



中国科学院大学

University of Chinese Academy of Sciences

博士学位论文

基于机器学习的高精度太阳磁场测量和定标方法研究

作者姓名: 胡兴

指导教师: 邓元勇 研究员 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

2024年6月

Research on High-precision Measurement and Calibration
Method of Solar Magnetic Field Based on Machine Learning

A dissertation submitted to
University of Chinese Academy of Sciences
in partial fulfillment of the requirement
for the degree of
Doctor of Philosophy
in Astronomy Technology and Methods

By

Xing Hu

Supervisor: Professor Yuanyong Deng

National Astronomical Observatories, Chinese Academy of Science

June, 2024

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。承诺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享有著作权的研究成果，未在以往任何学位申请中全部或部分提交。对本论文所涉及的研究工作做出贡献的其他个人或集体，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：

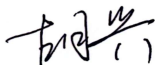
2024.05.31

中国科学院大学 学位论文授权使用声明

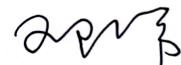
本人完全了解并同意遵守中国科学院大学有关收集、保存和使用学位论文的规定，即中国科学院大学有权按照学术研究公开原则和保护知识产权的原则，保留并向国家指定或中国科学院指定机构送交学位论文的电子版和印刷版文件，且电子版与印刷版内容应完全相同，允许该论文被检索、查阅和借阅，公布本学位论文的全部或部分内 容，可以采用扫描、影印、缩印等复制手段以及其他法律许可的方式保存、汇编本学位论文。

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：



导师签名：



日期：

2024.05.31

日期：

2024.05.31

摘要

太阳活动对人类和日地空间有着十分重要的影响，这些活动如太阳耀斑、日冕物质抛射等现象均与太阳磁场密切相关。如何测得更高精度的太阳磁场一直是太阳物理领域的重要研究方向。怀柔太阳观测基地是世界上首批进行太阳矢量磁场常规观测的基地，建站至今一直保持良好运行状态，积累了近 4 个太阳活动周的太阳活动区矢量磁场数据。怀柔基地窄带滤光器型磁像仪在常规观测时，首先在固定波长点观测获得偏振像，然后通过线性定标获得矢量磁场。固定波长点观测会造成黑子本影强磁场测量信号减弱（常被称为饱和效应）。同时，受到机械误差温度漂移等影响，波长发生漂移，也会造成信号减弱，定标参数不准确。地球大气湍流影响太阳矢量磁场的测量，也对怀柔高质量数据发布产生影响，此外，怀柔太阳观测基地缺乏长期的视宁度评估和分析。机器学习作为一种人工智能技术，能够有效处理大规模数据，进行非线性拟合和隐变量关系挖掘，并支持融合物理信息的神经网络构建。本文利用机器学习的方法，基于怀柔基地长期积累的海量观测数据尝试解决以上问题，提升怀柔太阳观测基地太阳矢量磁场的测量精度。在以下三个方向开展研究工作：

1、基于神经网络 (MLP, Multilayer Perceptron) 的工作谱线波长位置进行标定

滤光器型磁像仪在固定工作谱线波长位置观测时，受到温度变化、机械误差等因素影响，工作谱线波长位置发生偏移。传统的工作谱线波长位置定标方法通过拟合谱线轮廓来对观测点进行定标，耗时多且无法实时校正工作谱线波长位置。为此提出一种基于神经网络的工作谱线波长位置的高效定标方法。该方法首先通过分析不同波长点处的图像特征差异，设计一套有效的数据预处理方案；然后通过机器学习下的神经网络建立起实时观测图像与对应工作谱线波长位置的非线性关系。方法验证和实际测试的结果表明该方法比现有的方法快 100 多倍，同时可监测仪器运行状态。最后，针对磁像仪系统频繁维修后需重新训练网络的问题，给出克服系统变化的方案。该方法可实现滤光器位置实时定标，有效减少定标过程中电机频繁旋转带来的滤光器工作寿命缩短现象，提高地面和空间太阳磁场观测的效率和稳定性。

2、使用卷积神经网络对纵场的磁饱和效应去除研究

借助卷积神经网络，对怀柔基地的单点观测磁场进行磁饱和效应去除研究。太阳动力学天文台 (SDO, Solar Dynamics Observatory) 载荷 HMI (Helioseismic and Magnetic Imager) 在 6 个工作谱线波长位置处观测，通过反演获得太阳磁场，测量结果相对更准确，故以怀柔数据为输入，以 HMI 数据为标签构建网络。首先对图像进行预处理：将两个仪器的图像尺寸调整为同一大小 1024×1024 ，使用 SIFT (Scale Invariant Feature Transform) 算法将怀柔数据和 HMI 数据进行对齐，建立起机器学习数据集，并使用镜像、翻转等方式对齐进行增广。然后使用 ResNet 建立起 SMAT 获得的 Stokes 参数 I、V 和 HMI 获得的纵场 B_l 之间的映射关系，

训练中损失函数设计上加强活动区权重。使用机器学习方法定标得到的磁场和 HMI 相关性为 0.859，高于线性定标结果和 HMI 相关性 (0.705)，同时从活动区的定标结果面图来看，机器学习获得的结果明显更符合黑子本影区域磁场强于周围区域的科学规律。表明使用卷积神经网络可以有效地改善线性定标带来的磁饱和效应。同时，使用定标曲面对网络内在的机制进行了解释。

3、基于 MLP 对怀柔基地历史白日视宁度进行估算

视宁度好坏是影响天文观测磁场测量的一个决定性因素，目前白日视宁度数据主要是通过太阳差分像运动视宁度检测仪 (SDIMM, Solar Differential Image Motion Monitor) 或者谱比法获得。由于 SDIMM 和实际观测仪器的非同一性，其测得的视宁度无法反映数据获取时刻的实际视宁度情况，也无法回溯历史既有观测数据对应的大气视宁度。而使用谱比法需要海量短曝光数据，计算成本巨大。基于以上天文观测面临的困难，提出了一种基于神经网络的白日视宁度估算方法，该方法首先对获得的短曝光数据使用谱比法计算对应的视宁度 r_0 ，构建数据集。然后采用主成分分析的方法对数据进行降维，通过神经网络建立起窄带滤光器太阳光球观测图像和视宁度之间的非线性回归关系，训练集和测试集实验的结果表明该方法可以用于估算视宁度。使用该方法对怀柔观测基地 2020 年的视宁度进行估算。视宁度中值为 2.89cm，对 1989 年到 2010 年连续 22 年的历史观测数据进行长周期的视宁度统计分析，结果表明怀柔基地发布的历史数据对应的视宁度中值在 3cm 左右，大于 3cm 以上的视宁度超过 40%，一年中 9 月份的视宁度最好，该结果验证了怀柔基地视宁度长期稳定。为怀柔基地高质量数据发布提供了参考。

关键词：机器学习，高精度磁场测量，工作谱线波长位置定标，磁场定标，视宁度估算

Abstract

The solar activity has a significant impact on humanity and the space environment between the Sun and the Earth. The solar magnetic field, as an important physical quantity for observing solar activity, has always been a key research direction in the field of solar physics. In ground-based solar magnetic field measurements, sunlight passes through the Earth's atmosphere, the telescope system, and the filtering system in sequence. After polarization demodulation, it is imaged on the detector and then calibrated to obtain the solar magnetic field. The Huairou Solar Observation Base is one of the first bases in the world to conduct routine observations of solar vector magnetic fields, accumulating vector magnetic field data from nearly four solar activity cycles. The narrowband filter magnetograph at the Huairou Solar Observation Base observes at a fixed wavelength point to obtain polarized images, and then obtains vector magnetic fields through linear calibration. Fixed wavelength point observations can cause a weakening of the measurement signal of the strong magnetic field in the umbra of sunspots (commonly known as the saturation effect). At the same time, due to the influence of mechanical errors and temperature drift, wavelength drift can also cause signal weakening and inaccurate calibration parameters. The impact of Earth's atmospheric turbulence on the measurement of solar vector magnetic fields also affects the release of high-quality data from the Huairou base, in addition to which, the Huairou Solar Observation Base lacks long-term turbulence assessment and analysis. In the era of big data and artificial intelligence, machine learning is widely used and gradually increasing its application in the astronomical field, including the solar domain. Machine learning is a method to achieve artificial intelligence, suitable for nonlinear fitting of massive data and mining of hidden variable relationships, while also supporting the construction of neural networks embedded with physical information. This paper attempts to solve the above problems based on the massive accumulated observation data from Huairou, improving the measurement accuracy of solar vector magnetic fields at the Huairou Solar Observation Base, and conducts research work in the following three directions:

1. Calibration of the observed wavelength points based on neural networks (MLP, Multilayer Perceptron)

When the filter-type magnetograph observes at fixed wavelength points, the observed wavelength points are affected by temperature changes, mechanical errors, and other factors, causing deviations. The traditional wavelength point calibration method calibrates the observed points by fitting the spectral profile, which is time-consuming and cannot correct the observed wavelength points in real-time. To address this, an efficient calibration method for observed wavelength points based on neural networks is

proposed. This method first analyzes the differences in image features at different wavelength points and designs an effective data preprocessing scheme. Then, a nonlinear relationship between real-time observed images and corresponding observed wavelength points is established through neural networks under machine learning. The results of method verification and actual testing show that this method is more than 100 times faster than existing methods and can monitor the operating status of the equipment. Finally, a solution is proposed to overcome the need to retrain the network after frequent repairs of the magnetograph system. This method can achieve real-time calibration of filter positions, effectively reducing the shortening of the filter's working life caused by frequent motor rotation during the calibration process, and improving the efficiency and stability of ground and space solar magnetic field observations.

2. Study on the removal of magnetic saturation effect in the longitudinal field using convolutional neural networks

The Helioseismic and Magnetic Imager (HMI) on board the Solar Dynamics Observatory (SDO) observes at six wavelength points and obtains the solar magnetic field through inversion, with accurate measurement results. We use the HMI magnetic field as a label and conduct research on the removal of magnetic saturation effects in the single-point observed magnetic field at the Huairou base using convolutional neural networks. First, the images are preprocessed: the image sizes of the two instruments are adjusted to the same size of 1024×1024 , and the Huairou data and HMI data are aligned using the SIFT (Scale Invariant Feature Transform) algorithm to establish a machine learning dataset, and mirroring, flipping, and other methods are used to augment the alignment. Using ResNet to establish the mapping relationship between the Stokes parameters I, V, and H obtained from SMAT and the longitudinal field B_l obtained from HMI, the loss function design in the training process strengthens the weight of the activity area. In the full-disk results, the correlation between the magnetic field obtained by machine learning calibration and HMI is 0.859, higher than the correlation between the linear calibration result and HMI (0.705). At the same time, from the face map of the calibration result in the dynamic activity area, the result obtained by machine learning clearly conforms more to the scientific law that the magnetic field in the umbra region of sunspots is stronger than the surrounding area. This indicates that convolutional neural networks can effectively improve the magnetic saturation effect brought by linear calibration. At the same time, this paper explains the internal mechanism of the network through the calibration curve.

3. Estimation of historical daytime seeing at the Huairou base based on MLP

The quality of seeing is a decisive factor affecting the quality of astronomical observation images. Currently, daytime seeing data is mainly obtained through the Solar Differential Image Motion Monitor (SDIMM) or the spectral ratio method. Due to the

non-identity of SDIMM and actual observation instruments, the measured seeing cannot reflect the actual seeing situation at the time of data acquisition, nor can it retrospectively analyze the atmospheric seeing corresponding to historical observation data. The spectral ratio method requires massive short-exposure data, and the computational cost is huge. Based on the difficulties faced in astronomical observations, this paper proposes a method for estimating daytime seeing based on neural networks. This method first calculates the corresponding seeing r_0 using the spectral ratio method for the obtained short-exposure data to construct a dataset. Then, principal component analysis is used to reduce the dimensionality of the data, and a nonlinear regression relationship between the narrowband filter solar photospheric observation image and seeing is established through a neural network. The results of the experiment on the training set and test set show that this method can be used to estimate seeing. Using this method to estimate the seeing at the Huairou Observation Base in 2020, the median value of seeing is 2.89cm . A long-term statistical analysis of the historical observation data from 1989 to 2010 shows that the median value of the seeing corresponding to the historical data released by the Huairou base is around 3cm , with more than 40% of the seeing above 3cm , and the best seeing is in September of each year, which validates the long-term stability of the seeing at the Huairou base. This provides a reference for the release of high-quality data at the Huairou base.

Key Words: Machine learning, high-precision magnetic field measurement, calibration of the working spectral line wavelength position, magnetic field calibration, and estimation of seeing

目 录

第 1 章 绪论	1
1.1 太阳磁场测量简介	1
1.1.1 太阳与太阳磁场	1
1.1.2 太阳磁场测量方式	2
1.2 怀柔基地测量设备现状	9
1.2.1 怀柔基地磁场测量现状	9
1.3 基于机器学习的高精度磁场测量	17
1.3.1 当前磁场测量可改进的空间	17
1.3.2 机器学习在天文领域的应用	18
1.4 主要研究内容	21
第 2 章 快速高效工作谱线波长位置定标研究	23
2.1 数据分析以及预处理	23
2.1.1 数据来源	23
2.1.2 数据预处理	24
2.2 基于 BP 神经网络的工作谱线波长位置标定方法	31
2.2.1 BP 神经网络简介	31
2.2.2 BP 波长标定网络	34
2.2.3 实验方法介绍	35
2.3 实验结果和讨论	36
2.3.1 方法验证	36
2.3.2 分组测试	37
2.3.3 克服系统变化实验	40
2.3.4 两种方法效率对比	40
2.4 本章小结	41
第 3 章 基于卷积神经网络的纵场磁饱和效应解决	43
3.1 数据介绍	43
3.2 方法介绍	45
3.2.1 数据预处理	45
3.2.2 基于 ResNet 的纵场磁饱和效应改正	48
3.3 结果以及讨论分析	54
3.3.1 机器学习结果	54

3.3.2 机器学习与线性定标比较·····	55
3.3.3 机器学习可解释性——定标曲面·····	56
3.4 本章小结·····	57
第 4 章 历史数据应用挖掘·····	59
4.1 数据来源·····	60
4.2 数据预处理·····	60
4.2.1 谱比法获取视宁度数据·····	60
4.2.2 历史数据分辨率调整·····	61
4.2.3 PCA 降维·····	61
4.3 基于 BP 神经网络的视宁度估算算法设计·····	63
4.4 结果和分析·····	63
4.4.1 方法测试·····	63
4.4.2 2020 年视宁度实际估算·····	64
4.4.3 1989-2010 年视宁度实际估算·····	64
4.5 本章小结·····	68
第 5 章 总结与展望·····	69
5.1 工作总结·····	69
5.2 未来展望·····	70
参考文献·····	73
致谢·····	79
作者简历及攻读学位期间发表的学术论文与其他相关学术成果·	81

图目录

图 1-1	横向和纵向塞曼分裂	3
图 1-2	自然光, 线偏振光和圆偏振光	4
图 1-3	庞加莱球	5
图 1-4	矢量磁场的描述	8
图 1-5	滤光器型磁像仪系统	8
图 1-6	一组数据拟合得到的谱线轮廓	11
图 1-7	偏振分析器	14
图 1-8	经过偏振分析器后得到的图像以及解析后的 Stokes 图像	16
图 1-9	纵场磁饱和效应	18
图 1-10	机器学习在天文领域和太阳领域的应用趋势	21
图 2-1	非光滑或者拟合错误的谱线	24
图 2-2	太阳光球不同尺度特征	24
图 2-3	太阳自转引起的多普勒速度对单色像的影响	25
图 2-4	数据处理前后的对比。(a) 原始图像; (b) 原图像的灰度变化图; (c) 去除临边昏暗后图像; (d) 去除临边昏暗后的灰度变化图	26
图 2-5	极坐标和直角坐标转换	27
图 2-6	去除日面外数据。(a) 原始图像; (b) 极坐标变换后的图; (c) 日面 部分	27
图 2-7	PCA 分解贡献率	30
图 2-8	20 阶重构前后图像对比	30
图 2-9	图像预处理流程	31
图 2-10	神经元模型	32
图 2-11	BP 神经网络结构	32
图 2-12	Regression MLP 网络	34
图 2-13	BP 神经网络对工作谱线波长位置进行标定总流程	36
图 2-14	训练集和测试集相关图	37
图 2-15	第一个实验组训练集和测试集相关图	37
图 2-16	训练集和测试集的残差变化图	38
图 2-17	每一天残差均方差随时间的变化	39
图 2-18	不同实验组的残差均方差变化图	39
图 2-19	[-0.06, 0.06] 范围下的试验结果	40
图 2-20	谱线扫描数据磁图纵场	41
图 3-1	怀柔数据 Stokes I V 信号	44

图 3-2	HMI 数据磁场 B、倾角 inclination、纵场 B_l	44
图 3-3	预处理后的怀柔数据	47
图 3-4	预处理后的 HMI 数据	47
图 3-5	怀柔和 HMI 的特征图	48
图 3-6	特征点标识图	49
图 3-7	特征点匹配图	49
图 3-8	对齐后的怀柔和 HMI 数据	50
图 3-9	卷积、池化过程	51
图 3-10	ResNet 残差模块	52
图 3-11	MagResNet 结构	53
图 3-12	全日面训练结果	54
图 3-13	活动区训练结果	55
图 3-14	活动区磁场对比	55
图 3-15	定标曲面	56
图 4-1	主成分分析。(a) 不同阶数的 PCA 贡献率, (b) 重构前后图像对比	61
图 4-2	数据预处理流程	62
图 4-3	训练集和测试集相关图	64
图 4-4	2020 年视宁度估算结果	65
图 4-5	1989-2010 视宁度年中值变化曲线	65
图 4-6	1-12 月的视宁度变化曲线	66
图 4-7	1 月到 12 月的光球图	66
图 4-8	1989-2010 视宁度值大于 3cm 所占的百分比	67
图 4-9	视宁度占比。(a) 不同大小视宁度占比, (b) 不同区间视宁度占比	67

表目录

表 1-1	太阳磁场望远镜参数	9
表 1-2	全日面太阳磁场望远镜参数	10
表 1-3	KD*P 调制方案的偏振原件工作状态	14
表 2-1	激活函数	35
表 2-2	实验环境	36
表 2-3	传统定标方法和机器学习方法时间精度比较	41
表 3-1	数据集列表	44
表 3-2	MagResNet 实验环境	54
表 4-1	数据分辨率和单帧曝光时间	60

第 1 章 绪论

1.1 太阳磁场测量简介

1.1.1 太阳与太阳磁场

在宇宙天体中，与人类关系最为密切的就是太阳，太阳的存在使得地球上具有万物生存的光和热，为万物生长提供了适当的环境，并带来了漂亮的日出日落、极光、彩虹等美景，我们所看到的四季交替，昼夜变化，气候变化，都是太阳作用的结果。人类对太阳的探索从未停止过脚步，自两千三百多年前，伟大的诗人屈原就在他的著名诗篇中提出了许多问题，包括宇宙如何由混沌变为有序、日月归属、恒星划分、以及太阳运行特征；太阳升降到底走了多少公里；为什么太阳还未升起来，却能在西北若华林上看光彩等等，这些问题中很多都跟现代自然科学有紧密的关系。

太阳研究对科学的发展具有十分重要的价值和深远的意义。首先，太阳的研究对天文学的发展有重要的影响。太阳是距离人类最近的恒星，也是人类唯一一个可以通过高分辨率（空间、时间、光谱）、高精度以及多视角展开全波段电磁辐射和粒子辐射探测的恒星（邓元勇等, 2020）。作为一颗典型的恒星，对太阳的详细研究有助于我们了解广阔的恒星世界，对大多数恒星的状况能有大致认识，了解一般性的恒星规律。比如，我们可以基于太阳的研究结果对恒星大气的辐射传输、内部构造和演化等问题进行类比研究。此外，太阳的高清观测所揭示规律亦可以推广到其他恒星、星系、黑洞吸积盘、喷流、中子星、分子云、活动星系乃至星系（颜毅华等, 2023）。其次，太阳也是一个多尺度物理过程并存的等离子体物理实验室，太阳可以提供许多地面难以实现的物理环境。比如可以展开对复杂的太阳夫琅禾费光谱、色球光谱以及高温日冕光谱的研究；对谱线证认、谱线加宽机制和高次电离原子的光谱特征等方面的研究；对太阳能源的研究。借助于太阳上呈现的丰富等离子体物理现象，还可以展开流体力学、高能物理和原子物理的研究。诸如此类的研究促进了光谱学、核物理等诸多物理学科的发展。

太阳研究也具有重要的社会意义。太阳为人类提供合适生存环境的同时，人类也在利用太阳造福于自身。太阳作为一种可再生能源，比常规能源如化石燃料有很多优势，太阳能取之不尽用之不竭（王亚男, 2005），利用太阳能作为能源不会产生废气废料，因此不污染环境，是一种清洁能源。在人类利用太阳能的同时，也需要警惕太阳活动对人类的威胁，如日冕物质抛射、太阳耀斑等剧烈活动会在日地空间引发一系列剧烈扰动。这些灾害性的天气往往发生在短短的几分钟到几个小时之内，但是对空间天气的影响十分严重。比如航空航天会受到太阳风的影响而产生故障，导航通讯受到磁暴而失灵，如 2003 年的“万圣节”太阳风暴导致数十颗地球轨道卫星暂时性失灵，导致通讯损坏，对人类的日常生活造成严重影响（seanp, 2019）。电力系统等行业受到太阳剧烈活动影响而对人类的用电、生活生产带来严重的影响。广为人知的 1989 年 3 月的太阳风暴造成加拿大魁北克

省电力和供暖系统在几秒内瘫痪，美国 200 多处电力系统出现异常 (Ilinsky et al., 2022)；1859 年发生的“卡林顿”太阳耀斑事件也是太阳影响人类社会的一个重要事件，卡林顿事件导致了全球电报网络失灵 (Hudson, 2021)。随着人类对高科技系统的依赖程度不断增加，太阳活动和空间天气的预报愈加重要。

太阳大气是由磁场主导并耦合在一起的巨大等离子体环境，太阳大气到处存在着磁场。太阳上的耀斑爆发、日冕物质抛射等活动都与太阳磁场密切相关。比如磁重联——相反方向的磁力线相互靠近导致原有的磁场拓扑结构发生改变，并形成新的“联结”——是太阳爆发能量释放的主要机制，磁重联的过程中，伴随着磁自由能的快速释放。太阳大尺度磁场的周期性变化导致了太阳黑子 11 年为周期进行有规律的变化 (QU et al., 2007)。小尺度的太阳活动也与磁场变化密切相关，日冕温度的升高实际上是由于磁流体波动，小尺度的耀斑也是如此。当今太阳物理领域的三大科学难题——太阳活动周起源、太阳爆发机制以及日冕加热机制都与太阳磁场密切相关。当今太阳物理的重大成就和主要困难都与太阳磁场的观测及理论研究有关，因此高精度的太阳磁场测量至关重要。

1.1.2 太阳磁场测量方式

1.1.2.1 太阳磁场测量历史

太阳磁场在 1908 年由美国天文学家 Hale 发现。太阳磁场的测量基于 1896 年荷兰物理学家 Zeeman 提出的 Zeeman 效应如图 1-1，即原子光谱线受到外磁场的作用，会由一条谱线分裂成几条偏振化的谱线 (林元章, 2000)。对于正常塞曼效应，塞曼三分裂为 σ_v 、 π 、 σ_r ，其中 π 子线是线偏振，偏振方向与磁场平行；对称位于红蓝端的两条线 σ_v 和 σ_r 是在与磁场垂直的平面内圆偏振，分别为左右旋，左右旋的线可以沿磁场方向（沿 y 轴方向）看到。当垂直磁场方向观测时（沿 x 轴方向），可以看到三条子线，均为线偏振。其中 π 线的偏振方向与磁场平行， σ_v 和 σ_r 的偏振方向与磁场垂直。

1908 年，美国科学家 Hale 首次利用 Zeeman 效应在威尔逊天文台测得太阳黑子磁场 (Hale, 1908)，虽然 Hale 的方法只适用于测量太阳强磁场，对于 500G 以下的弱磁场无能为力，但却开创了天体磁场测量的先河。此后的太阳磁场测量中，基本沿着 Hale 的仪器思路缓慢发展。1953 年，美国 Babcock 父子基于光电原理，研制出了世界上第一台测试弱场的磁像仪，该磁像仪可以测出弱达 1G 的磁场。这台仪器实现了对太阳宁静区的观测，并且发现太阳极区也存在磁场 (Babcock, 1953)。1962 年 Severny 首次实现了对太阳矢量磁场的测量（在此之前都只能测量视向磁场分量）。六十年代初，克里米亚天文台 Stepanov 等人发明了可以用于测量太阳横向磁场的矢量光电磁像仪 (白先勇, 2014)。迄今为止，太阳磁场的测量主要还是借助于 Zeeman 效应，在太阳的光球部分可以做精确测量，色球谱线可做稍差观测 (Samanta, 2020)，日冕磁场部分主要用射电方法、磁震学方法估算。

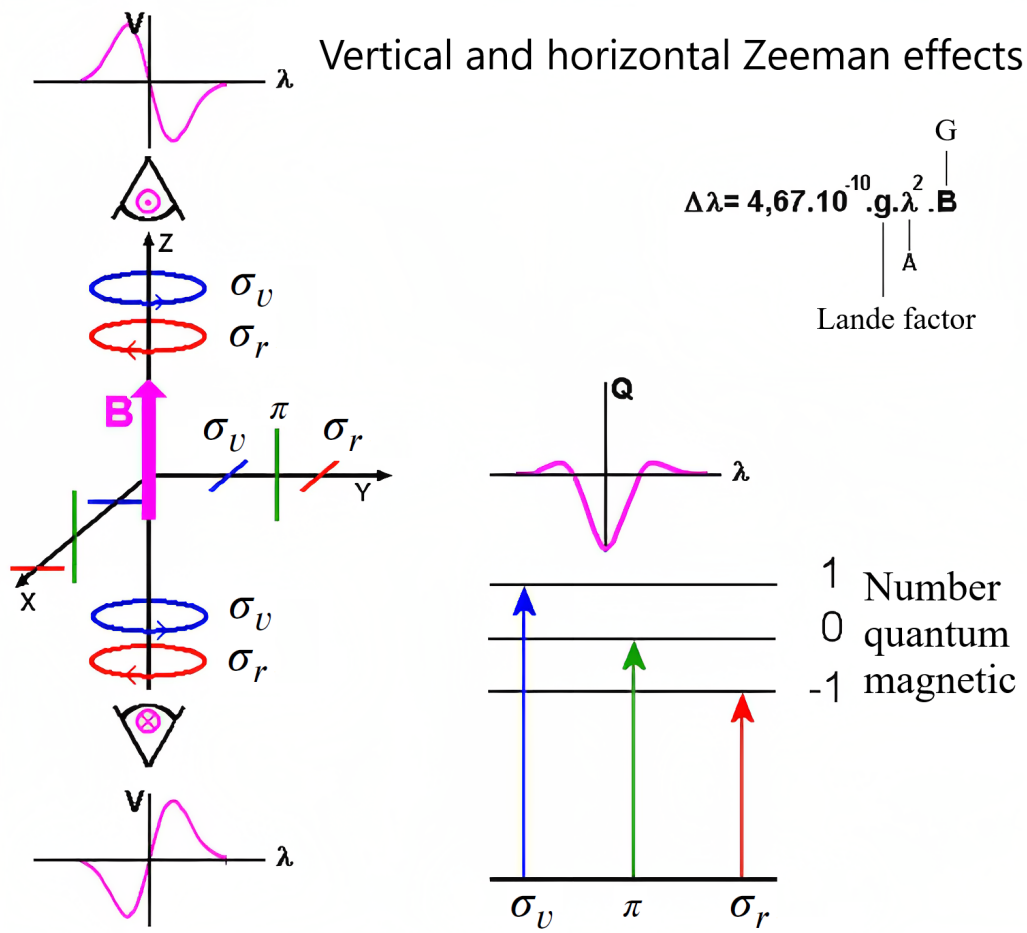


图 1-1 横向和纵向塞曼分裂

Figure 1-1 Horizontal and vertical Zeeman splitting

1.1.2.2 太阳磁场测量方式

由图 1-1可知，磁场测量的本质实际上是偏振测量。偏振是指振动方向对于传播方向的不对称性，它只在横波中发生，对于纵波则没有偏振现象。光是一种电磁波，具有波粒二象性，就其波动性展开讨论，在真空中光波以光速进行传播，其电矢量和磁矢量垂直于传播方向且相互正交。完全描述偏振光需要四个参数，任何一束偏振光都可以由以下三种偏振光线性叠加而成，他们分别是电矢量振动方向 0° 、 45° 的线偏振光 F_1 、 F_2 ，圆偏振光 F_3 ，如图 1-2所示，其中 F_0 是自然光。偏振光的描述通常采用琼斯矢量或者 Stokes 矢量，基于辐射转移方程测量




图 1-2 自然光，线偏振光和圆偏振光

Figure 1-2 Natural light, linearly polarized light, and circularly polarized light

磁场的方式中同常采用 Stokes 参数来描述。由于光矢量和电矢量相互垂直并存在固定相位关系，通常选用电矢量 E 来描述。沿观测方向传播的任何光束的电矢量的波动，都可以由垂直于视向的平面内两个正交方向的振动构成，对于单色波，其振动可以由公式 (1-1)表示

$$\begin{cases} E_x = A_x \cos(\omega t - \epsilon_x) \\ E_y = B_y \cos(\omega t - \epsilon_y) \end{cases} \quad (1-1)$$

其中 ω 为圆频率， A_x 、 B_y 为振幅， ϵ_x 、 ϵ_y 为相位。Stokes 矢量是由英国物理学家斯托克斯 (G.G.Stokes) 在 1852 年提出用来描述偏振光偏振态的四个参量 (S_0 、 S_1 、 S_2 、 S_3) (Stenflo, 1994)。Stokes 参量不是真正的矢量，它们不作为矢量进行变换或旋转，但是可以将 Stokes 参量作为矢量叠加来模拟非相干光束的叠加。Stokes 参量可以表征非偏振光、部分偏振光和偏振光，通过 Stokes 参量可以描述光波的状态，如相干性等，其表述形式如式 (1-2):

$$S = \begin{pmatrix} S_0 \\ S_1 \\ S_2 \\ S_3 \end{pmatrix} = \begin{pmatrix} P_H + P_V \\ P_H - P_V \\ P_{45} - P_{135} \\ P_R - P_L \end{pmatrix} = \begin{pmatrix} I \\ Q \\ U \\ V \end{pmatrix} \quad (1-2)$$

其中 S_0 是光束的总辐照度, S_1 为水平 (0°) 偏振光通量分量 (P_H) 与垂直 (90°) 偏振光分量 (P_V) 之差。当 $S_1 = 0$ 时, 水平线偏振器测得的光通量与垂直线偏振器测得的光通量相等。因此, S_1 度量的是水平偏振超过垂直偏振的程度, 如果 $P_V > P_H$, S_1 为负。同理, S_2 是 45° 偏振光通量 (P_{45}) 与 135° 偏振光通量 (P_{135}) 之差; S_3 度量了右旋 (P_R) 与左旋 (P_L) 圆偏振光通量之差。总的来说, I 表示光波的总强度, $\pm Q$ 表示偏振光水平或者垂直的程度, $\pm U$ 表示线偏振光与 Q 成 $\pm 45^\circ$ 的程度; $\pm V$ 表示圆偏振光左旋或者右旋的程度。Stokes 矢量 I 、 Q 、 U 、 V 与 (1-1) 的关系如式 (1-3) 所示:

$$\begin{cases} I = E_x^2 + E_y^2 \\ Q = E_x^2 - E_y^2 \\ U = \frac{2E_x E_y \cos(\epsilon_x - \epsilon_y)}{2} \\ V = \frac{2E_x E_y \sin(\epsilon_x - \epsilon_y)}{2} \end{cases} \quad (1-3)$$

其中的横线表示对时间的平均。实际上自然光并非纯粹单色的连续振动波, 是大量间断性的震动叠加, 因此存在一定的波宽。如果波宽远小于太阳谱线的宽度, 即可将其视为单色光。当振幅和相位差为常数时, 是一种椭圆偏振光。可以借助庞加莱球 1-3 表示偏振态参数。可以证明, Stokes 参量之间存在如下关系 (1-4):




图 1-3 庞加莱球
Figure 1-3 Poincare Ball

$$\begin{cases} I^2 = Q^2 + U^2 + V^2 \\ \tan 2\phi = U/Q \\ \sin 2\beta = V/(Q^2 + U^2 + V^2)^{1/2} \end{cases} \quad (1-4)$$

其中 ϕ 是方位角, β 是椭圆率角, 是偏振光短轴与长轴的比值, 决定了偏振度和方向。 $\beta < 0$ 和 $\beta > 0$ 分别代表左旋和右旋偏振。一般情况下, 多数自然光为部分偏振光, 其光强表达式为 $I^2 = I_{unpol}^2 + Q^2 + U^2 + V^2$, 其偏振度为 $P = (\frac{Q^2+U^2+V^2}{I^2})^{1/2}$ 。 Stokes 参数 IQUV 的量纲均为辐射强度, 易于使用仪器进行直接测量。磁场测量中通过磁分析器中偏振元件光轴方向的不同组合, 可以分离出各个参数进行测量。当一束光的 4 个 Stokes 参数给定后, 这束光便得到了确定, 其中 Q 和 U 描述线偏振光, V 描述圆偏振光。

由 Stokes 参数得到矢量磁场的过程称为磁场定标, 辐射转移方程是磁场定标的基础。辐射转移方程的发展经历了如下几个阶段: 1956 年 Unno 在假设磁场均匀, 谱线为吸收线以及吸收系数与连续谱吸收系数之比无关的条件下用唯象的方法得一组 Stokes 参数方程, 并求得 Stokes 轮廓, 该工作为天体磁场测量奠定了理论基础 (Unno, 1956); 1958 年, Stepanov 独立建立起一套比较严密的 Stokes 参数转移方程, 相比于之前的 Stokes 参数方程, Stepanov 在方程中包含了磁光效应 (反常色散); 1962 年, Rachkovsky 扩展了 Stepanov 的工作, 在假设局部热动平衡的条件下, 提供了一套更加经典、严密的转移方程; 1969 年, Beckers 在 Stokes 转移方程中考虑了矢量磁场、多普勒频移以及谱线吸收系数等物理参数随光深的变化, 建立起更合理的 Stokes 轮廓 (Beckers, 1969); 1988 年, Lites 以及 Jefferies 等人对 Stokes 辐射转移方程进行了更为细致的推导和描述 (Lites et al., 1988)。目前辐射转移的解析解和数值解已经逐步发展成熟, 各类反演程序和定标方法也应用而生, 为磁场的精确测量打下基础。Stokes 的辐射转移方程可以写为 (1-5):

$$\frac{dI_v}{d\tau_c} = (\eta + E)I_v - S_v \quad (1-5)$$

其中 τ_c 代表连续谱的光深, E 是 4×4 的单位矩阵。源函数 S_v 的表达式为 (1-6):

$$S_v = S_L \eta l + S_c l + j_{coh}/\kappa_c. \quad (1-6)$$

等式右边从左到右分别为 S_L 谱线的原函数, S_c 连续谱的原函数, j_{coh} 为相干散射

引起的发射。其中, $l = \begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \end{pmatrix}$, 谱线吸收矩阵的表达式为 $\eta = \begin{pmatrix} \eta_I & \eta_Q & \eta_U & \eta_V \\ \eta_Q & \eta_I & \rho_V & -\rho_U \\ \eta_U & -\rho_V & \eta_I & \rho_Q \\ \eta_V & \rho_U & -\rho_Q & \eta_I \end{pmatrix}$ 。

其中的具体元素含义由 (1-7) 给出。

$$\left\{ \begin{array}{l} \eta_I = 0.5[\eta_p \sin^2 \psi + 0.5(\eta_b + \eta_r)(1 + \cos^2 \psi)] \\ \eta_Q = 0.5[\eta_p - 0.5(\eta_b + \eta_r)] \sin^2 \psi \cos 2\phi \\ \eta_U = 0.5[\eta_p - 0.5(\eta_b + \eta_r)] \sin^2 \psi \sin 2\phi \\ \eta_V = 0.5(\eta_r - \eta_b) \cos \phi \\ \rho_Q = 0.5[\rho_p - 0.5(\rho_b + \rho_r)] \sin^2 \psi \cos 2\phi \\ \rho_U = 0.5[\rho_p - 0.5(\rho_b + \rho_r)] \sin^2 \psi \sin 2\phi \\ \rho_V = 0.5(\rho_r - \rho_b) \cos \phi \end{array} \right. \quad (1-7)$$

其中 (1-7), ψ 代表磁倾角, ϕ 代表方位角。如图 1-4 所示。 η_p 、 η_b 、 η_r 和 ρ_p 、 ρ_b 、 ρ_r 的表达式为 (1-8):

$$\left\{ \begin{array}{l} \eta_p = \eta_0 H(a, v) \\ \rho_p = 2\eta_0 F(a, v) \\ \eta_{b,r} = \eta_0 H(a, v \pm v_B) \\ \rho_{b,r} = 2\eta_0 F(a, v \pm v_B) \end{array} \right. \quad (1-8)$$

其中 η_0 为谱线吸收系数和连续谱吸收系数的比率; $F(a, v)$ 为 Faraday 函数, 用来描述反常色散 (磁光效应); $H(a, v)$ 为 Voigt 函数, 用来描写吸收效应。他们的数学表达式分别为 (1-9):

$$\left\{ \begin{array}{l} \eta_0 = \kappa_0 / \kappa_c \\ H(a, v) = \frac{a}{\pi} \int_{-\infty}^{+\infty} \frac{e^{-y^2}}{(v-y)^2 + a^2} dy \\ F(a, v) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \frac{(v-y)e^{-y^2}}{(v-y)^2 + a^2} dy \end{array} \right. \quad (1-9)$$

其中 $a = \frac{\Gamma \lambda_0^2}{4\pi c \Delta \lambda_D}$ 为阻尼系数, $v = \frac{\lambda - \lambda_0}{\Delta}$, v_B 为塞曼裂距。

描述矢量磁场需要三个参数, 即总磁场强度 B , 磁倾角 ψ , 方位角 ϕ , 如图 1-4 所示。

从太阳磁场测量设备的角度来分类, 基本上可以分为光谱型磁像仪和滤光器型磁像仪两种。光谱型磁像仪遍布世界各地, 比如美国萨克拉门托峰的 ASP (Advanced Stokes Polarimeter) (Elmore et al., 1992), 基特峰的 SOLIS (Synoptic Optical Long-term Investigations of the Sun) (Harvey et al., 2004), 法国意大利合作的 THEMIS 望远镜 (Mein, 2002), 瑞士的 ZIMPOL (Zurich Imaging Polarimeter) (Stenflo, 2007), 我国云南天文台的太阳 Stokes 光谱望远镜 (S^3T) (Qu et al., 2001), 日本的 Hinode/SP (Spectropolarimeter) 等。光谱型磁像仪可以获得高分辨率的偏振光谱, 从而得到较高精度的磁场, 进而获得观测对象的温度、速度、密度等丰富的物理信息, 便于研究太阳大气的三位结构, 但仅能获得沿着光谱仪狭缝方向的线缘信




图 1-4 矢量磁场的描述
Figure 1-4 Description of vector magnetic field

息。

滤光器型磁像仪也有很多台，比如马歇尔飞行中心 (Hagyard et al., 1982)、大熊湖天文台的向量磁像仪 (Zirin, 1985)、怀柔太阳观测基地太阳磁场望远镜 (艾国祥等, 1986)、SOHO 卫星上的 MDI(Michelson Doppler Imager)(Scherrer et al., 1995), Hinode 卫星上的 NFI(Tsuneta et al., 2008), 先进天基太阳天文台 ASO-S 卫星上的 FMG(Full-disk vector MagnetoGraph)(Deng et al., 2019)。滤光器磁像仪主要有望远系统、滤光系统、偏振分析系统组成。系统结构如图1-5所示。太阳光依次通过望远系统、滤光系统，经过偏振解调获得偏振像，最后通过磁场定标(或反演)的方式获得太阳磁场。不同滤光器型磁像仪之间的差别主要在于滤光系统，主要基于的类别有双折射滤光器，迈克尔逊干涉仪，法布里——珀罗干涉仪。滤光器型磁像仪特点在于面源成像，视场大，可以获得面源的 Stokes IQUV 像。




图 1-5 滤光器型磁像仪系统
Figure 1-5 filter-type magnetometer system

1.2 怀柔基地测量设备现状

怀柔太阳观测基地建站于1984年,位于北京怀柔水库北岸的一个小岛上(水库海拔64米,蓄水水域面积12平方公里)(王建民等,1977),现役主要观测设备有35cm太阳磁场望远镜和全日面太阳望远镜。其中多通道太阳望远镜是世界上具有领先水平的太阳望远镜系统之一,距离地面高度24米,由五个不同功能的望远镜组成,包括太阳磁场望远镜、三通道太阳望远镜、全日面矢量磁场和视向速度场望远镜、全日面 $H\alpha$ 望远镜、全日面 Ca 单色像望远镜。全日面望远镜包括全日面矢量磁场望远镜和全日面 $H\alpha$ 望远镜。多通道太阳磁场望远镜和全日面矢量磁场望远镜可以同时同地对太阳分别进行高分辨率局部磁场和全日面磁场进行测量。此外,怀柔基地还有位于冷湖的AIMS望远镜,空间的46.5nm极紫外太阳成像仪以及FMG全日面成像仪。其中,AIMS望远镜在中红外波段精确测量太阳磁场;46.5nm极紫外太阳成像仪工作在40-110nm波长范围,用于太阳过渡区探测;FMG是ASO-S空间望远镜上的载荷,工作在5324.19Å波段,在空间进行全日面磁场测量。

太阳磁场望远镜和全日面磁场望远镜均属于滤光器型磁像仪,太阳磁场望远镜能获得 $FeI5324.19\text{\AA}$ 波段的光球矢量磁场和视向速度场数据,还可以获得 $H\beta4861\text{\AA}$ 波段的色球视向磁场和视向速度场数据,具体参数如表1-1所示。

表 1-1 太阳磁场望远镜参数
Table 1-1 Solar magnetic field telescope parameters

项目	参数	
物镜	直径	350mm
	焦距	2800mm
观测谱线	光球	$FeI5324.09\text{\AA}$
	色球	$H\beta4861.34\text{\AA}$
	带宽	0.125Å
双折射滤光器	FeI 可调范围	$5324 \pm 0.12\text{\AA}$
	$H\beta$ 可调范围	$4861 \pm 0.98\text{\AA}$
灵敏度	纵场	$\pm 1 - 10G$
	横场	$\pm 30 - 50G$
速度纵场	$\pm 10 - 20m/s$	

全日面磁场望远镜于2005年年底投入运行使用,它在 $FeI5324.19\text{\AA}$ 谱线处通过观测偏振像来获得全日面矢量磁场。基于观测到的磁场对光球活动,特别是活动区的磁场演化展开研究。此外,该望远镜还为空间天气预报提供基础数据。全日面磁场望远镜的基本参数如表1-2所示。

1.2.1 怀柔基地磁场测量现状

对仪器的硬件以及其他指标进行定标后,目前工作状态下,磁场测量的定标主要涉及到波长定标,和磁场定标两个过程。

怀柔磁场望远镜和全日面磁场望远镜均属于滤光器型磁像仪,滤光器型磁像仪的系统如图1-5所示。这两台望远镜的滤光系统使用的是双折射窄带滤光器,

表 1-2 全日面太阳磁场望远镜参数
Table 1-2 Full solar magnetic field telescope parameters

项目	参数
工作谱线	$FeI5324.09\text{\AA}$
入瞳直径	100mm
有效视场	$2\omega = 33' \times 33'$
CCD 面阵	1K × 1K
滤光器透过波长半宽	0.125 \AA
纵场分辨率	优于 5G
横场分辨率	优于 150G
矢量磁图成像速度 (一组)	< 30min

双折射窄带滤光器工作在固定温度下 (HongQi Zhang, 2007; 苏江涛, 2004), 在夫琅禾费吸收线 $FeI5324.19\text{\AA}$ 偏离线心 -0.08\AA 处进行观测获得偏振信息, 然后通过定标过程获得太阳矢量磁场 (Yang Xiao, 2012; 白先勇, 2014)。 $FeI5324.19\text{\AA}$ 谱线等值宽度是 0.334\AA , 中心剩余强度是 0.1315 (中心剩余强度是指线心与线翼强度的比值, 比值越低, 吸收越强), 是一条较宽和较强的吸收线 (玄伟佳等, 2010; 艾国祥等, 1982; Gurtoenko E A, 1982)。在该线宽度内, 无其他谱线干扰, 谱线轮廓对称, Lande 因子 $g = 1.5$, 低激发电位为 $3.197eV$ 受到温度影响较小。该谱线在磁场中的主要特征:

1、强度 I 轮廓随磁场的变化较小, 当磁场强度 $H = 3000G$ 时, 由于 zeeman 分裂量小于 0.06\AA , I 轮廓也不出现明显分裂, 出现这种情况主要是由于谱线较宽, g 因子较小。

2、I 谱线轮廓斜率最大的位置约在距离线心 0.1\AA 附近, 同时该位置也是 Q、U、V 轮廓的极大位的位置。Q、U 在线心区域数值和同符号的范围相对较小, 若使用较宽的单色器观测横场, 为了获得较高灵敏度, 需要将透过带至于线翼处。

3、磁光效应对 Stokes 参数影响: 对 I、V 基本没有影响, 但是对 Q、U 影响很大。

4、 $FeI5324.19\text{\AA}$ 激发态能较高, 温敏不严重, 太阳温度对谱线轮廓影响相对较小。

常规观测下, 磁像仪在偏移线心 -0.08\AA 处进行观测。滤光器受到诸多因素的影响——最主要的为温度和机械误差 (比如齿隙)——观测谱线会发生相对漂移, 进而导致偏振信号减弱或消失, 直接影响影响到太阳矢量磁场测量的准确性和精确性。 $FeI5324.19\text{\AA}$ 谱线是一条吸收线, 在不同的波长点位置观测到的图像强度有差异, 可以根据这种强度差异来对谱线轮廓进行定标。常用的谱线定标方式是进行多项式拟合或者分段拟合 (Sánchez, 2006; A, 1605; 叶跟红等, 2013)。当前采用的波长点定标方法需要先进行观测谱线轮廓扫描, 进而完成工作谱线波长位置的定标。目前波长定标方案是从蓝翼 -0.3\AA 以 0.02\AA 的步长逐步移动滤光器透过带位置到红翼 $+0.03\text{\AA}$ 拍摄共 31 张图像, 然后通过拟合图像中心强度和对应波长点位置得到谱线轮廓, 进而获得线心位置, 如图 1-6 (线心位置 $\lambda_c = 0.171\text{\AA}$), 最后通过机械旋转波片使滤光器到工作谱线波长位置处进

行观测。




图 1-6 一组数据拟合得到的谱线轮廓

Figure 1-6 The spectral line profile obtained by fitting a set of data

从 Stokes 参数到磁场的过程称为磁场定标。滤光器型磁像仪由于缺少光谱信息，无法对观测目标辐射转移过程进行具体研究。从观测的 Stokes 参数得到矢量磁场需要采用弱场近似的假设，然后通过理论定标、观测定标、经验定标、非线性最小二乘拟合或交叉定标的方式得到线性定标系数。基于弱场近似假设的 Stokes 参数和磁场定标关系的过程如下：对辐射转移方程 (1-5) 中的吸收矩阵对角化处理，忽略磁光效应之后可以得到 (1-10)：

$$\begin{cases} I = I_+ + I_- \\ Q = (I_+ - I_-)\cos 2\beta \cos 2\phi \\ U = (I_+ - I_-)\cos 2\beta \sin 2\phi \\ V = (I_+ - I_-)\sin 2\beta \end{cases} \quad (1-10)$$

其中 I_+ 、 I_- 是关于 Q 、 U 、 V 的表达式，可以通过偏振分析器测量得到， β 是椭圆率角。忽略磁光效应，弱场近似满足多普勒宽度为单位的塞曼裂距 $B = \frac{\Delta\lambda_H}{\Delta\lambda_D} \ll 1$ ，对 Voigt 函数 $H(a, v)$ 进行泰勒展开：

$$H_{\pm} \approx H_0 \mp v_B \frac{\partial H_0}{\partial v} + \frac{1}{2} v_B^2 \frac{\partial^2 H_0}{\partial v^2} + \dots \quad (1-11)$$

定义 $h_1 = -v_B \frac{\partial H_0}{\partial v}$, $h_2 = -\frac{1}{4}v_B^2 \frac{\partial^2 H_0}{\partial v^2}$, 吸收矩阵 η 中的子项可以写为 (1-12)

$$\begin{cases} \eta_I \approx \eta_0 [H_0 - h_2(1 + \cos^2 \psi)] \\ \eta_Q \approx \eta_0 h_2 \sin^2 \psi \cos 2\phi \\ \eta_U \approx \eta_0 h_2 \sin^2 \psi \sin 2\phi \\ \eta_v \approx \eta_0 h_1 \cos \psi. \end{cases} \quad (1-12)$$

吸收矩阵为 (1-13):

$$\eta/\eta_0 \approx [H_0 - h_2(1 + \cos \psi)]E + \sin^2 \psi \begin{pmatrix} 0 & h_2 \cos 2\phi & h_2 \sin 2\phi & 0 \\ h_2 \cos 2\phi & 0 & 0 & 0 \\ h_2 \sin 2\phi & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} + \cos \psi \begin{pmatrix} 0 & 0 & 0 & h_1 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ h_1 & 0 & 0 & 0 \end{pmatrix} \quad (1-13)$$

其中 (1-13)的第二项代表横向塞曼效应, 正比于 $B_{\perp}^2 = B^2 \sin^2 \psi$; 第三项代表纵向塞曼效应, 正比于 $B_{\parallel} = B \cos \psi$ 。定义

$$\eta_{\pm} \approx \eta_I \pm \sqrt{\eta_Q^2 + \eta_V^2 + \eta_U^2} \quad (1-14)$$

线偏振信号远小于圆偏振信号, 即 $\sin 2\beta \approx 1$, 将 $\eta_{\pm} \approx \eta_I \pm \eta_V$ 代入式 (1-12) 可得:

$$\eta_{\pm} \approx \eta_0 \left[H_0 \mp v_B \cos \psi \frac{\partial H_0}{\partial v} \right] \approx \eta_0 H(a, v \mp v_B \cos \psi) \quad (1-15)$$

η_{\pm} 和 I_{\pm} 相关, 类比得到 $I_{\pm}(\Delta\lambda) \approx I_0(\Delta\lambda \mp \Delta\lambda_H \cos \psi)$, 带入式 (1-10) 可得:

$$\begin{cases} I = I_+ + I_- \approx 2I_0 \\ V \approx I_+ - I_- \approx -v_B \cos \psi \frac{\partial I}{\partial v} \end{cases} \quad (1-16)$$

对于 StokesQ 和 V,

$$\begin{cases} Q \approx (I_+ - I_-) \cos 2\beta \cos 2\phi \approx V \sqrt{\eta_Q^2 + \eta_U^2} / \eta_V \\ U \approx (I_+ - I_-) \cos 2\beta \sin 2\phi \approx V \sqrt{\eta_Q^2 + \eta_U^2} / \eta_V \end{cases} \quad (1-17)$$

带入式 (1-16) 可得:

$$\begin{cases} Q \approx -v_B \sin^2 \psi \cos 2\phi \frac{h_2}{h_1} \frac{\partial I}{\partial v} \\ U \approx -v_B \sin^2 \psi \sin 2\phi \frac{h_2}{h_1} \frac{\partial I}{\partial v} \end{cases} \quad (1-18)$$

因为 $h_1 = -v_B \frac{\partial H_0}{\partial v}$, $h_2 = -\frac{1}{4} v_B^2 \frac{\partial^2 H_0}{\partial v^2}$, 故有:

$$\begin{cases} Q \approx -\left(\frac{v_B \sin \psi}{2}\right)^2 \cos 2\phi \frac{\frac{\partial^2 H_0}{\partial v^2}}{\frac{\partial H_0}{\partial v}} \frac{\partial I}{\partial v} \\ U \approx -\left(\frac{v_B \sin \psi}{2}\right)^2 \sin 2\phi \frac{\frac{\partial^2 H_0}{\partial v^2}}{\frac{\partial H_0}{\partial v}} \frac{\partial I}{\partial v} \end{cases} \quad (1-19)$$

对于弱的吸收线 $\frac{\partial^2 H_0}{\partial v^2} \sim \frac{\partial^2 I}{\partial v^2}$, $\frac{\partial H_0}{\partial v} \sim \frac{\partial I}{\partial v}$ 得到:

$$\begin{cases} Q \approx -\left(\frac{v_B \sin \psi}{2}\right)^2 \cos 2\phi \frac{\partial^2 I}{\partial v^2} \\ U \approx -\left(\frac{v_B \sin \psi}{2}\right)^2 \sin 2\phi \frac{\partial^2 I}{\partial v^2} \end{cases} \quad (1-20)$$

参考 (1-16) 和 (1-20), 对于纵场和横场, 并考虑方位角, 可得弱场近似下的定标关系:

$$\begin{cases} B_l = B \cos \psi \propto -V \left(\frac{\partial I}{\partial v}\right)^{-1} \\ B_t = B \sin \psi \propto (Q^2 + U^2)^{1/4} \left(\frac{\partial^2 I}{\partial v^2}\right)^{-1/2} \\ \phi = 0.5 \tan^{-1}(U/Q). \end{cases} \quad (1-21)$$

用定标系数可以将上式写为:

$$\begin{cases} B_l = C_l V \\ B_t = C_t (Q^2 + U^2)^{1/4} \\ \phi = 0.5 \tan^{-1}(U/Q) \end{cases} \quad (1-22)$$

磁场用横场 B_t , 纵场 B_l , 方位角 ϕ 来描述与式 (1-22) 的相互转换关系如式 (1-23):

$$\begin{cases} B_l = B \cdot \cos(\psi) \\ B_t = B \cdot \sin(\psi) \\ \phi = \phi \end{cases} \quad (1-23)$$

基于弱场近似的磁场定标最终归结为计算纵场和横场的定标系数 C_l 和 C_t 。

观测过程中, 太阳磁场望远镜采用了对太阳活动课题观测和常规观测资料长时间积累的两种主要运行方式, 全日面磁场望远镜采用多点观测和单点观测

相结合的方式，一般情况下采用单点观测——在固定波长点下观测的方式。获得 Stokes 参数测量太阳磁场的主要获取步骤是望远镜通过望远系统、偏振解调系统后获得的图像分别被解析成 $0.5(I \pm Q)$ 、 $0.5(I \pm U)$ 、 $0.5(I \pm V)$ ，进而获得 Stokes I、Q、U、V 图像信息。然后通过线性定标的方式获得磁场（横场 B_t ，纵场 B_l ，方位角 ϕ ），线性定标采用公式 (1-22) 来计算。其中，偏振解调系统是将滤光器获得的图像信息解析成可测量的 Stokes 参数的关键，偏振分析器是偏振解调系统的核心器件。偏振分析器主要包括 $1/4$ 波片 ($\frac{\lambda}{4}$)，KD*P 晶体调制器以及光轴方位角为 0° 的偏振片组成。其中，偏振分析器的光轴方位角为 θ ，KD*P 晶体调制器由不断变化的电压控制，对其相位进行延迟（迟为 σ ），光轴方位角为 45° ，其结构见图 1-7。磁场测量时，各个偏振元件的工作状态见表 1-3。偏振




图 1-7 偏振分析器
Figure 1-7 Polarization analyzer

表 1-3 KD*P 调制方案的偏振原件工作状态
Table 1-3 The working state of polarization elements in KD*P modulation scheme

Stokes 参数	1/4 光轴 θ	KD*P 延迟 σ	P
+Q	45°	-90°	0°
-Q	45°	90°	0°
+U	0°	90°	0°
+Q	0°	-90°	0°
+Q	—	90°	0°
+Q	—	-90°	0°

分析器对偏振光的作用可以用 Mueller 矩阵来描述 (1-24):

$$\begin{aligned}
 S &= \begin{pmatrix} \frac{1}{2} & \frac{1}{2} & 0 & 0 \\ \frac{1}{2} & \frac{1}{2} & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \times \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos \sigma & 0 & \sin \sigma \\ 0 & 0 & 1 & 0 \\ 0 & \sin \sigma & 0 & \cos \sigma \end{pmatrix} \times \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos^2 2\theta & \frac{1}{4} \sin^2 4\theta & -\sin^2 \theta \\ 0 & \frac{1}{4} \sin^2 4\theta & \sin^2 2\theta & \cos^2 2\theta \\ 0 & \sin^2 2\theta & -\cos^2 2\theta & 0 \end{pmatrix} \times \begin{pmatrix} I \\ Q \\ U \\ V \end{pmatrix} \\
 &= 0.5I + 0.5Q(\cos \sigma \cos^2 2\theta - \sin \sigma \sin 2\theta) + 0.5U\left(\frac{1}{4} \cos \sigma \sin^2 4\theta + \sin \sigma \cos^2 2\theta\right) \\
 &\quad - 0.5V \sin^2 2\theta \cos \sigma \tag{1-24}
 \end{aligned}$$

其中 θ 为波片方位角, σ 为 KD*P 加高压引起的相角延迟。工作时, σ 取 0.1 周矩形 $\pm \frac{1}{4}$ 波长调制, 即 σ 分别取 $\frac{\pi}{2}$ 和 $-\frac{\pi}{2}$ 调制。Stokes 参数 V、U、Q 的获得过程如下:

1、去掉 1/4 波片时, 式 (1-24) 变为: $S_{\pm} = 0.5(I \mp V)$, 可得与纵场相关的 Stokes 参数 V, $V = S_- - S_+$ 。

2、当 1/4 波片位于方位角 $\vartheta = 0^\circ$ 时, $S_{\pm} = 0.5(I \pm U)$, 可得到与横场相关的 Stokes 参数 U, $U = S_+ - S_-$ 。

3、当 1/4 波片位于方位角 $\vartheta = 45^\circ$ 时, $S_{\pm} = 0.5(I \mp Q)$, 可得到另外一个与横场有关的 Stokes 参数 Q, $Q = S_- - S_+$ 。

在实际观测中, 为了提高信噪比, 采用多帧短曝光图像叠加的方法, 并对 Stokes 参数进行归一化, 具体计算如式所示 (1-25):

$$\begin{cases} \frac{I_Q}{I} = \frac{1}{N} \sum \frac{I_{+Q} - I_{-Q}}{I_{+Q} + I_{-Q}} \\ \frac{I_U}{I} = \frac{1}{N} \sum \frac{I_{+U} - I_{-U}}{I_{+U} + I_{-U}} \\ \frac{I_V}{I} = \frac{1}{N} \sum \frac{I_{+V} - I_{-V}}{I_{+V} + I_{-V}} \end{cases} \tag{1-25}$$

其中 I_{+Q} 、 I_{-Q} 分别表示经过偏振分析器后解析得到的图像, 关于 U、V 的表达式同理, 经过偏振分析器得到的图像以及由该图像获得 Q、U、V 信号图像见图 1-8。




图 1-8 经过偏振分析器后得到的图像以及解析后的 Stokes 图像

Figure 1-8 Images obtained after polarization analyzer and Stokes images after analysis

1.3 基于机器学习的高精度磁场测量

1.3.1 当前磁场测量可改进的空间

全日面太阳望远镜使用的通过扫描谱线获得观测位置的这种波长定标方法具有较高的准确率，但并不是完美的解决方案。首先，现有的定标方式需要移动滤光器逐一拍摄 31 张图像来进行定标，这种方式花费了较多的时间，因此减少了观测数据的数量和时间分辨率。同时，现有的波长点定标方法也无法形成一个对工作谱线波长位置进行判断和控制的实时闭环系统，因此无法实时确定工作谱线波长位置的准确性。此外，频繁的机械旋转导致滤光器寿命降低，进一步影响稳定高质量磁场数据的获取。

磁场的测量本质上是偏振测量，望远镜通过滤光系统获得单色像后，经过一些列预处理（平暗场改正、偏振解调和偏振定标）的到偏振图像（Stokes I, Q, U, V 图像），然后通过磁场定标（或反演）的方法将偏振图像转化为矢量磁场，这是滤光器型磁像仪从观测数据转化为物理参数的关键。传统的磁场定标（反演）的方式是基于太阳大气辐射转移模型发展起来的，已经较为成熟，但其中仍然存在着固有缺陷。

从偏振图像到矢量磁图的反演过程中，需要获得目标谱线的 Stokes 光谱轮廓（多个波长点），然后基于偏振辐射转移方程的解析解（或者数值解），通过最小二乘拟合这一轮廓来获得相应的磁场参数。反演方法目前认为是最佳的获取磁场的方法，但对硬件设备有很高要求，且很难获得高时间分辨率的磁图。

针对滤光器型磁像仪，先需要进行少量的偏振光谱扫描观测并反演磁场，建立一个特定波长点的 Stokes 参数和光谱反演磁图之间的数学关系，即磁场定标关系。常规观测只在这个特定波长点处进行观测，这种单点观测模式相对简单，且可以获得高时间分辨率磁场，但是面临一个主要难题：弱场近似下，采用线性定标的方式获得的磁场在强磁场区域存在磁饱和效应。太阳矢量磁场纵场磁饱和效应见图 1-9， V_{HR} 为怀柔单点观测的 Stokes 参数 V 信号，线性定标下纵场和 V 信号关系为线性关系， BI_{HMI} 为 HMI 通过多点观测图像反演得到的纵场。可以看出，在磁场强度应该高的地方，单点观测获得的 V 信号存在不升反降得情况，而在反演获得得 HMI 图像中则没有，该现象则称为磁饱和效应。

如何同时获得更高时间分辨率、更高精度的磁场是目前急需解决的问题。目前徐海清等人使用最小二乘法对活动区的磁饱和效应进行了改正 (Xu et al., 2021)；也有使用机器学习解决磁场定标中存在的问题进行探索。比如郭晶晶等人使用对单波长点观测带来的磁饱和效应进行了探索，验证了可以使用机器学习的方法解决单点观测中存在磁饱和效应等不足 (Jingjing Guo, 2020)；胡子尧等人对空间的设备进行单点观测磁场定标，将轨道速度考虑在内进行了波长漂移下的磁饱和效应改正探索 (Hu et al., 2022)。但这些工作全部基于同一个设备，且有成熟的磁场观测数据。如何使用机器学习的方法解决现有观测方式中存在的不足，全方位提高磁场测量精度，是一个十分值得研究的方向。

怀柔基地运行多年以来，优良的观测资料、开放的管理模式、良好的科学研

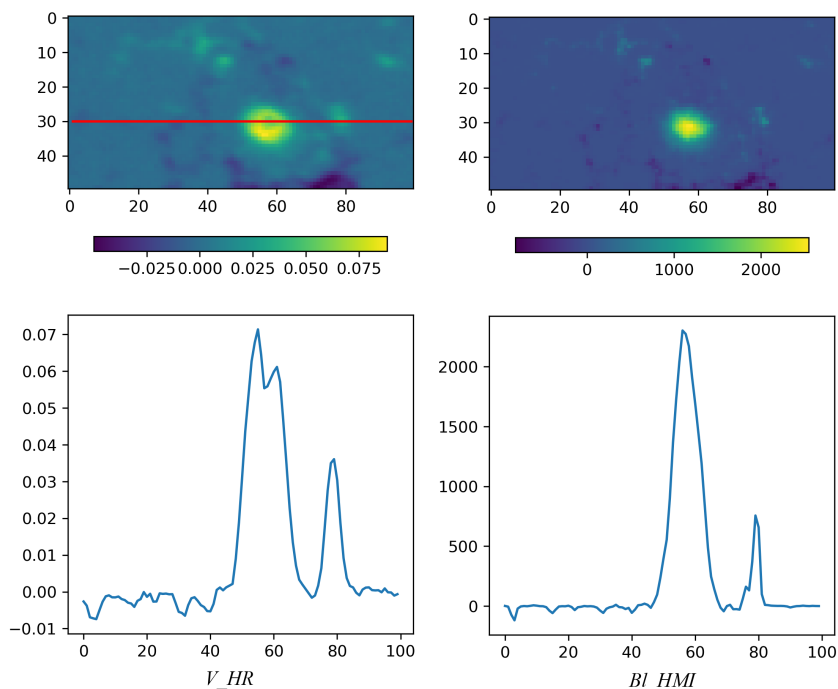


图 1-9 纵场磁饱和效应
Figure 1-9 Longitudinal magnetic field saturation effect

究环境，取得了许多重要的研究成果。怀柔太阳观测基地拥有近 40 年的太阳磁场观测资料，这是目前世界上单台仪器持续时间最长的太阳磁场观测数据集。在太阳磁场速度场形态演化、磁场非势特征与太阳活动、太阳电流螺度与磁螺度观测、小尺度磁场及内禀性质和基于矢量磁场观测的三维外推等方向涌现出一大批重要的研究成果。目前怀柔基地已经积累了连续三十多年的太阳观测数据，这种对太阳长周期的连续观测数据的积累在世界上是独一无二的。如何从历史数据中获取更多的信息并将研究成果用于高精度磁场测量，是一个亟需开展的工作。

针对上面存在的问题，本文尝试从工作谱线波长位置稳定性、磁场定标准确性、长周期历史数据的应用结合高质量数据遴选发布三个方面进行研究。对目前工作谱线波长位置定标存在的耗时、影响磁场测量准确性的问题进行解决，研究一套快速高效的工作谱线波长位置定标方案。对目前磁场定标——线性定标存在的磁饱和效应等问题进行研究，提出一套高精度、高时间分辨率的定标方案。对长周期历史数据进行挖掘研究，对怀柔基地历史视宁度估算，并基于此给出一种历史数据遴选的方法。

1.3.2 机器学习在天文领域的应用

机器学习是一种实现人工智能的方法，可以从数据中学习隐含的模式并建立模型，主要用于解决难以用普通规则描述的问题。作为人工智能的核心，机器学习这一概念最早由 Arthur Samuel 于 1959 年提出，区别于传统的数学推导算法，

机器学习借助于计算机从数据中寻找关系，从而建立数据与数据之间的特殊映射关系，基于此关系对相似的问题进行预测。机器学习的出现，使得计算机拥有“自主思考”能力的基础。机器学习不仅改变着人们的生活方式，也改变着人们的工作方式。比如 2019 年，人工智能研究人员给神经网络输入了在地球上观测的火星和太阳运动的数据，大约只花了一天的时间，人工智能就准确得出了和哥白尼“日心说”一样的结论——太阳才是太阳系的中心。

机器学习基于数据进行训练，然后构建可预测的模型。根据数据训练方式的不同，机器学习可以分为监督学习、无监督学习和强化学习三种类型。监督学习是借助数据以及对应的标签进行网络训练，通过梯度下降的算法不断优化网络的输出和标签的差距，得到误差范围内的模型，该模型对没有标签的数据进行预测。监督学习算法是分析该训练数据，并产生一个推断的功能，其可以用于映射出新的实例。常见的算法框架包括 KNN、决策树、朴素贝叶斯、分类以及回归等。从评估的难以来看，由于监督学习目标明确，所以容易衡量其模型的训练效果。对预测结果和实际结果的衡量方式上，常见的衡量方式有均方误差 (Mean squared error, MSE)、平均绝对误差 (Mean absolute error, MAE)、相关系数 R 等。无监督学习是与有监督学习像对应的一种学习方式，旨在解决“聚类”和“降维”问题。无监督学习不需要带有标签的数据，无法量化效果如何。常见的无监督学习算法有 k-means、主成分分析 (Principal Component Analysis, PCA) 等。强化学习 (Reinforcement Learning, 简称 RL) 是机器学习的一个重要分支，它主要研究在没有明确指示的情况下，智能体 (agent) 应如何通过尝试和错误来发现在特定环境中获得最大累积奖励的行为策略。强化学习被广泛应用于各种领域，包括游戏、机器人导航、资源管理、推荐系统等。它是一个活跃的研究领域，并且随着深度学习等技术的发展，强化学习在解决复杂问题上展现出巨大的潜力。

天文学家从 20 世纪 90 年代起便开始探索使用机器学习方法，当时使用方法名称多与“统计”有关，2004 年逐步形成规模，2012 年之后迎来热潮。众多研究表明，在许多特定任务上机器学习优于传统的依靠人工或规则编程的方法，获得了接近甚至超越人类专家的表现，具有广阔的应用前景。近年来，由于大数据、高性能计算机和神经网络训练技术的突破，深度学习得到了快速的发展。在天文领域，也正在进入大数据时代，机器学习作为一种有效的工具，可以从大数据中共提取相关的信息，提供了一种可以使用判别模型直接从数据中学习的可能性。机器学习在天文领域已经有了很广泛的应用，自 2014 年起，天文学领域就出现了很多应用深度学习机器学习进行数据分析处理的论文，并逐年增加。根据不同的天文数据类型和研究方向，天文中机器学习任务主要包括：目标监测和分类、参数估计、时序数据分析、数据降噪和生成等。代表性应用主要有：引力波探测、系外行星搜索、强引力透镜识别和参数测量、星系形态分类、测光红移估计、暂现源检测、光谱分类和参数估计等。比如使用机器学习方法对 LMOST 望远镜的工作稳定性和行能进行检测 (Hu et al., 2020)；Gorge 和 Huerta 使用深度卷积神经网络应用于引力波的时间序列数据，快速检测引力波信号；Pearson

等人利用模拟时序数据训练深度卷积神经网络，从中学习类地系外行星的测光特征。机器学习方法已经在天文领域的很多方面都有了应用，为处理海量天文数据、解释和挖掘未知天体和物理特性提供了新的解决思路和方案。

在太阳物理领域机器学习应用逐年增多且发展迅速，2010年 Yuan 等人使用1996-2005年地230个SOHO/MDI活动区磁图借助SVM和LR相结合的方式对太阳耀斑进行预报 (Yuan et al., 2010); 同年, Henwood 等人1959-1964年格林尼治天文台的光球数据(GPR)用ANN对长周期(>20d)复发黑子群进行识别, 训练好的网络模型具有良好的迁移能力 (Henwood et al., 2010); 2012年 Byrne 等人使用SOHO/LASCO和STEREO/SECCHI图像以及数值模拟的CME图像利用多尺度小波变换, 特征匹配的方法进行CME检测和跟踪 (Byrne et al., 2012); 2015年 Bobra 和 Coudinat 用2010-2014年的2071个SDO/HMI活动区磁图, 从25个参数中选取了对预测影响值最高的13个参数进行48h预报 (Bobra et al., 2015); 同年, Boucheron 等人使用2000-2010年的2125个活动区SDO/MDI磁图, 基于38个磁图特征对耀斑尺寸和时间演化进行了回归预测 (Boucheron et al., 2015); 2017年, Zhang 等人使用SOHO/LASCO C2的图像, 基于ELM进行CME检测并结合空间和时间连续性排除误判区域 (Zhang et al., 2017); 2017年 Liu 等人用2010-2016年的845个活动区的SDO/HMI磁图, 借助随机森林方法提取了13个太阳活动区特征 (Liu et al., 2017); 2018年 Florios 等人使用2012-2016年地23134和SDO/HMI的活动取数据对MLP、SVM、RF三种方法进行了预报比较 (Florios et al., 2018); 2018年 Huang 等人对1996年2015年的SOHO/MDI、SDO/HMI的磁图和强度像使用CNN进行太阳耀斑预报 (Huang et al., 2018); 2020年 Guo 等人使用机器学习的方法对磁饱和效应的解决进行了探索 (Jingjing Guo, 2020); 2024年 Grim 等人使用transformer对耀斑进行了预测 (Grim et al., 2024)。从astrophysics data system上以关键词“deep learning or machine learning (solar)”进行文献检索, 从统计结果可以得到对于机器学习在天文领域和太阳领域的文献逐年增长, 如图1-10所示:

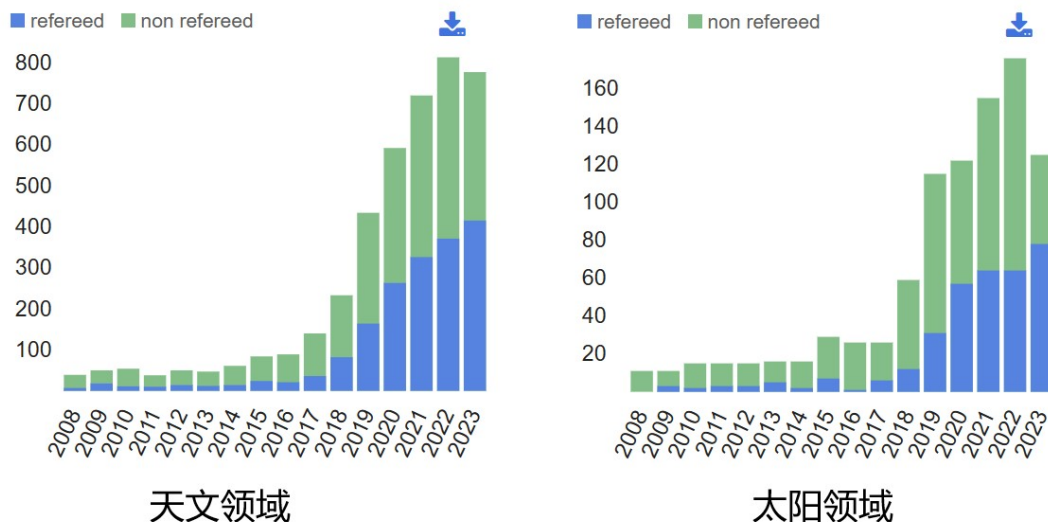


图 1-10 机器学习在天文领域和太阳领域的应用趋势

Figure 1-10 Trends in the application of machine learning in astronomy and the solar field

1.4 主要研究内容

至此，本章已经将太阳磁场测量的相关背景进行了介绍，并对怀柔基地磁场测量设备以及磁场测量现状进行了介绍。本文的研究目的是从滤光器型磁像仪磁场测量入手，以怀柔基地磁场测量设备和测量方式为研究对象，对高精度的磁场测量方法展开研究。基于上述研究目的，本文研究内容包括提升工作谱线波长位置稳定性、磁场定标准确性、历史数据挖掘及高质量数据遴选三个主要方面。首先从波带稳定性的角度出发，对谱线扫描数据中不同波长点处图像特征进行研究，基于此对图像数据的进一步处理展开研究，然后使用机器学习的方法建立起观测图像和对应观测点之间的关系。对传统方法和机器学习方法进行时间上的对比，说明机器学习方法的快速高效。其次从磁场定标准确性的角度出发，对怀柔全日面磁场望远镜的全日面图像和 HMI 观测到的图像进行研究，该部分主要包括怀柔数据和 HMI 数据的对齐，预处理等方法，最后以 HMI 数据作为标签，建立网络进行训练。解决线性定标中，存在的磁饱和效应问题。最后从历史视宁度估算的角度对怀柔基地历史数据的挖掘展开研究，首先分析图像和视宁度之间的关系，使用观测到的数据建立起图像和视宁度之间的关系。然后对图像进行预处理，最后搭建神经网络建立起图像和视宁度之间的直接关系，并提基于视宁度值对图像数据进行遴选的方法。

本文的研究内容主要通过以下几个章节展开：

第二章从波带稳定性展开研究，对谱线扫描数据中不同观测点处的图像特征进行分析，介绍图像的预处理方法，并对机器学习进行波长定标的方法展开介绍。对实验的结果进行讨论和分析。第三章从磁场高精度定标展开研究，介绍跨设备的磁场定标方案中数据预处理算法，基于此对机器学习的方法展开介绍。最后对机器学习方案下实验结果进行展示，对机器学习方法对解决磁饱和效应这

一方案进行阐述。第四章从历史视宁度数据的应用挖掘入手，估算台址的历史视宁度数据，进而提出可以用此方法为数据高质量的快速发布提供参考方案。第五章对本工作进行总结和讨论，从磁场测量中涉及到的两个关键步骤——波带稳定性，定标稳定性，以及获取到数据挖掘应用和快速高质量的发布站开讨论，并对本工作的扩展应用以及不足之处进行分析说明，进而提出下一步的工作计划。

第2章 快速高效工作谱线波长位置定标研究

滤光器型磁像仪是太阳磁场测量的一种仪器，其工作原理主要是基于塞曼效应，塞曼效应即谱线在磁场中分裂，进而产生偏振光谱信号。滤光器型磁像仪利用这一现象来测量太阳磁场的分量。滤光器型磁像仪通过一个双折射滤光器选择太阳光谱中的特定谱线，如光球磁场测量时选择的 $\text{FeI}5324.19\text{\AA}$ ，色球磁场测量时选择的 $\text{Na}5896\text{\AA}$ 、 $\text{Mg}5173\text{\AA}$ 等。选好谱线后，通过光学偏振系统获得偏振态的 Stokes 参量 I、Q、U、V。滤光器可以在谱线的不同波长位置进行观测以获得该位置的偏振信息，但由于受到温度、机械误差等因素的影响，观测的谱线发生漂移。因此，需要在观测前进行工作谱线波长位置定标。本章使用机器学习的方法对怀柔基地全日面磁场望远镜的工作谱线波长位置定标展开研究，并与目前正在使用的方法进行对比，探索一种高效的工作谱线波长位置定标方案。

2.1 数据分析以及预处理

2.1.1 数据来源

工作谱线波长位置标定的数据来自怀柔太阳观测基地全日面太阳矢量磁像仪，该磁像仪于 2005 年年底投入运行使用，它的主要任务是通过观测偏振像来获得全日面矢量磁场，对光球活动，特别是活动区的磁场演化展开研究(艾国祥等, 1986; 林佳本, 2009)。此外，该磁像仪还为空间天气预报提供基础数据。

在第一章中已经提到，全日面太阳矢量磁像仪首先进行工作谱线波长位置定标，然后在谱线偏离线心-0.08 处进行观测(白先勇, 2014)，然后通过定标的方式获得磁场(HongQi Zhang, 2007; 苏江涛, 2004; Yang Xiao, 2012)。因此，全日面太阳矢量磁像仪的日常观测数据主要分为谱线扫描数据和常规观测数据。谱线扫描数据包含了 31 帧解析的图像，即 $0.5(I \pm V)$ ，这些图像用于谱线定标，如图 1-6 所示。常规观测的图像数据主要包含了 $0.5(I \pm Q)$ ， $0.5(I \pm U)$ ， $0.5(I \pm V)$ ，该部分数据用于对磁场进行定标。

本文挑选了全日面太阳矢量磁像仪 2018 年和 2019 年的谱线扫描数据进行实验，全波段数据一共 206 组（每组 31 张图像，共 6368 张图）。数据分配上，取 70% 作为训练集，30% 作为测试集，在训练集中取 15% 作为验证集。方法验证中，将所有数据打乱顺序随机分配。此外，在研究系统稳定性对算法的影响时，由于滤光器和电机的变化是影响系统的主要因素，本文将滤光器和电机的维修时间作为分界点来选取数据进行实验，将以上数据重新分配为 5 组，每组取 70% 作为训练集，30% 作为测试集，在训练集中取 15% 作为验证集，对每组进行相同的实验。最后针对系统偶尔维修需要重新训练网络的问题，进行了克服系统变化实验，实验中使用更窄波带范围数据进行网络训练和测试，数据分配和前两组一致。

2.1.2 数据预处理

为了排除问题研究过程中不必要的干扰因素，首先需要对数据进行筛选。我们选取可以拟合出光滑谱线轮廓的数据，光滑谱线轮廓如图 1-6所示，非光滑或者拟合错误的谱线轮廓如图 2-1所示。同时，通过剔除亮度饱和的数据。为了进一步减小系统观测谱线轮廓的误差，结合 2018 2019 年观测时间段内观测经验，选取的数据需要满足其拟合出的线心位置处于 0.16 ± 0.04 之间。

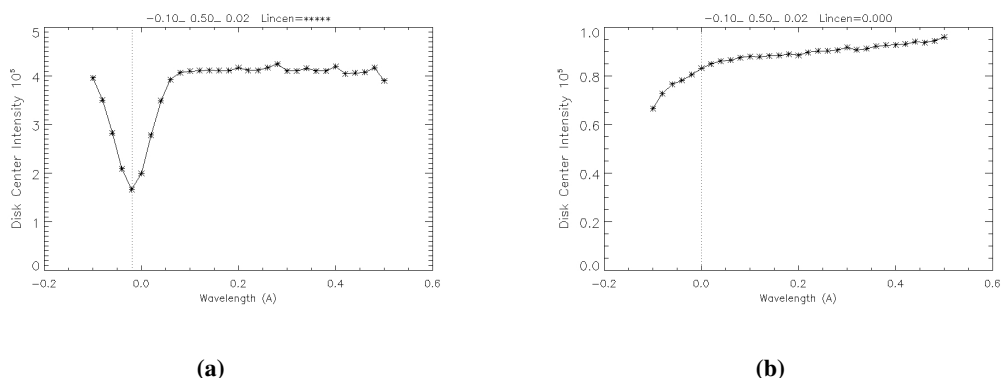


图 2-1 非光滑或者拟合错误的谱线

Figure 2-1 Non smooth or incorrectly fitted spectral lines

对于 5324.19\AA 谱线观测到的太阳光球像而言，观测到的太阳像在空间位置上主要有三种特征：首先是大尺度特征，包括临边昏暗轮廓和太阳自转等因素导致的波长漂移。从图 2-2(a) 的太阳白光照片上可以看到太阳边缘部分比中心部分稍暗，这就是临边昏暗现象，用可见光和红外连续谱区中的单色光观测太阳，均会出现临边昏暗现象。此外，在地面观测时，太阳自西向东自转产生对地的多普勒速度，从观测到的图像上来说，这种多普勒速度导致图像强度的变化，对图像的影响表现出大尺度灰度分布不均匀（呈现为一边亮一边暗）的特点，如图 2-4d(c)(d) 所示。其次是中等空间尺度的特征，主要包括黑子、谱斑等；此外还有小空间尺度的特征，如针状体、米粒等 (白先勇 等, 2018)。三种太阳尺度特征分别如图 2-2(a)(b)(c) 所示。




图 2-2 太阳光球不同尺度特征

Figure 2-2 Different scale characteristics of the solar photosphere

当滤光器逐步从谱线蓝翼到红翼不同工作谱线波长位置处拍摄图像时，受多普勒速度的影响，图像随着拍摄位置由左亮右暗逐步变化到左暗右亮。谱线不同点上太阳自转的多普勒速度对图像的效应如图 2-3 所示




图 2-3 太阳自转引起的多普勒速度对单色像的影响

Figure 2-3 The influence of Doppler velocity caused by solar rotation on monochromatic images

由多普勒速度所引起的大尺度图像差异体现了图像对应的不同工作谱线波长位置，而临边昏暗同样作为大尺度的特征不具有明显的区分性，是一种干扰信息，而且会叠加在这种特征上如图 2-2(a) 和 2-4(a)(b)。因此，在数据预处理时，需要去除临边昏暗。

临边昏暗效应可以用式 (2-1) 来表示：

$$F_{\lambda} = \frac{I_{\lambda}(0, \theta)}{I_{\lambda}(0, 0)} \quad (2-1)$$

其中 θ 为日心角， $I_{\lambda}(0, 0)$ 表示日面中心的辐射强度， $I_{\lambda}(0, \theta)$ 表示日心角 θ 处的辐射强度。可以假设 F_{λ} 为 $\cos\theta$ 的二阶函数形式。

$$\frac{I_{\lambda}(0, \theta)}{I_{\lambda}(0, 0)} = A_{\lambda} + B_{\lambda} \cos\theta + C_{\lambda} \cos^2\theta \quad (2-2)$$

其中 A 、 B 、 C 为待定系数。由于图像中的 $I_{\lambda}(0, \theta)$ 和 θ 是已知的，因此通过最小二乘法即可求得 A 、 B 、 C 的值，从而得到临边昏暗图像。通过观测图像除以临边昏暗图像即可去除临边昏暗。

对去除临边昏暗后的数据进行归一化，归一化采用图像除以自身中心强度

的方式来完成。完成处理后的数据如图 2-4(c)(d) 所示，图 2-4 中用日面纬度 0 纬度（中红线标识）的数据来展示图像的亮暗变化，图像对应的波长标注在本图上方。可以看出，做完临边昏暗和数据归一化后，不同工作谱线波长位置的图像大尺度差异变得非常明显：从蓝翼到红翼，图像由左亮右暗逐步变化到左暗右亮。数据预处理前后对比如图 2-4 所示

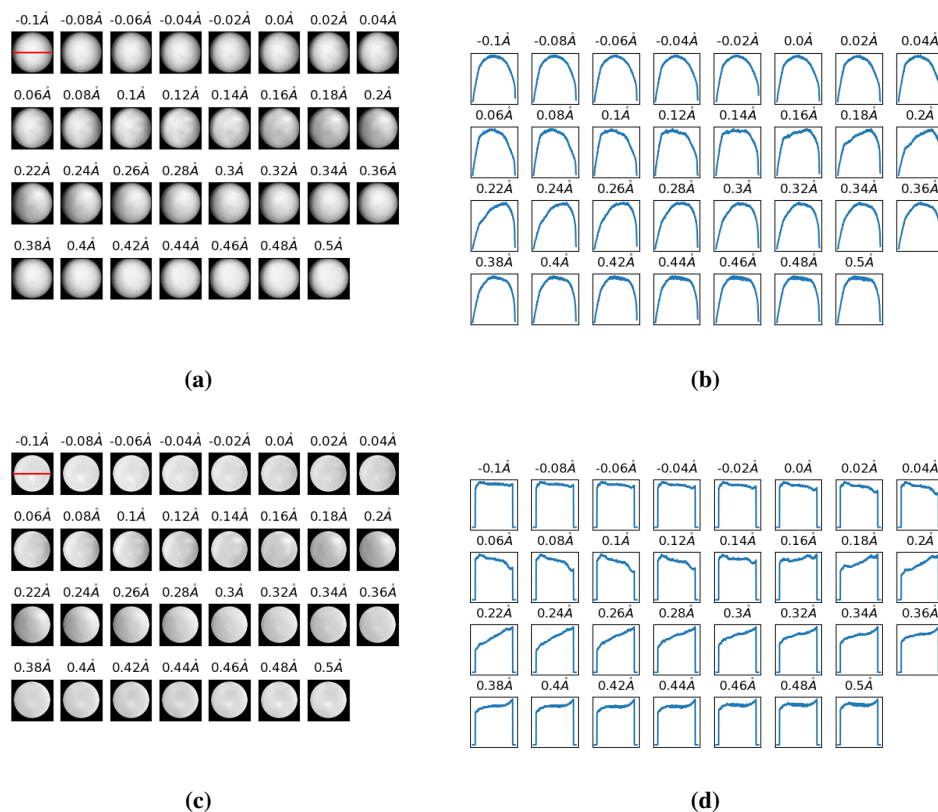


图 2-4 数据处理前后的对比。(a) 原始图像；(b) 原图像的灰度变化图；(c) 去除临边昏暗后图像；(d) 去除临边昏暗后的灰度变化图

Figure 2-4 Comparison before and after data processing (a) Original image; (b) grayscale change image of the original image; (c) image after solar limb darkening is removed; (d) grayscale change image after solar limb darkening is removed

日面外的数据是一种无效信息。本文使用极坐标转换的方式去除日面外信息，将日面看作圆，取极坐标的初始射线为正 x 轴，射线 $\theta = \frac{\pi}{2}, r > 0$ ，如图 2-5 所示：通过公式 (2-3) 即可相互转化

$$\begin{cases} x = r \cos \theta, y = r \sin \theta \\ x^2 + y^2 = r^2, \frac{y}{x} = \tan \theta \end{cases} \quad (2-3)$$

实际操作过程中，在进行极坐标转换运算的同时，对图像进行降采样来缩小图像，以此保留大尺度信息的同时减小运算量。完成极坐标转换后，图像由 $992\text{pixel} \times 992\text{pixel}$ 变为 $45\text{pixel} \times 50\text{pixel}$ ，如图 2-6(b) 所示，其中 45pixel 是角度方向， 50pixel 是半径方向。在半径方向取 122pixel 保留日面部分数据，如




图 2-5 极坐标和直角坐标转换

Figure 2-5 Polar and Cartesian Coordinate Conversion

图 2-6(c) 所示。

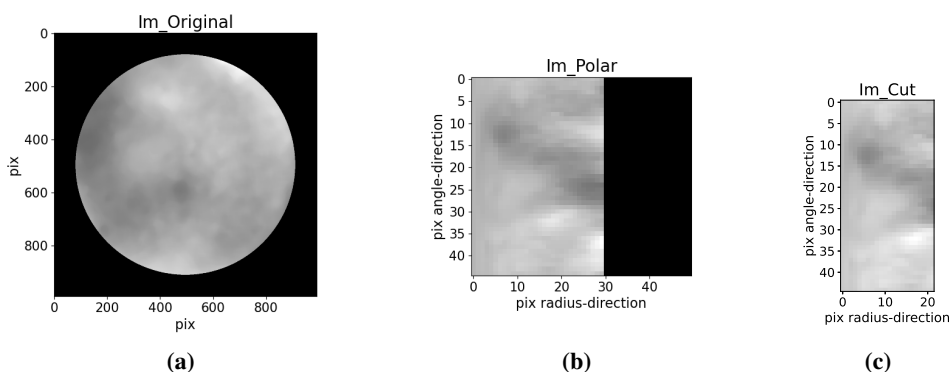


图 2-6 去除日面外数据。(a) 原始图像；(b) 极坐标变换后的图；(c) 日面部分

Figure 2-6 Remove the outside of the solar circle. (a) Original figure; (b) after polar coordinate transformation; (c) Solar part

最后，对数据进行降维。在数据处理中，主要是对高维数据进行预处理，不同的目的使用不同的降维方法，但都是将主要的信息保存下来，去除噪声和不重要的特征。通过降维可以实现数据处理速度提升的和减少噪声数据的目的。然而在实际的生产和应用中，降维也会存在一定的信息损失。可以针对需要提取的特征采用不同的降维方法，来为我们的数据处理中节省时间和成本。归纳起来，降维具有如下一些优点：

- 1、提取数据集主要特征，易于使用。
- 2、降低计算资源开销。
- 3、去除噪声对主要特征的干扰。
- 4、产生容易理解的结果。

本文选用主成分分析 (PCA, Principal Component Analysis) 对数据进行降维。PCA 是一种使用最广泛的数据降维算法, 它有许多名字, 如线性代数中矩阵奇异值分解 (SVD)、统计学中的因子分析 (factor analysis)、信号处理中共的离散 K-L 变换 (Karhunen-Loeve Transform)、图像分析中的 Hotelling 变换文本分析中的潜在语义分析 (LSA)、机械工程中的本征正交分解 (POD)、气象学中的经验直交函数 (EOF)、结构动力学中的经验莫分析 (EMA)、心理学中的 Schmidt-Mirsky 定理等。它的主要思想是将 n 维特征通过简单的向量减法和矩阵向量乘法投影到低维空间 k 维 ($k < n$) 上, 这 k 维是全新的正交特征也被称为主成分, 是在原有 n 维特征的基础上重新构造出来的 k 维特征。在实际降维中, PCA 从原始的空间中找到一组新的正交坐标, 将数据以最大方差的方式映射到上面, 第一个新坐标轴与原始数据方差最大, 第二个坐标与第一个坐标正交平面方差最大, 第三个轴与第 1、2 个轴的坐标轴正交平面方差最大, 依次投影。由于后面的数据跟前面的数据方差越来越小, 几乎为零, 这样就将大部分的数据包含在前面的 k 个坐标中。低维空间与原始的空间有所差异, 这里舍弃了方差少的数据, 这是降维导致的结果。但是舍弃这些数据往往是必要的: 一方面, 舍弃这部分薪资之后能使样本的采样密度增大, 这也是降维的主要目的; 另一方面, 实际观测的数据中包含了噪声的影响, 后面坐标投影数据实际上往往与噪声相关, 将他们舍弃在一定程度上能够起到去噪的效果, 在本文的实验中, 也恰恰证明了这点。

通过 PCA 将原始数据变换为一组各维度线性无关的数据, 然后提取数据的主要特征分量, 一方面可以去除小的干扰的信号, 另一方面可以使训练的网络轻量化, 快速迭代。

本文将所有的数据整合之后进行主成分分析, 最终将每一张图像变为一个 1 维数组 (该一维数组即图像通过 PCA 降维后映射的主成分), 具体操作步骤如下:

1、将极坐标转换后去掉日面外的图像 (如图 2-6(c) 所示, 大小为 $22pixel \times 45pixel$) 展平为一维向量 ($[1, m], m = 990 = 22 \times 45$)。

2、将所有的数据整合为 $[n, m]$ 的二维数组, 整合后的数据可以表示为 $(X_{i*j})_{n \times m}$ (下面公式使用 X 表示), 这里 n 表示图像的数量, m 表示数据的特征方向, 在特征方向进行降维。

首先, 对原始数据矩阵 X 进行中心化处理, 得到中心化后的数据矩阵 X' , 中心化过程如式 (2-4) 所示:

$$X' = X - \frac{1}{n} \mathbf{1}_n \mu^T \quad (2-4)$$

其中 $\mathbf{1}_n$ 表示 $n \times 1$ 的列向量, 所有元素都是 1, μ 是 $m \times 1$ 的列向量, 包含了每个特征的均值。

计算中心化后的协方差矩阵 C 可用式 (2-5) 表示:

$$C = \frac{1}{n-1} X'^T X' \quad (2-5)$$

求解协方差矩阵的特征值和特征向量，设 C 的特征值为 λ_i ，对应的特征向量为 v_i ，则有如式 (2-6) 对应关系：

$$Cv_i = \lambda_i v_i \quad (2-6)$$

将特征值 λ_i 按大小降序排列，并选择前 k 个最大的特征值对应的特征向量，这些特征向量构成了一个 $m \times k$ 的矩阵 V_k ，称为加载矩阵 (loading matrix)。使用加载矩阵 V_k 构造投影矩阵 $P = V_k V_k^T$ ，使用投影矩阵 P 将原始数据集 X 映射到 k 维子空间，见式 (2-7)：

$$Y = X'P \quad (2-7)$$

3、选择降维阶数，完成对数据的降维。 Y 是降维后的数据集，是一个 $n \times k$ 的矩阵。

为了对 PCA 降维的模型进行评价，使用降维后的数据集来 Y 进行评价。对于每一个主成分分配一个权重 w_i ，权重同常与对应的特征值 λ_i 成正比。权重的计算方法见公式 (2-8)：

$$w_i = \frac{\lambda_i}{\sum_{j=1}^k \lambda_j} \quad (2-8)$$

对于每个样本，计算其在降维后的特征空间中的得分，即综合得分 S (2-9)，得分越高，特征和模型选择越可信。

$$S = \sum_{i=1}^k w_i y_i \quad (2-9)$$

在应用主成分分析时，为降低分析变量的维度，应保留最大的 k 阶主成分来进行综合评价分析，一般应使选取的所有主成分贡献量累计超过 85% 以上，才认为这些主成分能够反映出原始变量的大部分信息。

主成分的贡献率通过其特征值进行计算 (2-10)

$$\eta_i = \frac{\lambda_i}{\sum_{j=1}^m \lambda_j} \quad (2-10)$$

图 2-7 和图 2-8 分别展示了在以上步骤 3 中 PCA 降维过程中贡献率随阶数的变化和降维前和降维后图像重构的对比。本文选用不同阶数进行实验，当阶数为 20 时，贡献率达到了 99.4%，说明了该降维方法有效。所以本文选用 PCA 降维后的主成分为 [1, 20] 的数组（长度为 20 的一维数组），该数组代表图像的主要特征。同时也可以看出使用 PCA 降维后的图像比之前平滑，重构后的图像大尺度特征与降维前的图像没有差异，说明 PCA 降维步骤非常成功。

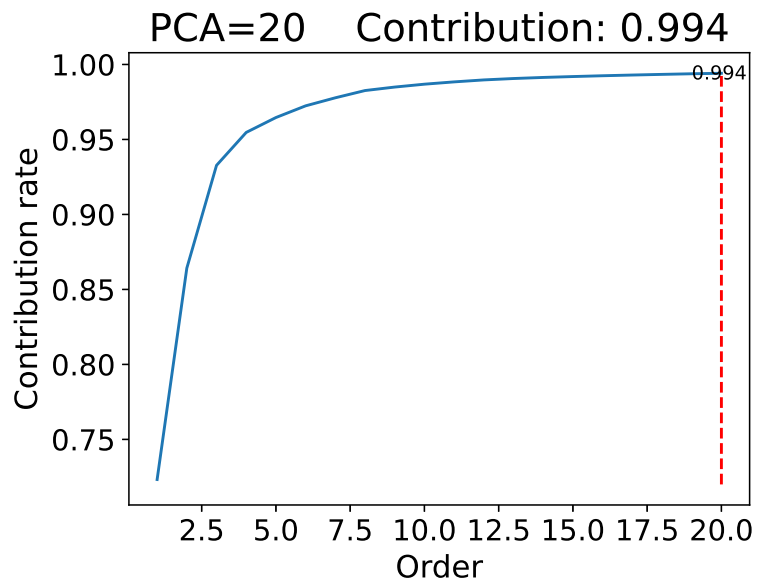


图 2-7 PCA 分解贡献率

Figure 2-7 PCA decomposition contribution rate diagram




图 2-8 20 阶重构前后图像对比

Figure 2-8 Image comparison before and after 100th-order reconstruction

重构前后图像如图 2-8 所示

综合本节内容，图像预处理流程图如图 2-9 所示

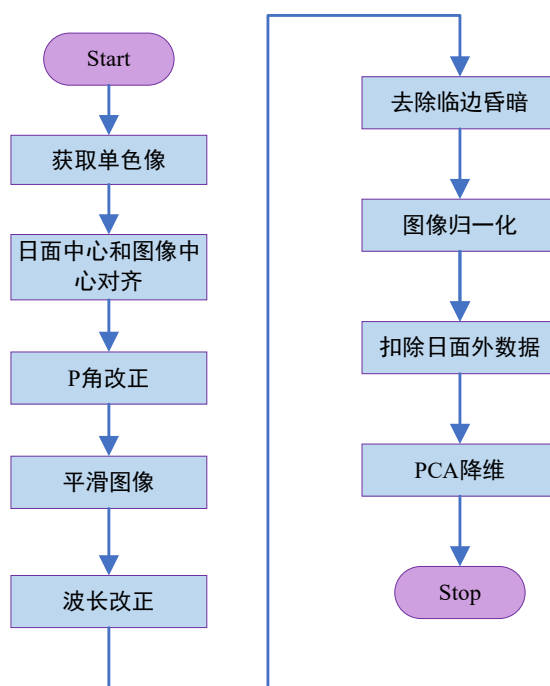


图 2-9 图像预处理流程
Figure 2-9 Image preprocessing process

2.2 基于 BP 神经网络的工作谱线波长位置标定方法

2.2.1 BP 神经网络简介

2.2.1.1 神经网络

神经网络 (neural networks) 顾名思义，研究始于人脑中神经元的研究，以树突和轴突为研究对象，这样面方面的研究已经有了很长的历史现。当代的神经网络主除了对于人类脑神经的研究，还包括了计算机人工智能下神经网络的研究 (灵感来自于对脑神经的研究，基于生物神经网络中的概念)，神经网络应用于多个学科，已经形成很多交叉学科。在计算机人工智能领域，神经网络中最基本的成分是神经元 (neuron) 模型。神经网络中的每一个神经元与其他神经元相连，当它“兴奋”时，会向相连的神经元发送化学物质，从而改变这些神经元内的电位，如果神经元的电位超过某一个阈值，那么他就会被激活，想起他神经元发送化学物质。人工智能领域下神经网络的信号传递过程同生物神经元信号传递过程是相同的，该过程被 McCulloch 抽象为简单神经元模型，如图 2-10 所示 该模型中，神经元接收来自 n 个其他神经元传递过来的输入信号 x_i ，同时包含了一个偏置信号，这些输入信号通过带权重 $w_i x_i$ 的连接进行传递，神经元接




图 2-10 神经元模型
Figure 2-10 The Neuron

收到总输入值将与给定的神经元阈值进行比较，如果大于该值，则输出到下一个神经元，如果小于该阈值，则不产生信号。该过程由激活函数 $f(\bullet)$ 来进行处理。

2.2.1.2 BP 神经网络

BP(Backpropagation algorithm) 神经网络是基于反向传播算法的神经网络，这一概念在 1986 年由 Rinehart 和 McClelland 等提出，它的拓扑结构包括一个输入层，多个隐藏层和一个输出层 (M, 1997; HaykinS, 2009)，其模型结构如图 2-11 所示。BP 神经网络具有强大的非线性映射能力，能够学习输入数据和输出数据之

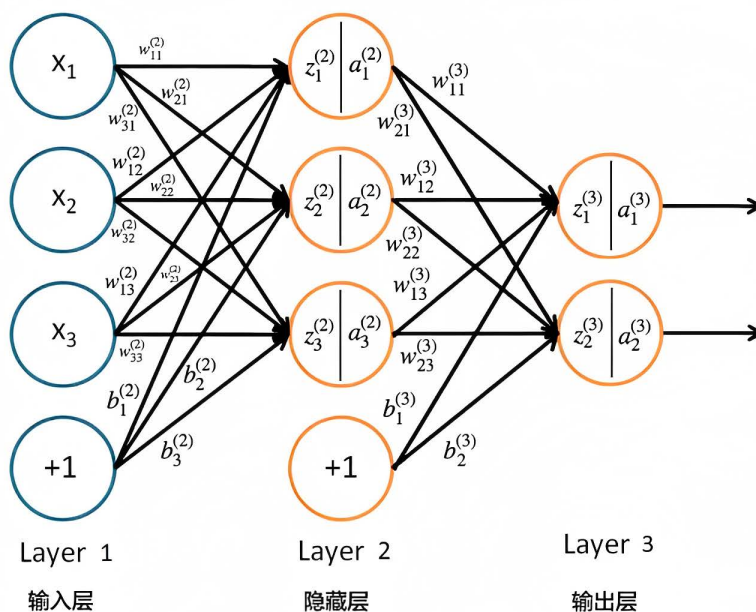


图 2-11 BP 神经网络结构
Figure 2-11 BP neural network structure

间的复杂非线性关系，这对于许多现实世界的回归问题至关重要。通过训练，BP 神经网络可以捕捉数据的统计规律，对未见过的数据具有良好的泛化能力。BP 网络结构灵活，可以根据问题的复杂性设计不同大小和深度的 BP 神经网络，以适应不同的数据和任务需求。在全局优化方面，BP 算法通过梯度下降等优化技术寻找网络权重的全局最小值，有助于提高模型的性能。BP 网络中，各层级之间相互连接，层级内部神经元相之间互独立。一般来说，只有一层隐含层的反向传播即可模拟任何非线性函数，并且不需要使用者预先设置任何映射关系。BP 算法可以被描述为如下过程：

1、正向传播：输入样本从输入层进入网络，经隐层逐层传递至输出层。

2、反向传播：输出层的实际输出与期望输出 (标签值) 进行比较，将比较结果反向传播，反向传播的过程中，将误差逐级分摊到各层的每一个神经元，获得每一个单元的误差。

3、权值修正：基于 2 步骤中的误差进行神经元的权值和阈值进行修正。该过程基于梯度下降算法完成。

4、反复迭代，直到达到预先训练的次数或者误差减小到允许的程度。

更详细的步骤可以描述如下所示：

首先正向传播：初始值通过输入层、隐藏层、输出层得到结果。神经网络的初始输入是：

$$P = [P_1, P_2, P_3, \dots, P_R]^T \quad (2-11)$$

网络的参数向量可以由式 (2-12) 来表示：

$$W = [W_{1,1}, W_{1,2}, W_{1,3}, \dots, W_{1,R}]^T \quad (2-12)$$

该神经网络包含一个偏移量 b ，它和初始值及逆行加权累加得到输入 n ：

$$n = W_{1,1}P_1 + W_{1,2}P_2 + W_{1,3}P_3 + \dots + W_{1,R}P_R + b \quad (2-13)$$

其矩阵形式为：

$$n = WP + b \quad (2-14)$$

输出结果为：

$$a = f(WP + b) \quad (2-15)$$

多层 BP 算法中的 m 层的输出值为 $m + 1$ 层的输入值

$$a^{m+1} = f^{m+1}(W^{m+1}a^m + b^{m+1}), m = 0, 1, \dots, M - 1 \quad (2-16)$$

其中 M 是算法总层数。

BP 神经网络训练过程本质上采用的是一种全局逼近的方法，它具有良好的泛化能力，可以作为一种一般性质的非线性输入与输出映射模型 (HaykinS, 2009;

C, 2009)。

2.2.2 BP 波长标定网络

目前，对于图像和波长的关系尚无函数表示，通过图像来预估波长是一个多重非线性的回归问题，可以借助 BP 神经网络模型的强大非线性拟合功能来建立图像和波长之间的联系。

本文所提出的基于 BP 的波长标定网络是一个多层感知机的回归网络 (Regression MLP network, Regression Multilayer Perceptron network)，输入为一个 [1, 20] 的数 (预处理后的数据)，隐藏层一共 8 层 (1000, 1000, 500, 500, 300, 300, 200, 100)，输出为一个 [1, 1](数组大小为 1×1) 的数 (波长)，网络的结构如图 2-12 所示。

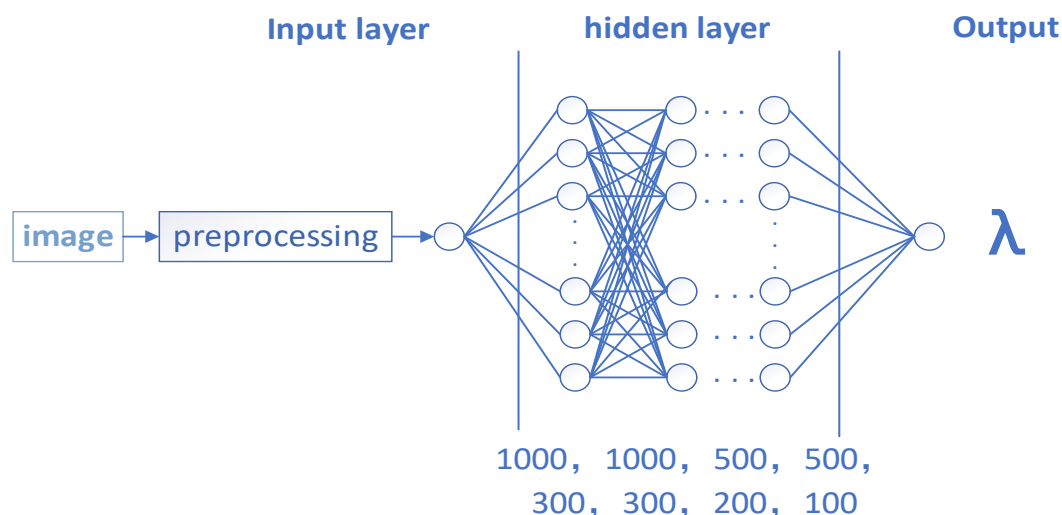


图 2-12 Regression MLP 网络
Figure 2-12 Regression MLP Network

在隐藏层中，使用 ReLU(Rectified Unit) 作为激活函数 (Nair et al., 2010)，通常意义下，该函数指代数学中的斜坡函数，即 (2-17)：

$$f(x) = \max(0, x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2-17)$$

ReLU 函数是神经元的激活函数的一种，如前面所述，它的主要功能是决定该神经元在线性变换 $w^T x + b$ 之后的输出结果。常见的激活函数见表 2-1：

使用 ReLU 激活函数具有更快的训练速度，它只对输入值的正部分激活，这导致网络中的神经元只有一部分被激活，从而产生稀疏的输出。这种稀疏性有助于减少计算量，并且可能有助于提高模型的解释性。此外，相比于 sigmoid 或 tanh 等其他激活函数，ReLU 在正输入值处的梯度是恒定的，这有助于缓解梯度消失问题，特别是在深层网络中，可以减轻过拟合的风险。激活函数 ReLU 具体

表 2-1 激活函数
Table 2-1 Activation function

Activation function	formula
ReLU	$\text{ReLU}(x) = \max(0, x)$
Sigmoid	$\sigma(x) = \frac{1}{1+e^{-x}}$
Tanh	$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
Softmax	$\text{Softmax}(x)_i = \frac{e^{x_i}}{\sum_j e^{x_j}}$
Leaky ReLU	$\text{Leaky ReLU}(x) = \max(\alpha x, x)$
Parametric ReLU	$\text{PReLU}(x) = \max(\alpha x, x)$
ELU	$\text{ELU}(x) = \begin{cases} x & ,x>0 \\ \alpha(e^x - 1) & ,x0 \end{cases}$
Swish	$\text{Swish}(x) = x \cdot \sigma(\beta x)$
Hard Sigmoid	$\text{Hard Sigmoid}(x) = \max(0, \min(1, \alpha x + \beta))$
Softplus	$\text{Softplus}(x) = \ln(1 + e^x)$

作用于神经元的过程可以表示为：对于来自上一层的神经网络的输入向量 x ，其输出为 $\max(0, w^T x + b)$ ，该结果作为下一层神经元的输入，如果是网络的最后一层，则作为整个网络的输出。

网络参数的初始化采用随机初始化的方式。学习率的设置如下，初始阶段的学习率 lr 设为：

$$lr = 0.001 \quad (2-18)$$

训练过程中，只要 $Loss$ 不断下降，就保持当前的学习率不变。所有的数据完成一次训练记为一个 $epoch$ ，当两个 $epoch$ 之间的 $Loss$ 下降小于 10^{-7} 或者验证分数增长小于 10^{-7} 时，通过下面式子更新学习率：

$$lr^* = 0.2lr \quad (2-19)$$

其中 lr^* 为新学习率。如果连续的 10 个 $epoch$ 中的验证分数提高小于 10^{-7} ，则终止训练。为了防止程序一直训练下去，训练的最大迭代次数设为 5000。

2.2.3 实验方法介绍

基于前面的算法描述，BP 神经网络的工作谱线波长位置标定算法总流程可以描述为：

- 1、获取图像数据
- 2、对图像数据进行预处理
- 3、训练网络
- 4、使用训练好的网络对图像进行预测，获的该图像对应波长值。

具体流程如图 2-13所示：

本算法的软件环境在 Windows 系统下使用 python 基于 Scikit-learn 框架搭建实现。Scikit-learn 是一个开源的，简洁高效的数据挖掘和数据分析工具，它涵盖了机器学习常用的模块，十分方便搭建属于自己的网络。算法的硬件环境涉及到的




图 2-13 BP 神经网络对工作谱线波长位置进行标定总流程

Figure 2-13 General process of calibration of observed wavelength points using BP neural network

主要信息如表 2-2所示:

表 2-2 实验环境
Table 2-2 Experimental Environment

Hardware Environment	Specifications
CPU	Intel Core i9-9900KF @ 3.60GHz 8-Core
RAM	64 GB
GPU	NVIDIA GeForce RTX 2070 (8 GB)
MainBoard	ASUS TUF Z390-PLUS GAMING

在实验设计上, 主要分为三个部分: 方法验证、实际测试、克服系统变化实验三个部分。方法验证主要用于对本文提出算法的有效性进行验证; 实际测试中, 需要考虑到系统维修对系统稳定性的影响, 因此需要设计的算法进行分组实验; 克服系统变化实验目的是探索一种可以解决由于望远镜系统机械结构变化、滤光器维修等因素对系统稳定性带来的影响所导致的网络需要重新训练的问题。

2.3 实验结果和讨论

在呈现实验结果时, 使用预测值和实际值的相关线 1:1 线来表示, 以方便对结果进行评价。以图 2-14为例, 横轴为实际值, 纵轴为预测值, 并且给出训练集和测试集的均方误差。按照实验方法, 在实验设计上, 主要包括了方法验证, 分组测试实验以及克服系统变化实验三个主要部分。分组测试的目的主要是考虑了系统在 2018-2019 年这段时间内进行过数次维修, 由于滤光器等机械维修是影响系统误差的主要原因, 为了尽可能保证系统的一致性, 以滤光器等机械维修为节点, 对数据进行分组测试, 这里一共分为五组, 每组进行相同的实验。克服系统变化实验用于展示不考虑磁像仪维修对系统带来的影响下, 使用机器学习方法的实验结果。

2.3.1 方法验证

本文使用 2018 年和 2019 年的数据进行实验, 从所有的数据中随机取出 70% 作训练, 30% 作测试。实验结果如图 2-14所示, 横纵坐标分别代表实际波长值和预测波长值。训练集和测试集的均方误差 (E_{MS}) 采用式 (2-20)计算:

$$E_{MS} = \frac{1}{m} \sum_{i=1}^m (\hat{e} - e)^2 \quad (2-20)$$

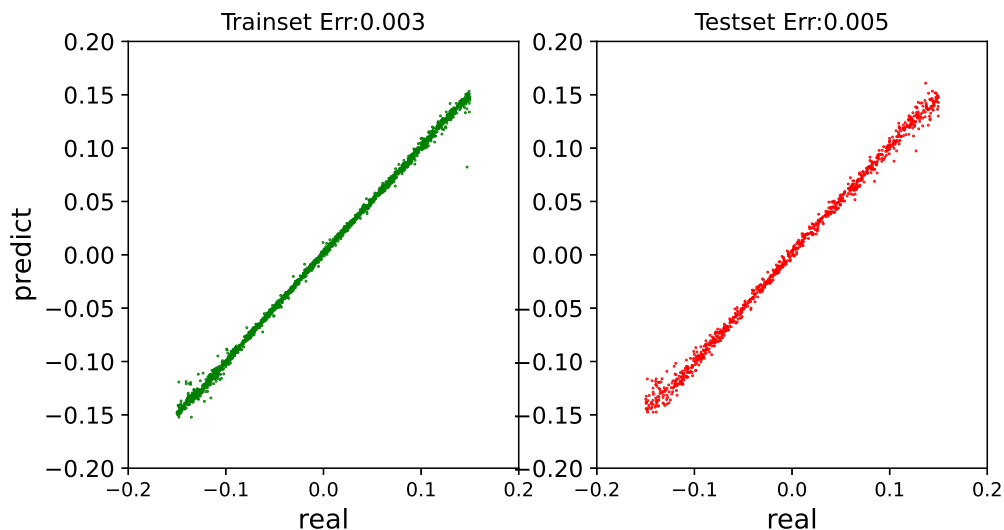


图 2-14 训练集和测试集相关图

Figure 2-14 Correlation Diagram of Training Set and Test Set

来计算，从试验结果来看，训练集和测试集误差的均方差分别为 0.003 和 0.005，说明有 99.73% 的数据误差范围小于 0.009\AA 和 0.015\AA

2.3.2 分组测试

分组测试实验中，考虑到磁像仪的维修对系统稳定性的影响，为保证实验组的数据在相对稳定的系统下观测得到，按照维修节点将数据分为 5 个实验组。对按照维修节点分配好的每一组数据分别进行相同的实验，实验中的训练集和测试集按照观测时间分配，取前 70% 作为训练集，后 30% 作为测试集。按照时间序列，取第一个实验组的结果展示如图 2-15 所示。从结果上来看，训练集的 E_{MS}




图 2-15 第一个实验组训练集和测试集相关图

Figure 2-15 Correlation Diagram of Training Set and Test Set of the first experimental group

为 0.002，测试集的 E_{MS} 为 0.027。

该实验组中训练集和测试集按照时间序列排序的数据对应的残差如图 2-16所示，其中，横轴为数据量，纵轴为残差大小。对测试集的结果进行分析，可以看出，时间上靠近训练集的测试集预测结果的误差小，说明了本方法的有效性。时间上远离训练集的测试集误差逐渐增大，这种误差随时间增大的现象符合系统由稳定到不稳定变化的实际情况。




图 2-16 训练集和测试集的残差变化图

Figure 2-16 Residual variation graphs for training set and test set

以每一天的数据为一组，计算每组数据的残差均方差，如图 2-19所示，该结果可以更直观看出时间上靠近训练集的测试集预测结果的误差小，时间上远离训练集的测试集误差逐渐增大。表明了方法的有效性，此外说明了仪器状态的变化。

其他实验组的测试集残差变化如图 2-18所示。同样符合误差随时间逐渐增大的特点，同时也对应系统随时间变化由稳定到不稳定的实际情况。

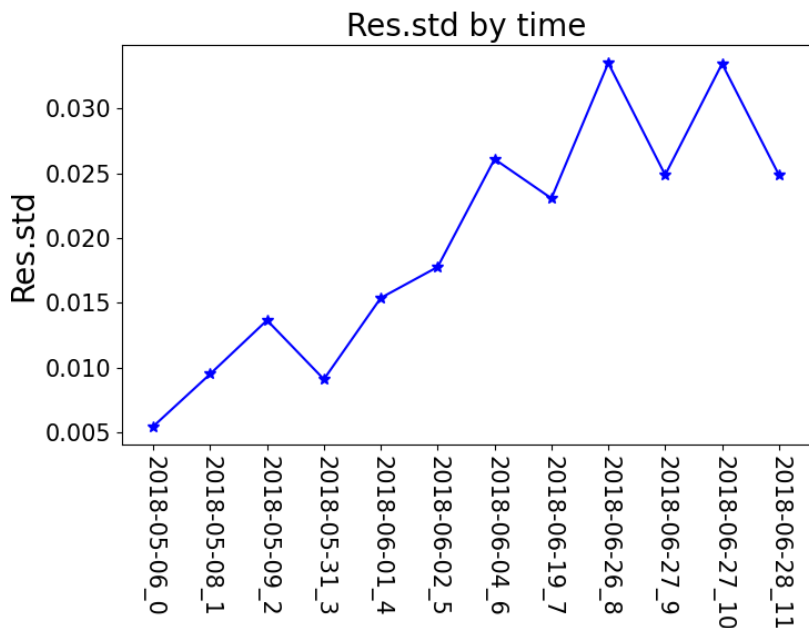


图 2-17 每一天残差均方差随时间的变化

Figure 2-17 Variation of mean square deviation of each day residual with time

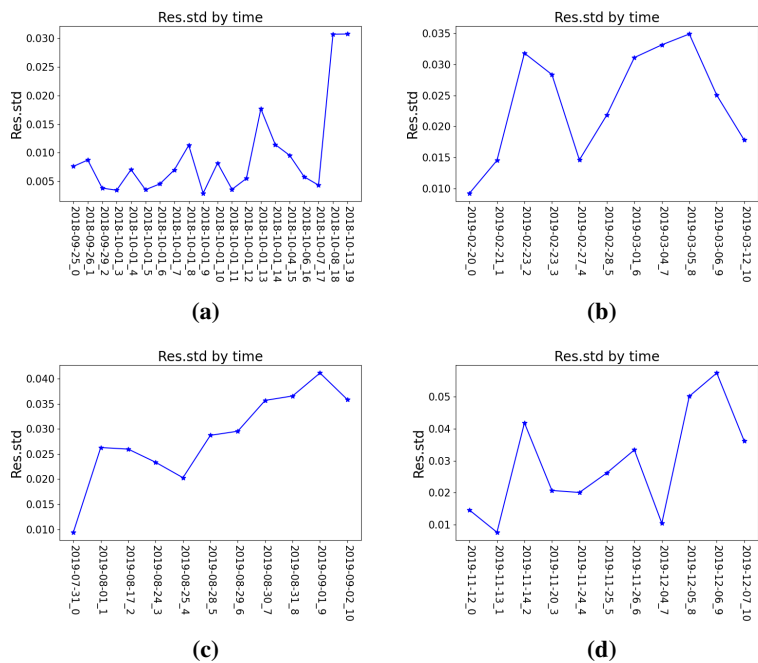


图 2-18 不同实验组的残差均方差变化图

Figure 2-18 3 Variation of residual mean square deviation of different groups

2.3.3 克服系统变化实验

对于上述实验的结果看，在线心处的预测误差受到系统变化影响较小，因此做了以下实验。对所有数据不进行分组，选取 $[-0.06, 0.06]$ 波带范围的数据进行试验，取 2018 年和 2019 年前半年的数据作为训练集，2019 年后半年的数据作为测试集，实验结果如图 2-19 所示




图 2-19 $[-0.06, 0.06]$ 范围下的试验结果
Figure 2-19 Test results in the range of $[-0.06, 0.06]$

图像的横轴是实际的波长值，纵轴是预测的波长值。从相关性来看，训练集和测试集都有很强的相关性。测试集的相关性较训练集差，分析原因，一方面可能是由于测试集数据量少所致；另一方面，系统随时间发生变化，使用之前训练的数据无法学习到这些信息，导致此实验结果。训练集和测试集误差的均方差分别为 0.001 和 0.006，说明有 99.73% 的数据误差范围小于 0.003\AA 和 0.018\AA 。可以看出，使用缩小波带范围的数据进行训练网络，可以有效克服系统不稳定性的影响。

2.3.4 两种方法效率对比

怀柔全日面矢量磁像仪在进行磁场测量前，谱线扫描数据间隔为 0.02\AA ，其中一方面的原因是因为间隔 0.02\AA 的相邻两张磁图特征差别不大，一组谱线扫描数据的纵场磁图进行展示见图 2-20。在该组扫描数据中，共拍摄 31 张图像，线心 λ_c 为 0.171\AA 。 0.02\AA 可以作为衡量波带定标误差的阈值。

怀柔全日面矢量磁像仪基于 windows 系统计算机平台，通过软件对磁像仪的机械结构进行控制移动滤光器的位置拍摄 31 张图像，拟合图像中心强度和观测位置之间的关系得到谱线轮廓，进而得到工作谱线波长位置的位置。仪器正常工作的情况下，对不同时间段的 20 组数据进行了时间统计，传统方法标定所需的时间大约 15—20min。使用该网络进行工作谱线波长位置的标定，程序运行时间小于 7s，相对于传统的方法，耗时减少了 100 多倍，时间对比以及传统精度要求和机器学习方法误差范围对比如表 2-3 所示。在满足精度要求下，缩短了标定




图 2-20 谱线扫描数据磁图纵场

Figure 2-20 Spectral line scanning data magnetic map longitudinal field

时间意味着大大提高了定标效率，故可在日常的观测中引入一种反馈机制，实时调整观测点的位置，以保证高质量数据的稳定输出。

表 2-3 传统定标方法和机器学习方法时间精度比较

Table 2-3 Time comparison between traditional calibration method and machine learning method

传统方法			机器学习方法		
图像获取耗时	谱线拟合耗时	总耗时	图像获取耗时	波长定标耗时	总耗时
14 ~ 19min	大约 60s	15 ~ 20min	5s	2s	7s
传统方法要求精度 <0.02Å			机器学习方法误差 [0.015Å, 0.018Å]		

2.4 本章小结

方法验证的实验中，假设系统稳定，随机将数据分配为 70% 作为训练集，30% 作为测试集，数据选取的波带范围为 [-0.15, 0.15]。从实验的结果来看，训练集和测试集的数据有 99.73% 的数据误差范围小于 0.009Å 和 0.015Å。在实际观测进行磁场测量时，定标误差小于 0.02Å 则可满足定标需求，说明了该方法的有效性。

在实际测试实验中，考虑时间因素，使用的是观测到的数据进行建模来预测未观测到的数据。因此需要在划分训练集和测试集时，以观测时间来进行划分。此外，还需要考虑到系统变化这个因素，在本实验中，系统的变化主要与滤光器和机械结构的维修相关。因此，进行实验时，根据系统的变化将数据划分为

5 个实验组来进行相同实验。分组实验的结果可以看出，在测试集的预测中，观测时间靠近训练集的数据误差较小，可以满足应用需求。但是观测时间远离训练集的测试结果误差较大，并且误差逐渐增大。这个结果符合仪器系统由稳定到不稳定变化的实际情况。此外，任何预测问题，时间越长，结果越不准。这恰恰启发我们可以使用该网络对仪器的运行状况进行判断，即：对同一组数据进行定标，判断预测值和标签值的残差大小和变化趋势来分析磁像仪是否稳定运行。此外，本文探索了一种克服系统变化方案。在该方案中，预测的波带范围为 $[-0.06\text{\AA}, 0.06\text{\AA}]$ 。在该波带范围内进行预测，可以满足测试集有 99.73% 的数据误差小于 0.018\AA 。此结果说明线心附近的数据受到系统变化影响较小。分析该结果产生的原因，可能是由于线心附近的数据容易受到光球大尺度变化的影响，因此受到系统干扰较小。

从时间效率上来看，本文提出的基于机器学习的方法比传统的方法快 100 多倍，所花费的时间已经远远小于传统方法，极大地提高了定标效率。

在未来的应用中，可考虑通过该方案在滤光器波带调节中引入一种实时闭环反馈机制，例如应用到多通道二维实时光谱仪中 (艾国祥胡岳风, 1986)，以支持滤光器位置的自动化实时调控，保证观测数据质量稳定输出。我们的实验在方法验证实验和分组测试实验的网络预测结果存在差异，从目前分析来看，两个实验的不同之处在于训练集和测试集是否存在时间交叉，但具体原因还需要进一步展开分析研究。对滤光器透过带轮廓的常规扫描从 2017 年才开始进行，该方法还可以应用于全日面太阳矢量磁像仪从 2005 年开始的无滤光器透过带轮廓扫描的历史数据中，确定全日面的观测波长位置，提高磁场定标系数的精度从而提高全日面历史矢量磁场观测数据的准确性和可靠性。此外，本方法也提供了一种可以监测全日面磁像仪系统运行状态的方案。

第3章 基于卷积神经网络的纵场磁饱和效应解决

太阳磁场是太阳物理的重要观测研究的物理量，也是望远镜系统的最终获得量，磁场的定标十分重要。在第一章中已经指出怀柔基地磁场定标的方法是基于辐射转移方程而建立的，采用了弱场近似的前提。目前怀柔基地通过单点观测的方法在谱线 $FeI5324.19\text{\AA}$ 偏离线心 -0.08\AA 处进行单点观测，获得偏振像后，通过线性定标的方法获得磁场数据。对于谱线 $FeI5324.19\text{\AA}$ 而言，当纵场强度过高，反而使得磁场测量信号减弱，即称为磁饱和。对于磁饱和效应的解决，徐海清用传统的最小二乘拟合的方法对磁饱和效应进行改正 (Xu et al., 2021)，这种方法的一个优点是可以计算饱和阈值并自动校正，但是当活动区远离日面中心时，准确度会降低。也有尝试使用机器学习对磁饱和效应进行改正，比如郭晶晶 (Jingjing Guo, 2020) 和胡子尧的工作 (Hu et al., 2022)，但他们的工作都是在同一设备下进行的实验，并未将方法实际应用到磁饱和效应得改正中。目前使用机器学习进行磁饱和效应的解决，已经证明了机器学习方法的可行性，但主要是基于同一设备的探索工作，并未真正将机器学习的方法应用在磁饱和效应的解决中。

HMI 在谱线 6173\AA 的 6 个波长点处对光球层进行观测，获得偏振像后通过反演得到磁场，反演的方式得到的磁场是目前测量方式中最为准确的一种。怀柔太阳观测基地在谱线 5324.19\AA 处单点观测获得的光球磁场与 HMI 测得的磁场在太阳大气的高度基本一致。本项工作中，我们对 SDO 的 HMI 和怀柔太阳观测基地全日面矢量磁场望远镜开展跨设备研究，尝试使用机器学习的方法对怀柔太阳观测基地当前磁场测量的磁饱和效应问题进行研究。

3.1 数据介绍

高精度磁场定标的研究数据来自怀柔太阳观测基地全日面太阳矢量磁像仪 (SMAT) 的 Stokes 图像数据和 HMI 的图像数据。文章第一章和第二章都对 SMAT 展开过详细介绍，这里不再赘述，这里对使用到 HMI 进行补充介绍。HMI 由斯坦福大学负责，是用来研究太阳变化与判断太阳内部结构和磁场活动与结构的仪器，也是太阳动力学天文台 (SDO, Solar Dynamics Observatory) 的三个仪器之一。HMI 观测谱线 6173\AA 的全日面，获取的数据可以用于研究太阳活动的内部能量来源，亦可以对太阳表面的磁场活动进行研究，了解太阳内部物理机制，使用 HMI 的数据可以对日冕磁场进行研究，进一步判断日冕外的大气变化。同时，还可以使用观测到的数据对太阳内部的动力结构与磁场活动进行研究，了解两者的关联，从而进一步了解太阳活动。HMI 主要提供四种类型的数据：多普勒速度图 (太阳表面速度图)、连续滤光器图 (太阳光球层的宽波长强度像) 以及光球层的纵场和矢量磁图。HMI 纵场数据每 45s 测量输出一次，矢量磁场每 720s 测量输出一次，空间分辨率大于等于 1.5 角秒，图像大小为 4096×4096 ,

720s 数据具有较低的噪声水平 (Hoeksema et al., 2014)。

在第二章中已经提到，SMAT 的常规观测的图像数据主要包含了 $0.5(I \pm Q)$, $0.5(I \pm U)$, $0.5(I \pm V)$, 该部分数据用于对磁场进行定标。本文选取了时间跨度从 2020 年 11 月份到 2022 年三月份的数据，以及对应的 HMI 数据。主要对纵场的磁饱和效应进行研究。不同仪器选取的数据见表 3-1

表 3-1 数据集列表

Table 3-1 dataset list

仪器	数据	数量
SMAT	I, V	151
HMI	B, inclination	151

根据怀柔观测数据可以得到原始的 I、V 信号见图 3-1。




图 3-1 怀柔数据 Stokes I V 信号

Figure 3-1 Huairou Data Stokes I V Signal

HMI 数据的原始数据，以及根据磁场 B，倾角 inclination 计算出的纵场 B_L 见图 3-2。




图 3-2 HMI 数据磁场 B、倾角 inclination、纵场 B_L

Figure 3-2 HMI data magnetic field B, inclination, longitudinal field B_L

3.2 方法介绍

3.2.1 数据预处理

数据筛选：数据的选择至关重要，为了排除不必要的干扰因素，在挑选数据的时候，选择图像数据良好，磁场活动区较大且多的数据。本文先选择怀柔数据，然后选择同一时间的 HMI 数据。

数据对齐：考虑到训练集和测试集的尺寸一致性，将图像调整为相同尺寸大小 1024×1024 。怀柔数据和 HMI 数据除了尺寸大小不一致，还存在其他的差异。首先是怀柔数据属于地基观测数据，受到大气湍流的影响，图像在局部会发生一些小的畸变，无法与 HMI 图像保持对齐；此外，望远镜口径的不一致也会导致两者真实空间分辨率存在差异。与怀柔数据相比，HMI 数据对细节的分辨更为清楚，此外观测波段的不一致，细微之处也会存在差异，这些局部的特征不一致导致了两者之间难以精细地直接一一对应。因此，需要对图像进行一定的预处理。选择合适的算法进行数据的匹配和对齐十分重要，因为数据的对齐直接影响到后续的算法效果。图像匹配算法一般分为两类：基于图像特征点匹配法和基于区域信息的统计匹配法。点匹配法是通过图像特征点的测量和提取进行匹配，其中包含了局部图像的拉伸和整个图像的平移和缩放的处理，在特征点数量足够时，可以获得较为理想的效果。当图像的匹配涉及较多的平移时，使用统计匹配算法可以获得更好的效果。地面的图像由于受到大气湍流的影响，局部会发生畸变，无法跟空间的图像只通过平移操作对齐。本文选用点匹配算法中的尺度不变特征变换 (scale-invariant feature transform, SIFT) 来对图像进行匹配对齐。SIFT 算法是一种经典的基于特征点的图像匹配方法，它从寻找图像特征和描述图像特征两个部分入手来建立一套描述图像特征的完整体系，此算法最先由 Lowe 在 1999 年提出，并在后续不断进行完善，在 2004 年进行了完善算法的发表 (Lowe, 2004)。SIFT 算法广泛应用在图像处理领域，在天文领域也有了应用，比如 2018 年杨盼等人将这一方法应用到了国家天文台怀柔太阳观测基地的图像配准中，获得了较好的效果 (杨盼等, 2018)。2019 年季凯帆等人使用 SIFT 算法时，对图像进行了预处理，获得了良好的效果 (Ji et al., 2019)。SIFT 方法已经具有较好的鲁棒性，在利用多尺度分解的方法上可自适应地选出合适的特征点。从图像匹配的本质来讲，相似性是制约匹配精度的关键因素。使用 SIFT 算法对图像配准之前，做一些针对性的预处理，可以大大提高特征点的检测与匹配数量，获得良好的匹配效果。

SIFT 算法是基于特征点来进行匹配对齐的，使用 SIFT 算法进行图像配准对齐主要包括三个步骤：

首先是特征点标识。特征点标识过程中，首先通过高斯滤波来获得图像的边缘和轮廓特征，同时对图像纹理和次要细节以及噪声进行了抑制；在这个过程中，为了提取图像特征的不变性尺度，确保特征算法对图像检索、图像匹配等问题的鲁棒性，对原图进行不同程度的降采样。然后对这些图像进行高斯差分，以进一步凸显图像主要特征，削弱无用信息。高斯差分后的新图像所代表的成分

凸显了代表图像边缘、轮廓特征成分，该部分新图像称为“高斯金字塔”。接下来，选择高斯金字塔中的极值点作为可以代表图像特征的关键点，对这些点进行高阶拟合，选择高边缘度、少噪声的关键点。然后对这些关键点进行主方向分配，计算指定大小领域中的所有关键点梯度方向并赋值，并对所有梯度方向对应的赋值求和，作为关键点周围 i 邻域梯度方向的直方图。获得图像关键点，每个关键点包含了位置、尺度、方向三个信息。最后，将这些关键点所在区域分成 4×4 的子块，统计每一个子块进行 8 个方向的梯度，构成 $4 \times 4 \times 8$ 的一个 128 维的描述向量，该向量可以对图像进行唯一性地描述。

其次是特征点匹配。该步骤通过对比图像和被匹配图像之间的关键点来建立图像与被匹配图像间关键点描述关系，关键点的匹配方通过计算关键点的欧氏距离来对相似性进行度量，通过比较实时图距离与次近邻距离的比值来确立（小于某个预值作为匹配点，Loew 使用的预值为 0.8）。匹配关键点可以采用穷举法完成，也可以采用最近邻算法，但这两中方法计算量较大，实际计算中一般采用快速近似最近邻库（fast library for approximate nearest neighbors, FLANN）来减小计算的复杂度。

最后是确定图像配准参数。得到匹配的特征点之后，需要求解齐次变换矩阵来完成图的配准，该变换矩阵则是图像配准参数。变换矩阵包括了被匹配图像的旋转角、缩放比例以及两个平移量，共四个参数。需要变换的即通过匹配点对求解齐次坐标变换矩阵，获得图像和被匹配图像之间的相似变换矩阵参数，包括旋转角、缩放比例和 2 个平移量，共 4 个参数。理论上，2 个及以上匹配点对可得到图像之间的对应关系，但实际匹配中，更多的特征点有助于对图像进行更精确的对齐。此外，实际使用该 SIFT 对图像进行匹配时，会采用抽样一致性算法（random sample consensus, RANSAC）对匹配点进行选择，进而来提升匹配精度。

从上述的步骤中可以看出，特征点获取和基于此数量的图像间匹配是整个算法的核心，基本上决定了图像的配准精度。虽然使用了 FLANN 和 RANSAC 来简化算法，提升算法精度，但是 SIFT 算法依然复杂，且计算量大。随着 SIFT 的广泛应用，很多编程语言对该算法进行了封装，使其应用大为方便。本工作使用 Opencv 库封装的 SIFT 算法进行图像的匹配。由于太阳图像不同于经典图像，不同仪器之间的图像之间存在较大的信号差异，如缩放比例不一致、图像细节特征不明显、缺乏高频信息、噪声大等差异，给直接使用该算法进行图像的配准带来很大麻烦。为了获得理想的匹配效果，需要在使用 SIFT 算法前对图像进行预处理。对于 HMI 图像和怀柔的图像，对齐前预处理主要包括如下步骤：

- 1、尺寸调整：对于怀柔数据和 HMI 数据而言，最大的不同在于尺寸不同，怀柔数据尺寸大小为 992×992 ，HMI 数据尺寸大小为 4096×4096 。在数据的操作，不改变怀柔数据的像元分辨率，对于怀柔数据的调整方式使用周围补零的方法将数据调整为 1024×1024 ，日面中心和图像中心重合，对 HMI 的数据采用缩放的方法将其尺寸调整为 1024×1024 大小。改变 HMI 尺寸的过程中，选用了双三次插值（BiCubic）的方式，这种方式将相邻像素的灰度以及灰度变化率考

虑率进去,可以得到更平滑的图像边缘,在降采样的过程中更多保留图像的细节信息。

2、调整图像位置符号信息:由于怀柔数据和 HMI 观测位置不同,获得的图像存在较大尺度的偏差,需要将怀柔数据进行横向反转;此外,在观测过程中,存在少量数据纵场正负号相反的情况,也需要将正负号进行改正,以 HMI 的数据为准进行正负号改正。

3、去掉日面外噪声:由于日面外的信号属于无效信号,对于 SIFT 算法是一种干扰信号,也需要去除。对于怀柔数据而言日面外的噪声属于高分辨率噪声,本文中采用日面外数据清零的方式来去除日面外噪声。对于 HMI 数据而言,日面外为 NAN 信号,本文将这些数据用零替换。

4、降低 HMI 数据分辨率:怀柔基地数据和 HMI 数据的衍射极限分辨率虽然相近,但是由于受到大气湍流的影响,实际的分辨率无法达到衍射极限分辨率。HMI 数据由于没有受到大气湍流的影响,其空间分辨率依然高于怀柔基地分辨率,因此通过高斯滤波的方式来对 HMI 数据进行模糊处理,使其分辨率降低。

完成预处理的怀柔数据如图 3-3所示:




图 3-3 预处理后的怀柔数据

Figure 3-3 Pre processed Huairou data

完成预处理的 HMI 数据如图 3-4所示:




图 3-4 预处理后的 HMI 数据

Figure 3-4 Pre processed HMI data

实际操作中, HMI 和怀柔数据的对齐,也即匹配步骤如下:

1、获得数据特征图：对于磁场数据而言，无论是怀柔数据还是 HMI 数据，在其图像特征上和传统的图像有很大差异。基于 SIFT 算法的特征点的识别是对 0 – 255 灰度值范围的图像进行识别的，而磁场图像的灰度值范围大于 0 – 255，因此需要将磁图转为 0 – 255，以获得数据特征图。在获得数据特征图的过程中，如果直接以磁场的最大值来进行灰度压缩，则无法获得有效的特征图像，这里取不同的阈值对磁场图像进行转化。对怀柔数据 V 信号采用 ± 0.005 作为阈值进行转换，即对于大于 0.005 的信号全部使用 0.005 代替，小于 -0.005 的信号使用 -0.005 代替，然后使用最大最小归一化的方式将图像映射到 0-255 范围；对于 HMI 数据，采用 ± 50 作为阈值进行转换，方法同怀柔数据。特征图如图 3-5 所示：




图 3-5 怀柔 and HMI 的特征图
Figure 3-5 Feature maps of Huairou and HMI

2、特征点的标识与匹配：特征点标识使用 SIFT 方法获得特征点和特征描述向量，特征点匹配使用 FLANN 获得初始参数点配对。特征点的检测图像如图 3-6 所示，这里显示了前 100 个匹配点。特征点的匹配图如图 3-7 所示。

3、图像配准参数确定：使用 RANSAC 确定最终的求解配准参数，包括：旋转角度、缩放比例、2 个平移量共 4 个参数。

4、图像对齐：使用匹配参数对怀柔数据进行变换。这里需要注意的是，使用配准参数进行变换时，仅对调整过位置信息和正负号的怀柔数据 Stokes V 信号和 I 信号进行变换。对于 HMI 的数据，使用调整尺寸后，去除 NAN 的数据作为数据集的标签值。对齐后的数据如图 3-8 所示：

至此，完成数据集的建立。

3.2.2 基于 ResNet 的纵场磁饱和效应改正

第二章中已经提到使用神经网络对工作谱线波长位置定标的方法，从机器学习的角度来说，这是一个从图到点的映射。而从 Stokes 参数获得磁场的过程，从机器学习的角度来看是一个图到图的映射关系，虽然可以使用神经网络来建




图 3-6 特征点标识图
Figure 3-6 Feature point recognition map




图 3-7 特征点匹配图
Figure 3-7 Feature point matching map




图 3-8 对齐后的怀柔 HMI 数据
Figure 3-8 Aligned Huairou and HMI data

立这种映射关系，但是难以在图像或者视频高维数据上取得更好的应用，其原因是全连接层网络中的权重数量随着网络的复杂性（由神经元的数量定义）快速增加，计算很快变的不可行。由于给定层的每个神经元都连接到前一个神经元，因此在层中添加一个新的神经元也意味着添加大量权重，等于该层神经元中的数量。更多的神经元意味着连接数量的大幅度增加，显然成为一个无法克服的障碍。此外，神经网络建立起来的映射关系是一个点对点的关系，没有考虑到图像领域之间的关系。CNN 的提出使用了权共享的概念，大大减少了未知数的数量。从数学的角度来看，CNN 定义了一组小尺寸的卷积核，用作卷积内核，然后将输入与他们的卷积作为输出。CNN 通常由几层组成，这种逐层架构利用了许多自然信号由模式的分层组合生成的属性。这样就可以设计出特定的内核从输入中提取这些信息。CNN 致力于每个卷积层提取有关某些模式的信息，这是在训练期间通过迭代调整卷积内核以适应特定的特征来完成的。尽管与神经网络相比，自由参数的数量呈现指数型减少，但由于 CNN 还将图像的结构间的关系考虑进去，通常产生更好的效果。

3.2.2.1 ResNet 简介

本文采用了经典的深度残差网络 ResNet (Deep residual network, ResNet) 来进行训练，它卷积神经网络 (Convolutional Neural Networks, CNN) 的一种。卷积神经网络是一种典型的深度学习算法，它采用“权值共享”（一组神经元是用相同的连接权值）训练策略，这样可以有效节省训练的开销。与 MLP 点对点的网络不同，CNN 采用图像作为训练样本，但网络结构都是由输入层、隐藏层、输出层组成。CNN 的隐藏层包含卷积层、池化层和全连接层等多种简单结构，此外还有残差块、Inception 模块等跨连接结构。卷积层和池化层为网络所特有，卷积层包含权重系数，而池化层不包含权重系数。卷积层通过卷积核对图像进行特

征提取，卷积核的大小、步长和边缘填充为卷积层的可调参数，且卷积层输出特征图像的尺寸由这三个方面决定，卷积和池化过程如图所示 3-9:

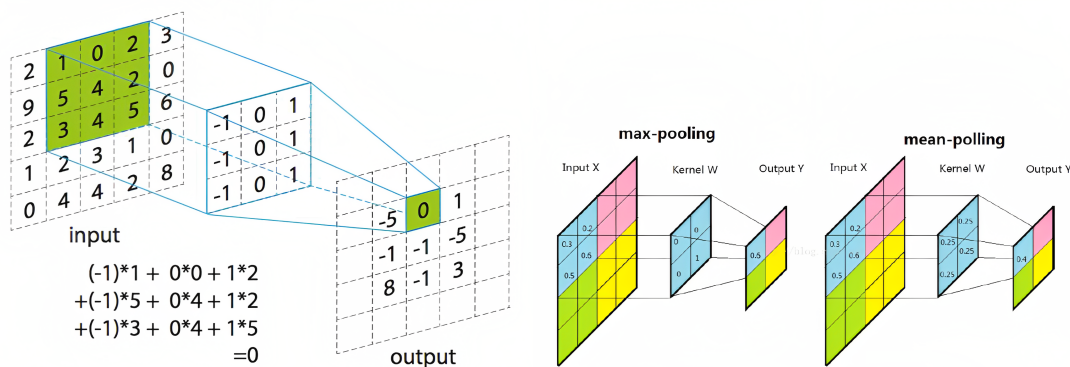


图 3-9 卷积、池化过程
Figure 3-9 Convolutional and pooling processes

ResNet 是 CNN 的一个变种，ResNet 是在 2015 年首次提出的。这一网络由微软研究院的何恺明等人共同研发 (He et al., 2015)，并在同年的 ImageNet Large Scale Visual Recognition Challenge (ILSVRC) 中取得了冠军。传统的卷积网络下，随着网络的加深，更加复杂的特征模式可以被提取，理论上应该得到更好的效果。然而网络的加深也出现了负面的问题：退化问题。过深的网络会导致准确率出现饱和，对问题更多特征的学习导致了准确率下降。在学习的过程中，出现梯度弥散和梯度爆炸的问题，使得损失函数一直无法下降，给模型的训练带来很大的困难。ResNet 网络通过在网络中引入跨层连接，构造了残差块，解决了网络退化的问题。构造的残差模块（又称捷径链接 shortcut connection）见图 3-10。

在一个残差模块中，一般只跨越 2 或 3 层，用 $H(x)$ 标识相应的计算结果，在加入跨层连接后的计算结果 $F(x)$ 与 $H(x)$ 之间的关系可有式 (3-1) 描述。

$$H(x) = F(x) + x \tag{3-1}$$

这意味着跨链接模块计算时，省去了不跨连接的部分，该部分形成残差，所以又称为残差模块。从整体功能上来看，如果用 w_i 表示残差模块的所有权值，那么残差模块实际计算的输出结果如式 (3-2) 所示：

$$y = F(x, w_i) + x \tag{3-2}$$

其中 $F(x, w_i)$ 又称为残差函数，通过学习获得。基于残差模块，不仅解决了网络层数增加导致性能退化的问题，同时因为允许训练更深层次的网络，所以不会出现梯度消失的问题，深层残差网络可以具有非常深的结构，深度可达 1000 层以上。ResNet 的结构设计使其在多种计算机任务如图像分类、目标检测、语义分割和视频分析等都有出色的表现。同时 Resnet 也有不足之处，随着网络深度的加深，参数数量和计算量也随之增加，虽然残差连接缓解了过拟合问题，但是非常




图 3-10 ResNet 残差模块
Figure 3-10 ResNet residual module

深的网络仍任存在过拟合的风险。此外，相比于较浅的网络，ResNet 的训练需要更多的时间和资源。

3.2.2.2 MagResNet 设计以及训练策略

MagResNet: 经过前面的数据预处理，怀柔数据和 HMI 数据的尺寸均调整为同样大小尺寸，网络的输入为怀柔数据 Stokes 参数 V 、 I ，标签为同样尺寸的 HMI 纵场数据 B_l ，因此输入为两通道，输出为单通道。此外，由于过深的网络仍会存在过拟合的风险，且 ResNet 较一般的网络需要更多的时间时间和资源。所以本文在借鉴 ResNet 思想的基础上，对网络的输入输出通道数进行修改，网络的层数上减少连接层数，设计了用于磁场定标的 MagResNet 网络。MagResNet 网络的结构见图 3-11。

MagResNet 模型中，首先设置了一个卷积层，包含卷积核大小为 3×3 ，这些卷积核用于生成初始的特征图。接下来的卷积核大小同样为 3×3 。这里设置卷积核大小为 3×3 的原因是太大的卷积核会使图像产生平滑现象，而太小则会减少空间相关性。卷积层之后为激活函数提供非线性特征，激活函数选用 ReLU，这样可以在进入残差块的数据每一个卷积层包含多个训练参数，并通过卷积核提取特征来生成相应的特征图。模型中的残差块如图 3-11 方框所示，每一个残差快包含了两个卷积层。模型的初始输入和输出各有一个卷积层，分别接收图像数据和输出图像数据，本模型的详细的参数设置如图 3-11。

训练策略：

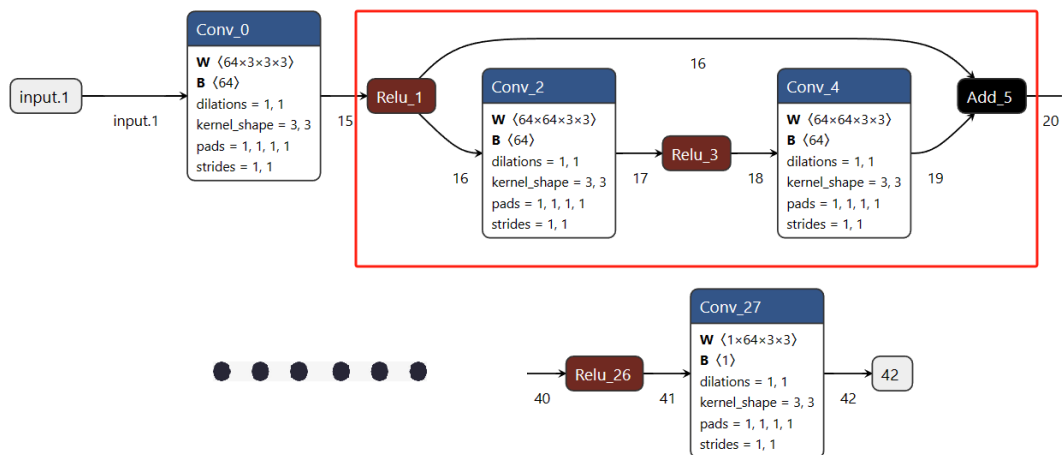


图 3-11 MagResNet 结构
Figure 3-11 MagResNet structure

(1) 均衡数据：全日面磁图中，活动区占很少面积，这造成了弱场和强场数据的不均衡性。此外，主要考虑解决磁饱和效应，且磁饱和效应发生在强磁场区域，因此，在训练的过程中可以对磁场数据进行切割，使其主要包含强磁场区域，然后进行训练。获取目标数据采用的方法为：循环随机选取 $150\text{pixel} \times 150\text{pixel}$ 大小的区域；对选区的最高磁场强度进行判断，直到磁场强度大于 500G 或者小于 -500G 时（纵场有正负之分，这里取绝对值大于 500G 来划尽量选出强磁场区域），跳出循环。完成数据的选取。

(2) 数据增广：通过随机旋转 0° 、 90° 、 180° 、 270° ；随机对数据进行镜像；随机数据正负反号三种方式对数据进行增广

(3) 损失函数：由于数据的不均衡性导致计算损失函数时对不同强度的磁场重视程度不一样，致使参数在空间中的损失函数下降方向发生变化。而经过训练网络的输出可能在强磁场数据上的损失依旧很高，但是弱场区域的损失减低也会使损失函数看上去很小，导致强场区域得不到充分训练。因此需要平衡数据集活动区和宁静区的数量差异，在这种情况下对不同强度的磁场进行加权可以有效对目标区域进行训练。

(4) 训练参数设置：训练集的 batch size 大小设为 8，验证集的 batch size 大小设为 5；以 Adam 算法为优化器；初始的学习率为 0.001，每 500 个 epoch 学习率除以 1.1。

3.2.2.3 平台和硬件

网络在 PyTorch 平台上搭建，使用了 GPU 加速训练，这在深度学习尤其是 CNN 中是常见的。硬件参数如表 3-2 所示：

表 3-2 MagResNet 实验环境

Table 3-2 Experimental Environment of MagResNet

Hardware Environment	Specifications
CPU	Intel Core i9-9900KF @ 3.60GHz 8-Core
RAM	64 GB
GPU	NVIDIA GeForce RTX 2070 (8 GB)
MainBoard	ASUS TUF Z390-PLUS GAMING

3.3 结果以及讨论分析

3.3.1 机器学习结果

全日面的训练结果见图 3-12。这里取了样本 2021 年 06 月 19 日的训练结果为例作为展示，图中，hr_v 表示怀柔基地全日面磁像仪观测的 Stokes 参数 V 信号，ML_BI 表示机器学习方法得到的纵场，hmi 表示 HMI 设备观测得到的纵场，res 为机器学习方法得到结果和 HMI 纵场之间的均方误差。图 HMI_BI-hr_v 表示 HMI 测得的纵场与怀柔基地观测的 Stokes 参数 V 信号之间的相关性，HMI_BI-Pre_BI 表示 HMI 测得的纵场和机器学习预测得到的结果之间的相关性。需要补充说明的是，在线性定标中，Stokes 参数 V 信号与纵场 BI 之间是线性关系，所以在对比实验结果时，对比 V 信号和 hmi 纵场的相关性即可。

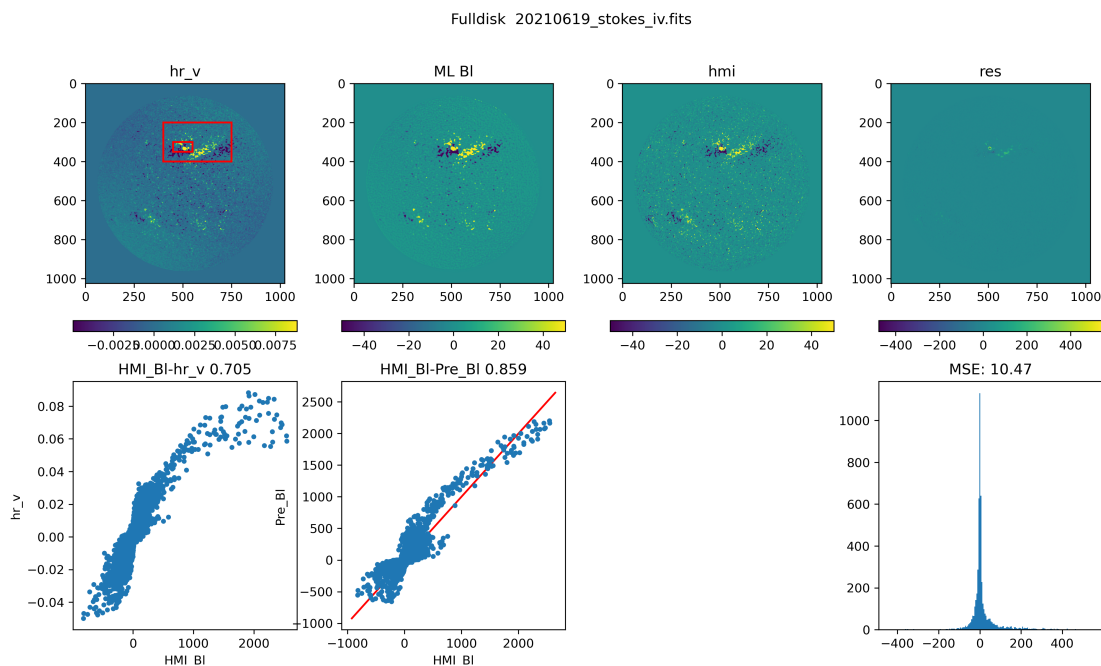


图 3-12 全日面训练结果

Figure 3-12 Full day training results

取图 3-12 较大的红色框所选取范围进行局部区域训练展示，结果见图 3-13，图标所示含义同 3-12。可以看出，在怀柔的 Stokes 参数 V 信号正极性区域中间存在暗斑，这实际上就是磁饱和效应。

截取图 3-12 中较小红色框选区域进行磁饱和效应的展示。在所选区域中，取




图 3-13 活动区训练结果
Figure 3-13 Activity Area Training Results

活动区截面数据（如图中红线所示）见图 3-14，图标所示含义同 3-12。从截面图上可以看出，Stokes 参数 V 信号在磁场强度较强区域存在明显磁饱和和效应，而使用机器学习方法得到的纵场 ML_BI 和 HMI 测得的纵场则没有磁饱和和效应，可以看出第一张图对应的图像可磁饱和效应得到了改善。机器学习结果和 HMI 纵场结果的均方误差为 77.18G，较全日面低（10.47G），分析原因可能是由于全日面宁静区域机器学习方法得到的结果与标签误差更小，因此平均误差较小。

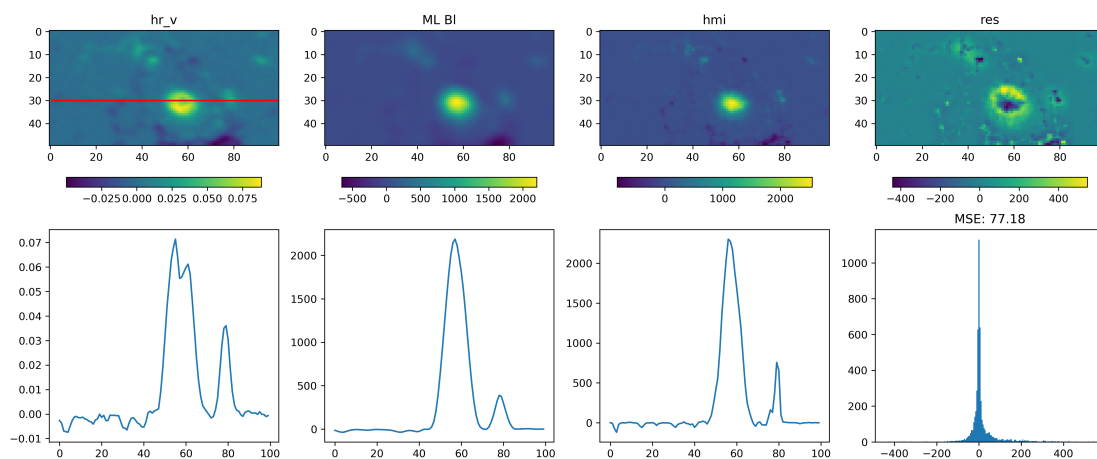


图 3-14 活动区磁场对比
Figure 3-14 Comparison of magnetic fields in activity areas

3.3.2 机器学习与线性定标比较

线性定标实际上就是 Stokes V 信号乘以定标系数得到的结果，考虑到不同模型下定标系数不同，本文从 Stokes V 信号和 HMI 纵场 B_l 的相关图对线性定标和机器学习方法进行对比。从图 3-12 中的结果可以看出，使用机器学习方法定标得到的磁场和 HMI 相关性为 0.859，高于线性定标结果和 HMI 相关性 (0.705)，其中，在高磁场强度区域，线性定标结果明显存在平缓趋势，而在机器学习定标结果则有更强的相关性，有效改善了磁饱和和效应。从活动区域的截面图结果 3-14 来看，机器学习获得的结果明显更符合黑子本影区域磁场强于周围区域的科学规律，说明了机器学习在改善磁饱和和效应中，有明显效果。

3.3.3 机器学习可解释性——定标曲面

由 Stokes 参数 I 、 V 定出 B_l 是一个非线性的复杂过程，该变量之间的关系可以用式 3-3 表示。

$$B_l = f(I, V) \quad (3-3)$$

神经网络生成模型的内在机制尚不明确，本文利用现有数据集。从统计学的角度对来拟合模型的输入和输出，给出 Stokes 参数 I 、 V 和 B_l 之间的关系。以 I 、 V 为坐标轴，绘制 B_l 的定标曲面 3-15。曲面绘制步骤如下：

- 1、计算输出参数的最大值和最小值作为 I 、 V 轴的坐标范围。
- 2、依据最大最小值生成网格矩阵
- 3、使用三维数据网格化，进行三维曲面的绘制。

横坐标为 Stokes 参量 I ，纵坐标为 Stokes 参量 V ，图表中的 B_l 表示纵场 B_l 。线性定标情况下，纵场强度 B_l 只与 V 相关，正是因为这样才导致了磁饱和效应。从定标曲面上可以看出，纵场 B_l 实际上和 Stokes 参量 I 、 V 存在这复杂的关系，在 V 较高的情况下， I 以相对较低的分量参与了实际的纵场。从定标曲面可以相对直观地看出纵场 B_l 上和 Stokes 参量 I 、 V 之间的关系。在三维曲面有效坐标范围内，给出 I 、 V 的值，可查到对应的磁场强度。总的来说，机器学习学得的模型为这个光滑连续的曲面模型，通过三维曲面可以直观地看到使用网络对磁场定标的模型。




图 3-15 定标曲面
Figure 3-15 Calibration surface

3.4 本章小结

本章从观测到的数据角度出发,对高质量磁场数据进行研究。以怀柔基地的全日面矢量磁像仪观测到的数据和对应同一时间段的 HMI 数据建立数据集,对机器学习中有监督算法下的卷积神经网络 ResNet 进行结构化的调整,并以此作为网络进行训练。输入为 Stokes 参数 I、V 标签为 HMI 纵场 B_l 进行磁饱和效应的解决。从结果上来看,跟线性定标的结果相比较,发生在活动区的磁饱和效应有了明显的改善,说明机器学习方法在解决磁饱和效应中的有效性。

第4章 历史数据应用挖掘

在对磁场高精度的测量进行研究后,本章对高质量数据发布以及怀柔基地历史数据的应用挖掘展开研究。建成于1984年的怀柔太阳观测基地是世界上最重要的太阳观测研究台站之一,在过去的40年里,太阳磁场望远镜一直保持良好的运行状态,滤光器始终处于恒温状态,已经积累了近4个太阳活动周的数据,这是目前世界上持续时间最久的太阳矢量磁场观测资料,且仍在积累中。它涵盖了第22太阳活动周(1986年-1996年),完整覆盖了第23-24太阳活动周(1996年-2019年),第25个太阳活动周(2020-今)的数据。这些数据是宝贵的科学财富,对这些数据的挖掘和应用具有十分重要的意义。一直以来怀柔基地的数据发布采取无差别发布的方式,在改进数据发布方式以及历史数据的挖掘应用上,是一个十分有意义的事情。本章从历史数据入手,对历史数据应用挖掘展开探索,估算历史白日视宁度数据。基于此提供了一种数据的甄选方式,本方法对于数据高质量的发布具有一定的意义。

视宁度 r_0 又称为Fried参数(Fried, 1966),是地球大气影响天体成像品质的量度。视宁度本质上是指波前相干直径,也是天文选址中的重要参数(刘忠等, 1993),其准确和长期观测记录对天文选址以及高分辨率成像都十分重要。比如在冷湖进行选址时,就对视宁度进行了长期的监测(Licai Deng, 2021),中国巨型太阳望远镜(Chinese Giant Solar Telescope, CGST)选址时,也对无名山视宁度进行了监测(T. F. Song, 2018; Song et al., 2021),自适应光学中的Shack-Hartmann波前传感器微透镜阵列的数量也取决于视宁度(Michael C. Roggemann, 1996)。此外,历史视宁度数据对于历史观测数据的甄选也具有重要的参考作用。目前,估算视宁度的方法主要分为两类,一种是用仪器来获得视宁度参数,比如使用太阳差分像运动视宁度检测仪(SDIMM, Solar Differential Image Motion Monitor)对白日视宁度估算(刘忠等, 2000; Liu Zhong, 2001),探空气球或者声雷达测量不同高度的大气温度结构常数,使用干涉仪中被大气干扰的干涉条纹推算视宁度(Wu et al., 2020)。另一种是通过算法来对视宁度进行估算,比如通过望远镜观测过程中拍摄的短曝光图像的斑点图来估算(Michael C. Roggemann, 1996; A, 1973),对于太阳这种扩展目标,常常使用谱比法,通过长曝光功率谱与短曝光功率谱的比值曲线来确定白日视宁度 r_0 (邓元勇等, 1994)。这两种方法获得的视宁度数据准确,但存在不足:由于SDIMM仪器和实际观测仪器的非同一性,无法反映数据获取时刻的实际视宁度情况。谱比法需要大量的短曝光数据,计算成本巨大。而且,这些方法都无法对历史的白日视宁度数据进行估算。而如何获得历史白日视宁度数据,为未来观测设备的升级提供参考,是一个十分重要且亟需开展的工作。

针对以上问题,本文提出了一种基于机器学习下神经网络的对长周期历史白日视宁度估算的方法。我们首先使用谱比法推算白日视宁度,然后对图像进

行主成分分析 (PCA, principal components analysis), 提出了一套有效的预处理方案。最后借助机器学习下 BP(back propagation) 神经网络 (闻新等, 2015; M, 1997; Haykin, 2008) 的强大非线性拟合能力建立起观测图像和白日视宁度之间的回归关系。最后通过训练集和验证集对机器学习方法进行了测试, 并基于历史的长期太阳光球观测数据对白日视宁度进行回溯估计, 检验怀柔太阳观测基地长期的视宁度稳定性。

4.1 数据来源

本文使用的数据来自怀柔太阳观测基地太阳磁场望远镜, 于 1985 年投入使用 (艾国祥等, 1982), 自运行以来, 采用了对太阳活动课题观测和常规观测资料长时间积累的两种主要运行方式, 为国内和国际太阳物理发展做出了重要的贡献。同时, 为我国的空间天气预报提供基础的太阳磁场观测数据。

本文选取的数据由两类构成: 一类是用谱比法建立训练神经网络并对方法进行测试的数据集, 这部分数据来自 2021 年一段时间内随机采集的单色像以及对应的短曝光图像。取其中的 70% 作为训练集, 30% 作为测试集, 在训练集中取 15% 作为验证集, 另一类是检验怀柔长期历史视宁度稳定性的数据集, 这部分数据主要包括了 1989 年-2010 年连续 22 年的单色像数据和 2020 年单独一整年的单色像数据。1989-2010 和 2020-2021 观测数据的像元分辨率和单帧曝光时间见表 4-1。

表 4-1 数据分辨率和单帧曝光时间
Table 4-1 数据分辨率和单帧曝光时间

DATA		
(YYYYMMDD)	Pixel resolution	Exposure time
19890101-20010825	$0.61'' \times 0.43''$	30ms – 60ms
20010825-20011130	$0.48'' \times 0.32''$	30ms – 60ms
20011201-20101231	$0.35'' \times 0.35''$	30ms – 60ms
20200101-20211212	$0.242'' \times 0.242''$	30ms – 60ms
2021 谱比法数据	$0.242'' \times 0.242''$	10ms

4.2 数据预处理

数据的预处理主要分为三个部分: 使用谱比法对观测到的短曝光图像进行计算, 获取视宁度 r_0 ; 对历史数据的分辨率进行调整; 使用主成分分析 (PCA, Principal Component Analysis) 方法对数据进行降维。

4.2.1 谱比法获取视宁度数据

谱比法是指通过将一组图像的实际谱比值与理论值比较得到视宁度 r_0 的方法, 最初由 O.von der Luehe 提出 (von der Luehe, 1984)。谱比 $\epsilon_{(u)}$ 的定义见公

式 (4-1):

$$\varepsilon_{(u)} = \frac{|\langle \tilde{I}_{(u)} \rangle|^2}{\langle |\tilde{I}_{(u)}|^2 \rangle} \quad (4-1)$$

其中 $|\langle \tilde{I}_{(u)} \rangle|^2$ 表示望远镜长曝光功率谱, $\langle |\tilde{I}_{(u)}|^2 \rangle$ 表示望远镜短曝光功率谱。“~”表示对物理量 I 的傅里叶变换, “ $\langle \rangle$ ”表示某段采样时间中的序列平均。“ $|\cdot|$ ”表示取模运算, $\tilde{I}_{(u)}$ 表示傅里叶变换后图像的能量强度, u 表示频域坐标变量。 $|\langle \tilde{I}_{(u)} \rangle|^2$ 的值迅速截止于 $\frac{r_0}{\lambda}$ 处, 其中 λ 为光波长, $\langle |\tilde{I}_{(u)}|^2 \rangle$ 截止于望远镜极限分辨率处。谱比曲线在 r_0 处会有一个突降, 只要在谱比曲线上找到这个点, 即可定出 r_0 。

4.2.2 历史数据分辨率调整

像质和 r_0 存在直接的对应关系, 像元分辨率直接影响到图像的像质进而对视宁度 r_0 产生影响。故需要将图像的分辨率调整为统一大小。构建训练集和测试集数据的像元分辨率大小 $0.484'' \times 0.484''$, 对照表 4-1, 将图像数据像元分辨率调整为大小 $0.484'' \times 0.484''$ 。

4.2.3 PCA 降维

最后, 本文对数据进行了主成分分析 (PCA), PCA 是一种无监督学习算法, 通过 PCA 将原始数据变换为一组各维度线性无关的数据, 然后提取数据的主要特征分量, 一方面可以消除小信号的干扰, 另一方面, 也使训练的网络轻量化, 从而加速收敛。PCA 降维的原理在第二章中已经介绍, 本章不在赘述。只介绍降维的方法和结果。本文将所有数据整合之后进行主成分分析, 最终将图像变换为 1 维数组 (该一维数组即图像通过 PCA 降维后映射的主成分)。本文所选取的 PCA 降维阶数为 60, 不同的阶数对图像的贡献率如图 4-1 中 a 所示, 重构前后的图像如图 4-1 中 b 所示:




图 4-1 主成分分析。(a) 不同阶数的 PCA 贡献率, (b) 重构前后图像对比

Figure 4-1 principal component analysis. (a) PCA contribution rates of different orders, (b) comparison before and after image reconstruction

可以看出, 当阶数为 60 时, 有效信息的成分达到了 99.9%, 图像重构前后无明显差异。说明了 PCA 降维的有效性。详细的数据预处理流程见图 4-2

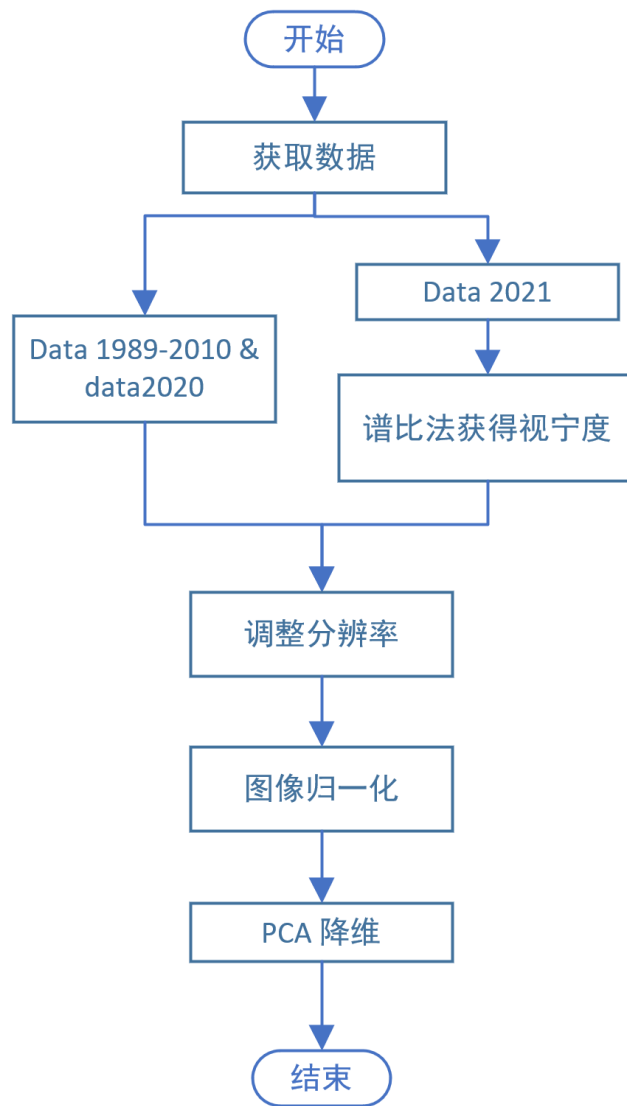


图 4-2 数据预处理流程

Figure 4-2 Data Preprocessing Workflow

4.3 基于 BP 神经网络的视宁度估算算法设计

图像和视宁度的对应关系很难用一个解析函数来表征, 这种多重非线性的回归关系可以借助 BP 神经网络模型的非线性拟合能力来建立得到. 本文提出的基于 BP 的视宁度估算网络的输入为一个 60 维的一维向量 (预处理之后的数据), 隐藏层一共 8 层, 输出为一个 $[1, 1]$ (数组大小为 1×1) 的数值 (r_0). 网络使用均方误差 (MSE, Mean Square Error) 作为 $Loss$ 函数, 计算公式 (4-2):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2 \quad (4-2)$$

隐藏层中使用 $ReLU$ (*Rectified linear units*) 作为激活函数. 网络参数的初始化采用随机初始化的方式. 学习率的设置如下, 初始阶段的学习率 lr 设为:

$$lr = 0.001 \quad (4-3)$$

训练过程中, 只要 $Loss$ 不断下降, 则学习率保持不变. 所有的数据完成一次训练记作一个 $epoch$, 当两个 $epoch$ 之间的 $Loss$ 下降小于 10^{-7} 或者验证分数增长小于 10^{-7} 时, 通过下面式子更新学习率:

$$lr^* = 0.2lr \quad (4-4)$$

其中 lr^* 为新学习率. 如果连续的 10 个 $epoch$ 中的验证分数提高小于 10^{-7} , 则终止训练. 为了防止程序一直训练下去, 训练的最大迭代次数设为 5000.

4.4 结果和分析

在呈现方法测试的结果时, 使用预测值和实际值的相关线 1:1 线来呈现网络的训练结果, 以方便对结果进行评价. 以图 4-3 为例, 横轴为实际值, 纵轴为预测值, 并且给出训练集和测试集的均方误差. 本实验主要包括方法测试, 2020 年整年视宁度预测结果, 连续 22 年的视宁度变化估算三个部分.

4.4.1 方法测试

本文使用谱比法获得的数据进行了方法测试. 从所有的数据中选取 70% 作为训练集, 30% 作为测试集. 实验结果如图 4-3 所示,

训练集和测试集的均方误差采用式 (4-5) 计算:

$$E_{MS} = \frac{1}{m} \sum_{i=1}^m (\hat{e}_i - e_i)^2 \quad (4-5)$$

其中 \hat{e}_i 表示标签值, e_i 表示预测值. 从实验结果来看, 训练集和测试集均方误差

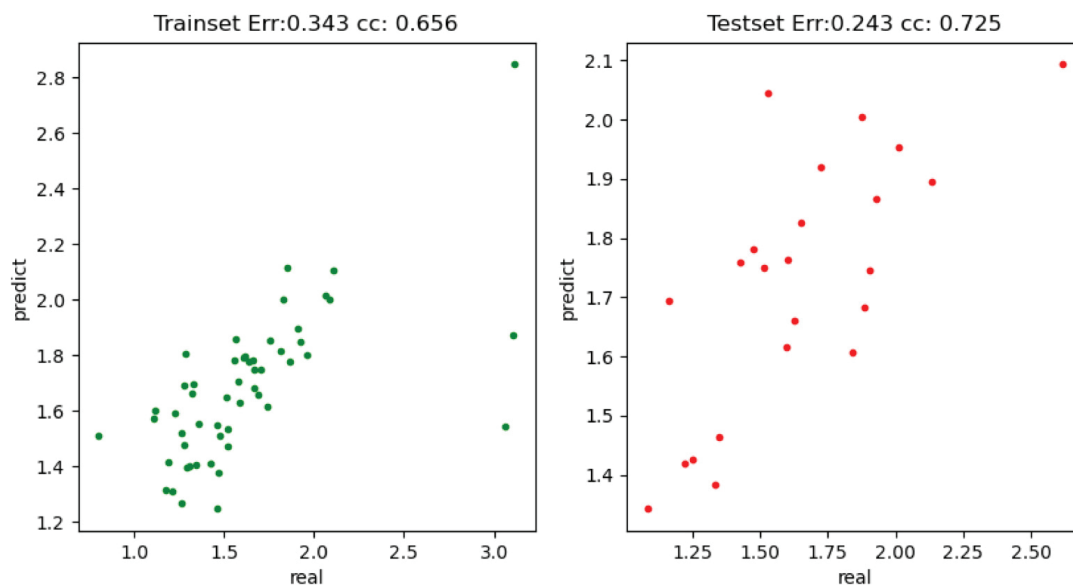


图 4-3 训练集和测试集相关图

Figure 4-3 Correlation Diagram of Training Set and Test Set

分别为 0.343 和 0.243，说明有 95% 以上的数据误差小于 0.68cm 和 0.48cm。对预测值和实际值的相关性通过 (4-6) 来计算。

$$r = \frac{\sum_{i=1}^n (x_i - \bar{X})(y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{Y})^2}} \quad (4-6)$$

其中 \bar{X} 和 \bar{Y} 分别代表 x , y 的均值，相关系数为 0.656 和 0.725。

结合训练集和测试集的实验，该结果说明在误差范围为 0.48cm 0.68cm 范围内，可以将本方法用于对观测图像的视宁度进行估算，估算结果的准确率为 95%。实验中，测试集的误差统计小于训练集的误差统计，分析原因可能是因为数据集的数量较少。

4.4.2 2020 年视宁度实际估算

使用训练的网络对 2020 年的数据进行估算，估算结果如图 4-4 所示：

横轴为月份，纵轴为视宁度 r_0 的值 (单位是 cm)。从 2020 年的数据估算结果可以看出，视宁度 r_0 的主要分布范围是在 1cm – 10cm 之间，大小符合实际情况。视宁度从 4 月到 10 月处于相对较高的范围，符合怀柔太阳观测数据质量的经验判断情况。也可以看出，视宁度在短时间内就有剧骤的变化，这也符合大气的实际变化情况。全年的视宁度中值为 2.89cm。

4.4.3 1989-2010 年视宁度实际估算

使用怀柔太阳观测基地积累的 1989-2010 年连续 22 年的太阳光球图像数据对视宁度进行估算，计算每一年的视宁度中值，连续 22 年的长期视宁度变化情




图 4-4 2020 年视宁度估算结果
Figure 4-4 r_0 forecast results in 2020

况如图 4-5所示:




图 4-5 1989-2010 视宁度年中值变化曲线
Figure 4-5 r_0 Annual median change curve of seeing acuity from 1989 to 2010

横轴为年份，纵轴为视宁度 r_0 的值。从图上来看，视宁度的变化基本分布在 $2.5\text{cm} - 3\text{cm}$ 之间，说明两个太阳活动周内，怀柔观测基地的视宁度稳定。

如果取所有年份相同月的视宁度中值，从 1-12 月的视宁度变化曲线如图 4-6 所示:

图中，横轴为月份，纵轴为视宁度大小。可以看出，4 月相较相邻两月视宁度好，9 月的视宁度条件较其他月份要好，达到了 3.06cm 。这个实验结果符合一




图 4-6 1-12 月的视宁度变化曲线
Figure 4-6 seeing change curve from January to December

年中实际观测经验情况。同时也验证了观测经验上 9 月份的图像数据质量相对其他月份要更好。

挑选基本上一天内同一时刻的 2016 年的 1 月到 12 月的光球活动区进行展示，见图 4-7。图标题为拍摄日期，可以定性地看出，8 月末 9 月份的图像质量好于其他时期，既符合观测的经验，也符合本方法提出的神经网络的预测结果。




图 4-7 1 月到 12 月的光球图
Figure 4-7 The partial photosphere images from January to December

对所有数据进行视宁度 $r_0 > 3cm$ 所占总数的百分比进行统计，见图 4-8。横轴为年份，纵轴表示视宁度 $r_0 > 3cm$ 所占的百分比。从图上可以看出，从 1989




图 4-8 1989-2010 视宁度值大于 3cm 所占的百分比
 Figure 4-8 Percentage of seeing acuity value greater than 3cm from 1989 to 2010

年开始到 2010 年几乎每年都有超过 20% 的数据在视宁度大于 3cm 的情况下拍摄得到，最高有 59.5% 的数据是在视宁度 $r_0 > 3cm$ 的情况下拍摄得到。该结果说明了怀柔太阳观测基地观测时间段内，有相当比例的时间视宁度条件稳定。

所有数据中，不同大小视宁度占比统计如图 4-9 所示：




图 4-9 视宁度占比。(a) 不同大小视宁度占比，(b) 不同区间视宁度占比
 Figure 4-9 Proportion of seeing. (a) Proportion of different sizes of seeing, (b) Proportion of seeing in different sections

从图上来看，1989 年-2010 年连续 22 年的视宁度数据 $r_0 > 3cm$ 的数据占到 40% 以上，说明怀柔太阳观测基地有 40% 以上的时间具相对稳定的视宁度条件。

4.5 本章小结

本章节从已有的图像数据获取历史视宁度数据的问题出发, 使用现有设备观测的图像数据训练网络, 提出了一种基于神经网络的天文台址长期视宁度变化估算方法。本文首先使用现有设备获取图像以及对应的多帧短曝光图像, 然后通过谱比法得到叠加图像对应的视宁度 r_0 , 完成数据集的构建。在数据的预处理上, 采用 PCA 主成分分析的方法对数据进行了有效降维。进一步, 提出了一种基于 BP 回归网络的机器学习方案。然后对方案进行了验证, 并对单个年份和连续 22 年的视宁度结果进行了估算, 方法快速, 有效。

在对方法测试的实验中, 将数据集随机分配 70% 作为训练集, 30% 作为测试集。从实验结果来看, 训练集和测试集的预测结果和标签值存在较强相关性, 有 95% 以上的数据误差小于 0.68 和 0.48。说明了对于用已有图像数据估算视宁度这一问题而言, 该方法是有效的。在对 2020 年单个年份进行测试的实验中, 可以看出视宁度在一整年内变化的趋势和实际的观测情况基本上相吻合, 说明了本方法的有效性。

从 1989 年到 2010 年连续 22 年的视宁度估算结果来看, 怀柔基地的视宁度长期稳定在 3cm 左右。在所有观测时间段内, 至少有超过 20% 的时间视宁度大于 3cm, 一年中最高有 59.5% 的时间视宁度 $r_0 > 3cm$ 。

本章主要讲述以一个新的方式——机器学习的方式建立图像和视宁度的直接对应关系, 并对天文台址长期视宁度变化进行了估算。在未来的应用中, 可以使用该方法对其他台址的历史视宁度进行估算。本章所提出的方法必定有改进空间, 本章使用了积累的较少的数据集进行实验, 这也是导致预测集的均方误差 E_{MS} 比训练集小的原因。更多的数据可以帮助构建更稳定的网络, 因此需要在这方面加以改进。此外, 在数据集质量的改进方面, 还可在图像观测时, 实时用 SDIMM 仪器同步记录视宁度的大小, 以此构建数据集, 进行该方法系统误差更精确的估计。如何改进视宁度的估算方法, 以及改进后的方法用于图像帧选择将是下一步的研究内容。

第5章 总结与展望

磁场作为太阳活动的主要推动物理量，与黑子、谱斑、日珥和日冕物质抛射有着密切的关系。对太阳磁场的测量和研究不仅有助于理解太阳磁场的起源、太阳活动的成因、能量积累和释放过程，同时对空间天气预报有着极大的推动作用。太阳磁场的测量理论方法已经发展了百余年，高精度、高时间分辨率磁场测量一直是太阳物理的重点研究方向。目前磁场测量方式基本上都是基于塞曼效应原理间接测量，需要首先选定测量的谱线，然后在谱线的不同点处进行观测，获得 Stokes 偏振参数后，通过定标或反演获得磁场。反演方式提供了相对精确的磁场测量参量，已经较为成熟，但是对假设模型的依赖性较强，而且反演的时间过长。而线性定标方法虽然可以获得高时间分辨率的磁场，但是定标结果存在磁饱和效应。

随着科技的发展，人类已经进入了人工智能大数据时代。机器学习可以直接从数据中学习，从而加速复杂的模型建立。机器学习已经逐渐应用到了天文学、太阳物理学中，且显现出了巨大的应用潜力。应用机器学习研究太阳物理科学问题可以大大增强太阳物理学家对太阳科学领域复杂过程的理解。比如通过分析来自太阳的大量数据，可以对太阳剧烈活动诸如耀斑爆发、日冕物质抛射等事件有新的理解。太阳物理是一门观测科学，我们无法改变实验条件，只能进行观测。因此，唯一的方法是不断建立新的模型并不断调整，直至模型可以解释观测到的现象。随着观测数据的迅速积累，使用机器学习强大的数据处理能力可以直接从数据中判别模型。从概率的角度来看，机器学习不断地对数据的分布进行建模，从观察中直接判断数据属性。

本文针对怀柔基地目前磁场测可改进的地方，使用机器学习方法以一个新的角度——数据驱动和数据挖掘的角度对高精度磁场测量展开研究。从观测位置准确性、观测数据准确性以及长周期历史数据挖掘应用三个方面入手，对高精度太阳磁场测量和定标方法进行研究。本文的创新点主要有三点：

- (1) 将机器学习的方法应用在了怀柔太阳观测基地高精度磁场测量的实际应用中。
- (2) 首次将机器学习方法应用在窄带滤光器工作谱线波长位置定标中。
- (3) 首次使用机器学习的方法进行了历史数据长周期的视宁度估算。

下面对研究工作进行总结，并对下一步的工作计划展开描述。

5.1 工作总结

1、从太阳工作谱线波长位置准确性展开研究，提出了一种基于机器学习的定标方法，比传统的方法快 100 多倍。滤光器型磁像仪在固定工作谱线波长位置观测时，受到温度变化、机械误差等因素影响，工作谱线波长位置发生偏移。传

统的工作谱线波长位置定标方法通过拟合谱线轮廓来对观测点进行定标, 耗时多且无法实时校正工作谱线波长位置。为此提出一种基于神经网络的工作谱线波长位置的高效定标方法。该方法首先通过分析不同工作谱线波长位置处测得的图像之间的特征差异, 设计一套有效的数据预处理方案; 然后通过神经网络建立起实时观测图像与对应工作谱线波长位置的非线性关系。方法验证和实际测试的结果表明该方法比现有的方法快 100 多倍, 同时可监测仪器运行状态。最后, 针对磁像仪系统频繁维修后需重新训练网络的问题, 给出克服系统变化的方案。该方法可实现滤光器位置实时定标, 有效减少定标过程中电机频繁旋转带来的滤光器工作寿命缩短现象, 提高地面和空间太阳磁场观测的效率和稳定性。

2、磁场定标, 从机器学习的角度对线性定标中的磁饱和效应展开研究, 有效解决线性定标带来的磁饱和效应。线性定标是 Stokes V 信号乘以定标系数得到的结果, 考虑到不同模型下定标系数不同, 本文从 Stokes V 信号和 HMI 纵场 B_l 的相关图对线性定标和机器学习方法进行对比。使用机器学习方法定标得到的磁场和 HMI 相关性为 0.859, 高于线性定标结果与 HMI 相关性 (0.705)。从对比图的趋势来看, 在高磁场强度区域, 线性定标结果明显存在平缓趋势, 而机器学习定标结果有效改善了磁饱和效应。从活动区域的截面图结果来看, 机器学习获得的结果明显更符合黑子本影区域磁场强于周围区域的科学规律, 说明了机器学习对于改善磁饱和效应有明显效果。

3、对怀柔基地长周期历史数据的挖掘与应用展开研究, 估算了历史视宁度数据。视宁度好坏是影响天文观测图像质量的一个决定性因素, 目前白日视宁度数据主要是通过太阳差分像运动视宁度检测仪 (SDIMM) 或者谱比法获得。由于 SDIMM 和实际观测仪器的非同一性, 其测得的视宁度无法反映数据获取时刻的实际视宁度情况, 也无法回溯历史既有观测数据对应的大气视宁度。而使用谱比法需要海量短曝光数据, 计算成本巨大。基于以上天文观测面临的困难, 提出了一种基于神经网络的白日视宁度估算方法。该方法首先使用谱比法对获得的短曝光数据计算对应的视宁度 r_0 , 构建数据集; 然后使用主成分分析对数据进行降维, 通过神经网络建立起窄带滤光器太阳光球观测图像和视宁度之间的非线性回归关系。训练集和测试集的实验结果表明该方法可以用于估算视宁度。使用该方法对怀柔观测基地 2020 年的白日视宁度进行估算, 视宁度中值为 2.89cm, 对 1989 年至 2010 年连续 22 年的观测数据进行白日视宁度的长期统计分析, 结果表明怀柔基地发布的历史数据对应的白日视宁度中值在 3cm 左右, 大于 3cm 以上的白日视宁度超过 40%, 一年中 9 月份的视宁度最好, 该结果验证了怀柔基地白日视宁度长期稳定。此外, 该方法也可以从白日视宁度 r_0 的快速判断出发, 为采集到的高质量短曝光图像帧选提供判断依据。

5.2 未来展望

本文从以机器学习的角度, 分别从观测位置准确性、磁场测量准确性对高精度太阳磁场测量展开研究, 对怀柔基地历史数据的挖掘应用与发布展开研究。对

于接下来的工作，可以从以下几个方面继续展开：

1、在工作谱线波长位置标定的工作中，探索了一种基于机器学习的波长定标方法，在怀柔全日面磁场望远镜观测中进行测试。接下来的工作将主要放在：（1）工作谱线波长位置定标网络准确性和稳定性的研究，以及在其他仪器设备，如赣榆观测站太阳望远镜、AIMS 望远镜。（2）以上工作是针对白光像进行的探索，偏振测量的准确性和稳定性对磁场的测量同样十分重要，可以从偏振图像出发，探索一种有反馈调节的机制偏振测量系统。（3）该方法可以应用到未来空间磁像仪极区探测中，在观测中以图像这一单一变量作为因素引入反馈机制，提高磁场、速度场的测量精度。

2、磁场定标中，太阳磁场纵场的磁饱和效应得到了一定的改善，接下来的工作可以包括：（1）机器学习物理过程解释：使用机器学习进行磁场的定标时，尽管使用定标曲面从统计学的角度对 Stokes 参数 I 、 V 和纵场的关系进行解释，还需要从物理角度对机器学习解决磁饱和效应的方法进行解释。（2）对横场和方位角进行定标，建立从 Stokes 参数到矢量磁场的定标。（3）使用机器学习方法对滤光器误差进行探索，使用测得的数据和解析函数的谱线轮廓进行映射建立，得到更高精度的磁场。

3、传统的 SDIMM 设备口径大、精密零件多，造价昂贵且不便于多点测量，使用机器学习方法可以低成本地进行视宁度的测量，为大口径太阳望远镜的建设提供支持。接下来可从：（1）多点对圆顶视宁度进行测量。（2）以视宁度作为图像质量评价参考，选帧叠加，提高磁场测量精度。（3）将机器学习方法本地化部署，迁移到 FPGA、ARM 等芯片上，实现视宁度实时动态监测。

参考文献

- 艾国祥, 胡岳风, 1986. 太阳磁场望远镜的工作原理[J]. 天文学报(02): 173-180.
- 艾国祥, 李威, 张洪起, 1982. Fe I λ 5324.19 Å 在太阳磁场中的形成和太阳磁场望远镜的理论定标[J]. 天文学报, 23(1): 39-48.
- 白先勇, 邓元勇, 王怡然, 等, 2018. 利用太阳自转提取全日面太阳望远镜的平场和偏振本底[J]. 科学通报, 63(3): 301-310.
- 邓元勇, 甘为群, 颜毅华, 等, 2020. 太阳磁场探测现状与展望[J]. 红外与激光工程, 11(49): 230-236.
- 林元章, 2000. 太阳物理导论[M]. 北京: 科学出版社.
- 玄伟佳, 王东光, 邓元勇, 2010. 双折射滤光器的误差分析与性能优化[J]. 光学精密工程, 18(1): 52-59.
- 叶跟红, 叶中付, 祝佳, 2013. 基于分段拟合的 LAMOST 波长定标方法[J]. 天文学报, 54(5): 478-488.
- 刘忠, 仇朴章, 邱耀辉, 1993. 差分像运动视宁度测量实验[J/OL]. 云南天文台台刊(04): 22-30. DOI: 10.14005/j.cnki.issn1672-7673.1993.04.004.
- 刘忠, 楼柯, 张瑞龙, 等, 2000. 白日视宁度监测仪和在抚仙湖的初步观测结果[J/OL]. 云南天文台台刊(04): 95-100. DOI: 10.14005/j.cnki.issn1672-7673.2000.04.019.
- 杨盼, 曾曙光, 刘锁, 等, 2018. 基于尺度不变特征点匹配的太阳磁场图像配准与定位方法[J/OL]. 天文研究与技术, 15(01): 59-68. DOI: 10.14005/j.cnki.issn1672-7673.20171106.002.
- 林佳本, 2009. 高分辨率太阳观测方法的研究[D]. 中国科学院国家天文台.
- 王亚男, 2005. 向我们走来的绿色电力[J]. 环境经济(05): 16-23+7.
- 王建民, 钱忠钰, 艾国祥, 等, 1977. 沙河、兴隆、怀柔太阳光学观测候选台址的比较(二)——近地面层大气温度脉动观测[J/OL]. 天文学报(02): 182-191+275. DOI: 10.15940/j.cnki.0001-5245.1977.02.004.
- 白先勇, 2014. 太阳活动区的矢量磁场测量研究[D]. 中国科学院国家天文台.
- 艾国祥胡岳风, 1986. 多通道双折射滤光器——原理和视频光谱仪[J/OL]. Science in China Series A-Mathematics, Physics, Astronomy Technological Science (in Chinese), 16(8): 889-896. [http://www.sciengine.com/publisher/ScienceChinaPress/journal/ScienceinChinaSeriesA-Mathematics,Physics,Astronomy&TechnologicalScience\(inChinese\)/16/8/10.1360/za1986-16-8-889](http://www.sciengine.com/publisher/ScienceChinaPress/journal/ScienceinChinaSeriesA-Mathematics,Physics,Astronomy&TechnologicalScience(inChinese)/16/8/10.1360/za1986-16-8-889). DOI: <https://doi.org/10.1360/za1986-16-8-889>.
- 苏江涛, 2004. 太阳矢量磁场测量[D]. 中国科学院国家天文台.
- 邓元勇, 艾国祥, 张斌, 等, 1994. 太阳宁静区的高分辨率像复原[J]. 天文学报(04): 380-386.
- 闻新, 李新, 张兴旺, 2015. 应用 MATLAB 实现神经网络[M]. 北京: 国防工业出版社.
- 颜毅华, 邓元勇, 甘为群, 等, 2023. 空间太阳物理学科发展战略研究[J]. 空间科学学报, 43(02): 199-211.
- A B L, 1605. Wavelength calibration of arc spectra using intensity modelling[J/OL]. Monthly Notices of the Royal Astronomical Society, 409(4): 1601. DOI: 10.1111/j.1365-2966.2010.17403.x.
- A L, 1973. Attainment of diffraction limited resolution in large telescopes by fourier analysing speckle patterns in star images[J]. Astronomy and Astrophysics, 6: 85.
- BABCOCK H W, 1953. The solar magnetograph[J/OL]. Astrophysical Journal, 118: 387. <https://articles.adsabs.harvard.edu/pdf/1953ApJ...118..387B>.

- Beckers J M, 1969. The Profiles of Fraunhofer Lines in the Presence of Zeeman Splitting. I: The Zeeman Triplet[J/OL]. , 9(2): 372-386. DOI: [10.1007/BF02391659](https://doi.org/10.1007/BF02391659).
- Bobra M G, Couvidat S, 2015. Solar Flare Prediction Using SDO/HMI Vector Magnetic Field Data with a Machine-learning Algorithm[J/OL]. , 798(2): 135. DOI: [10.1088/0004-637X/798/2/135](https://doi.org/10.1088/0004-637X/798/2/135).
- Boucheron L E, Al-Ghraibah A, McAteer R T J, 2015. Prediction of Solar Flare Size and Time-to-Flare Using Support Vector Machine Regression[J/OL]. , 812(1): 51. DOI: [10.1088/0004-637X/812/1/51](https://doi.org/10.1088/0004-637X/812/1/51).
- Byrne J P, Morgan H, Habbal S R, et al., 2012. Automatic Detection and Tracking of Coronal Mass Ejections. II. Multiscale Filtering of Coronagraph Images[J/OL]. , 752(2): 145. DOI: [10.1088/0004-637X/752/2/145](https://doi.org/10.1088/0004-637X/752/2/145).
- C W, 2009. Theorie der linearen wechselstrom schaltungen[M]. Jägerberg: Akademie.
- Deng Y Y, Zhang H Y, Yang J F, et al., 2019. Design of the Full-disk MagnetoGraph (FMG) onboard the ASO-S[J/OL]. Research in Astronomy and Astrophysics, 19(11): 157. DOI: [10.1088/1674-4527/19/11/157](https://doi.org/10.1088/1674-4527/19/11/157).
- Elmore D F, Lites B W, Tomczyk S, et al., 1992. The Advanced Stokes Polarimeter - A new instrument for solar magnetic field research[C/OL]//Goldstein D H, Chipman R A. Society of Photo-Optical Instrumentation Engineers (SPIE) Conference Series: Vol. 1746 Polarization Analysis and Measurement. 22-33. DOI: [10.1117/12.138795](https://doi.org/10.1117/12.138795).
- Florios K, Kontogiannis I, Park S H, et al., 2018. Forecasting Solar Flares Using Magnetogram-based Predictors and Machine Learning[J/OL]. , 293(2): 28. DOI: [10.1007/s11207-018-1250-4](https://doi.org/10.1007/s11207-018-1250-4).
- FRIED D L, 1966. Optical resolution through a randomly inhomogeneous medium for very long and very short exposures[J/OL]. J. Opt. Soc. Am., 56(10): 1372-1379. <https://opg.optica.org/abstract.cfm?URI=josa-56-10-1372>. DOI: [10.1364/JOSA.56.001372](https://doi.org/10.1364/JOSA.56.001372).
- Grim L F L, Gradvohl A L S, 2024. Solar Flare Forecasting Based on Magnetogram Sequences Learning with Multiscale Vision Transformers and Data Augmentation Techniques[J/OL]. , 299(3): 33. DOI: [10.1007/s11207-024-02276-0](https://doi.org/10.1007/s11207-024-02276-0).
- GURTOVENKO E A K N N, Fedorchenko G L, 1982. The empirical determination of damping constants in the solar photosphere[J/OL]. Solar Physics, 77(1): 291-297. DOI: <https://doi.org/10.1007/BF00156112>.
- Hagyard M J, Cumings N P, West E A, et al., 1982. The MSFC Vector Magnetograph[J/OL]. , 80(1): 33-51. DOI: [10.1007/BF00153422](https://doi.org/10.1007/BF00153422).
- Hale G E, 1908. On the Probable Existence of a Magnetic Field in Sun-Spots[J/OL]. Terrestrial Magnetism and Atmospheric Electricity, 13(4): 159-160. DOI: [10.1029/TE013i004p00159](https://doi.org/10.1029/TE013i004p00159).
- Harvey J, Giampapa M, Henney C, et al., 2004. Early Results from SOLIS[C]//American Astronomical Society Meeting Abstracts: Vol. 204 American Astronomical Society Meeting Abstracts #204. 37.01.
- HAYKIN S O, 2008. Neural networks and learning machines[M]. New York: Pearson.
- HAYKINS, 2009. Neural networks and learning machines[M]. New York: Prentice Hall.
- HE K, ZHANG X, REN S, et al., 2015. Deep residual learning for image recognition: arXiv:1512.03385[M/OL]. arXiv[2024-05-14]. <http://arxiv.org/abs/1512.03385>.
- HENWOOD R, CHAPMAN S C, WILLIS D M, 2010. Increasing lifetime of recurrent sunspot groups within the greenwich photoheliographic results[J/OL]. Solar Physics, 262(2): 299-313 [2024-05-14]. <http://link.springer.com/10.1007/s11207-009-9419-5>.
- HOEKSEMA J T, LIU Y, HAYASHI K, et al., 2014. The helioseismic and magnetic imager (HMI)

- vector magnetic field pipeline: Overview and performance[J/OL]. *Solar Physics*, 289(9): 3483-3530[2023-09-11]. <http://link.springer.com/10.1007/s11207-014-0516-8>.
- HONGQI ZHANG Y D K H J L, DongGuang Wang, 2007. Solar magnetism and the activity telescope at hsos[J]. *Chinese Journal of Astronomy and Astrophysics*(2): 281-288.
- HU T Z, ZHANG Y, CUI X Q, et al., 2020. Telescope performance real-time monitoring based on machine learning[J/OL]. *Monthly Notices of the Royal Astronomical Society*, 500(1): 388-396. <https://doi.org/10.1093/mnras/staa3087>.
- HU Z, JI K, CHEN J, et al., 2022. Calibration scheme for space-borne full-disk vector magnetograph under the influence of orbiter velocity[J/OL]. *Astronomy Astrophysics*, 666. DOI: [10.1051/0004-6361/202142920](https://doi.org/10.1051/0004-6361/202142920).
- HUANG X, WANG H, XU L, et al., 2018. Deep learning based solar flare forecasting model. i. results for line-of-sight magnetograms[J/OL]. *The Astrophysical Journal*, 856(1): 7. <https://dx.doi.org/10.3847/1538-4357/aaae00>.
- HUDSON H S, 2021. Carrington events[J/OL]. *araa*, 59: 445-477. DOI: [10.1146/annurev-astro-112420-023324](https://doi.org/10.1146/annurev-astro-112420-023324).
- ILINSKY Y, LAPSHINA V, VERZHUTSKY D, et al., 2022. Genetic evidence of an isolation barrier between flea subspecies of *Citellophilus tesquorum* (wagner, 1898) (siphonaptera: Ceratophyllidae)[J/OL]. *Insects*, 13(2). <https://www.mdpi.com/2075-4450/13/2/126>. DOI: [10.3390/insects13020126](https://doi.org/10.3390/insects13020126).
- JI K, LIU H, JIN Z, et al., 2019. An automatic approach of mapping the solar high-resolution image to helioprojective-cartesian coordinates system[J/OL]. *Chinese Science Bulletin*, 64(16): 1738-1746[2023-09-11]. <http://engine.scichina.com/doi/10.1360/N972019-00092>.
- JINGJING GUO Y D H L J L J S X Y K J, Xianyong Bai, 2020. A non-linear magnetic field calibration method for filter-based magnetographs by multilayer perceptron[J/OL]. *Solar Physics*, 295(1): 5. <https://doi.org/10.1007/s11207-019-1573-9>.
- LICAI DENG X C F H Q L B Z C Z K W N L A R Z L Z Y J T J P, Fan Yang, 2021. Lenghu on the tibetan plateau as an astronomical observing site[J/OL]. *Nature*, 596(7872): 353-356. <https://doi.org/10.1038/s41586-021-03711-z>.
- Lites B W, Skumanich A, Rees D E, et al., 1988. Stokes Profile Analysis and Vector Magnetic Fields. IV. Synthesis and Inversion of the Chromospheric MG i B Lines[J/OL]. , 330: 493. DOI: [10.1086/166487](https://doi.org/10.1086/166487).
- LIU C, DENG N, WANG J T L, et al., 2017. Predicting solar flares using SDO/HMI vector magnetic data products and the random forest algorithm[J/OL]. *The Astrophysical Journal*, 843(2): 104 [2024-05-14]. <https://iopscience.iop.org/article/10.3847/1538-4357/aa789b>.
- LIU ZHONG J M B, 2001. Comparative solar seeing and scintillation studies at the fuxian lake solar station[J/OL]. *Solar Physics*, 198(1): 197-209. <https://doi.org/10.1023/A:1005262911134>.
- LOWE D G, 2004. Distinctive image features from scale-invariant keypoints[J/OL]. *International Journal of Computer Vision*, 60(2): 91-110[2024-04-13]. <http://link.springer.com/10.1023/B:VISI.0000029664.99615.94>.
- M M T, 1997. Machine learning[M]. New York: McGraw-Hill.
- Mein P, 2002. The MSDP of THEMIS: Capabilities, first results and prospects[J/OL]. , 381: 271-278. DOI: [10.1051/0004-6361:20011418](https://doi.org/10.1051/0004-6361:20011418).
- MICHAEL C. ROGGEMANN B M W, 1996. Imaging through turbulence[M]. Boca Raton: CRC Press.

- NAIR V, HINTON G E, 2010. Rectified linear units improve restricted boltzmann machines[C]// ICML'10: Proceedings of the 27th International Conference on International Conference on Machine Learning. Madison, WI, USA: Omnipress: 807-814.
- QU W Z, HUANG F, ZHAO J P, et al., 2007. The significance of solar magnetic field direction variation on anomalous variability of the atmosphere temperature on the earth[J/OL]. Chinese Journal of Geophysics, 50(5). DOI: [10.1002/cjg2.1131](https://doi.org/10.1002/cjg2.1131).
- Qu Z Q, Zhang X Y, Chen X K, et al., 2001. A Solar Stokes Spectrum Telescope[J/OL]. , 201(2): 241-251. DOI: [10.1023/A:1017978822648](https://doi.org/10.1023/A:1017978822648).
- SAMANTA T, 2020. Generation of Solar Spicules and Subsequent Atmospheric Heating[J]. Bulletin of the AAS.
- Scherrer P H, Bogart R S, Bush R I, et al., 1995. The Solar Oscillations Investigation - Michelson Doppler Imager[J/OL]. , 162(1-2): 129-188. DOI: [10.1007/BF00733429](https://doi.org/10.1007/BF00733429).
- SEANP, 2019. Retrospect:october19 – november7,2003:halloweensolarstorms[J]. WEATHERWISE, 72(5).
- SONG T, LIU Y, CAI Z, et al., 2021. Evaluation of the day-time ground-level turbulence at Mt Wumingshan with a microthermal sensor[J/OL]. Monthly Notices of the Royal Astronomical Society, 505(2): 3070-3077. <https://doi.org/10.1093/mnras/stab1469>.
- Stenflo J O, 2007. Solar polarimetry with ZIMPOL . Plans for the future[J]. , 78: 181.
- STENFLO J O, 1994. Astrophysics and space science library: Vol. 189 solar magnetic fields [M/OL]. Dordrecht: Springer Netherlands[2024-04-15]. <http://link.springer.com/10.1007/978-94-015-8246-9>.
- SÁNCHEZ S F, 2006. Techniques for reducing fiber-fed and integral-field spectroscopy data: An implementation on r3d[J/OL]. Astronomische Nachrichten, 327(9): 850. <https://doi.org/10.48550/arXiv.astro-ph/0606263>. DOI: <https://doi.org/10.1002/asna.200610643>.
- T. F. SONG Y L A E A S K M Y Z X F Z X B L J X W Y F X M C F Y X, Y. M. Wen, 2018. utomatic solar seeing observations at mt. wumingshan in western china[J/OL]. Solar Physics, 293(2): 37. <https://doi.org/10.1007/s11207-018-1254-0>.
- Tsuneta S, Ichimoto K, Katsukawa Y, et al., 2008. The Solar Optical Telescope for the Hinode Mission: An Overview[J/OL]. , 249(2): 167-196. DOI: [10.1007/s11207-008-9174-z](https://doi.org/10.1007/s11207-008-9174-z).
- Unno W, 1956. Line Formation of a Normal Zeeman Triplet[J]. , 8: 108.
- VON DER LUEHE O, 1984. Estimating fried' s parameter from a time series of an arbitrary resolved object imaged through atmospheric turbulence[J/OL]. Journal of The Optical Society of America A-optics Image Science and Vision, 1: 510-519. <https://api.semanticscholar.org/CorpusID:124862911>.
- WU S, HU X, HAN Y, et al., 2020. Measurement and analysis of atmospheric optical turbulence in lhasa based on thermosonde[J/OL]. Journal of Atmospheric and Solar-Terrestrial Physics, 201: 105241. <https://www.sciencedirect.com/science/article/pii/S1364682620300584>. DOI: <https://doi.org/10.1016/j.jastp.2020.105241>.
- XU H, LIU S, SU J, et al., 2021. Automatic detection and correction algorithms for magnetic saturation in the SMFT/HSOS longitudinal magnetograms[J/OL]. Research in Astronomy and Astrophysics, 21(3): 067[2023-09-11]. <http://arxiv.org/abs/2009.03597>. DOI: [10.1088/1674-4527/21/3/067](https://doi.org/10.1088/1674-4527/21/3/067).
- YANG XIAO G Y G J L G, Zhang HongQi, 2012. A statistical study on photospheric magnetic nonpotentiality of active regions and its relationship with flares during solar cycles 22-23[J/OL]. Solar Physics, 280(1): 165-181. <https://doi.org/10.1007/s11207-012-0061-2>.

- YUAN Y, SHIH F Y, JING J, et al., 2010. Automated flare forecasting using a statistical learning technique[J/OL]. *Research in Astronomy and Astrophysics*, 10(8): 785-796. DOI: [10.1088/1674-4527/10/8/008](https://doi.org/10.1088/1674-4527/10/8/008).
- Zhang L, Yin J Q, Lin J B, et al., 2017. Detection of Coronal Mass Ejections Using Multiple Features and Space-Time Continuity[J/OL]. , 292(7): 91. DOI: [10.1007/s11207-017-1107-2](https://doi.org/10.1007/s11207-017-1107-2).
- Zirin H, 1985. Evolution of weak solar magnetic fields[J/OL]. *Australian Journal of Physics*, 38: 961-969. DOI: [10.1071/PH850961](https://doi.org/10.1071/PH850961).

致 谢

在完成我的博士学位论文之际，我首先想要表达深深的感激之情，特别感谢我的导师邓元勇研究员。邓老师不仅对课题的全局有着精准的把握，而且在论文撰写的每一个环节都给予了我极大的帮助，提出了宝贵的修改和完善意见。他的耐心指导和专业建议是我能够完成这项研究的坚实基础。

我也要向杨尚斌研究员表示诚挚的感谢，他为课题的研究思路提供了开阔的视野，独到的见解和建议极大地丰富了我的研究视角，并对论文提出了许多重要的修改建议。杨老师的见解和帮助对提升我的研究质量起到了关键作用。

对于季凯帆研究员在课题技术方面给予的无私帮助，我表示衷心的感谢。季老师的专业知识和技术支持是我能够克服研究过程中技术难题的关键。

感谢林佳本研究员在我研究方法上遇到难题时提供的解决方法和建议，对我帮助巨大，林老师的指导让我在面对挑战时能够找到解决问题的途径。

我也要感谢白先勇老师，他在思路上的帮助让我受益匪浅。同时，苏江涛研究员在博士课题中提供的帮助和建议，让我受益良多。

回顾这几年来的博士生涯，得益于怀柔大家庭的滋养，我收获颇丰。感谢王薏站长、王东光总工程师、首席科学家张枚老师，他们与邓元勇主任一同攻坚克难，引领怀柔基地的发展。感谢侯俊峰师兄在规划上给予的建议；感谢杨潇师姐在工作中的帮助；感谢王全博士在课题上的有益讨论，尤其是在太阳物理领域的帮助。感谢佟立越师兄、胡子尧在算法上的讨论；感谢郭晶晶博士在磁场定标上的帮助，郭师姐之前的工作为我后续的研究奠定了基础；感谢朱晓明、黄威这两位好兄弟在求学道路上的相互支持；感谢孙文君师兄在工作上的帮助，使很多事情进行的顺利。

我还要感谢怀柔基地的教职工：林钢华、谭宝林、李文显、包星明、徐海清、陈洁、刘锁、宋勇亮、黄静、张印、孙英姿、张志勇、冯宇飞、白阳、沈宇堦、车慧利、朱丽佳、王慧、王国萍、荆帅、王建、王丙祥、闫璐、张鼎波、阮文东、王立东、杨桂莲、苏海奇，他们对我的科研和工作给予了各种帮助。

感谢怀柔组的师兄师姐、师弟师妹：王刚、张鑫伟；吴玮；陈垂裕、王强、荀辉、王雅琦、周明尧、李鑫、郑州、吴昱川、高碧源、郭思璠、喻子晗、邵明福、王哲楷、关思琦、钟云毅、商益、Mohamed Sedik、Shahid Idrees，感谢他们的相互帮助和共同成长。

感谢国家天文台研究生办公室的梁艳春老师、马怀宇老师、李响老师和艾华老师，他们对我读博期间的学习生活提供了极大的帮助。

我亦深表感激于所有文章与论文的审稿人及评委们，他们细致的评审工作和宝贵的反馈意见极大地提升了我撰写科学论文的技巧与水平。

特别致谢我的硕士导师李彬华教授，是他引领我踏入了天文学的殿堂。衷心

感谢我的家人王丹女士，在攻读博士学位期间，她给予了我无限的支持与鼓励。同时，我也要感谢我的父母和兄弟，在我求学的道路上，他们无条件的爱和支持是我不断前进的动力。

谨以此文，我再次向所有给予我帮助和支持的人表示最深的谢意。感谢你们在我的学术旅程中扮演的重要角色，我将永远铭记这段宝贵的经历。我希望能够将这份对知识的热爱和对学术的追求，传递给未来的学生和研究者，以此回报那些曾经指导和帮助过我的人。

2024年5月

作者简介及攻读学位期间发表的学术论文与其他相关学术成果

作者简介:

2012年9月——2016年7月,山西农业大学工学院获得电气工程及其自动化学士学位。

2016年9月——2019年7月,在昆明理工大学信息工程与自动化学院获得电路与系统硕士学位。

2019年9月——2024年7月,中国科学院国家天文台博士研究生,专业:天文技术与方法。

已发表(或正式接受)的学术论文:

- (1) 胡兴,杨尚斌,季凯帆,等.基于神经网络的双折射窄带滤光器型磁像仪观测波长点的定标.中国激光,2023,50(13):92-101.
- (2) 胡兴,杨尚斌,邓元勇,等.基于神经网络的天文台址长期白日视宁度变化估算.天文学报.(已录用)
- (3) Yang Bai, Jia-Ben Lin, Xian-Yong Bai, Xiao Yang, Dong-Guang Wang, Yuan-Yong Deng, Xiao-Ming Zhu, **Xing Hu**, Wei Huang, Li-Yue Tong. A Region Selection Method for Real-time Local Correlation Tracking of Solar Full-disk Magnetographs, 2022 Res. Astron. Astrophys. 22 095010.
- (4) 朱晓明,白先勇,林佳本,段帷,张志勇,冯志伟,邓元勇,杨潇,黄威,胡兴.面阵傅里叶变换太阳光谱仪高速采集系统设计与实现.光谱学与光谱分析,2022,42(12):3842-3850.

参加的研究项目及获奖情况:

中科院先导专项 A——先进天基太阳天文台 (ASO-SA) 卫星全日面矢量磁像仪 (FMG)

用于太阳磁场精确测量的中红外观测系统 (AIMS)

北京市自然科学基金资助项目——太阳跨赤道环日冕的研究

中国科学院大学三好学生

