相关的研究成果，我们分析了当前用于太阳暗条识别研究的一些进展情况，以及他们主要采用的方式和应用的数据情况。我们提出了一种可以针对大数据的太阳暗条的解决方案，主要有以下贡献：

1. 首先我们提出了基于大数据的太阳圆盘获取圆心坐标和半径的方法，可以自动化的对大批量数据进行计算，通过Hough变换先从缩小的原始图像中将可能存在的太阳圆盘所在区域粗略的切割出来，然后提高圆盘和背景的对比度，用大津算法(OTSU)将太阳圆盘分割出来，然后对圆盘进行边缘检测计算其圆度，来判断图像中是否存在太阳圆盘；然后通过标记连通域，保留最大的连通

域，排除其他小的噪声干扰，再对边缘进行膨胀后细化，对边缘点用最小二乘进行第一次拟合圆保存半径信息，然后再次切割出来置于图像中心，并且背景置0，进行第二次最小二乘圆拟合，然后比较两次半径是否相等判断太阳圆盘是否符合要求；最后保存圆心坐标和半径信息。论证了本方法可以有效的获取太阳圆盘的圆心坐标和半径。

2. 鉴于上述传统方法虽然能够得到很高的准确度，但依然难以得到100%的结果，说明对于最后结果是否正确的判断还是存在巧合性的错误。所以我们提出了基于卷积神经网络的回归圆心坐标和半径的新的方法，设计了一个由10个卷积层、3个最大池化层、3个全连接层构成的CNN网络；并且构造了相应的数据集，由全日面 $H\alpha$ 太阳图像和相应的数值型的圆心坐标和半径；为了能够增加模型的鲁棒性，还进行随机太阳圆盘圆心坐标等的数据增强；对于训练好的模型同样可以实现实时处理的要求。论证了本方法可以有效的回归太阳圆盘的圆心坐标和半径。这样达到预期结果的尝试，可以为下一步对结果准确性的判断提供基础。

3. 提出了改进传统方法的太阳圆盘识别算法，通过将临边昏暗、不均匀性等干扰排除之后，统计太阳圆盘内各个强度的数量，形成直方图，然后基于统计学思想用单高斯函数拟合直方图曲线，当拟合的R-square满足0.988后，用拟合得到的均值和标准差得到适合的阈值，然后得出识别分割结果后，根据长宽比、面积、圆度等条件排除噪点和黑子。论证了本方法可以有效的识别太阳暗条。

4. 由于传统方法的局限性，识别太阳暗条的同时会产生大量的噪点，所以提出基于全卷积神经网络的太阳暗条识别方法，通过改进的U-Net网络能够实现直接识别图像中的太阳暗条特征，而不会产生过多的噪点。通过在U-Net网络的收缩路径的加入若干Dropout层避免网络发生过拟合，同时把反卷积的上采样操作作用最近邻域插值的方法代替，可以保证可靠性的同时加快网络的训练速度；并且我们构造出太阳暗条识别的数据集，由全日面 $H\alpha$ 太阳图像和带有太阳暗条的二值图构成；还加入多种数据增强的方式，如旋转、平移、裁剪等；并论证了本方法可以有效的在全日面 $H\alpha$ 太阳图像中识别太阳暗条。

通过我们使用改进的传统图像处理方法和基于深度学习方法分别获取太阳圆盘的圆心坐标和半径，我们发现虽然使用传统方法可以以很高的准确度获取

圆心坐标和半径，但是对于获取到的坐标和半径，如果我们不将其可视化输出，并加以人工判断，依然难以确定其是否正确；所以我们尝试使用深度学习回归圆心坐标和半径，并且经过验证也可以有效的获取坐标和半径，这给进一步使用双输出(一个是图像质量概率，另一个是圆心坐标和半径)提供了可能性。

通过使用改进传统图像处理方法和基于深度学习进行太阳暗条的识别，我们发现两种方法各有优缺点。对于传统方法而言，可以方便、快速的进行有效的识别，但是对于分割结果中一般都会存在大量的噪点，需要进行噪点去除，这是传统方法的局限性；而对于深度学习，它的优势是可以直接对图像中的太阳暗条进行有效的识别，不会带有大量的噪点，但是缺点是，由于其学习到的是强度特征，所以图像中呈现暗黑色的非暗条区域，也有可能识别成暗条。因此，传统方法改进的空间越来越小，深度学习方法可以继续探索式改进。

6.2 进一步工作展望

虽然我们提出了新的方式来实现获取太阳圆盘的圆心坐标、半径和太阳暗条的识别，但是它们目前仍处于研究发展阶段，还有一些局限性存在，比如对于基于卷积神经网络回归圆心坐标和半径的方法，它还可以进行一些新的尝试，如果能一个模型两个输出，一个是对图像质量的评估，另一个是圆心坐标和半径，它们可以共用一套特征提取的部分，这样就能很大程度说明我们当前的获取到的圆心坐标和半径准确的可能性，而不用再人为的检查所得结果是否正确，只需要看当前输出的评估值就可以判断，这将会极大的提高工作效率。本方式的一个更大的展望是通过卷积神经网络从全日面图像中直接回归出具体的数值型数据，意味着对于天文学更多的数据都可以用类似的方法进行多方面的尝试。对于基于全卷积神经网络识别太阳暗条的方法，下一步还可以尝试在不去除临边昏暗的情况下，是否依然能够通过本方法去识别，或者需要进一步的改进本方法才能实现从原始图像中识别暗条；而且本方法还存在陷入局部最优的可能性，所以如何能够避免陷入局部最优也是下一步可以改进的方向。

最后通过我们利用深度学习在天文数据处理上的尝试，并且取得了预期的结果，我们有理由相信深度学习可以在天文领域发挥更大的作用，让我们共同努力，并期待它能够有一天真正的成为主流的方法。

附录 A 附录

A.1 不均匀性去除

设 $f(x, y)$ 表示均匀H α 太阳图像 $h(x, y)$ 和不均匀性的强度图像 $g(x, y)$ 的结合, 表示为: $f(x, y) = h(x, y) + g(x, y)$, 其中 $g(x, y)$ 用四阶二元多项式表示:

$$g(x, y) = \alpha_0 + \alpha_1 x + \alpha_2 y + \alpha_3 x^2 + \alpha_4 y^2 + \alpha_5 xy + \alpha_6 x^3 + \alpha_7 y^3 + \alpha_8 x^2 y + \alpha_9 xy^2 \quad (\text{A.1})$$

我们需要使得 $f(x, y)$ 和 $g(x, y)$ 的均方误差最小:

$$\begin{aligned} d(\alpha) &= \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N (f(x, y) - g(x, y))^2 \\ &= \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N (f(x, y) - (\alpha_0 + \alpha_1 x + \alpha_2 y + \alpha_3 x^2 + \alpha_4 y^2 + \alpha_5 xy + \alpha_6 x^3 + \alpha_7 y^3 + \alpha_8 x^2 y + \alpha_9 xy^2))^2 \end{aligned} \quad (\text{A.2})$$

为了求出 $g(x, y)$, 我们只要计算出其中的 α , 所以我们计算 $d(\alpha)$ 的偏导数设置等于0, 然后可以用矩阵运算的形式表示为: $H = \alpha w$ (详细可以参考:[Yuan 等 2011](#)), 所以 $\alpha = H^{-1}w$ 可以计算获得所需, 相应的 $g(x, y)$ 也就确定, 最后再从图像中扣除不均匀性即可。

参考文献

- 冈萨雷斯, C. R, 伍兹, 等. 数字图像处理: 第3版= Digital Image Processing, Third Edition: 英文 [M]. 电子工业出版社, 2010.
- 冯玉珉. 数据图像压缩编码[M]. 中国铁道出版社, 1993.
- 方成, 丁明德, 陈鹏飞. 太阳活动区物理[M]. 南京大学出版社, 2008: 221.
- 林元章. 太阳物理导论[M]. 科学出版社, 2000.
- 沈岷, 李舜酩, 毛建国, 等. 数字图像复原技术综述[J]. 中国图象图形学报, 2009, 14(9):1764-1775.
- 王旭, 王宏, 王文辉. 人工神经网络原理与应用-第2版[M]. 东北大学出版社, 2007.
- 罗希平, 田捷, 诸葛婴, 等. 图像分割方法综述[D]. 1999.
- 郝奇. 太阳暗条的自动检测及其特征分析[D]. 2015.
- AI G X, HU Y. Propose for a solar magnetic field telescope and its working theorem.[J]. Publ. Beijing Astron. Obs., 1986, 8:1-10.
- BADRINARAYANAN V, KENDALL A, CIPOLLA R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation[J/OL]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(12):2481-2495. DOI: DOI: [10.17863/CAM.17966](https://doi.org/10.17863/CAM.17966).
- BAEK W S, LEE H W. A modified top-hat and bottom-hat transform for edge detection[J]. The Journal of the Korea institute of electronic communication sciences, 2016, 11(9):901-908.
- BAI X, ZHOU F. Analysis of new top-hat transformation and the application for infrared dim small target detection[J]. Pattern Recognition, 2010, 43(6):2145-2156.
- BERNASCONI P N, RUST D M, HAKIM D. Advanced automated solar filament detection and characterization code: description, performance, and results[J]. Solar Physics, 2005, 228(1-2): 97-117.
- BERZINS V. Accuracy of laplacian edge detectors[J]. Computer Vision, Graphics, and Image Processing, 1984, 27(2):195-210.
- BOTTOU L. Large-scale machine learning with stochastic gradient descent[M]//Proceedings of COMPSTAT'2010. Springer, 2010: 177-186.
- BOUREAU Y L, PONCE J, LECUN Y. A theoretical analysis of feature pooling in visual recognition [C]//Proceedings of the 27th international conference on machine learning (ICML-10). 2010: 111-118.
- BREIMAN L. Random forests[J]. Machine learning, 2001, 45(1):5-32.
- CHATTERJEE S, HEGDE M, BANERJEE D, et al. Long-term study of the solar filaments from

- the synoptic maps as derived from spectroheliograms of the kodaikanal observatory[J]. *The Astrophysical Journal*, 2017, 849(1):44.
- CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected crfs[J/OL]. *Computer Science*, 2014(4):357-361. DOI: [10.1080/17476938708814211](https://doi.org/10.1080/17476938708814211).
- CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs[J/OL]. *IEEE transactions on pattern analysis and machine intelligence*, 2016, 40(4):834-848. DOI: [10.1109/T-PAMI.2017.2699184](https://doi.org/10.1109/T-PAMI.2017.2699184).
- CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2017, 40(4):834-848.
- COLLOQUIUM I, WEBB D, RUST D, et al. New perspectives on solar prominences[J]. 1998.
- CORTES C, VAPNIK V. Support-vector networks[J]. *Machine learning*, 1995, 20(3):273-297.
- CSIZMADIA S, PASTERNAK T, DREYER C, et al. The effect of stellar limb darkening values on the accuracy of the planet radii derived from photometric transit observations[J]. *Astronomy & Astrophysics*, 2013, 549:A9.
- DENG Y, AI G, WANG J, et al. Reports on test observations with the multi-channel solar telescope [J]. *Solar Physics*, 1997, 173(2):207-221.
- DENKER C, JOHANNESSON A, MARQUETTE W, et al. Synoptic $h\alpha$ full-disk observations of the sun from big bear solar observatory-i. instrumentation, image processing, data products, and first results[J]. *Solar Physics*, 1999, 184(1):87-102.
- DERICHE R. Using canny's criteria to derive a recursively implemented optimal edge detector[J]. *International journal of computer vision*, 1987, 1(2):167-187.
- DING L, GOSHTASBY A. On the canny edge detector[J]. *Pattern Recognition*, 2001, 34(3): 721-725.
- ENGVOLD O. Observations of filament structure and dynamics (review)[J]. 1998.
- FREEMAN A. *The analytical theory of heat*[M]. Cambridge:University Press,London, 1878.
- FULLER N, ABOUDARHAM J, BENTLEY R. Filament recognition and image cleaning on meudon $h\alpha$ spectroheliograms[J]. *Solar Physics*, 2005, 227(1):61-73.
- GAO J, WANG H, ZHOU M. Development of an automatic filament disappearance detection system [J]. *Solar Physics*, 2002, 205(1):93-103.
- GILBERT H R, HOLZER T E, BURKEPILE J T, et al. Active and eruptive prominences and their relationship to coronal mass ejections[J]. *The Astrophysical Journal*, 2000, 537(1):503.

- GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks[C]//Proceedings of the fourteenth international conference on artificial intelligence and statistics. 2011: 315-323.
- GOPALSWAMY N, SHIMOJO M, LU W, et al. Prominence eruptions and coronal mass ejection: a statistical study using microwave observations[J]. The Astrophysical Journal, 2003, 586(1):562.
- HAO Q, FANG C, CHEN P. Developing an advanced automated method for solar filament recognition and its scientific application to a solar cycle of mlso $h\alpha$ data[J]. Solar Physics, 2013, 286(2): 385-404.
- HAO Q, FANG C, CAO W, et al. Statistical analysis of filament features based on the $h\alpha$ solar images from 1988 to 2013 by computer automated detection method[J]. The Astrophysical Journal Supplement Series, 2015, 221(2):33.
- HARALICK R M, STERNBERG S R, ZHUANG X. Image analysis using mathematical morphology [J]. IEEE transactions on pattern analysis and machine intelligence, 1987(4):532-550.
- HARRIS C G, STEPHENS M, et al. A combined corner and edge detector.[C]//Alvey vision conference: volume 15. Citeseer, 1988: 10-5244.
- HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification[C]//Proceedings of the IEEE international conference on computer vision. 2015: 1026-1034.
- HEBB D O. The organization of behavior: a neuropsychological theory[M]. J. Wiley; Chapman & Hall, 1949.
- HEINZEL P, DOROTOVIĆ I, RUTTEN R J. The physics of chromospheric plasmas: Proceedings of the coimbra solar physics meeting held at the university of coimbra, coimbra, portugal, 9-13 october, 2006: volume 368[M]. Astronomical Society of the pacific, 2007.
- HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural computation, 2006, 18(7):1527-1554.
- HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural computation, 1997, 9 (8):1735-1780.
- HUANG T, YANG G, TANG G. A fast two-dimensional median filtering algorithm[J]. IEEE transactions on acoustics, speech, and signal processing, 1979, 27(1):13-18.
- HUMMEL R. Image enhancement by histogram transformation[J]. iehrt, 1975.
- HUNDHAUSEN A, HANSEN R, HANSEN S. Coronal evolution during the sunspot cycle: Coronal holes observed with the mauna loa k-coronameters[J]. Journal of Geophysical Research: Space Physics, 1981, 86(A4):2079-2094.
- JOSHI A D, SRIVASTAVA N, MATHEW S K. Automated detection of filaments and their disappearance using full-disc $h\alpha$ images[J]. Solar Physics, 2010, 262(2):425-436.

- KINGMA D P, BA J. Adam: A method for stochastic optimization[J]. arXiv preprint arXiv:1412.6980, 2014.
- KIPPENHAHN R, SCHLÜTER A. Eine theorie der solaren filamente. mit 7 textabbildungen[J]. Zeitschrift für Astrophysik, 1957, 43:36.
- KITTLER J. On the accuracy of the sobel edge detector[J]. Image and Vision Computing, 1983, 1(1):37-42.
- KOO J I, PARK S B. Speckle reduction with edge preservation in medical ultrasonic images using a homogeneous region growing mean filter (hrgmf)[J]. Ultrasonic imaging, 1991, 13(3):211-237.
- KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]//Advances in neural information processing systems. 2012: 1097-1105.
- KUPERUS M, RAADU M. The support of prominences formed in neutral sheets[J]. Astronomy and Astrophysics, 1974, 31:189.
- Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- LIN G, ZHU G, YANG X, et al. A new comprehensive data set of solar filaments of 100 yr interval. i.[J]. The Astrophysical Journal Supplement Series, 2020, 249(1):11.
- LIN Y, MARTIN S, ENGVOLD O, et al. On small active region filaments, fibrils and surges[J]. Advances in Space Research, 2008, 42(5):803-811.
- LIU S. A full-disk image standardization of the chromosphere observation at huairou solar observing station[J]. Advances in Space Research, 2020, 65(3):1054-1061.
- LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C/OL]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 3431-3440. DOI: [10.1109/tpami.2016.2572683](https://doi.org/10.1109/tpami.2016.2572683).
- MARTIN S, RAMSEY H, MCINTOSH P, et al. Solar activity observations and predictions[J]. eds McIntosh, PS & Dryer, M., MIT Press, Cambridge, Massachusetts, 1972:371.
- MARTIN S, BILIMORIA R, TRACADAS P. Solar surface magnetism, ed[J]. RJ Rutten, & CJ Schrijver, 1994, 303.
- MAUNDER E W. Sun, place of the, distribution of sun-spots in heliographic latitude, 1874-1913 [J]. Monthly Notices of the Royal Astronomical Society, 1913, 74:112.
- MCCULLOCH W S, PITTS W. A logical calculus of the ideas immanent in nervous activity[J]. The bulletin of mathematical biophysics, 1943, 5(4):115-133.
- MINSKY M, PAPER S. An introduction to computational geometry[J]. Cambridge tiass., HIT, 1969.
- MUNRO R, GOSLING J, HILDNER E, et al. The association of coronal mass ejection transients with other forms of solar activity[J]. Solar Physics, 1979, 61(1):201-215.

- NAIR V, HINTON G E. Rectified linear units improve restricted boltzmann machines[C]//ICML. 2010.
- NEUVO Y, HEINONEN P, DEFEE I. Linear-median hybrid edge detectors[J]. IEEE transactions on circuits and systems, 1987, 34(11):1337-1343.
- NEWTON H, MILSOM A. Note on the observed differences in spottedness of the sun's northern and southern hemispheres[J]. Monthly Notices of the Royal Astronomical Society, 1955, 115(4): 398-404.
- NOH H, HONG S, HAN B. Learning deconvolution network for semantic segmentation[C/OL]// Proceedings of the IEEE international conference on computer vision. 2015: 1520-1528. DOI: [10.1109/ICCV.2015.178](https://doi.org/10.1109/ICCV.2015.178).
- OTSU N. A threshold selection method from gray-level histograms[J]. IEEE transactions on systems, man, and cybernetics, 1979, 9(1):62-66.
- OZHOGINA O. Solar limb darkening in the wings of the caii h and k lines[J]. Geomagnetism and Aeronomy, 2009, 49(7):879-883.
- QIAN N. On the momentum term in gradient descent learning algorithms[J]. Neural networks, 1999, 12(1):145-151.
- QU M, SHIH F Y, JING J, et al. Automatic solar filament detection using image processing techniques [J]. Solar Physics, 2005, 228(1-2):119-135.
- QUINLAN J R. Induction of decision trees[J]. Machine learning, 1986, 1(1):81-106.
- RANZATO M, HUANG F J, BOUREAU Y L, et al. Unsupervised learning of invariant feature hierarchies with applications to object recognition[C]//2007 IEEE conference on computer vision and pattern recognition. IEEE, 2007: 1-8.
- RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]//International Conference on Medical image computing and computer-assisted intervention. Springer, 2015: 234-241.
- ROSENBLATT F. The perceptron: a probabilistic model for information storage and organization in the brain.[J]. Psychological review, 1958, 65(6):386.
- RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. nature, 1986, 323(6088):533-536.
- SHIH F Y, KOWALSKI A J. Automatic extraction of filaments in $h\alpha$ solar images[J]. Solar Physics, 2003, 218(1-2):99-122.
- SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv:1409.1556, 2014.
- SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. The journal of machine learning research, 2014, 15(1):1929-1958.

- SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 1-9.
- TANDBERG-HANSSSEN E. The nature of solar prominences[M]. Kluwer Academic, 1995: 11.
- TANG F. The two types of flare-associated filament eruptions[J]. Solar physics, 1986, 105(2): 399-412.
- TOUZI R, LOPES A, BOUSQUET P. A statistical and geometrical edge detector for sar images[J]. IEEE Transactions on geoscience and remote sensing, 1988, 26(6):764-773.
- WANG H, KOMENDA A E, TANG F, et al. Filament disappearances during the period of september 1991 through september 1994[J]. Solar Physics, 1998, 178(1):109-117.
- WANG T, WU D J, COATES A, et al. End-to-end text recognition with convolutional neural networks [C]//Proceedings of the 21st international conference on pattern recognition (ICPR2012). IEEE, 2012: 3304-3308.
- WANG W, WANG W, HU Z. Segmenting retinal vessels with revised top-bottom-hat transformation and flattening of minimum circumscribed ellipse[J]. Medical & biological engineering & computing, 2019, 57(7):1481-1496.
- WEBB D, HUNDHAUSEN A. Activity associated with the solar origin of coronal mass ejections [J]. Solar physics, 1987, 108(2):383-401.
- YANG J, YU K, GONG Y, et al. Linear spatial pyramid matching using sparse coding for image classification[C]//2009 IEEE Conference on computer vision and pattern recognition. IEEE, 2009: 1794-1801.
- YOUNG I T, VAN VLIET L J. Recursive implementation of the gaussian filter[J]. Signal processing, 1995, 44(2):139-151.
- YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[C]//ICLR. 2016.
- YUAN Y, SHIH F, JING J, et al. Automatic solar filament segmentation and characterization[J]. Solar Physics, 2011, 272(1):101.
- ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks[C]//European conference on computer vision. Springer, 2014: 818-833.
- ZHANG H Q, WANG D G, DENG Y Y, et al. Solar magnetism and the activity telescope at hso5 [J]. Chinese Journal of Astronomy and Astrophysics, 2007, 7(2):281.
- ZHANG J, LIN G, ZENG S, et al. Intelligent recognition of time stamp characters in solar scanned images from film[J]. Advances in Astronomy, 2019, 2019.
- ZHARKOVA V V, IPSON S S, ZHARKOV S, et al. A full-disk image standardisation of the synoptic solar observations at the meudon observatory[J]. Solar physics, 2003, 214(1):89-105.
- ZHARKOVA V, SCHETININ V. Filament recognition in solar images with the neural network technique[J]. Solar Physics, 2005, 228(1-2):137-148.

发表的学术论文与研究成果

已发表(或正式接受)的学术论文:

1. **Zhu, G.**, Lin, G., Wang, D. et al. Solar Filament Recognition Based on Deep Learning. *Sol Phys* 294, 117 (2019).
2. **Zhu, G.**, Lin, G., Wang, D. et al. A New Approach for the Regression of the Center Coordinates and Radius of the Solar Disk Using a Deep Convolutional Neural Network. *ApJ* 902, 72 (2020).
3. Lin G, **ZHU G**, Yang X, et al. A new comprehensive data set of solar filaments of 100 yr interval.i. *ApJS*, 2020, 249(1):11.
4. Lin G, Wang X, Liu S, Yang X, **Zhu, G.**, et al. Chinese Sunspot Drawing and Its Digitization-(I) Parameter Archives. *Sol Phys* 294, 79 (2019).

申请或已获得的专利:

专利受理: 一种太阳圆盘识别方法 (201911150821.2)

参加的研究项目:

用于太阳活动规律研究的百年太阳色球数据的构建与信息提取(国家自然科学基金天文联合基金重点项目; U1531247)

我国太阳物理历史观测资料整编(科技部基础性工作专项; 2014FY120300)

致 谢

虽已秋至即将冬寒，可是内心却依旧火热，感慨万千，回望这一路，短短数年，从对学术的懵懵懂懂到深感敬畏，才知道人类在了解自然的过程是多么的艰辛，无数的研究者在对客观存在的探索中前仆后继，自己的认知也得到了空前的提高，而自身的每一点的进步都离不开身边人的帮助、支持和鼓励。

首先，我要感谢我的导师林钢华研究员和王东光研究员，林老师是一位对科研工作抱有极大热情，对待工作严谨，对学生耐心负责的好老师；林老师不仅提供了一个非常好的研究课题，而且还为学生在研究工作中提供各种思路 and 方向，这些让学生的理论知识和科研能力得到了很大的提高；并经常提供一些参加学术会议的机会，让我有机会去接触到当前研究方向的最新进展；生活上，林老师让我不光要提高科研能力，还教我为人的道理，同时还要让我多锻炼身体，身体好才能科研好；林老师对待科研工作的认真负责的精神，是我需要一直学习的榜样。王老师是一位对工作认真负责，对学生关爱有加，并希望学生能够尽快成长的好老师；无论在学术上还是生活上，王老师都会对学生不时地叮嘱；让学生参加学术会议，可以开拓视野，提高科研能力，以便让学生能够在科研工作 and 生活都能够很好地平衡；并且带领着怀柔的光学团队，迎难而上努力的攻克一个又一个难啃的项目，这样的科研精神同样也是我一直学习的榜样。千言万语，都难以表达我对两位恩师的感激之情，谨此对两位老师表达衷心的感谢和敬意。

其次，要感谢杨潇师姐，在我的科研工作中，也给予了很多的帮助和建议，并且非常耐心的给予讲解和论文英语方面的修改，在日常生活中也给予了非常多的帮助；还要感谢张枚研究员和苏江涛研究员，感谢两位老师给予论文的英语修改的指导。感谢孙文君师兄给予日常工作和生活上的支持和帮助。感谢硕士导师郑胜教授多年来时时刻刻的关心、无私的帮助和培养，感谢曾祥云师兄的一直的帮助和鼓励。

感谢邓元勇研究员在学生期间给予非常多有用的建议和帮助，对学生各方面的提高起到了重要的作用。还要感谢团组内的各位老师提供的帮助和支持：张洪起研究员、林佳本研究员、刘锁副研究员、徐海清副研究员、王晓

帆副研究员、白先勇高级工程师、侯俊峰高级工程师、杨尚斌副研究员、陈洁副研究员、张志勇高级工程师、包星明副研究员、孙英姿高级工程师、王慧站长、汪国萍老师、罗琳秘书，以及站上工作人员：荆帅、王丙祥、阮文东、王建、张鼎波、王立东、杨桂莲、苏海奇、朱丽佳。感谢教育处的杜红荣老师、马怀宇老师、艾华老师、李响老师在各方面提供的帮助和支持。

感谢团组内的各位师兄师姐和同学的帮助和陪伴：宋永亮、王全、吴伟、佟立越、张洋、朱晓明、张鑫伟、王刚、郭晶晶、白阳、李鑫、胡兴、沈宇梁、黄威、王强、荀辉、周明尧、王雅琪、陈垂玉。特别感谢杨潇师姐、宋永亮师兄、王全和吴伟在处理印度数据提供的帮助，以及郑胜老师带领的团队对NSO数据的时间戳的识别校验的工作。

最后，我要感谢我的家人和那个她，你们总是在我的背后默默的支持，默默的付出，虽然我很少用语言表达情感，但是从内心中非常感谢你们这么多年的养育、培养和支持，谢谢你们！以及一路上遇到所有帮助过我的人，非常感谢！同时感谢国家和革命先烈给予的和平年代，让我们可以有机会感受这份盛世繁华和岁月静好。

一段路程的结束，就是另一段旅程的开始，远方未远，终将而至！加油！

2020年秋.