

# 博士学位论文

### 机器学习在磁像仪数据处理中的可行性研究



2020年12月

# Feasibility Study on Magnetic Imaging Data Process Based on Machine Learning

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

Supervisor: Professor Deng Yuanyong Senior Engineer Lin Jiaben

National Astonomical Observatories, Chinese Academy of Sciences

December, 2020

# 中国科学院大学 学位论文原创性声明

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

作者签名:

日 期:

# 中国科学院大学 学位论文授权使用声明

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

涉密及延迟公开的学位论文在解密或延迟期后适用本声明。

| 作者签名: |    | 导师签名: |    |
|-------|----|-------|----|
| 日     | 期: | 日     | 期: |

#### 摘要

磁场对于太阳活动的研究非常重要,太阳表面上各种活动的物理机制和动 力学过程都与磁场的发生、演化等密切相关。目前磁场的测量主要依靠Zeeman效 应来间接获得,测量设备主要分为光谱仪型和滤光器型磁像仪。光谱仪型磁像 仪拥有丰富的光谱信息,可通过磁场反演的方式来较精确的获得磁场。但其也 存在许多问题,由于需要扫描空间信息,导致时间分辨率相对较低。滤光器磁 像仪常规观测只有一个波长信息,可提供高时间分辨率的磁场,但由于其缺乏 光谱信息,不能通过光谱反演的技术来生成磁场,只能在弱场近似下进行线性 定标。线性定标方法产生的磁场在高磁场区域存在较严重的磁饱和问题。另一 方面,我国第一台空间磁像仪FMG预计在2021年发射升空,它是一个滤光器型 的设备,常规观测模式下只有一个波长位置观测。对其进行磁场定标,不仅存 在磁饱和问题,还由于太阳自转、卫星轨道速度等的影响,存在波长漂移的问 题,给磁场定标带来了更大难度。在这个背景下,本文展开了机器学习方法在 窄带滤光器型磁像仪非线性磁场定标中应用的可行性研究。

本文选择光谱信息丰富,磁场精度较高的Hinode/SP卫星载荷的StokesIQUV 和光谱反演生成的磁场参数作为数据集。根据不同的研究内容,采用不同的预 处理方法从数据集中产生不同的样本集,建立不同任务的机器学习模型,然后 进行模型的训练、验证和测试工作。主要开展了以下几个方面的研究:

 首先采用6301.5Å谱线的多波长点数据建立多波段的磁场反演模型,并 由16个波长点逐步减少到2个波长点,共建立16-8-4-2波长点数的机器学习模型。
 结果显示这些模型都能够很好的预测磁场:虽然随着波长信息的减少,精度略 有下降,但直至2波长模型仍能够收敛,且预测结果接近反演结果。另外发现机
 器学习方法具有一定的去噪功能。以上说明可以采用实际观测的数据进行机器
 学习方法的多波段磁场定标,进一步说明机器学习方法是很有希望应用于单波 长磁场定标中。

2. 针对单波长定标中的磁饱和问题展开研究。通过选取偏离线心6301.5Å位 置-0.063Å波长点的StokesIQUV来模拟滤光器单波长观测,为机器学习方法提 供样本集。分别采用简单神经网络多层感知机MLP和卷积神经网络CNN开展单

Ι

波长的非线性磁场定标的研究,来论述机器学习方法解决磁饱和问题的可行性。 MLP是以一个像素为一个样本的,CNN是以一幅图像为样本的。

首先进行MLP方法的研究,综合考虑了多普勒速度场Vel、填充因子α、不同磁场分量等因素的影响,训练了12个相应模型进行多方面分析。得出以下结论:(1)有效的解决了磁饱和问题,与线性定标结果相比在黑子本影区域与目标值的残差平均要低700多高斯。(2)输入参数加入Vel会使网络模型精度更高,但不显著;考虑α的参数使磁场参数与Stokes参量的关系更加复杂,不考虑α的磁场参量具有明显更好的结果。(3)发现磁场反演数据中,倾角在宁静区存在很多"亮点"和"暗点",而MLP方法能够合理的预测它们,预测结果中没有这些点,再次说明机器学习方法具有去噪的功能。

然后采用深度学习方法之一CNN进行研究。CNN与MLP最大的不同在于, 不再把单独像素作为样本,而是考虑了相邻像素的空间关系。对于Vel和α的对 模型影响与MLP一致,没有再做具体分析。主要针对B<sub>t</sub>、B<sub>t</sub>和θ三维矢量磁场的 三个分量进行模型训练与分析。得出以下结论: (1)同样CNN网络在解决磁饱和 问题上表现良好。与MLP方法相比,在测试集样本中CNN网络对横纵场的预测 值与反演结果的残差 RMS 多数在50 G 以下,而CNN的结果多数在100G以上, 单从这方面来说,CNN网络模型能够具有更好的性能。(2)CNN网络模型不仅在 横纵场取得了较好的结果,在方位角上性能也比线性定标方法好。并且方位角 是一个周期量,在模型训练中针对这种周期量设计了一个单独的loss函数,使 其在0°和180°附近能够很好的收敛。(3)CNN网络产生的数据比反演的结果包含 更少的噪声数据,说明CNN具有一定的去噪能力。对于反演数据中倾角在宁静 区存在的很多"亮点"和"暗点"问题,由CNN模型产生的横纵场推断的倾角, 也能够去除。

3. 通过在单波长模拟观测波长点上下各选取两个波长点的方法来模拟波 长漂移问题进行变波长定标研究。变波长模型的建立更能近似的描述空间传统 滤光器型设备实际观测的情况。采用Hinode/SP的5个波长点实测数据进行波长 漂移数据模拟。建立了横、纵场的变波长定标模型。单从结果来看,最后模型 收敛的loss函数值比CNN单波长定标的结果稍高,但是还是比MLP单波长定标 的loss结果低,说明变波长模型能够较好收敛。通过对测试集的样本的预测结果 的分析,得出以下结论: (1)CNN网络模型能够兼容不同波长的Stokes参量进行

II

变波长磁场定标。(2)变波长模型相比单波长模型的结果精度上稍差,但这个差别并不显著,说明变波长模型的性能并不会比单波长模型的结果差多少。(3)插值的数据比实际观测的数据预测的结果要略差,插值方法还有待改进,从反面说明如果全部采用实际观测的数据可能会获得更好的结果。总之,变波长模型能够更好的为FMG的磁场定标方法提供了一个可供参考的非线性定标方法。

最后对目前研究取得的进展和存在的不足进行了总结,并对未来的研究计 划进行一个展望。

关键词: 磁场定标,窄带滤光器,磁饱和,波长漂移,机器学习,曲面解释, 多层感知机,残差网络

#### Abstract

The magnetic field is very important for the study of solar activity. The physical mechanisms and dynamic processes of various activities on the surface of the sun are closely related to the occurrence and evolution of the magnetic field. At present, the measurement of magnetic field is mainly obtained indirectly by the Zeeman effect. The measurement equipment is mainly divided into spectrometer-based and filter-based magnetograph. The spectrometer-based magnetograph has a lot of spectral information and can obtain the magnetic field more accurately through magnetic field inversion. But it also has many problems. The time resolution is relatively low due to the need to scan spatial information. The filter-based magnetograph has only one wavelength information for normal observation, which can provide a magnetic field with high time resolution. However, due to its lack of spectral information, the magnetic field cannot be generated by the technique of spectral inversion. It can only be linearly determined under weak-field approximation. The magnetic field generated by the linear calibration method has a serious magnetic saturation problem in the high magnetic field region. On the other hand, my country' s first space magnetic imager, FMG, is expected to be launched in 2021. It is a magnetograph that only has one wavelength position in the normal observation mode. Magnetic field calibration not only has the problem of magnetic saturation, but also has the problem of wavelength shift due to the influence of the sun's rotation and satellite orbit speed, which brings greater difficulty to the magnetic field calibration. In this context, this article develop a feasibility study on the application of machine learning methods in the calibration of narrow-band filter-based magnetograph.

In this paper, the *StokesIQUV* loaded by the *Hinode*/SP satellite with rich spectral information and high magnetic field accuracy and the magnetic field parameters generated by spectral inversion are selected as the data set. According to different research contents, different preprocessing methods are used to generate different sample sets from the data set, and machine learning models for different tasks are established, and

then the training, verification and testing of the models are carried out. Mainly carried out the following researches:

1. First use the multi-wavelength point data of the 6301.5Åspectral line to build a multi-band magnetic field inversion model, and gradually reduce the 16 wavelength points to 2 wavelength points, creating a total of 16-8-4-2 wavelength points machine Learning model. The results show that these models can predict the magnetic field well, and the more abundant wavelength information, the higher the accuracy. And found that the machine learning method has a certain denoising function. It shows that the actual observation data can be used for the multi-band magnetic field calibration of the machine learning method, and further shows that the machine learning method is very promising to be applied to the single-wavelength magnetic field calibration.

2. By selecting the Stokes IQUV that deviates from the line center 6301.5Åposition -0.063Åwavelength point to simulate the single wavelength observation of the filter, and provide a sample set for the machine learning method. The simple neural network MLP and the convolutional neural network CNN are used to carry out the research of single-wavelength nonlinear magnetic field calibration to discuss the feasibility of the machine learning method to solve the magnetic saturation problem. MLP uses a pixel as a sample, and CNN uses an image as a sample.

First, the research of MLP method is carried out, and the influence of Doppler velocity field *Vel*, filling factor  $\alpha$ , different magnetic field components and other factors are comprehensively considered, and 12 corresponding models are trained for multi-faceted analysis. The following conclusions are drawn: (1) Adding *Vel* to the input parameters will make the network model more accurate, but not significant; therefore, considering the parameters of  $\alpha$  makes the relationship between the magnetic field parameters and the Stokes parameters more complicated, and does not consider  $\alpha$  The magnetic field parameter of has significantly better results. (2) The magnetic saturation problem is effectively solved. Compared with the linear calibration result, the residual error between the sunspot umbral region and the target value is on average more than 700 Gauss lower. (3) It is found that in the magnetic field inversion data, the dip exists in the quiet zone There are many "bright spots" and "dark spots", and the MagMLP

method can predict them reasonably. The prediction results do not have these points, which again shows that the machine learning method has the function of denoising.

Then use CNN, one of the deep learning methods, for research. The biggest difference between CNN and MLP is that it no longer takes individual pixels as samples, but considers the spatial relationship of adjacent pixels. The impact of Vel and  $\alpha$  on the model is consistent with MLP, and no specific analysis is made. The model training and analysis are mainly for the three components of  $B_t$ ,  $B_l$  and  $\theta$  three-dimensional vector magnetic field. The following conclusions are drawn: (1) The CNN network model not only achieves better results in the horizontal and vertical fields, but also has better performance in the azimuth angle than the linear calibration method. And the azimuth angle is a periodic quantity, and a separate loss function is designed for this periodic quantity in the model training, so that it can converge well around  $0^{\circ}$  and  $180^{\circ}$ . (2) The data generated by the CNN network contains less noisy data than the inversion result, indicating that CNN has a certain denoising ability. For the many "bright spots" and "dark spots" in the inversion data that exist in the quiet zone, the inferred angles of the horizontal and vertical fields generated by the CNN model can also be removed. (3) The same CNN network performs well in solving the magnetic saturation problem. (4) Compared with the MagMLP method, in the test set samples, the MagReses network predicts the horizontal and vertical fields and the residual RMS of the inversion result is mostly below 50G, while most MagMLPs are above 100G. From this perspective, The MagReses network model can have better performance.

3. By selecting two wavelength points above and below the single-wavelength simulated observation wavelength point to simulate the wavelength drift problem for variable wavelength calibration research. The establishment of the variable wavelength model more closely describes the actual observation situation of the spatial filter equipment. Use Hinode/SP measured data at 5 wavelength points plus random interpolation for simulation. The horizontal and vertical variable wavelength calibration model is established. From the results alone, the final loss value is slightly higher than the result of ResNet single-wavelength calibration, but it is not much different. Compared with the result of MLP, it is lower. Through the analysis of the prediction results of

the samples in the test set, the following conclusions are drawn: (1) It shows that the neural network model can fuse Stokes parameters of different wavelengths for variable wavelength magnetic field calibration. (2) Compared with the single-wavelength model, the accuracy of the variable-wavelength model is slightly worse, but this difference is not particularly significant, indicating that the performance of the variable-wavelength model is not much worse than that of the single-wavelength model. (3) The predicted result of the interpolated data is worse than the actual observed data. The interpolation method needs to be improved. From the negative side, it shows that if all the actual observed data are used, better results may be obtained. In short, the variable wavelength model can better provide a reference non-linear calibration method for FMG's magnetic field calibration method.

Finally, the current research progress and existing deficiencies are summarized, and the future research plan is prospected.

**Keywords:** Magnetic field calibration, Narrowband filter-based magnetograph, Magnetic saturation, Wavelength shift, Machine learning, Surface interpretation, MLP, ResNet

| 第1章 绪论 ······  | 1  |
|--|----|
| 1.1 太阳磁场测量概述 · · · · · · · · · · · · · · · · · · ·     | 1  |
| 1.2 磁场定标面临的问题与挑战 · · · · · · · · · · · · · · · · · · · | 3  |
| 1.2.1 多点磁场反演的问题与发展                                     | 3  |
| 1.2.2 单点磁场定标存在的问题                                      | 5  |
| 1.2.3 单点磁场测量问题解决方案——机器学习                               | 8  |
| 1.3 主要研究内容 ······                                      | 9  |
| 1.3.1 章节安排 · · · · · · · · · · · · · · · · · · ·       | 9  |
| 第2音 田干可行性研究的磁场数据                                       | 11 |
|  | 11 |
| 2.1  | 11 |
| 2.2  | 11 |
| 2.5  | 12 |
|  | 12 |
|  | 14 |
|  | 14 |
|  | 10 |
| 2.3.5 000 支援长期续误至件本数据                                  | 17 |
| 第3章 机器学习用于单波长磁场定标的可能性研究                                | 19 |
| 3.1 机器学习方法简介   | 19 |
| 3.1.1 机器学习的发展历程简介                                      | 19 |
| 3.1.2 学习方式 · · · · · · · · · · · · · · · · · · ·       | 20 |
| 3.1.3 神经网络 ······                                      | 21 |
| 3.1.4 结果评价指标   | 24 |
| 3.2 在磁场定标中的可行性分析                                       | 25 |
| 3.2.1 训练方法与策略 ·····                                    | 25 |
| 3.2.2 结果与验证  | 28 |
| 3.2.3 结果比较分析 ·····                                     | 32 |
| 3.2.4 讨论·····  | 34 |
| 3.3 小结   | 34 |

| 第4章 应用简单神经网络解决磁饱和问题                                  | 37 |
|--|----|
| 4.1 数据说明 · · · · · · · · · · · · · · · · · · ·       | 37 |
| 4.2 训练方法与策略 ······                                   | 38 |
| 4.3 结果   | 40 |
| 4.3.1 训练结果 · · · · · · · · · · · · · · · · · · ·     | 40 |
| 4.3.2 可行性验证 · · · · · · · · · · · · · · · · · · ·    | 43 |
| 4.3.3 填充因子的影响  | 43 |
| 4.4 结果比较分析 ······                                    | 44 |
| 4.4.1 与线性定标比较 ······                                 | 45 |
| 4.4.2 倾角的亮暗点分析 · · · · · · · · · · · · · · · · · · · | 48 |
| 4.5 三维定标曲面 ······                                    | 49 |
| 4.5.1 训练模型 · · · · · · · · · · · · · · · · · · ·     | 49 |
| 4.5.2 定标曲面绘制 ······                                  | 50 |
| 4.5.3 解释分析   | 50 |
| 4.6 小结   | 50 |
| 第5章 应用券积网络BesNet解决磁饱和问题 ······                       | 53 |
| 51 数据和方法说明   | 53 |
| 5.2 结果与可行性验证   | 54 |
| 5.2.1 纵场   | 56 |
| 5.2.2 横场   | 56 |
| 5.2.3 方位角 ······                                     | 56 |
| 5.3 结果分析与比较 ······                                   | 59 |
| 5.3.1 横纵场与线性定标比较分析                                   | 59 |
| 5.3.2 方位角与线性定标比较分析                                   | 61 |
| 5.3.3 倾角比较分析   | 63 |
| 5.4 小结   | 63 |
|  |    |
| 第6章 用于解决实测中波长漂移问题的变波长足称研究                            | 65 |
| 6.1 数据和方法说明 ······                                   | 65 |
| 6.2 结果与测试验证 ······                                   | 65 |
| 6.2.1 训练结果 · · · · · · · · · · · · · · · · · · ·     | 65 |
| 6.2.2 横场测试结果   | 66 |
| 6.2.3 纵场测试结果   | 66 |
| 6.3 与单波长定标比较 · · · · · · · · · · · · · · · · · · ·   | 68 |
| 6.3.1 横场比较结果   | 68 |
| 6.3.2 纵场比较结果   | 70 |

| 6.4 泛化能力测试                                       | 70 |
|--|----|
| 6.4.1 测试结果 · · · · · · · · · · · · · · · · · · · | 71 |
| 6.5 小结   | 75 |
| 第7章 总结与展望  | 77 |
| 7.1 工作总结 ······                                  | 77 |
| 7.2 未来展望   | 79 |
| 参考文献 ·····                                       | 81 |
| 作者简历及攻读学位期间发表的学术论文与研究成果 · · · · · ·              | 87 |
| 致谢 · · · · · · · · · · · · · · · · · · ·         | 89 |

# 图形列表

| 1.1 (a)先进天基太阳天文台(ASO-S)卫星, (b)FMG原理图。  | • 5  |
|--|------|
| 1.2 (a)左右旋, (b)磁像仪磁场测量原理。  | • 6  |
| 1.3 磁饱和效应。   | • 7  |
| 2.1 不同多波段的波长数据选择   | · 13 |
| 2.2 采用实测的Hinode/SP的数据来模拟窄带滤光器观测 ······   | · 15 |
| 2.3 StokesIQUV和Vel直方图均衡化前后对比图  | · 15 |
| 2.4 输入参数为偏离6301.5Å谱线线心-0.063Å的波长位置 <i>StokesIQUV</i> 逐像样本实例。该样本是于2014年9月11日10:47UT在 <i>Hinode/</i> SP上观测 | <br> |
| 的,活动区号为NOAA AR 12158。样本为通过公式2.1归一化处理后  | i    |
| 的数据。   | • 16 |
| 2.5 作为输出参数不考虑填充因子的 $B_l$ 和 $B_t$ (主要参数)和 $\varphi$ 样例图 ······  | · 17 |
| 2.6 变波长数据选择。   | • 17 |
| 3.1 经验模型 ······  | · 19 |
| 3.2 神经元和神经网络结构示意图  | · 22 |
| 3.3 卷积过程和池化过程示意图   | · 24 |
| 3.4 ResNet模型的结构设计 ·····  | · 25 |
| 3.5 不同数量波长模型横场预测结果   | · 27 |
| 3.6 不同数量波长模型横场预测结果与目标数据的残差直方图  | · 28 |
| 3.7 不同数量波长模型横场预测结果与目标数据的散点图  | · 28 |
| 3.8 不同数量波长模型的纵场预测结果  | · 29 |
| 3.9 不同数量波长模型纵场预测结果与目标数据的残差直方图  | · 30 |
| 3.10 不同数量波长模型纵场预测结果与目标数据的散点图   | · 30 |
| 3.11 简单黑子样本在16波长点模型下的预测结果  | · 31 |
| 3.12 残差和噪点分析图 ······   | · 32 |
| 3.13 2波长点模型与线性定标结果比较图  | · 33 |
| 4.1 MagMLP的网络结构示意图 ······  | · 38 |
| 4.2 以StokesIQUV和Vel作为输入的模型在第一阶段的loss函数 ·······   | · 39 |
| 4.3 B' <sub>l</sub> 的训练结果与反演数据的散点图分布 ····································                                | · 41 |
| 4.4 MagMLPs在测试集样本上的预测结果。左列为磁场反演的数据, 左  |      |
| 边第二列为MagMLPs的预测结果,左三列为预测结果与目标数据的残  |      |
| 差图,最右侧为残差的直方图。前四行为 $B'$ 、 $arphi$ 、 $B'_i$ 和 $B'_i$ 的结果,最  |      |
| 后一行为预测的B' <sub>t</sub> 和B' <sub>l</sub> 通过公式2.4计算得到总磁场强度B'' ········                                     | · 42 |

| <ul> <li>4.6 左边的散点图显示了B<sub>t</sub>和(Q<sup>2</sup>+U<sup>2</sup>)<sup>1/4</sup>之间的分布关系。右图表示B<sub>t</sub>和V之间的关系。红色的直线是线性定标拟合的线。Stokes参数Q,U,和V为除以I归一化后的数据。</li> <li>44</li> <li>4.7 磁场反演,MagMLP和线性定标的横、纵场结果。上图为横场,下图是纵场。</li> </ul> |
|--|
| <ul> <li>除以<i>I</i>归一化后的数据。 44</li> <li>4.7 磁场反演, MagMLP和线性定标的横、纵场结果。上图为横场,下图 是纵场。 45</li> </ul>   |
| <ul><li>4.7 磁场反演, MagMLP和线性定标的横、纵场结果。上图为横场, 下图</li><li>是纵场。</li></ul>  |
| 是纵场。   |
| 4。 #47兆关始休田,大利日二乙和6网络共利在例休日466、资料均约兆   |
| 4.8  |
| 结果和反演数据散点图,右下图为线性标定结果和反演数据的散点图 46  |
| 4.9 纵场残差的结果。左列显示了MLP网络模型预测结果和反演数据的残  |
| 差(上),以及反演数据与线性定标的残差(下)。右上图为MLP网络模型   |
| 结果和反演数据散点图,右下图为线性标定结果和反演数据的散点图 47  |
| 4.10 反演和MagMLP在倾角上结果比较。左上图是反演的结果,左卜图   |
|  |
| 4.12 反演生成的三维曲面   |
| 4.13 训练集预测结果 ····································  |
| 4.14 在XOY面上的投影视场结果 ····································  |
|  |
|  |
| 5.2 纵场的MagRes定标结果。上图从左至石依次内反演的结果,MagRes预<br>测结果及其碳差。左下图导碳差直方图及其高斯核密度曲线。右下图   |
| 是散点图,颜色表示反演结果与测试结果的密度分布 ····································   |
| 5.3 横场的MagRes定标结果。上图从左至右依次为反演的结果,MagRes预   |
| 测结果及其残差。左下图是残差直方图及其高斯核密度曲线。右下图   |
| 是散点图,颜色表示反演结果与测试结果的密度分布 ··········57   |
| 5.4 方位角的MagRes定标结果。上图从左至右依次为反演的结果,MagRes预  |
| 测结果及具残差。左卜图是残差直万图及具局斯核密度田线。石卜图<br>————————————————————————————————————   |
| z $x$ $z$  |
| 纵场的结果,下图为横场的结果。 · · · · · · · · · · · · · · · · · · ·  |
| 5.6 方位角的反演、MagRes预测结果和线性定标的结果比较。左下图  |
| 是ResNet和反演方法结果的散点图。右下图是线性标定和反演方法   |
| 结果的散点图。  |
| 5.7 倾角的MagRes预测结果。上图从左至右依次为反演的结果, MagRes预<br>测结用及其成差。大下图具成美声之图及其直斯按密度曲线。大下图  |
| ////如木风央戏左。在下图定戏左旦刀图风央同别物留及曲线。右下图<br>是散点图.颜色表示反演结果与测试结果的密度分布   |

| 6.1  | 横场在5个波长点的预测结果                   | 67 |
|------|---------------------------------|----|
| 6.2  | 横场在5个波长点的预测结果与反演数据的残差图          | 68 |
| 6.3  | 横场在5个波长点的预测结果与反演数据的散点图          | 68 |
| 6.4  | 纵场在5个波长点的预测结果                   | 69 |
| 6.5  | 纵场在5个波长点的预测结果与反演数据的残差图          | 70 |
| 6.6  | 纵场在5个波长点的预测结果与反演数据的散点图          | 70 |
| 6.7  | 变波长数据中间插值示意图 ······             | 71 |
| 6.8  | 横场在5个波长点的中间点的预测结果               | 72 |
| 6.9  | 纵场在5个波长点的中间点的预测结果               | 73 |
| 6.10 | 〕横纵场在5个波长点中值的预测结果与反演数据的残差直方图。上  |    |
|      | 图为横场的结果,下图为纵场的结果。               | 74 |
| 6.1  | 1 横纵场在5个波长点中值的预测结果与反演数据的散点图。上图为 |    |
|      | 横场的结果,下图为纵场的结果。                 | 74 |

# 表格列表

| 2.1 | 训练集、测试集和验证集划分列表 ····································     | 14   |
|-----|--|------|
| 3.1 | 测试集在不同波长点模型残差RMS ······                                  | 35   |
| 4.1 | 训练集和测试集列表  | 37   |
| 4.2 | 主要的MagMLP网络训练参数与设置 · · · · · · · · · · · · · · · · · · · | 40   |
| 4.3 | 12个网络模型训练结果与目标数据的线性拟合系数(K)值 · · · · · · · · ·            | 41   |
| 5.1 | 18年和19年测试集样本的模型预测结果与对应的反演结果的残差RMS值                       | 直 61 |

#### 第1章 绪论

#### 1.1 太阳磁场测量概述

太阳是与我们息息相关的一颗恒星,是我们赖以生存的球体。自古人类便 对太阳充满着好奇,远古只能通过神话传说如夸父逐日、后羿射日等来解释太 阳的存在。而随着近现代天体物理的发展,太阳的本来面目逐步被人们所认识。 它几乎是一个热等离子与磁场交织着的日复一日、年复一年变化着的理想球体。 通过太阳物理学家们坚持不懈的研究发现许多太阳活动都与太阳磁场密切相关: 耀斑的触发和能量的释放过程与磁场作用密不可分,太阳黑子的形态和黑子大 气的平衡与磁场结构紧密相连,日珥形成的物理环境和条件总与磁场演变休戚 相关,等等。因此太阳磁场是我们理解、研究太阳活动的一个主要参量和根本 手段(Jin 和 Wang, 2007)。

1896年,荷兰物理学家Zeeman发现在足够强的磁场中置入产生光谱的光源, 磁场会使光谱发生变化,一条谱线即会分裂成几条偏振化的谱线,随后这种现 象被称为Zeeman效应。这项被认为19世纪末20世纪初物理学最重要的发现之一, 为我们奠定了精确测量天体磁场的理论基础。1908年美国天文学家Hale首先利 用Zeeman效应在威尔逊山天文台测量了太阳黑子区域的磁场强度(Hale, 1908)。 他通过在光谱仪狭缝前放置一套偏振分析器,选择一条lande因子g≥2.5的磁敏 线在黑子区域测得磁场强度达三、四千高斯。Hale成功测得磁场,虽然只适用 于强磁场,但开启了太阳磁场测量的大门,影响了近百年的太阳磁场观测研 究(Su, 2004)。1952年美国Babcock父子研制了世界上第一台磁像仪,利用光电 原理和Zeeman效应测出了1高斯的磁场,初步揭示了太阳磁场的分布与其他太 阳活动的关联。迄今为止,太阳磁场的测量主要还是借助于Zeeman效应,精确 测量目前还仅限于光球,色球谱线较宽可做稍差观测(Bai, 2014),日冕磁场可 用射电方法、磁震学方法(Samanta 等, 2020)等略估,光球以上磁场可做理论外 推(Lin, 2001)。

现代光电科技的进步,太阳磁场的深入研究,不断推动着磁像仪的更新换 代,地基、空基磁像仪相继发光发热,朝着更快、更稳、更准的测量磁场这一 主要目标快速前进着。目前,磁场测量设备按照终端的不同可大致分为光谱仪

型磁像仪(SGa)和滤光器型磁像仪(FGs)(Lin, 2001; Iglesias 和 Feller, 2019)。此 外,积分场解决方案正在发展,以解决SGs和FGs无法同时覆盖所需的空间和光 谱视场的问题(Iglesias 和 Feller, 2019)。我国正在开发的二维实时光谱仪(Deng 和 Zhang, 2009),光纤阵列太阳光学望远镜FASOT(Fiber Arrayed Solar Optical Telescope)(Qu, 2011)等同时成谱成像磁像仪也在不断发展着。

安装在泰德天文台(Observatorio del GREGOR Infrared Spectrograph)(Collados 等, 2012), 美国萨克拉门托峰的 ASP (Advanced Stokes Polarimeter)(Elmore 等, 1992), 基特峰的 SOLIS (Synoptic Optical Long-term Investigations of the Sun) (Harvey 等, 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 (S3T)(Qu 等, 2001) 等地基磁像仪以及日本的Hinode卫星载荷之一SOT/SP, 美国太阳动力学观测站SDO(Solar Dynamics Observatory)上的HMI(Helioseismic and Magnetic Imager)(Schou 等, 2012)等天基磁像仪都属SGs(Bai, 2014)。它们主 要由望远系统、磁偏振分析器和光谱仪组成,虽然大体结构组成大同小异,但 其工作谱线、观测分辨率、视场大小却各有差异。SGs通过沿着光谱狭缝方向扫 描谱线源的Stokes(del Toro Iniesta, 2003)I、Q、U、V光谱,来获得偏振分量的光 谱轮廓*Stokes I*( $\lambda$ ),  $Q(\lambda)$ ,  $U(\lambda)$ , and  $V(\lambda)$ (这里的 $\lambda$ 是指波长)。这类磁像仪至少 需要扫描四个以上光谱点的谱线轮廓,且多数需要测量精度优于0.1(Borrero 等, 2011)才能通过目前最成熟最完善的磁场反演技术来推断磁场,这是自1970年代 初期以来最有用的工具(Rees 等, 2000; Socas-Navarro 等, 2001; del Toro Iniesta 和 Ruiz Cobo, 2016; Socas-Navarro, 2001)。它是在一定的大气模型以及吸收机 制的假定下,主要在偏振辐射转移方程解的基础上,通过最小二乘方法不断迭 代直至获得Stokes观测光谱轮廓的最佳拟合,这时形成最佳拟合轮廓的大气参 量对应的物理参量即为磁场相关参数。偏振辐射转移理论最早可追溯到1956年, Unno (1956)以现象学的方式成功的建立起来。Nikulin 等 (1958)独立提出了一个 更严格的隐含磁光效应的经典推导, Rachkovsky (1962)对其进行了扩展。Landi Degl'Innocenti, Egidio and Landi Degl'Innocenti, Maurizio(Landi Degl'Innocenti 和 Landi Degl'Innocenti, 1972)对磁场中的偏振辐射传递方程进行了量子力学推导。 基于辐射转移方程下的谱线反演方法有AHH反演法(Auer 等, 1977)、M-E反演 法(Skumanich 和 Lites, 1987)、SIR反演法(Cobo 和 Iniesta, 2012)、Zurich反演

法(Solanki 等, 1992)以及屈中权等人的反演法(Qu 等, 2006; Jin 等, 2006)。

马歇尔飞行中心(Hagyard 等, 1982)、大熊湖天文台的向量磁像仪 (Zirin, 1985)和怀柔太阳观测基地的太阳磁场望远镜 (Ai 和 Hu, 1986)等地基磁像仪,以及SOHO卫星上的MDI(Michelson Doppler Imager)(Hoeksema 等, 1992), Hinode 卫星上的NFI(Narrowband Filter Imager) (Tsuneta 等, 2008)等天基磁像仪都属于FGs。这些滤光器型的磁场测量设备大同小异,都是由望远系统、滤光系统和偏振分析器组成,不同之处在于滤光系统,滤光系统有多种,或基于双折射滤光器(Hagyard 等, 1982; Ai 和 Hu, 1986; Tsuneta 等, 2008; Zirin, 1985),或基于迈克尔逊干涉仪(Hoeksema 等, 1992),或基于法布里一珀罗干涉仪 (Cavallini, 2006; Leka 等, 2012; Scharmer 等, 2008)。滤光器型的磁场测量设备特点在于面源成像观测,视场比较大,可以获得所成面源的StokesIQUV图像。传统滤光器型磁像仪在常规观测中只有一个波长点的Stokes偏振信号,由于缺少光谱信息,无法进行基于辐射转移理论的光谱反演方法来获得磁场。只能进行线性定标,通过弱场近似假设(Stenflo, 1994)下的辐射传递方程来计算纵向磁场强度(*B<sub>l</sub>*)和横向磁场强度(*B<sub>l</sub>*),以及方位角(φ),定标公式为:

$$B_l = C_l V \tag{1.1}$$

$$B_t = C_t (Q^2 + U^2)^{1/4}$$
(1.2)

$$\varphi = 0.5 \arctan(U/Q). \tag{1.3}$$

其中*C*<sub>*l</sub></sub>是<i>B*<sub>*l*</sub>的定标系数,而*C*<sub>*t*</sub>代表*B*<sub>*t*</sub>的定标系数。目前有五种不同的算法来获 得定标系数(Bai 等, 2013)。该方法在弱磁场区域效果很好,而在强磁场区域(例 如发生磁饱和的黑子本影区域)不起作用(Bai 等, 2014)。为了克服磁饱和效应, Chae 等 (2007)采用一阶多项式方法来模拟偏振信号在场强上的反演,从而获得 较高精度的磁场。</sub>

#### 1.2 磁场定标面临的问题与挑战

#### 1.2.1 多点磁场反演的问题与发展

光谱反演方法虽然能够获得很多方面的成功,但也存在很多问题: (1)这些 方法都是在一系列假设下建立大气自由参数的模型,然后通过解析解或数值解 来测磁场。这些模型基本都是简化的,无法保证所建立的模型能够非常精确的

来描述太阳大气,且解不唯一,因此通过反演得出的磁场精确性和可靠性很难 保证。但它又确实是通过观测数据的轮廓中推导出来的,也无法否定其正确性。 (2)即使最好的反演方法也是从模拟数据或者观测数据中获得信息,模拟数据受 限于人们的认知水平和所采用的方法,观测数据受限于观测仪器的各种状态指 标,都无法确保正确完美。(3)横场测量精度低。(4)如果不考虑以上问题,仅考 虑反演这种算法模式,一次反演过程从开始到推断出磁场短则需要几小时长则 需要几天的时间(Carroll 和 Staude, 2001; Milic 和 Gafeira, 2019)。一是计算资源消 耗非常大,二是无法满足天文学家想要获取实时数据的需求。

因此寻找一种快速稳定计算精度高的替代方法是物理学家一直的追求。受益于计算机计算能力的增加,一些新的方法和技术已经应用在磁场反演方面,并获得了一些不错的结果。Rees 等 (2000)首先利用主成分分析(PCA)从Stokes轮廓推断磁场强度和倾斜角度,Socas-Navarro等(Socas-Navarro 等,2001;Socas-Navarro,2001)后期又对该方法进行了改善。PCA方法是通过降维的方法,来减少反演所需的数据量从而来减少耗时,仍然需要通过最小二乘迭代求解。该方法在一定程度上加速了反演。差不多同时,Carroll和Staude (2001)应用人工神经网络(ANN)来训练Stokes参数轮廓与太阳大气参数之间的映射网络,结果表明ANN能够快速稳定的预测磁场参数。Teng (2015)提出了一种基于Mer-cer核的统计机器学习技术来反演矢量磁场。这些方法主要在第二次人工智能浪潮的背景下发展起来的,MLP方法由于缺乏理论指导,且当时设备的计算能力不强,使其发展受阻。

2016年3月,阿尔法围棋AlphaGo一个采用深度学习方法(Goodfellow等,2016) 进行训练的机器人,打败了围棋世界冠军李世石,顷刻轰动世界。受益于大数 据时代到来和计算设备的飞速发展,以深度学习为代表的机器学习方法再次 火热起来,开启了人工智能的第三次浪潮。深度学习方法开始在诸多领域(如 医学、生物学、物理学等自然科学领域)广泛应用,在天文物理中也应用日盛, 为处理海量天文数据、揭示和挖掘未知的天体和物理特性提供了新的解决思 路(Tao 等,2020)。在耀斑、日冕物质抛射、黑子和磁场等太阳物理领域也进行 了大量的研究(Liu 等,2019)。Asensio Ramos 和 Díaz Baso (2019); Liu 等 (2020); Milic 和 Gafeira (2019)将卷积神经网络(CNN)应用于*Stokes*反演,取得了较为理 想的实验结果,精度较ANN方法有了较大提升。由于CNN是基于图像的,考虑

了相邻像素之间的关系,极大的减少了由于局部噪声或多个极小值导致的模型 退化(Milic和Gafeira,2019),但需要更长的时间来训练优化模型。Asensio Ramos 和 Díaz Baso (2019)使用在太阳大气的三维MHD模拟中合成的Stokes光谱,并利 用训练数据集中编码的所有空间信息进行CNN网络模型训练。Milic和Gafeira (2019)训练的CNN磁场反演模型输入数据除Stokes光谱外,还加入了日心角,并 推断模型参数(节点值)。论证了该方法适用于在不同状态下形成的谱线(他们 在Fe I 6300, Na ID, Ca II 8542, MgI b等上进行了测试),同样适用于真实的光 谱图数据和滤镜图数据的反演。Liu等 (2020)的方法利用像素中Stokes轮廓的空 间信息执行逐像素的反演。

机器学习方法以其快速和强大的非线性逼近能力,虽受到太阳物理学家的 欢迎,但采用此方法推断的磁场结果因包含极少的物理机制也受到了不少质疑。 模型训练使用的训练数据大多来自数值模拟的数据,与实测的数据存在一定差 异,虽在实际观测的样本中进行了测试验证也取得了较好的结果,但离真正能 够应用于实际观测还较远。



图 1.1 (a)先进天基太阳天文台(ASO-S)卫星, (b)FMG原理图。 Figure 1.1 (a)Advanced Space-based Solar Observatory (ASO-S) satellite, (b)Schematic diagram for FMG.

#### 1.2.2 单点磁场定标存在的问题

"先进天基太阳天文台"(Advanced Space-based Solar Observatory,简称ASO-S)卫星(如图1.1(a))是中国科学院空间科学战略性先导专项第二批立项的我国首 颗太阳观测卫星。ASO-S卫星以观测太阳上两类最剧烈的爆发现象——太阳耀 斑和日冕物质抛射(CME)以及产生它们的磁场结构作为主要科学目标。项目 已于2018年正式启动,计划在第25个太阳活动周前发射。ASO-S卫星配置了三 台载荷,分别是:全日面矢量磁像仪(FMG)(如图1.1(b))、莱曼阿尔法太阳望远 镜(LST)和太阳硬X射线成像仪(HXI),将对太阳上的"一磁两暴"进行观测。"一 磁"即太阳磁场,"两暴"即指太阳耀斑和日冕物质抛射。ASO-S卫星独特的有 效载荷组合将首次实现在一颗卫星上同时观测太阳全日面矢量磁场、太阳耀斑 高能辐射成像和日冕物质抛射的近日面传播。瞄准当代太阳物理领域重大前沿 科学问题——太阳磁场、太阳耀斑和日冕物质抛射三者之间的关系,揭示太阳 磁场演变导致太阳耀斑爆发和日冕物质抛射的内在物理机制。在拓展人类知识 疆野的同时,也为严重影响人类生存环境的空间天气提供预报的物理基础。 FMG是基于双折射滤光器的传统磁像仪,主要通过偏振的测量(如图1.2所示)借 助于Zeeman效应获取太阳全日面光球矢量磁场图像。为提高信噪比,通常对接 收到的信号做多次累加后,才能得到比较好的磁图。常规模式2分钟(一组矢量 磁图),相当于时间分辨率为2分钟;爆发模式40秒;空间分辨率1角秒;纵向磁 场测量精度5高斯。相较于Hinode的Stokes参数仪,具有更大的视场、更高的观 测效率和时间分辨率;相较于SDO和SOHO的磁像仪,观测模式简单,磁场测量 灵敏度高。



图 1.2 (a)左右旋, (b)磁像仪磁场测量原理。



FMG作为我国第一台空间磁像仪,具有特殊的意义。磁场定标方法对FMG 来说非常重要,关系着其最终的科学应用程度。在弱场近似下,对于局部区矢 量磁场观测,可以直接给偏振图像一个标定常数(理论计算、观测均都可以得 到)来推算磁场。但是,对于全日面矢量磁场观测,问题就复杂的多,因为太阳 的较差自转、活动区等离子体的视向运动等都会造成工作谱线漂移,而且漂移 量随日面位置的不同而不同。空间磁像仪还存在轨道速度的影响,波长漂移问

题比地面更严重。另外,弱场近似在弱场区域能够较好的推算磁场,但在高磁场区域却存在很多问题,最大的问题便是磁饱和问题。所以,直接赋值给全日面偏振图像一个定标系数方法失效。总之,对于空间传统滤光器型磁像仪的磁场定标面临着较严重的磁饱和效应和波长偏移等非线性问题。





Figure 1.3 Magnetic saturation effect.

#### 1.2.2.1 磁饱和效应

传统滤光器型磁像仪在常规观测下是工作在*Stokes*轮廓的一个固定波长位置 上。在弱磁场的情况下,随着磁场的增加,该波长位置的偏振信号会增加。但 随着磁场的增强、Zeeman裂距变大导致这一波长位置的偏振信号反而开始变弱, 就产生磁饱和现象,如图1.3所示。理论研究和实际观测都表明,磁饱和现象是 一个非常复杂的问题,不但和磁场强度有关,还与*I*信号强度、散射光等强烈有 关。现在的方法基本是采用分段线性近似的方法,即根据*I*信号强度先将目标划 分成不同的区域(如黑子外部、黑子半影和本影),然后对于弱场区域(黑子外部 和半影)直接用线性拟合求解系数*C*<sub>1</sub>和*C*<sub>1</sub>,而对于本影则通过负相关的线性拟合 来实现。但是这种分段拟合并没有一个完整的、通用的方法,对个例研究有效, 却很难普适地应用于一台常规设备的常规数据定标中。

#### 1.2.2.2 波长漂移问题

FMG是全日面、大视场观测,常规观测只有一个设定的工作波长点。但观 测数据中的实际光谱波长点在日面不同位置上却是不同的,即存在波长漂移问 题。引起波长漂移的原因有多个:1)太阳较差自转在视向方向的投影产生多普 勒位移:其在全日面上表现为东西两个边缘最大,而在自转轴上为零;2)卫星平 台相对于太阳运动带来多普勒位移:这个位移对于全日面是一样的,但随着卫 星在轨道上的位置不同而不同。ASO-S是太阳同步轨道卫星,轨道周期约99.2分 钟,轨道速度不但有日变化,还有月变化;如果视向速度达到±4km/s,多普勒 效应引起的波长漂移可达±0.07Å。3)太阳活动区等离子体的视向运动:这个运 动不但与其在活动区的位置(如本影区、半影区)有关,还和活动区在日面的位置 有关;4)虽然滤光器放置远心光路,但在实测中仍然发现滤光器视场中的不均 匀问题(Liu等,2018)。对全日面矢量磁场标定时,困难在于需要知道日面上各个 空间点测量时的实际工作波长位置。原则上,没有实时的太阳速度场测量很难 精确解决这一问题,我们需要在现有条件下尽量克服和解决这一困难。

#### 1.2.3 单点磁场测量问题解决方案——机器学习

线性定标方法可以满足实时快速计算的要求,并且具备高时间分辨率观测, 但是在强磁场区域存在较严重的磁饱和现象,另外还受多普勒速度和透过率不 均匀等引起的谱线漂移问题,使线性定标的难度增大。在还无法很好的直接测 量磁场的时代,寻找更快、更好、更精确的磁场定标方法对传统滤光器型磁像 仪来说是非常重要的。

当今处于大数据时代,依靠数据驱动的机器学习方法应用日盛。从1.2.1中 可以知道人们已经采用机器学习方法在多点磁场生成问题上做了很多研究,并 取得一定的成果。单点磁场测量中线性定标存在的磁饱和和波长漂移问题均是 非线性问题,线性定标无论如何都无法克服本身局限性解决这些问题。因此, 本文开展了机器学习在单波长磁场定标中的可行性研究,以期能够解决传统滤 光器型磁像仪磁场定标中存在的非线性问题,从而生成更高精度的高时间分辨 率的磁场供太阳物理学家研究。

#### 1.3 主要研究内容

本文尝试在单波长下进行非线性磁场定标,进一步提高FMG磁场定标的精 度。解决因轨道速度引起波长漂移情况下的单波长观测的非线性磁场定标,并 克服线性定标存在的磁饱和问题,建立可以兼容不同波长的单波长机器学习 方法的定标模型。现有的机器学习进行磁场反演的模型基本都采用模拟数据 进行训练的,本文采用Hinode/SP卫星载荷实测的数据进行研究。先采用多波 长点进行训练,说明可以直接使用实测数据进行机器学习模型训练,不仅为后 续单波长定标精度提供一个参考,也为即将建成的AIMS望远镜提供一个快速 的多点磁场定标方案。目前最成熟的基于最小二乘法的磁场反演方法是采用单 像素进行反演的,首先尝试采用以单像素为一个训练样本的简单的MLP模型进 行单波长定标,说明单波长下也可以进行非线性磁场定标。然后用两个输入变 量的MLP网络的结果,建立三维定标曲面,说明MLP可以建立两个自由变量的 三维曲面模型,也有能力建立多个自由变量的四维或超维的精度更高的映射关 系模型。可视化的曲面为机器学习定标模型提供了一个物理解释。基于单像素 的MLP没有考虑相邻像素之间的关系,我们获得的磁场是以图像的形式展示出 来的,相邻像元之间必然存在一定的关联。因此,进一步采用CNN的方法进行 单波长定标有望获得更高精度的磁场。且CNN方法已在很多图像相关领域取得 了很多成果,磁场反演中也已进行了实验证明其可行性、稳定性和准确性。最 终,针对FMG载荷空间滤光器型磁像仪设备,考虑其轨道速度引起的波长漂移 问题,采用一定范围内变波长的Stokes参数,并把对应的波长信息加入到输入 参数中,进行变波长磁场定标研究。

1.3.1 章节安排

本文研究内容主要通过以下几个章节展开介绍:

第二章:机器学习是依靠数据驱动的方法,本章详细介绍了实验数据来源,数据选择,数据预处理方法等。

第三章:简单介绍机器学习方法的发展历程,以及相关的一些算法、概念 等。机器学习方法已应用在磁场反演中,基本采用全波段模拟数据,取得了很 好的实验结果,但尚不成熟,未在实际观测中应用。本章尝试在实际观测的数 据上采用机器学习的方法进行多波段磁场定标,并逐渐减少波长信息,验证其

在少量波长点实测数据上的可行性。

第四章:上一章验证在少量波长点实测数据中,机器学习方法也能够取得 较好的结果。滤光器型磁像仪常规下只有一个波长点,本文首先尝试采用简 单的经典的MLP的方法进行单波长定标研究。MLP是以一个像素点作为一个训 练样本的,本章尝试用V和I作为输入来训练纵场,(Q<sup>2</sup> + U<sup>2</sup>)<sup>1/4</sup>和I作为输入来 训练横场模型。然后通过输入全范围[min,max]等间隔的数据,来预测结果。由 于MLP基于单像素的,我们可以通过拟合建立两个自由变量的定标曲面,来直 观的观察我们的网络模型到底建立了怎样的一个曲面,通过这样基于物理关系 的曲面可以直观看出其强大的逼近非线性映射关系的能力。

第五章:基于单像素的MLP没有考虑相邻像素之间的关系,我们获得的磁场是以图像的形式展示出来的,相邻像元之间必然存在一定的关联。进一步采用考虑相邻像素之间关系的CNN的方法进行单波长定标有望获得更高精度的磁场。CNN方法已在很多图像相关领域取得了很多成果,磁场反演中也已进行了实验证明其可行性、稳定性和准确性。

第六章:最终,针对FMG载荷,考虑其轨道速度引起的波长漂移问题,以 及其他因素的影响,实际观测得到的数据,波长在一定范围内变化。通过多个 波长点数据来模拟变波长数据,把波长信息加入到输入参数中,进行变波长的 磁场定标研究。

第七章:对目前研究取得的进展和存在的不足进行总结,并对未来的计划 进行一个展望。

#### 第2章 用于可行性研究的磁场数据

#### 2.1 数据来源

Hinode/SP采用0.16×151角秒的狭缝连续扫描Fe I 630.15nm和630.25nm两条 谱线轮廓的空间信息。通过相机曝光和连续读出获得偏振解调器调制的原始偏 振光谱,然后在卫星上通过加减运算实时产生StokesIQUV光谱图像。它的最大 视场为320角秒,只能进行太阳局部视场的观测。望远镜设有常规观测、快速观 测、动态观测以及深积分磁图四种观测模式(Tsuneta 等, 2008),可以根据科学 目标进行灵活成像观测。本文主要采用常规观测下的数据开展研究。常规观测 下获得数据在0.15×0.16角秒像素分辨率下的偏振精度为0.1%,扫描一个160角秒 宽可覆盖中等大小的活动区需要83分钟。本文数据来自网站http://csac.hao. ucar.edu/sp\_data.php,包含了Level 1和Level 2的数据。Level 1的数据为平、 暗场等校准后的可以直接用于相关科学分析的StokesIQUV参量,Level 2的数据 为磁场反演的大气相关参数。

#### 2.2 数据介绍

Level1数据是一个4D数据(波长×空间(DX×DY)×Stokes参量),波长方向有112 个波长点,空间方向根据观测任务不同具有不同的视场,Stokes参量依次为IQUV 四个分量。文件存储方式为fits格式,fits头文件记录了观测时间、光谱分辨率、 曝光时间、日面位置等仪器、数据相关信息。

Level 2 数据是采用Stokes反演方法HAO"MERLIN"代码而获得的太阳大 气相关参数。它同样采用fits格式存储,每个fits文件包含42个反演参数或辅助 参数。42个参数中,与本文研究相关的主要有考虑填充因子的总磁场强度(*B'*)、 倾角(θ)、方位角(φ)、速度场(*Vel*)和填充因子(α)。*B'、*θ和φ是描述矢量磁场的 三个分量。速度场与磁场具有一定的耦合关系,填充因子在滤光器型磁像仪 中无法获得。因此,本文中所用到的数据主要有以上五个参数。由绪论可知, 反演过程依靠假设模型,需要一定的约束条件,存在不足之处。下面对Level 2数据反演过程的主要特性进行说明: (1)用于反演的Stokes轮廓数据为偏离线 心+/-0.3Å所有波长点,两条谱线都适用。 (2)通过最小二乘拟合最小化谱线轮 廓的波长漂移。 (3)反演获得的填充因子 $\alpha$ 与观测的StokesI参量的关系为:  $I = \alpha I_{mag} + (1 - \alpha)I_{scatt}$ 。其中 $I_{mag}$ 表示磁化分量,  $I_{scatt}$ 散射光轮廓。 (4)反演获得总 磁场强度最大强度限制为5000G。 (5)反演未尝试解决方位角180°不确定性问题, 方位角和倾角的范围为[0 180], 方位角以西向为正, 顺时针旋转为正。

#### 2.3 数据预处理

#### 2.3.1 数据清洗和标准化

Hinode/SP实际观测的数据含有很多噪声数据:有些数据包含较多的太阳边 缘数据;有些数据有较多噪点或坏点。针对这几种情况,本文首先选择包含较 大活动区的样本进行下载,然后对下载的数据进行可视化,去除噪点、坏点多 的数据。最后,剩下的数据作为样本,共计收集176个样本数据。176个样本中 有些数据包含大面积宁静区数据,活动区数据占比较小。另外,每个样本由于 在不同的时间进行观测的,样本之间存在一定的差异。因此,首先对数据进行 清洗和规范化处理:

1.选择感兴趣区域ROI(Region of interest)。用矩形框选择包含较多活动区的 强磁场区域,去除太阳边缘数据,减少宁静区数据。

2.标准化处理。依据Stokes参数之间的关系和宁静区强度一致的规则,对所 有StokesIQUV数据进行标准化处理来减小个体差异。StokesI(总光强)通过除以 样本本身宁静区像素值的中值I<sub>med</sub> (本文认为总磁场强度300G下的区域为宁静区 数据),StokesQUV直接除以总光强StokesI进行归一化。公式如下:

$$I_{\text{norm}} = \frac{I}{I_{\text{med}}} \quad Q_{\text{norm}} = \frac{Q}{I} \quad U_{\text{norm}} = \frac{U}{I} \quad V_{\text{norm}} = \frac{V}{I}.$$
 (2.1)

#### 2.3.2 多波段训练模型样本数据

多波段训练采用16-8-4-2波长点逐减的方式训练模型。分析随着波长点数的 减少,机器学习模型结果的精度变化情况,进一步比较分析采用单波长进行磁 场定标的可能性。本文将112个波长点依次编号为0-111,16波长点的选择为[20 22-28 30-36 38](如图2.1(d)所示),8波长点为[22 24 26 28 30 32 34 36](如图2.1(c)所 示),4波长点为[22 26 32 36](如图2.1(b)所示),2波长点为[26 32](如图2.1(a)所 示)。因此16波长模型有64个输入(16个波长点的*StokesIQUV*),8波长有32个输 入参数,4波长有16个输入参数,2波长有8个输入参数。


图 2.1 不同多波段的波长数据选择

Figure 2.1 Wavelength data selection for different number of multi-waves

由线性定标公式可知,线性定标下直接获得矢量磁场分量为横场、纵场和 方位角。并且方位角无需定标系数,不存在磁饱和问题。因此多波段主要考虑 横纵场的测量,横纵场与总磁场强度关系如下:

$$B_l = B\cos(\varphi) \tag{2.2}$$

$$B_t = B\sin(\varphi) \tag{2.3}$$

$$B = \sqrt{B_l^2 + B_t^2}.$$
 (2.4)

另外,由于无法从单波长的Stokes数据中提取出填充因子这个参数,本研 究采用不考虑填充因子的磁场参数作为输出(MLP单波段、CNN单波段和变波 长的磁场定标均采用不考虑填充因子的磁场参数)不考虑填充因子的总磁场强 度(*B*)可简单通过以下公式获取:

1

$$B = \alpha B' \tag{2.5}$$

1

由公式 2.2、2.3 和 2.5 可获得不考虑α的横纵场为:

$$B_l = B\cos(\varphi) \tag{2.6}$$

<sup>1</sup>本公式没有严格遵循 2.2 小节中反演特性(3) 参考本文方法时请慎重。

#### 表 2.1 训练集、测试集和验证集划分列表

| DATA        | DATE              | NO     | τοται | RATIO |  |
|-------------|-------------------|--------|-------|-------|--|
| SET         | (YYYYMMDD)        | 110.   | TOTAL |       |  |
| Training    | 20140726-20141220 | 98     |       |       |  |
|             | 20150101-20150216 | 14 121 |       | 0.69  |  |
| Set         | 20170905-20170907 | 9      |       |       |  |
| Validate    | 20170822-20170904 | 9      | 18    | 0.10  |  |
| Set         | 20170907-20170929 | 9      | 10    | 0.10  |  |
| Test<br>Set | 20110728-20111107 | 9      |       |       |  |
|             | 20140104-20140418 | 12     |       |       |  |
|             | 20141021-20141024 | 4      | 37    | 0.21  |  |
|             | 20180206-20180621 | 5      |       |       |  |
|             | 20190321-20190508 | 7      |       |       |  |

Table 2.1 The list for the training set validation set and test set.

$$B_t = B\sin(\varphi). \tag{2.7}$$

因此采用不考虑α的*B*<sub>l</sub>和*B*<sub>t</sub>作为目标数据来训练网络模型,研究机器学习方法在实际观测数据下进行磁场定标的可行性。在机器学习中,一般将样本分成独立的三部分:训练集(train set),验证集(validation set)和测试集(test set)。其中,训练集用于建立模型。176个活动区样本具体划分如表格2.1所示。

#### 2.3.3 MLP单波段训练模型样本数据

单波段定标采用Hinode/SP的偏离6301.5Å谱线线心-0.063Å的波长位置(如图 2.2所示)来模拟滤光器型磁像仪。在实际观测中,由于多普勒速度场Vel会引起 谱线漂移,这意味着每个样本的波长位置并不是严格一致的,因此考虑将Vel加 入到输入参数中进行训练来分析Vel的影响,输入参数将有两种情况:一种情况 是只有StokesIQUV,另一种是StokesIQUV和Vel。为了分析对比不同磁场分量 的模型性能,输出参数考虑总磁场强度、倾角、横场和纵场四个参数。

在单波长磁场中,基于MLP网络的学习方法是采用单个像素作为一个样本,



图 2.2 采用实测的Hinode/SP的数据来模拟窄带滤光器观测

Figure 2.2 The schematic diagram of simulating the narrow-band observation using the actual observed data of *Hinode/SP*.

这点与磁场反演一致。由于图像中存在很多噪点,为了减少噪声数据的影响,除了数据清洗和标准化的处理之外,还做以下处理:



图 2.3 StokesIQUV和Vel直方图均衡化前后对比图



(1)消噪处理: 首先使用5×5的中值滤波算子来消除输入和输出数据中的脉冲噪声。然后去除总磁场强度低于200G的像素点,并且去除8连接域小于20个像

素的斑点数据。

(2)均衡化数据:从目标数据的直方图中可直观地看出(如图2.3所示)样本中 高磁场(少)和低磁场(多)数据占比差距较大。为了平衡这种差距,把所有像素点 按强度值等间隔划分,随机从每个间隔抽取固定数量的数据(强磁场数量不足取 全部)。



图 2.4 输入参数为偏离6301.5Å谱线线心-0.063Å的波长位置*StokesIQUV*图像样本实例。该 样本是于2014年9月11日10:47UT在*Hinode*/SP上观测的,活动区号为NOAA AR 12158。样本为通过公式2.1归一化处理后的数据。

Figure 2.4 The Stokes *I Q U* and *V* at -0.063 Å apart from the line center of Fe *I* 6301 Å as the input parameters. The data was observed at 10:47 UT on 2014-09-11 in the NOAA AR 12158. These maps of Stokes parameters are normalized quantities by Equation 2.1 after data preprocessing.

## 2.3.4 CNN单波段训练模型样本数据

选取与MLP方法同样波长位置的数据作为样本集,不同的是CNN以图像为

训练样本。训练集、测试集和验证集的样本划分与多波段相同。但CNN单波段中,将不再考虑速度场Vel的影响(因实际观测中Vel是无法获得的,且MLP方法 说明Vel在本文选择的样本数据上对训练结果影响较小)。因此输入为归一化后 的Stokes参数如图2.1所示。在CNN方法中将对方位角进行训练,进一步分析机 器学习方法的可行性。本阶段输出参数为横场*B*<sub>t</sub>、纵场*B*<sub>l</sub>和方位角α(如图2.5所 示)。



图 2.5 作为输出参数不考虑填充因子的B<sub>l</sub>和B<sub>t</sub>(主要参数)和φ样例图

Figure 2.5 The  $B_l$  and  $B_t$  (our main concerning parameters) without considering the  $\alpha$  and  $\varphi$  (azimuth angle) as the target parameters.

## 2.3.5 CNN变波长训练模型样本数据



图 2.6 变波长数据选择。

Figure 2.6 Variable wavelength data selection.

变波长模型是针对空间滤光器磁像仪在轨道速度、太阳自转等影响下产生 谱线漂移问题而设计的,其中轨道速度的影响尺度最大,其它因素影响较小, 下面根据轨道速度估算谱线漂移的范围。FMG卫星轨道速度约为±4km,工作波 长在5324.1Å。通过公式2.8得到在轨道速度下,FMG谱线漂移约为为±0.072Å。

$$\Delta \lambda = \lambda \times \frac{v}{c} \tag{2.8}$$

式中, c 表示光速, Δλ表示线心的偏移量, λ表示工作波长, v表示卫星轨道速度。本文采用的*Hinode*的6301 谱线的实测数据来进行该研究。模拟滤光器单波长观测点在6301线心-0.063 附近, 假定轨道速度和FMG相同, 它的谱线漂移约为±0.084。*Hinode*/SP的谱线扫描间隔为0.021, 约为蓝红移各四个波长间隔, 会漂移到线心位置。由于FMG的谱线比*Hinode*/SP宽, 一般情况不会漂移至线心位置, 因此本文选取滤光器型磁像仪模拟观测点(如图2.6)上下2个波长位置, 加模拟点共计5个波长点进行变波长定标(如图2.6红色圆圈所在位置所示)。

## 第3章 机器学习用于单波长磁场定标的可能性研究

#### 3.1 机器学习方法简介

## 3.1.1 机器学习的发展历程简介

机器学习是人工智能(AI)发展到一定阶段的必然产物,AI是目标,机器学 习是实现人工智能的一种手段。机器学习,顾名思义就是让机器自己学习知 识。而在AI早期的知识表示和自动推理等方法中,机器是不能自己学习知识 的,只能由人把知识总结出来再交给计算机。早在20世纪40年代初,心理学 家W.S.McCulloch和数理逻辑学家W.Pitts在分析、总结神经元的生物特性和运行 机理的基础上首先提出神经元的数学模型——神经网络雏形(Mcculloch 和 Pitts, 1994),并以两位科学家名字的首字母命名为M-P模型。M-P模型是机器学习方 法的重要萌芽。1957年,在布鲁塞尔举行的第十五届国际心理学大会上,康内 尔大学教授Frank Rosenblatt提出了一种具有计算单元的单层神经网络模型,并 称之为感知机(Perceptron)(Rosenblatt, 1959)。基于神经网络的"连接主义学派" 开始兴起。除此之外,基于逻辑表示的"符号主义学派",以强化学习为基础的 "行为主义学派"等机器学习方法也都有所发展。



# 图 3.1 经验模型 Figure 3.1 Empirical model

二十世纪八十年代是机器学习各种技术方法百花初绽的时期,使机器学习 出现了多种分类方式。而被研究最多、应用最广的是"从样例中学习"的归纳 学习。归纳学习首先要建立训练集以及对应假设空间,算法在所有假设空间中 搜寻与训练集"匹配"的假设,搜寻过程体现了算法的归纳偏好(Zhou, 2016), 大多时候直接决定了通过学习得到的模型的性能。它涵盖了监督学习、无监督 学习等,这也是当前机器学习研究领域的主要划分。利用误差反向传播(error BackPropagation,简称BP)算法的多层感知器是归纳学习的主流算法之一。它 于1986年在单层感知机基础之上发展起来的,使神经网络成为一种实用的工具, 可以用来解决一般性质的非线性输入-输出映射问题(Haykin, 2009)。BP也是被应 用最广泛的机器学习算法之一。但由于其学习过程是一个通过"试错"和"手 工调参"来确定网络模型结构和大量神经元参数值的,缺乏理论指导,产生的 结果是"黑箱模型"(Cauer, 1954),俗称黑盒子(如图3.1所示),使其发展受限。 在二十世纪九十年代,以支持向量机SVM(Support Vector Machine,简称SVM)和 "核方法(kernel methods)"为代表的"统计学习"方法兴起,成为当时的主流机 器学习方法。

二十一世纪初,人类进入了大数据时代,数据储量和计算设备都有了较大的发展,是以深度学习为代表的机器学习再次掀起了人工智能研究的热潮。深度学习是依靠大量数据驱动,通过多层的神经网络结构来模仿人脑学习的方法。 深度学习的理论基础尚不完备,但其涉及的模型复杂度较高,只要把参数调节 好,便会获得不错的性能,使其在工程实践中得以广泛应用。具有"局部感知" (卷积核作用于图像局部区域)特征的卷积神经网络(CNN)是深度学习最具代表的 方法之一。CNN采用"权共享"(即一组神经元使用相同的连接权值)的训练策略 有效的节省了训练开销。最近这些年,CNN在计算机视觉、自然语言处理等领 域应用非常广泛。

机器学习发展了近百年,其衍生了很多算法。有些算法是为了解决某一类问题而创造出来的,而有些算法是在其他算法的基础之上优化改进延伸出来的。 在我们选择算法时,需要根据不同的数据类型,不同的任务,确定其学习方式, 从而选择最合适的算法来建模。常规的磁场反演或者线性定标都是函数拟合的问题,即用一个预设的(如辐射转移方程或者线性函数)通过最小二乘法来求解固 定的参数(矢量磁场或者线性定标系数)。而机器学习方法神经网络的思路是使用 一系列基函数的组合来逼近这个未知的映射关系,并使误差最小化。也就是完 全基于数据驱动,在输入和输出数据之间通过有监督学习算法来挖掘其内在的 关联性,并用简单函数的组合来逼近这个关系。

## 3.1.2 学习方式

## 3.1.2.1 有监督学习

有监督学习(Supervised learning)是能够从由输入和相应的预期输出组成的训

练集中学到或建立一个映射方程或者模型。判断一个问题是否能够用监督学习 算法,要看用于解决该问题的数据集是不是有输入数据和对应的作为输出的标 示数据组成。没有预期输出数据的训练集,其问题则无法使用监督式学习方法 解决。此方法主要应用有两种:回归分析和分类任务。磁场测量问题属于前者, 模型的输入主要为Stokes参量,输出为磁场参量。

监督学习的工作过程可以简单描述如下:给定一个包含N个训练样本的数据集 (x<sub>1</sub>, y<sub>1</sub>), (x<sub>2</sub>, y<sub>2</sub>), ..., (x<sub>n</sub>, y<sub>n</sub>),其中x<sub>i</sub>为输入向量,y<sub>i</sub>是对应的预期输出。通过学习算法寻找一个能够表示X到Y的关系函数或模型g,X为输入空间,Y为输出空间,g是所有可能的假设空间G的一个元素。BP神经网络、SVM、核方法、决策树、线性回归、逻辑回归等算法,都属于有监督学习的范畴。

## 3.1.2.2 无监督学习

无监督学习(Unsupervised Learning)是与有监督学习相对的一种学习方式。 训练集不包含事先标记过的数据,缺乏足够的先验知识,只能依靠相关算法自 动对数据进行分类或者分群。无监督学习的主要应用有:聚类分析和维度缩减 等。

主成分分析(Principal Component Analysis,简称PCA)是无监督学习最主要的 代表算法之一。它是一种常用的降维方法。它的思想是把样本集想象成在超维 度正交空间中分布的点,然后根据超平面的最近重构性(样本点到这个超平面的 距离都足够近)和最大可分性(样本点在这个超平面上的投影能尽可能分开),对 数据样本在超空间投影上进行特征分解,把数据降到用户所需的维度空间,去 除数据间的冗余信息和非关键信息。

#### 3.1.3 神经网络

#### 3.1.3.1 神经网络基本结构

神经网络以神经元(如图3.2(a)所示)为基本单位,按照一定的层次结构连接起来的。一个神经元包含输入x<sub>i</sub>,权重w<sub>i</sub>,偏置<sub>i</sub>,激活函数f和输出y五部分组成。多层感知机(MLP)是典型的较早发展起来一种神经网络算法,在单层神经网络的基础上引入了一到多个隐藏层(hidden layer)。隐藏层位于输入层和输出层之间,每个隐藏层的输出通过激活函数进行非线性变换。多层感知机的层数和各隐藏层中隐藏单元个数都是超参数。图3.2(b)展示了一个单隐藏层神经网络结构

示意图。

常用的激活函数有:

(1)Sigmoid函数

$$sigmoid(x) = \frac{1}{1 + e^{-x}}.$$
 (3.1)

(2)tanh函数

$$tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}.$$
 (3.2)

(3)ReLu函数(Nair 和 Hinton, 2010)

ReLU(x) = max(0, x) = 
$$\begin{cases} x, & x \ge 0, \\ 0, & x < 0. \end{cases}$$
 (3.3)



图 3.2 神经元和神经网络结构示意图

Figure 3.2 Structural diagrames of neuron and neural network

3.1.3.2 BP算法

BP算法由信息的正向传播和反向传播两个过程。正向传播是样本从输入层进入隐藏层,再到输出层。如果输出与实际期望不符,误差回传,通过梯度下降算法调整参数;如输出与期望值相同或者达到其他停止学习的约束条件,则结束学习。反向传播是通过计算损失函数(loss函数)的梯度来反向调整神经元,通过隐藏层直至输入层,将误差信号分摊给各层各单元。整个训练过程可以看作在参数空间中寻找使得loss函数最小的"最优"参数组合,从而获得X到Y的关系函数或模型g。这里的"最优"是指"全局最小",但在训练过程中难免会

陷入"局部极小",这时需要一些策略来"跳出"局部极小,如模拟退火(Aarts 和 Korst, 2015),随机梯度下降(SGD),遗传算法(Goldberg, 1989)等。

损失函数是描述预测值ŷ<sub>i</sub>与真值y<sub>i</sub>之间偏差的,常用于回归问题的loss函数 有:

(1)均值平方差(Mean Squared Error, 简称MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2.$$
(3.4)

(2)平均绝对误差(Mean Obsolute Error, 简称MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^{n} |y_i - \hat{y}_i|.$$
(3.5)

## 3.1.3.3 万能逼近定理

万能逼近定理(Universal approximation theorem)(Cybenko, 1989; Carroll 和 Staude, 2001)是指神经网络可以以任意的误差和精度来逼近给定的函数,如果给 定的是连续函数,则一定存在单层神经网络可以以任意精度逼近这个连续函数。 许多应用程序的主要任务是通过从输入空间的概率分布中抽取样本来逼近/估计 函数。深度近似是通过许多层简单函数的组合来近似一个函数,这些简单函数 可以看作是一系列嵌套的特征提取器。深层学习网络的关键思想是将组合层转 换为可调参数层,通过学习过程进行调整,从而对目标数据达到较好的近似。

## 3.1.3.4 深度学习

理论上讲越复杂的学习任务需要越多参数的复杂模型,复杂模型意味着训练时间效率低且容易过拟合。而随着AI芯片、云计算的加速发展,有效缓解了训练的低效性;以及大数据时代的到来,可用的训练样本大规模增加降低了过 拟合的风险。深层的神经网络模型(深度学习)以其大容量(多隐藏层)带来的超强的学习能力,使其得到了广泛的应用。

卷积神经网络(Convolutional Neural Network, 简称CNN)(Lecun 和 Bengio, 1995; Lecun 等, 1998)是一种典型的深度学习算法。它采用的"权共享"(即一组神经元使用相同的连接权值)训练策略有效的节省了训练开销。CNN与MLP不同, MLP是点对点的网络, 而CNN采用图像作为训练样本, 但网络结构都是由输入层、隐藏层和输出层组成。CNN隐藏层包含卷积层、池化层和全连接层

等多种简单结构,还有残差块、Inception模块等跨连接结构。卷积层和池化层 为卷积网络所特有,卷积层中包含权重系数,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,并且卷积层输出特征图的尺寸由这三个方面决定,卷积过程如 图3.3(a)所示。池化层用于压缩中间数据、减少参数的数量和减小过拟合,主 要有最大池化和均值池化,池化过程如图3.3(b)所示。



图 3.3 卷积过程和池化过程示意图



## 3.1.4 结果评价指标

对于磁场测量这种回归问题来说,常用的定量性评价指标主要有:

(1) 预测值与目标值之间残差的均方根(Root Mean Square, 简称RMS)

$$RMS = \sqrt{MSE},$$
 (3.6)

(2) 预测值与目标值之间平均绝对误差(Mean Obsolute Error, 简称MAE

$$MAE = \frac{1}{n} \sum_{i=1}^{n} |(y_i - \hat{y_i})|$$
(3.7)

(3) 预测值与目标值之间线程相关程度的相关系数*R*如公式,*Cov*(*y<sub>i</sub>*, *ŷ<sub>i</sub>*)表示 两者的协方差,*Var*[*y<sub>i</sub>*]表示目标值的方差,*Var*[*ŷ<sub>i</sub>*]

$$R = \frac{Cov(y_i, \hat{y}_i)}{\sqrt{Var[y_i]Var[\hat{y}_i]}}.$$
(3.8)

(4) 决定系数*R*<sup>2</sup>, *R*<sup>2</sup>表示拟合的准确性, *R*<sup>2</sup>为1意味着可以从独立变量无误 地预测因变量。

$$R^{2} = 1 - \frac{\sum_{i=1}^{n} (y_{i} - \hat{y}_{i})^{2}}{\sum_{i=1}^{n} (y_{i} - \overline{y})^{2}}.$$
(3.9)

### 3.2 在磁场定标中的可行性分析

Hinnode/SP的磁场数据是由112个波长点的Stokes参量数据经过反演获得的, 而滤光器型只有一个观测位置。本章节选择6301.5Å谱线来进行可行性分析,由 谱线轮廓可看出,线心到连续谱在红蓝翼大约各有8个波长位置,因此选用16个 点作为输入进行机器学习方法的磁场测量模型训练。然后逐步减少选取的波长 点数,选取线心两侧的共8个、4个、2个点进行模型训练和研究分析。详细参 考2.3.2章节内容。



图 3.4 ResNet模型的结构设计

Figure 3.4 Schematic architecture of the ResNet used in this article

## 3.2.1 训练方法与策略

首先利用CNN(Le, 1989)体系结构——残差网络ResNet(He 等, 2016)来构建神 经网络模型。ResNet是2016年首次发布的著名的CNN架构之一,有效的解决了 深层网络退化问题。它的主要改进是重新构造了各层,采用残差学习方式使结

构更容易优化,并可以通过大大增加的网络深度使结果更准确。Asensio Ramos 和 Díaz Baso (2019)等作者已经使用了类似的体系结构用于太阳物理数据处理中,并且发现其具有出色的性能。

网络模型的结构设计对其性能至关重要。根据多次实验,发现残余块与 基本卷积层结合可以相对较好的生成磁场。ResNet模型的结构设计如图3.4所 示。每个卷积层都包含很多个训练参数,并通过卷积滤波器提取特征(Lecun 等, 1998)来生成不同的特征图。在我们的模型中,首先设置了一个卷积层,它包 含64个大小为3x3的卷积滤波器,来生成初始输入参数的特征图。并且本网络中 所有卷积层中卷积核的大小均为3×3。核大小对于模型的性能影响较大,这也许 是因为太大的卷积核会使结果图像产生平滑现象,而太小的核则会减少空间相 关性。卷积层之后为激活函数提供非线性特征,激活函数选择机器学习中常用 的ReLU函数(公式)。使进入残差块的数据为融合输入参数后的更多特征图。

该模型中有11个残差块。每个残差块均包含残差部分和输入x的信号。残 差部分由3个部分组成,如图3.4所示。有两个卷积层,均与初始卷积层相同。 两个卷积层之间使用ReLU层以提供非线性映射。输入x经过残差部分以获得残 差*F*(*x*)。输入*x*加残差*F*(*x*)再通过ReLU层进行非线性运算得到残差块的最终输 出。残差块之后为两个卷积层,对多个特征图进行融合,最后生成输出数据。 本章将该网络模型命名为MagRes。

训练策略: (1)由于磁场参数具有不同的单位和SNR,因此需要在损失函数 中为每个参数设置不同的权重。由于尚未找到为每个磁场参数分配权重的完美 解决方案,为了获得更准确的模型,采用为每个磁场参数建立一个模型的策略 来进行训练。(2)由2.3.2可知训练集共计有121个样本。每个样本尺寸各异且数 量少,为了统一尺寸和增加样本数,每一个epoch(一个epoch使用全部的训练集 样本完成一次前向过程,前后更新一次参数)训练过程中,随机从每个训练集样 本中选取85\*85的区域作为一个样本进行模型训练。一个模型训练完成需要上万 个epochs过程,大幅度地增加了样本数量。另外,样本尺寸不能选择的太小,太 小会减少空域信息;相反太大了会增加占用的显存空间。

模型主要训练参数设置及说明:训练批次大小为28,验证批次大小为18。 网络模型中有9万多个自由参数。以Adam算法(Kingma 和 Ba, 2014)为优化器, 初始学习率为1*e*<sup>-4</sup>,损失函数是回归网络中常用的MSE方法。



图 3.5 不同数量波长模型横场预测结果

Figure 3.5 The prediction results of transverse field for different number of wavelength



#### 图 3.6 不同数量波长模型横场预测结果与目标数据的残差直方图

# Figure 3.6 Residual histogram of transverse field between prediction results and target data for different number of wavelength models

这项工作是在以TensorFlow 1.5.0为计算平台,以Keras 2.2.2的深度学习框架 下进行实际训练的。为了加快训练速度,使用了在深度学习特别是CNN中广泛 应用的GPU加速。本研究使用了NVIDIA Quadro P2000(安装在Dell T3620图形工 作站中)和matrox g200er2显卡。P2000具有1024个CUDA内核和5GB GDDR5板载 内存。2个和4个波长点的模型,每个epoch平均需要约4s的训练时间;8个波长点 的需要约12s的时间,16波长点需要21s左右的时间。



图 3.7 不同数量波长模型横场预测结果与目标数据的散点图

#### 3.2.2 结果与验证

本章研究共计训练8个网络模型,横纵场各四个不同数量波长点的模型。下 面使用从测试集中选择的19年4月13日世界时10:26:49观测的NOAA AR 12738活 动区的样本来说明结果。

Figure 3.7 Scatter diagrams of transverse field between prediction results and target data for different number of wavelength models





Figure 3.8 The prediction results of longitudinal field for different number of wavelength

models

#### 3.2.2.1 横场

NOAA AR 11738是一个βα类型的黑子,从Hinode/SP反演的结果来看其最高磁场强度达到了反演code设置的最高限5000 G。图3.5展示了横场的四个模型对其预测的结果,中间图像为ResNet的结果,其四个模型的预测结果与反演的目标数据(左侧)直观上看非常接近,两个波长点的模型在高磁场区域与目标稍微有些不同。右侧为预测结果与目标数据的残差图,可看出大部分残差在300 G以内,尤其16和8个波长点模型的预测结果残差在±100 G以内。4个波长点的模型结果残差颜色明显变得更深,而2个波长的模型结果有比较多接近或超出±300 G。





Figure 3.9 Residual histogram of longitudinal field between prediction results and target data for different number of wavelength models



图 3.10 不同数量波长模型纵场预测结果与目标数据的散点图



进一步采用直方图和散点图的形式对其进行定量定性分析,图3.6为残差直 方图,图3.7为预测值与目标的散点图。从直方图的波峰来看,2个波长点模型的 宽度比其他模型要宽,4个波长点模型比2个的较窄,但比8个和16个的稍宽。这 与直观的结果吻合。图上面的RMS和MAE也是明显这个趋势,2个波长点模型的结果能达到137 G,而16个的为79 G,明显要低很多。如果预测值与目标值一致,则其散点图为一条线Y = X,显然这是理想情况下。实际情况几乎不可能达到,从图3.7可看出散点图都是具有一定宽度的分布在Y = X的左右两侧。同样随着波长信息的减少宽度增加。其决定系数分别为0.93、0.96、0.97、0.98,随着波长信息的丰富而增加。



图 3.11 简单黑子样本在16波长点模型下的预测结果

Figure 3.11 The prediction results of a simple sunspot sample under 16-wavelength point model

#### 3.2.2.2 纵场

纵场具有与横场相似的情况。图3.8展示了NOAA AR 11738纵场的四个模型 对其预测的结果。左侧为反演的结果,中间图像为ResNet的结果,右侧为预测结 果与反演的目标数据的残差图。直观上来看,在纵场上的预测结果与反演结果 很接近,从残差图可看出大部分残差在300 G以内。尤其16和8个波长点模型的 预测结果基本为白色,4个波长点的模型结果残差少数点超过了±100 G,而2个 波长的模型结果部分接近紫色或绿色,残差在±300 G左右。

同样采用直方图和散点图的形式对其进行定量定性分析,图3.9为残差直方 图,图3.10为预测值与目标的散点图。从直方图的分布来看,不同波长点模型 的结果都非常集中地分布在0 G附近,2波长点的残差RMS为31 G、MAE为13 G, 而16波长点结果的RMS为17 G,比2波长模型结果低了14 G。从图3.7可看出散 点图都是非常集中的分布在Y = X的左右两侧。其决定系数分别为0.97、0.98、 0.99、0.99,随着波长信息的减少而略降低,2波长模型的结果也达到了0.97。

## 3.2.3 结果比较分析

从图3.7的横场结果的散点图可以看出,预测值与目标基本在Y = X两侧分布,但在左下角有一部分呈拐角分布,这部分数据多数在1000 G以下,位于宁静区。下面将从小黑子活动区样本的噪点分析、2个波长模型与线性定标的比较分析以及不同模型的进一步分析比较三个方面论述。



图 3.12 残差和噪点分析图

Figure 3.12 Analysis diagrams of residual errors and noises

## 3.2.3.1 宁静区噪点分析

从测试集中选择2014年4月12日观测的NOAA AR 12032活动区样本进行说 明,NOAA AR 12032是一个βγ型的黑子。由图3.11可以看出16波长点MagRes模 型的结果(中图)与目标(左图)非常的接近,残差图(右侧)来看除了宁静区有一些 点残差超过了300 G。由图3.12的右上散点图可以看出其分布形状像鱼尾一样, 有一部分的预测值与目标偏差较大,分布完全偏离了45度线。左上直方图也可 以看出残差小于-200 G 的数据明显多于大于200 G的数据。为了定位这部分较 大偏差数据,用-200 G阈值对残差图进行分离。大于-200的部分如图左下方,小 于-200 G的位于图的右下方。从这两张图与目标图像对照来看,偏差大的数据 基本为噪声数据或者反演有问题的地方。右下图显示结果表明在黑子区域很干 净,完全没有点状分布。







## 3.2.3.2 2波长模型与线性定标比较

由结果部分可知,2波长模型的结果比更多波长模型的结果要差一些,尤其 在高磁场区域。且单波长线性定标中在高磁场区域存在磁饱和效应。2波长模型 只比单波长多了一个波长信息,不足以进行磁场反演。如果其模型结果能够接 近反演结果,说明机器学习也有可能进行单波长磁场定标。为了说明机器学习 的优势,将2模型的结果与线性定标结果进行比较。如图3.13所示,上面一行为 纵场结果,下面为横场结果。中间为MagRes的预测结果,与目标(左)还是非常 接近的,但线性定标的结果(右)与目标相差较大,尤其在强磁场区域,红色方框 中可以明显看出这一点。

#### 3.2.3.3 不同模型之间比较分析

一个样本的结果很难说明问题,将测试集预测值与目标的残差的RMS列出,如3.1表所示。横场残差: 2wav(2波长)、4wav、8wav、16wav的均值分别约为64.2 G、50.4 G、43.4 G、42.4 G。纵场残差: 2wav、4wav、8wav、16wav的均值分别约为59.7 G、35.3 G、31.1 G、30.8 G。说明波长信息的减少,机器学习的结果精度有所下降,但可以看出直至2波长点模型仍能很好的收敛。

#### 3.2.4 讨论

基于最小二乘的磁场反演方法需要至少5个波长点的Stokes参量,本章采 用16-8-4-2波长点的Stokes参量进行机器学习方法的可行性验证分析。16和8波 长点的模型多于磁场反演所需的最少点数,能够很好地预测磁场,结果相差不 大,对磁饱和区域能够较好地预测,并非常接近反演的结果。4个波长点的模型 相较于16和8个的,性能稍差,但与反演的残差平均也在50 G左右。2个波长点 模型,由于波长信息较反演所需最低5个点,少了很多信息。但其结果与其他几 个模型相比: 横场测试集平均残差在64.2 G,比16波长模型结果高了22 G;纵 场2波长点残差RMS为59.7,比16波长模型结果高了不到30 G。但其与线性定标 比较,可以非常明显地看出,其在很大程度了解决了磁饱和的问题,与反演的 结果总体上是很接近的。

#### 3.3 小结

人工智能经历了三次浪潮,机器学习是其发展到一定阶段的必然产物。神 经网络是机器学习最具代表性的方法之一,其强大的非线性逼近能力,使其在 很多领域广泛应用。单波长磁场定标是典型的回归问题,神经网络为解决回归 问题提供了一种强有力的方案。多点磁场定标中基本采用模拟数据训练模型, 模拟数据具有噪声少的特点,与实际观测的数据存在很多差异。本文首次采 用实测数据开展单波长磁场定标研究,先采用16波长点的实测数据证明实测数 据也能够用于机器学习的多点磁场生成模型的训练。然后逐步减少波长信息直 至2个波长,随着波长信息的减少,网络模型的性能虽有所下降,即使2个波长 点结果与反演结果相比也很接近。2波长模型的结果与线性定标比,明显克服了 磁饱和问题,说明了机器学习很有希望应用在单波长磁场定标中。

#### 表 3.1 测试集在不同波长点模型残差RMS

| Date            | Bt  |    |    | Bl |     |    |    |    |
|-----------------|-----|----|----|----|-----|----|----|----|
| YYYYMMDD_HHMMSS | 2   | 4  | 8  | 16 | 2   | 4  | 8  | 16 |
| 20140107_212011 | 58  | 44 | 38 | 36 | 68  | 35 | 29 | 29 |
| 20140416_170510 | 51  | 42 | 37 | 36 | 46  | 27 | 24 | 24 |
| 20190411_212127 | 74  | 49 | 37 | 37 | 74  | 39 | 34 | 35 |
| 20111011_165039 | 53  | 45 | 40 | 39 | 32  | 23 | 18 | 18 |
| 20180206_132557 | 56  | 47 | 41 | 40 | 35  | 23 | 20 | 20 |
| 20190413_102649 | 45  | 42 | 39 | 38 | 31  | 20 | 18 | 17 |
| 20190508_060014 | 48  | 43 | 40 | 39 | 32  | 21 | 18 | 18 |
| 20180422_181534 | 47  | 43 | 39 | 38 | 33  | 20 | 18 | 17 |
| 20140109_160028 | 58  | 45 | 39 | 38 | 57  | 33 | 28 | 27 |
| 20190321_135709 | 61  | 51 | 46 | 45 | 43  | 27 | 25 | 25 |
| 20110730_140511 | 45  | 40 | 36 | 35 | 42  | 26 | 23 | 23 |
| 20110924_222532 | 70  | 54 | 48 | 47 | 69  | 44 | 39 | 38 |
| 20140413_110600 | 44  | 40 | 37 | 36 | 30  | 19 | 17 | 16 |
| 20140227_233509 | 59  | 47 | 42 | 41 | 48  | 28 | 28 | 28 |
| 20110823_111502 | 52  | 43 | 39 | 38 | 46  | 27 | 24 | 23 |
| 20190412_180414 | 57  | 45 | 35 | 34 | 59  | 35 | 29 | 29 |
| 20110728_142340 | 51  | 42 | 38 | 37 | 44  | 27 | 25 | 24 |
| 20180210_050509 | 47  | 41 | 38 | 37 | 43  | 26 | 23 | 22 |
| 20140201_165409 | 99  | 79 | 54 | 51 | 108 | 54 | 49 | 51 |
| 20111107_121009 | 60  | 45 | 39 | 37 | 63  | 36 | 33 | 33 |
| 20140202_160009 | 105 | 71 | 52 | 54 | 107 | 53 | 47 | 50 |
| 20190416_112943 | 86  | 60 | 53 | 51 | 74  | 40 | 35 | 34 |
| 20140418_123410 | 56  | 46 | 40 | 39 | 46  | 28 | 25 | 25 |
| 20110804_021040 | 49  | 40 | 35 | 34 | 45  | 27 | 24 | 24 |
| 20141024_234109 | 78  | 53 | 45 | 44 | 88  | 55 | 47 | 48 |
| 20110924_104909 | 79  | 59 | 51 | 50 | 71  | 45 | 40 | 40 |

# Table 3.1 RMS of residual error between models at different wavelength points and inversion data on test set

## 第4章 应用简单神经网络解决磁饱和问题

由3.2可知,实测数据也可应用到机器学习方法的磁场生成中,并且在只 有两个波长点的数据信息时,在强磁场区域克服了磁饱和效应带来的影响。由 前几章节可知,在基于滤光器型的单波长观测的磁像仪中尚无完善的太阳物 理理论模型支持其可以像光谱仪型磁像仪一样通过反演获得高精度磁场。弱场 假设下的线性定标简化了斯托克斯参数与磁场之间的非线性关系。基于反向传 播BP算法训练的多层感知器MLP可以被视为一种用于实现一般性质的非线性输 入到输出之间映射关系的实用工具。为了解决该问题,本章尝试使用不依赖特 定数学函数的MLP建立单波长Stokes参数与磁场参数之间的关系模型。

#### 4.1 数据说明

本章节采用2.3.3小节MLP单波段模型样本数据中说明的方法进行数据预处理,与基于CNN的多波段网络模型所采用的数据略有不同,共计采用*Hinode/SP*活动区样本176组,分为训练集和测试集,如表4.1所示:训练集样本139组,测试集37组。

#### 表 4.1 训练集和测试集列表

| DATA            | DATE                     | NO   | τοται | ΡΑΤΙΟ |  |
|-----------------|--------------------------|------|-------|-------|--|
| SET             | (YYYYMMDD)               | 110. | IOIAL | MAIIO |  |
| Training<br>Set | 20140726-20141220        | 98   |       |       |  |
|                 | 20150101-20150216 14 139 |      | 0.79  |       |  |
|                 | 20170822-20170929        | 27   |       |       |  |
|                 | 20110728-20111107        | 9    |       |       |  |
| Test            | 20140104-20140418        | 16   | 37    | 0.21  |  |
| Set             | 20180206-20180621        | 5    |       | 0.21  |  |
|                 | 20190321-20190508        | 7    |       |       |  |

 Table 4.1 The list for the training set, and test set.

#### 4.2 训练方法与策略

本质上来讲,通过利用Stokes反演的结果来模拟单波长观测进行磁场定标 是一个多元非线性回归问题。多元非线性回归可以通过灵活设置输入变量数量 的单个或多层神经网络来完成。基于BP算法的MLP网络,是属于"从样例中学 习"的归纳学习,学习过程是通过"试错"和"手动调参"进行的。通过构建 了许多BP网络模型以进行反复试验来获得最佳的网络结构和参数数值。最后的 网络模型结构如图4.1所示,并将其命名为MagMLP。它由一个输入层,五个隐 藏层和一个输出层组成。每个隐藏层都是一个完全连接的层,包含20个神经元。



图 4.1 MagMLP的网络结构示意图

训练策略:(1)在训练集中一共约有12.9×10<sup>6</sup>个像素样本,由2.3.3的数据均 衡化可知,为了使不同磁场强度的样本在数量上尽可能均衡,实际参与训练的 数据为均衡化过程中随机选取的数据。为了加快网络的收敛,先用小样本快速 收敛,再逐步增加样本数,使模型得到更充分的训练。(2)平衡输入参数权重。 在输入参数进入网络结构之前将归一化、均衡化等预处理之后的数据按最大最 小值归一到[-1,1],使输入参量具有相同的权重。网络参数设置:使用贝叶斯正 则化算法(Foresee 和 Hagan, 1997)进行优化,该算法根据Levenberg-Marquardt优 化技巧来更新权重和偏差值,从而获得了具有较好泛化能力的神经网络。贝叶 斯正则化所需参数以及其他网络训练参数如表4.2所示。选择sigmoid函数作为每

Figure 4.1 Schematic architecture of the MagMLP network used in this article.



## 图 4.2 以Stokes IQUV和Vel作为输入的模型在第一阶段的loss函数

Figure 4.2 Loss function of the inclination model in the first stage of training with I, Q, U, V, and *Vel* as input parameters.

一个隐藏层的激活函数,提供非线性映射,输出层使用线性传递函数*output*(x) = x。选择L2范数的MSE作为loss函数。整个训练过程分为五个阶段。在每个阶段, 学习率和训练样本的数量(按照训练策略(1))采用不同的设置,以使网络更快, 更有效地收敛。使用指数衰减函数

$$lr = 0.3^{n-1} lr_0, \tag{4.1}$$

来设置学习速率。其中, n是所处的阶段, lr<sub>0</sub>是初始学习速率(设为0.03)。训练 样本的数量随着阶段数而增加。每个阶段都是按照数据均衡化方法随机的抽取 一定数量的数据进行训练。然后重复第五个阶段数次直到模型取得较好的收敛。 训练停止条件为:

(i)达到最大次数(epochs)。

(ii)超过了最长时间。

(iii)性能(loss函数)达到了预设的最小值。

(iv)性能梯度低于min\_grad。

(v) µ 超过µ\_max。

(vi)验证性能自上次提高以来,没有再提高的次数超过max\_fail。

在我们的训练过程中,将条件(ii),(iii)和(iv)相关的参数值设置得足够大或 足够小,以使训练不会因为这三个条件而终止。条件(i)在训练的前三个阶段

#### 表 4.2 主要的MagMLP网络训练参数与设置

| Parameters  | Value             | Content                           |
|-------------|-------------------|-----------------------------------|
| epochs      | 1500              | Maximum number of epochs to train |
| μ           | 0.005             | Marquardt adjustment parameter    |
| $\mu_{dec}$ | 0.1               | Decrease factor for $\mu$         |
| $\mu_{inc}$ | 10                | Increase factor for $\mu$         |
| $\mu$ _max  | $1 \times e^{10}$ | Maximum value for $\mu$           |
| max_fail    | 20                | Maximum validation failures       |
| min_grad    | 0.001             | Minimum performance gradient      |

# Table 4.2 Main training parameters with their values according to the Bayesianregularization.

偶尔会发生。μ\_max值相对较大,很少因为条件(v)终止训练。本文使用的最 终网络模型都是由于条件(vi)而停止。以倾角模型为例,图4.2显示模型训练在 第86个epoch结束,最终保存的模型在第66个epoch完成的。

网络模型的训练采用了并行计算。所使用计算机具有两个Intel Xeon E5-2609 CPU,处理器频率为1.7GHz,每个CPU有8个内核可进行并行计算,以及拥有32GB的内存。本计算占用了12个内核,当样本大小约为670×103时,一个epoch大约需要56秒的计算时间。可以从https://github.com/Guo-JJ/MagMLP下载此工作中使用的MagMLP网络训练过程程序以及相应的数据。

考虑到速度场*Vel*和填充因子α的影响,最终构建了12个具有不同输入或输出参数的 MagMLPs (如表4.2)来进行模型训练,直到它们全部收敛为止。通过分析比较训练结果与训练集目标值之间的线性拟合系数(*k*)和残差验证了MagMLP的有效性。

## 4.3 结果

#### 4.3.1 训练结果

MagMLP是一种有监督的回归网络模型。理想情况下,最好的结果是其输出值Y应该完全等于目标值T,即Y = *k*T(*k* = 1)。实际情况,Y可以无限接近T但无法做到等于T。以*B*<sub>1</sub>为例进行说明,如图4.3所示的*k*约为0.99,接近理想值1。



图 4.3 B;的训练结果与反演数据的散点图分布

# Figure 4.3 The scatter diagram displaying the distribution relationship between the training results and the inversion data for the $B'_{i}$ .

数据在直线*Y* = *T*的两侧分布,无法达到完美的直线分布。这是由于网络模型 系统误差、斯托克斯反演磁场方法存在的问题以及数据噪声等多方面的影响。 由于误差是不可避免的,因此在性能评估中将其忽略。下面使用Y和T之间的直 线拟合斜率*k*作为MagMLP的性能指标来比较分析12个模型的结果。使用训练好 的12个模型预测所有训练集样本(去除总磁场强度低于200G的数据),并对每个 模型预测数据Y和反演数据T之间进行拟合,结果如表4.3所示。

表 4.3 12个网络模型训练结果与目标数据的线性拟合系数(K)值

 Table 4.3 The linear fitting coefficients (K) of training results with target data for 12 network models

| Output    | I, Q, U, V, Vel |             | I, Q, U, V   |             |  |
|-----------|-----------------|-------------|--------------|-------------|--|
| parameter | Train subset    | Test subset | Train subset | Test subset |  |
| Β'        | 0.94396         | 0.90205     | 0.92643      | 0.90985     |  |
| arphi     | 0.98841         | 1.00090     | 0.98799      | 1.00350     |  |
| $B_t$     | 0.93385         | 0.97219     | 0.92007      | 0.99064     |  |
| $B_l'$    | 0.98550         | 1.04630     | 0.98160      | 1.05370     |  |
| $B_t$     | 0.94478         | 0.98967     | 0.92945      | 1.01040     |  |
| $B_l$     | 0.98503         | 1.03180     | 0.98286      | 1.04490     |  |

所有模型在训练集上的k值都在0.9以上,并且输入参数中加入Vel的结果 都比不使用Vel模型的k值约高0.01左右。这表明MagMLPs有效地处理了基于滤 光器型磁像仪的磁场定标,并且将Vel添加到训练中可以降低问题的复杂性并 提高准确性。下面将使用添加Vel的模型结果进行分析比较。另一方面,不考 虑α的B<sub>t</sub>和B<sub>t</sub>模型的k值比考虑α的k值高。关于这一点,后面将进行进一步的分 析讨论。



图 4.4 MagMLPs在测试集样本上的预测结果。左列为磁场反演的数据,左边第二列 为MagMLPs的预测结果,左三列为预测结果与目标数据的残差图,最右侧为残差的 直方图。前四行为*B'、φ、B'*<sub>i</sub>和*B'*<sub>i</sub>的结果,最后一行为预测的*B'*<sub>i</sub>和*B'*<sub>i</sub>通过公式2.4计算 得到总磁场强度*B'*<sup>'</sup>

Figure 4.4 The results predicted on one of the test sets by MagMLPs. The *leftmost colomn* is the target data from the magnetic field inversion. The *second column* displays the results of the networks prediction. The *third column* shows the residual of target data with the prediction. The *rightmost column* is the histogram of the errors. The *upper four rows* show the results for B',  $\varphi$ ,  $B'_t$ , and  $B'_l$  from top to bottom. The results of the combination of  $B'_t$  and  $B'_l$ , B'', using Eq. 2.4 is shown in the *bottom row*.

为了进一步验证模型的泛化能力,对测试集中的所有数据进行归一化、去 噪等预处理后,可获得大约9.3×10<sup>6</sup>个样本数据。用这些样本数据计算所有模 型在测试集上的k值,结果显示在表4.3的第三和第五列中。所有模型的k都高

于0.9,只有B的两个模型的k值稍低。因此,可以初步说明这些模型具有良好的 泛化能力。

4.3.2 可行性验证

我们选择测试集上的2019年4月20日UT14:13在*Hinode*/SP上观测到的活动区 NOAA AR 12738样本来评估模型。B,  $B_t$ ,  $B_l$ 和 $\theta$ 的模型预测结果如图4.4所示。 上面四行从上到下依次为B,  $\theta$ ,  $B_t$ 和 $B_l$ 的结果。最左边一列是Stokes反演的目标 数据。第二列显示为MagMLP的预测结果。第三列为预测结果与目标数据的残 差。最右边一列是残差的直方图。

预测的结果虽然不是所有细小部分都与反演的数据完全一致,但是大部分 区域从形态和数值上都是很接近反演数据的。从残差图中可看出大面积区域都 为灰色,意味着它们非常接近于0 G。θ的残差分布大部分在±30°内,其它磁场 参数的大部分残差则在±300 G内。最右边的残差直方图更是直观地显示了残 差的数值分布;它们的分布不符合红色虚线标示的曲线所表达的正态分布状 态,接近零的数据分布更密集,并且比正态分布波峰更高。*B*,θ,*B*<sub>t</sub>和*B*<sub>t</sub>的残 差RMS分别约为179.9 G,14.1°,167.8 G和110.2 G。

为了了解*B*<sub>t</sub>和*B*<sub>l</sub>分开训练与直接训练*B*模型之间的优缺点,将*B*<sub>t</sub>和*B*<sub>l</sub>的分开 训练的结果按照公式计算*B*<sup>"</sup>,结果显示在图的最后一行。小尺度细节与目标数 据相似。*B*<sup>'</sup>和*B*<sup>"</sup>的残差直方图均呈对称分布并且具分布相似。此外,*B*<sup>'</sup>的残差 的RMS为179.9 G,比*B*<sup>"</sup>低约5G。从以上分析可以看出,两种训练策略的结果 非常接近,很难说哪种更好。为了方便与线性定标进行比较,下面采用分开训 练*B*<sub>t</sub>和*B*<sub>l</sub>的策略。

#### 4.3.3 填充因子的影响

图4.5显示了不考虑填充因子的*B<sub>t</sub>*和*B<sub>l</sub>*模型的预测结果,从左至右代表的信息与上图一致。从残差直方图来看,*B<sub>t</sub>*和*B<sub>l</sub>*的网络模型比*B'<sub>t</sub>*和*B'<sub>l</sub>*的网络模型具有更好的收敛性。对于*B<sub>t</sub>*,残差的RMS为105.1 G,比*B'<sub>t</sub>*低约62 G(如上图第三行所示)。对于*B'<sub>t</sub>*,RMS是70.2 G,比*B'<sub>l</sub>*低约40 G(如上图的第四行所示)。说明当考虑α时,磁场参量与Stokes参数之间的关系变得更加复杂或者当前输入参数不能产生某些关系。这表明不考虑α的模型比考虑α的模型获得明显更好的结果。



图 **4.5** *B*<sub>*t*</sub>和*B*<sub>*l*</sub>的模型预测结果。上图为*B*<sub>*t*</sub>的结果,上图为*B*<sub>*l*</sub>的结果。从左到右的的内容 与**4.4**一致。

## Figure 4.5 The training results of $B_t$ and $B_l$ . The *top row* corresponds to $B_t$ , the *bottom* to $B_l$ . The *panels* have similar information as those in Figure 4.4, from left to right.

4.4 结果比较分析

对于基于滤光器型的磁像仪来说,通过线性定标获得的磁场中磁饱和效应 很明显,绝对磁场强度具有很大的系统误差。此外,*Stokes*反演的倾角中有很 多"亮点"和"暗点"。通过与*Hinode*/SP的相关工作人员沟通,得知这些像素 大多是无法通过反演code找到良好解决方案的点。且在这些像素中,大多数像 素点处的通量密度非常低。下面将进一步讨论这两个方面对MagMLPs的预测结 果的影响。



图 4.6 左边的散点图显示了B<sub>t</sub>和(Q<sup>2</sup> + U<sup>2</sup>)<sup>1/4</sup>之间的分布关系。右图表示B<sub>t</sub>和V之间的关系。 红色的直线是线性定标拟合的线。Stokes参数Q, U, 和V为除以I归一化后的数据。 Figure 4.6 The scatter *diagram on the left* displays the distribution relationship between the B<sub>t</sub> and (Q<sup>2</sup> + U<sup>2</sup>)<sup>1/4</sup>. The *right one* presents the relationship between B<sub>l</sub> and V. The *red lines* are the fitted lines. The *Stokes* parameters Q, U, and V are all normalized dividing by I.

#### 4.4.1 与线性定标比较

选择精确度更高的不考虑填充因子的B<sub>t</sub>和B1的MagMLPs模型进行分析。 从测试集中选择结构较复杂的黑子活动区NOAA AR 12192作为测试样本,它 是于2014年10月24日23:41UT在*Hinode*/SP上观测到的。根据线性定标公式1和2, 通过最小二乘法拟合*Stokes*参数和横纵场之间的直线来计算定标系数。该活动 区的线性定标的结果如图4.6所示。

图4.7显示了MagMLPs,线性定标和Stokes反演的横纵场结果。利用形态重 建和自适应区域生长技术(Yu 和 Feng, 2014)检测到黑子的本影,结果如图中的 闭合蓝色曲线内所示。在本影区域,MagMLPs的结果与反演结果非常接近,而 线性定标表现出明显的磁饱和效应。 MLP方法和线性定标之间的结果差异可



图 4.7 磁场反演, MagMLP和线性定标的横、纵场结果。上图为横场, 下图是纵场。 Figure 4.7 The results of the inversion, MagMLP, and linear calibration on the transverse field and longitudinal field. *Top* is for the transverse field, *bottom* for the longitudinal field.

以从残差中分析出来。横场不同方法的残差结果如图4.8所示。左下图显示了 线性定标结果和反演数据之间的残差,其中闭合的蓝色曲线中残差值大部分 区域大于1000 G,甚至在某些像素上超过2000G。这是因为随着磁场强度的增 加,弱场近似假设不再适用,相应的*Stokes*数值不再增加,本应存在高磁场的 区域结果却很弱,即具有磁饱和效应。MagMLP和反演数据之间的残差在本影 区大多在300 G以内,只有少数突破300G。总体而言,MagMLP与反演的残差 比线性定标与反演的残差低了一个数量级。此外,对残差的RMS进行了分析和 比较。MagMLP在整个图像的残差RMS约为257 G,而线性定标的残差约为323 G,比MagMLP的残差大了66G。对于MagMLP,本影区域中的差RMS约为301

## G,比线性定标的误差小724G。





Figure 4.8 The results of residual errors for the transverse field. The *left column* shows the residual-error outcome of MLP network models and inversion data (*top*), and linear calibration results with inversion data (*bottom*). The *upper right panel* presents the scatter plot of MLP network models and inversion data, the *lower right panel* displays the scatter plot of linear calibration results and inversion data.

图4.8的右侧显示了蓝色曲线内磁饱和区域中的残差的散点图。以MagMLP 和线性定标的结果为纵坐标,而反演的结果为横坐标来显示。除右上角的收敛 不好的点外,MagMLP的结果基本均匀分布在Y = T线的上方和下方,而线性定标的结果与Y = T的偏差很大,并且具有较大的离散度。

纵场的结果与横场结果相似,其结果如图4.9所示。左下图显示了线性定标 结果和反演数据之间的残差,其中闭合的蓝色曲线中残差值在"亮"和"暗" 两个区域均大于1000G,甚至在某些像素上超过2000G。和横场一样具有明显的 磁饱和效应。但MagMLP结果与反演的结果直观上很接近,它们之间的残差在本影区基本在300 G以内。MagMLP在整个图像的残差RMS约为299 G,而线性定标的残差约为371 G,比MagMLP的残差大了72G。对于MagMLP,本影区域中的差RMS约为270 G,比线性定标的误差小1042G。

图4.9右侧显示了蓝色曲线内磁饱和区域中的残差的散点图。以MagMLP和 线性定标的结果为纵坐标,以反演结果为横坐标来绘图。MagMLP的结果基本 分布在Y = T线的上方和下方,而线性定标的结果与Y = T的偏差很大,在正负 极强磁场区域具有很明显的离散化分布。



图 4.9 纵场残差的结果。左列显示了MLP网络模型预测结果和反演数据的残差(上),以及反 演数据与线性定标的残差(下)。右上图为MLP网络模型结果和反演数据散点图,右下 图为线性标定结果和反演数据的散点图

Figure 4.9 The results of residual errors for the longitudinal field. The *left columns* shows the residual-error outcome of MLP network models and inversion data (*top*), and linear calibration results with inversion data (*bottom*). The *upper right panel* presentes the scatter plot of MLP network models and inversion data, the *lower right panel* displays the scatter plot of linear calibration results and inversion data.

## 4.4.2 倾角的亮暗点分析



图 4.10 反演和MagMLP在倾角上结果比较。左上图是反演的结果,左下图是其直方图分布;右上图是MagMLP的结果,右下为其直方图分布

Figure 4.10 The comparison of the inclination angle between the inversion and MagMLP. The *upper left panel* is the map of results for the inversion and the *lower left panel* is its histogram, the *upper right panel* is for MagMLP and the *lower right panel* is its histogram.

在使用Stokes反演的Hinode/SP的倾角度数据时,发现其上有很多"亮点"和"暗点",它们与周围区域相比较突兀。"亮点"和"暗点"的值分别为180度和0度。下面以"亮点"为例进行阐述MagMLP对这些点的作用。选择2019年5月8日UT06:00观测的活动区NOAA AR 12740测试集样本。,如图4.10左上图所示,在红色矩形框中放大的反演结果中可以看到许多"亮点"。在这些像素处,由于噪声或其它因素,Stokes反演无法获得合理的结果。但是从右上图MagMLP的预测结果我们可以明显的看出其上没有这些突兀的点,整个图直观上浑然一体,红色矩形框(放大)中的整个区域较平滑,完全没有那些"亮点"存在。这
说明MagMLP可以相对合理处理这些点,获得较为可靠的结果。从直方图来看, MagMLP结果(右下图)没有180度的点,而反演数据(左下图)包含大约3900个180° 的点。"暗点"的情况类似。通常与这些像素对应的观测到的偏振分量以信号不 足的噪声为主,这时*Stokes*反演失败,而MagMLP能够较合理的对其进行预测。

#### 4.5 三维定标曲面



#### 图 4.11 万有逼近定理示意图



目前神经网络生成的模型内在机制尚不明确,给定其输入,无法确切地知 道它输出会是什么样。万有逼近定理给了我们一个较为直观的解释,图4.11为万 有逼近定理的一个证明,给定固定的权重w和偏置b,便能够输出右图所示的曲 线。而以上磁场模型的输入参数至少为4个,这种多变量的模型,很难直观地在 坐标平面展示出它的输出与输入变量之间的关系。由线性定标公式可知,纵场 与*I、V*有关,与*Q、U*关系不大,那么如果输入只有I和V也很有可能生成磁场, 这时自由变量只有*I、V*两个,输出为*B*<sub>*l*</sub>。这样模型训练完,可以以*I、V*为X、 Y轴,以预测值*B*<sub>*l*</sub>为Z轴建立三维定标曲面;同样横场可以以*I*与(*Q*<sup>2</sup>+*U*<sup>2</sup>)<sup>1/4</sup>为X、 Y轴,以*B*<sub>*t*</sub>为Z轴建立横场三维定标曲面。首先,对反演的磁场数据,进行二维 曲面绘制,如图4.12所示。

#### 4.5.1 训练模型

数据集划分、网络模型以及训练过程和策略与4.1和4.2基本相同。不同的 是输入和输出的参数不一样。横场模型的输入为*I*和(*Q*<sup>2</sup> + *U*<sup>2</sup>)<sup>1/4</sup>,输出为不考 虑α的*B*<sub>t</sub>;纵场模型的输入为*I*和*V*,输出为不考虑α的*B*<sub>l</sub>。所有训练集样本的训

练结果如图4.12所示

#### 4.5.2 定标曲面绘制

由训练结果算的横场预测的最大值为2672G,因此只使用训练集中2672G以下的横场数据进行曲面绘制。纵场的结果在整个有效范围内都能较好地收敛,可以直接进行曲面绘制。曲面绘制过程为:先计算输入参数的最大和最小值作为X、Y轴的坐标范围。然后依据最大最小值生成网格矩阵,再使用三维数据网格化,进行三维曲面绘制,如图4.13所示。







#### 4.5.3 解释分析

在三维曲面有效坐标范围内,可给出X、Y值,查到对应的磁场强度。说明 机器学习模型能够建立两个变量的光滑连续曲面模型。通过三维曲面的绘制, 能够直观看到MLP产生的磁场定标模型到底是怎样的。更多维度的模型,很难 直观地绘制出来,但是我们能够想象其描绘的也必将是一个超维曲面模型。

4.6 小结

本章建立了基于简单神经网络MLP的单波长磁场定标模型。MLP是早先发 展起来的最典型的一种神经网络模型,能够灵活地设置输入变量的个数和有 效的解决多变量回归问题。通过灵活设置输入和输出参数,本章建立了12个 MagMLPs 网络模型来分析比较其性能,以及速度场Vel、填充因子α等参量对磁 场的影响。结果表明,12个模型能够较好地进行收敛,且输入参数加入Vel的对 结果的影响并不显著,而考虑a的磁场参数明显比不考虑a的结果差。说明a增加了单波长数据到磁场参量之间映射关系的复杂性或不收敛性。进一步与线性



图 4.13 训练集预测结果



定标的结果进行了比较分析,与线性定标相比MagMLPs克服了磁饱和问题。在高磁场区域,线性定标与磁场反演的结果的残差RMS大部分区域在1000G以上,而MagMLPs的结果与反演结果的残差RMS大部分区域在300G以内,直观上很接近反演结果,能够有效克服磁饱和效应,在高磁场区域建立非线性磁场定标模型。



#### 图 4.14 在XOY面上的投影视场结果

Figure 4.14 Projection field of view on plane XOY

# 第5章 应用卷积网络ResNet解决磁饱和问题

由以上可知MLP网络在单波段磁场定标中能够有效的解决磁饱和问题,分 析了速度场Vel和填充因子α等参数对定标模型的影响,Vel对结果没有显著影 响,α的影响较为显著。不考虑α磁场参数模型明显要比考虑α的收敛性要好。 MLP是点对点的网络,未考虑空间相关性,本章将采用一种基于作用于相邻 像素之间的卷积核的ResNet网络进行单波长磁场定标的研究。通过对这些参 数建立ResNet模型,发现Vel和α对结果的影响和MLP网络的结果是一致的。本 章将不再讨论它们的影响,将以StokesIQUV为输入,不考虑α的B<sub>t</sub>、B<sub>l</sub>和方位 角(φ)的三维矢量磁场的三个完整分量作为输出进行模型训练,讨论机器学习在 三维矢量磁场的参数上的可行性。

#### 5.1 数据和方法说明

采用的数据已在2.3.4说明,除了输入和输出参数不同,使用与3.2.1相同的 网络结构MagRes,训练策略也与3.2.1基本相同。本部分不仅要训练 $B_t$ 和 $B_l$ ,还 会建立 $\varphi$ 的网络模型。 $\varphi$ 与 $B_t$ 和 $B_l$ 有些不同,不仅单位和强度值范围不同, $\varphi$ 还 是一个周期参数,其训练过程将略有不同。在矢量磁场的测量中,横场中存 在180°不确定性,这是由于对磁敏感谱线的偏振观测机制导致的(Metcalf 等, 2006)。从而使得方位角中 $\varphi = \varphi + 180^\circ$ ,即方位角的周期为180°。由于使用 与其他参数模型相同的训练过程,因此将0或180 附近的值推断为[0°,180°]范围 内的离散分布(如图5.1所示)。预测值和目标数据的散点图像是反转N形。因此,通过将损失函数更改为公式5.1来继续训练收敛模型以对其进行校正。这是因 为方位角周期为180°,预测值与目标值的角度差不应该大于90°,因此如果算 的 $|y_i - \hat{y_i}| > 90$ ,将按照(180 –  $|y_i - \hat{y_i}|$ )来计算角度差。

MyLoss = 
$$\frac{1}{n} \sum_{i=1}^{n} E_i^2$$
, (5.1)

其中

$$E_{i} = \begin{cases} y_{i} - \hat{y}_{i} & |y_{i} - \hat{y}_{i}| \le 90\\ 180 - |y_{i} - \hat{y}_{i}| & |y_{i} - \hat{y}_{i}| > 90 \end{cases}$$
(5.2)

这项工作是在以TensorFlow 1.5.0为计算背景的Keras 2.2.2的深度学习框架下进行实际训练的。使用NVIDIA Quadro P2000(安装在Dell T3620图形工作站中)进行GPU加速。



Figure 5.1 A discrete distribution diagram of the predicted results with azimuth angle around  $0^\circ$  and  $180^\circ$ 

#### 5.2 结果与可行性验证

对MagReses进行了全面的训练,最终得到三个收敛模型来推断*B<sub>l</sub>、B<sub>t</sub>和φ*,每个模型大约包含0.926万个自由参数。该模型预测一张像元分辨率为384×684的 图像,大约需要1.11秒的时间。最终收敛的*B<sub>l</sub>*,*B<sub>t</sub>和φ*模型在训练集上的损失函 数*MSE*值为3522 G, 3313 G, 525°(包括噪声)。这意味着训练结果与目标数据 的残差分别约为59.3 G, 57.6 G和22.9°。在训练过程中,输入图像设置为任意大 小,测试图像数据可以直接进入模型产生物理磁场量而不改变图像大小,无需 拼接。Stokes*I*,*Q*,*U*和*V*在进行网络之前仅需通过公式2.1进行归一化处理,便 可从模型输出所需要的预测。



图 5.2 纵场的MagRes定标结果。上图从左至右依次为反演的结果, MagRes预测结果及其 残差。左下图是残差直方图及其高斯核密度曲线。右下图是散点图, 颜色表示反演结 果与测试结果的密度分布

Figure 5.2 MagRes calibrations for longitudinal magnetic. Upper panels are inverted result, MagRes result and their residual difference, respectively. The lower left panel is the histogram of the residual error with its Gaussian kernel density curve. The lower right panel is the scatter diagram with identifying the density of the inversion results with the testing results.

#### 5.2.1 纵场

使用测试集中Hinode/SP于2019年4月13日UT10:26观测到的数据作为样本来 评估我们的模型,图像分辨率为每像素0.317"。图5.4给出了纵场*B*<sub>1</sub>的ResNet预 测结果。直观上ResNet的结果与反演的*B*<sub>1</sub>非常接近,但显得更干净。ResNet产 生的*B*<sub>1</sub>和反演的*B*<sub>1</sub>之间的残差大多在300G以内。整个样本一共有446976个像素 的像素点,只有284个像素残差大于300G,在黑子区域残差在300G以上约占比 为0.002。左下图是残差的直方图,由直方图可以看出残差集中分布在0附近, *B*<sub>1</sub>残差的RMS和MAE为35 G和17G。MAE与RMS之比代表包含异常大误差的程 度,*B*<sub>1</sub>残差的RMS和MAE之比为0.48。该比率越小,说明残差异常程度越大。 右下图是MagRes的结果与反演数据的散点图,并用colorbar所示颜色来标识反演 结果与测试结果之间在不同强度下的分布密度。这里MagRes的结果与反演的拟 合决定系数*R*<sup>2</sup>为0.99,说明拟合的很好,预测结果非常接近真实值。

#### 5.2.2 横场

图5.5给出了横场*B*<sub>t</sub>的MagRes结果,其内容也与图5.4相同。中上图*B*<sub>t</sub>的 MagRes 预测结果与左上图反演的结果非常相似。同样MagRes结果比反演结果的噪 声水平要低。右上图为 MagRes 预测结果与反演的残差图,可以看出大多数区域 在[-300 300] G范围内分布,少数一些像素为深紫色或深绿色达到或者超过了300 G,经统计整张图中只有85个像素的值大于300G。左下图是残差的直方图。残 差的RMS和MAE分别为34 G和22G,MAE与RMS之比为0.65,这意味着差异较 大误差存在程度较小。右下图是预测值和真值的散点图,不同颜色表示反演结 果与测试结果的分布密度不同。计算预测值与真值的确定系数*R*<sup>2</sup>为0.98。

#### 5.2.3 方位角

图5.6显示了φ的预测结果,其内容也与图5.4相同。从左上图来看在反演结 果中的宁静区有很多噪声。在黑子区域上,MagRes的结果与反演数据相似,除 了0°和180°交界区域。在右上图的MagRes结果与真值之间的残差图可以看出大 多数黑子区域都在[-20 20]范围内。宁静区噪声水平较高,ResNet具有去噪的 功能,与反演的差距较大,不好评价ResNet的性能。下面通过提取横场强度大 于300G的所有像素点来去除大部分宁静区域,来进一步分析其性能。左下图是 残差的直方图,残差主要分布在[-20,20]之间。这部分残差的RMS和MAE为6°和



图 5.3 横场的MagRes定标结果。上图从左至右依次为反演的结果, MagRes预测结果及其 残差。左下图是残差直方图及其高斯核密度曲线。右下图是散点图, 颜色表示反演结 果与测试结果的密度分布

Figure 5.3 The upper left panel shows the inversion result for transverse magnetic flux density. The testing result of is shown on the upper median panel. The upper right panel is the residual error of the inversion result and the testing result. The lower left panel is the histogram of the residual error. The lower right panel is the scatter diagram with identifying the density of the inversion results with the testing results.



图 5.4 方位角的MagRes定标结果。上图从左至右依次为反演的结果, MagRes预测结果及 其残差。左下图是残差直方图及其高斯核密度曲线。右下图是散点图, 颜色表示反演 结果与测试结果的密度分布

Figure 5.4 The upper left panel shows the inversion result for azimuth angle. The testing result of is shown on the upper median panel. The upper right panel is the residual error of the inversion result and the testing result. The lower left panel is the histogram of the residual error. The lower right panel is the scatter diagram with identifying the density of the inversion results with the testing results. 3°, MAE与RMS之比约为0.5。右下方的面板是散点图,不同颜色标识了反演结果与测试结果的拟合密度分布,拟合结果的确定系数 *R*<sup>2</sup>约为0.99。

总而言之, ResNet方法能够较精确的推断出磁场参数来接近反演方法,并 且它预测的结果具有更好噪声抑制效果的更清晰的图像。



图 5.5  $B_l$ 和 $B_t$ 的反演结果、MagReses结果和线性定标结果的比较。上图为纵场的结果,下 图为横场的结果。

Figure 5.5 The results of the inversion, MagRes, and linear calibration for the  $B_l$  and  $B_t$ . The top row is for the  $B_l$ , the bottom row are for the  $B_t$ .

#### 5.3 结果分析与比较

#### 5.3.1 横纵场与线性定标比较分析

这项研究的主要目的之一是在强磁场区域提高单波长磁场定标的精度,在 该区域线性定标方法无法处理磁饱和效应。下面将讨论ResNets在磁饱和区域中 的表现,并对ResNets的结果和强磁场下的*B*<sub>1</sub>和*B*<sub>1</sub>的线性定标方法的结果进行比 较分析。

由前面章节可知,2波长点的MagReses模型和MagMLP模型都具有解决磁饱 和的能力。单波长的MagRes模型在磁饱和问题也表现出良好的性能。以测试集 中的活动区域NOAA AR 12192数据进行演示。它是一个βγδ型的黑子,具非常

复杂的结构,于2014年10月24日UT23:41观测到的样本。*B*<sub>1</sub>和*B*<sub>1</sub>基于弱场近似下的线性定标,可以通过使用最小二乘法拟合Stokes参数和反演结果之间的直线来获得。线性定标的结果如公式5.3和5.4所示。图5.5显示了*B*<sub>1</sub>和*B*<sub>1</sub>的MagRes(中)、线性定标(右)和Stokes反演的结果(左)。红色矩形框中是一部分高磁场区域,以此为例可以看出MagReses的结果与反演结果具有非常相似的外观、结构和形状。但是,线性定标的结果与反演的结果相差很大,具有明显的磁饱和效应。

$$B_l = 2370.65(V/I) - 39.66, (5.3)$$

$$B_t = 2843.19((Q/I)^2 + (U/I)^2)^{1/4} - 63.16,$$
(5.4)



MagMLP方法也有效解决了 $B_i$ 和 $B_t$ 的磁饱和效应。下面通过两种网络的预测结



Figure 5.6 The results of the inversion, MagRes, and linear calibration for the  $\varphi$ . The scatter graph of results of ResNet and inversion method is displayed in lower left. In lower right of the figure is the scatter graph of results of Linear calibration and inversion method.

果与目标数据的残差的RMS,比较和分析了两种不同的神经网络方法在磁饱和

问题上的性能。以测试集中2018年和2019年的数据为测试样本说明,如表5.1所示MagReses的残差的RMS不到MagMLP的一半。基于定量评估方法RMS的比较,MagReses的性能优于MagMLP。

# 表 5.1 18年和19年测试集样本的模型预测结果与对应的反演结果的残差RMS值 Table 5.1 The RMS values residual errors of target data with the testing results of networks on 2018 and 2019 in the test set.

| Date              | Active region | Transverse field |        | Longitudinal field |        |
|-------------------|---------------|------------------|--------|--------------------|--------|
| (yyyymmdd_hhmmss) |               | MagMLP           | MagRes | MagMLP             | MagRes |
| 20180206_132552   | AR 12699      | 118              | 53     | 97                 | 44     |
| 20180210_050505   | AR 12699      | 99               | 40     | 99                 | 49     |
| 20180212_081503   | AR 12699      | 96               | 40     | 94                 | 47     |
| 20180422_181519   | AR 12703      | 105              | 36     | 84                 | 39     |
| 20180621_052804   | AR 12715      | 108              | 42     | 87                 | 45     |
| 20190321_135705   | AR 12736      | 125              | 58     | 100                | 55     |
| 20190411_212122   | AR 12738      | 172              | 76     | 137                | 83     |
| 20190412_180409   | AR 12738      | 151              | 61     | 122                | 68     |
| 20190413_102645   | AR 12738      | 99               | 34     | 72                 | 35     |
| 20190416_112936   | AR 12738      | 175              | 86     | 172                | 87     |
| 20190418_072036   | AR 12740      | 163              | 88     | 206                | 100    |
| 20190508_060010   | AR 12740      | 104              | 36     | 80                 | 38     |

#### 5.3.2 方位角与线性定标比较分析

方位角φ可以通过公式1.3直接推断出来。但是,在基于滤光器型磁像仪的 单波长观测数据受法拉第旋转等的影响,使得公式1.3推断出的磁场存在某些问 题,尤其是对于线心(Hagyard 等,2000; Su 和 Zhang,2004)附近的数据。因此,我 们将对ResNet和公式1.3方法之间的φ进行比较分析。

φ(方位角)是横场在天空平面上的所在的方向描述,并且对φ来说不存在磁 饱和问题。图5.6显示了在NOAA AR 12192上φ的MagRes(中),线性定标(右)和 Stokes 反演(左)的结果。它显示ResNet和线性定标的结果都与反演结果很相近。 进一步通过散点图来看他们与反演的结果的接近程度,如图5.6下面两个图所



图 5.7 倾角的MagRes预测结果。上图从左至右依次为反演的结果, MagRes预测结果及其 残差。左下图是残差直方图及其高斯核密度曲线。右下图是散点图, 颜色表示反演结 果与测试结果的密度分布

Figure 5.7 The upper left panel shows the inversion result for inclination angle. The testing result of is shown on the upper median panel. The upper right panel is the residual error of the inversion result and the testing result. The lower left panel is the histogram of the residual error. The lower right panel is the scatter diagram with identifying the density of the inversion results with the testing results. 示。与线性定标相比,ResNet的结果更接近反演结果,更集中分布在45°线附近; 而线性定标在45°线两侧的分布较宽。并且ResNet结果与反演结果的残差RMS要 小于线性定标的,残差RMS分别为16°和21°。表明ResNet相较于线性定标能够 提高φ的准确性。

5.3.3 倾角比较分析

由上一章可知,反演的倾角θ中有具有许多"亮点"和"暗点",分别为180度 和0度。MagMLP网络能够很好的泛化它们,消除噪声数据让图像较连续。本章 没有直接训练倾角的模型,但可以从*B*<sub>*i*</sub>和*B*<sub>*i*</sub>的预测结果推断出θ。从公式2.2和2.3, θ可以表示为:

$$\theta = \arctan(\frac{B_t}{B_l}) \tag{5.5}$$

θ的计算结果如图5.7所示。θ的计算结果与反演结果在黑子区域很接近,但 在宁静区域存在显著差异。说明在宁静区噪声水平较高,模型预测有高估的倾 向,不过和MagMLP模型一样消除倾角上的"亮点"和"暗点"等噪声数据。右上图 的ResNet结果和反演数据的残差图可以看出,大多数活动区残差都在[-20 20]范 围内,并且宁静区域上有很多像素不在[-20 20]范围内。宁静区因包含大量噪声, 不能很好的说明模型的性能,选择横场强度大于150 G的相应像素,以进一步评 估模型的性能。左图是高磁场区残差的直方图。残差基本分布在[-20 20]范围内。 残差的RMS和MAE为5°和3°。MAE与RMS的比率约为0.6,这说明存在一些异常 的残差较大的数据。右下图是ResNet与反演数据的散点图,可看出90°以上的数 据多于90°以下的数据,各角度分布不均衡,但都高度集中在45°线附近。其拟合 的确定系数*R*<sup>2</sup>为0.98。

5.4 小结

本章采用深度学习的代表性网络之一CNN网络建立单波长磁场定标模型 MagReses。MagRes是基于残差块的残差网络,是CNN网络的一种典型结构。在 模型建立时考虑了磁场的三个完整分量的定标。从结果来看,MagRes网络产生 的磁场图像比反演的数据更干净,通过网络模型生成的横纵数据推断的倾角, 与MagMLP一样能够去除"亮点"和"暗点",说明其具有去噪性能。与线性定 标方法相比,MagReses网络能够对高磁场区域进行较好解释,解决磁饱和问题。 与MagMLP方法相比,在测试集样本中MagReses网络对横纵场的预测值与反演

结果的残差RMS多数在50G一下,而MagMLPs多数在100G以上,单从这方面来 说,MagReses网络模型能够具有更好的性能。

# 第6章 用于解决实测中波长漂移问题的变波长定标研究

由第四和第五章可以获知采用机器学习方法进行单波长磁场定标能够有效 的解决磁饱和问题。在传统滤光器型磁像仪的单波长常规观测中,由于太阳较 差自转、等离子体视向运动、视场不均匀等的影响,观测数据会有波长漂移的 现象。对于空间磁像仪还存在轨道速度的影响,使得波长漂移问题更加严重。 本章针对波长漂移问题开展变波长研究。

#### 6.1 数据和方法说明

变波长与单波长不同在于:单波长只有一点的Stokes参量参与模型训练,不 包含波长信息;而变波长模拟滤光器型磁像仪的谱线漂移问题,需要包含波长 信息,确保每个波长下的Stokes参量作为输入都能够获得磁场参量。因此我们 的输入参数除了*StokesIQUV之外*,还需要把波长信息(W)作为输入进行模 型训练。在于处理中对Stokes参量进行了归一化处理,因此我们也对波长信息 进行标准化,使其与Stokes参量基本在同一量级。因此将线心位设定为0,5个 相对波长点的信息为[-0.105,-0.084,-0.063,-0.042,-0.021]。因此我们的输 入为*StokesIQUVW*五个图像。输出为横场和纵场。由第五章可知ResNet网络有 能力进行单波长磁场定标,较好地解决了磁饱和问题,因此我们同样采用如同 第五章一样的ResNet网络进行变波长定标研究。对横纵场分别训练一个网络模 型。

## 6.2 结果与测试验证

#### 6.2.1 训练结果

横场模型的最终收敛时,训练集loss函数的值为6861,验证集loss值为11744; 纵场模型训练集的loss为6029,验证集的loss为10461。这意味着训练结果与反 演结果的残差的RMS在横场训练集上约为83G,验证集上约为108G;在纵场 上训练集为78G,在验证集上102G。这与5.2中单波长训练的结果在横场训练 集59.3G,纵场上为57.6G。

下面采用与5.2.1中相同的测试集样本进行模型测试。即采用在Hinode/SP上

于2019年4月13日UT10:26观测到的数据,对横纵场的变波长定标模型进行量化 评价。

#### 6.2.2 横场测试结果

图6.1展示了横场的变波长模型在测试样本上的结果。从上至下即(a)到(e)图 分别对应[-0.105, -0.084, -0.063, -0.042, -0.021]5个波长点的测试结果。左侧 为反演的结果,中间为MagReses的结果,右侧为MagRes与反演结果的残差图。整体上来看,MagReses的结果与反演的结果很接近,一些细节结构直观上很像。由残差图看,中间的-0.063波长位置的残差比两边的要更接近与0值,且约接近 线翼和线心的结果,残差图颜色更深的地方增多,说明残差大的区域增大。

图6.2显示了残差的直方图分布,从整体分布来看,基本以0为中心呈高斯分布的状态。图(a)和(b)稍有些偏斜,其它分布较平衡,且绝大部分残差值在±100G内。在5个波长位置的残差RMS依次为[54 52 51 56 60],残差的MAE结果为[37 35 33 36 39],MAE与RMS的比为[0.69 0.67 0.65 0.64 0.65]。由此可看中间波长点的结果最佳,越靠两边结果越差,但这个差别很小,说明网络模型能够融合不同波长的信息来生成磁场。

图6.3显示了预测结果与反演结果的残差图,其中不同颜色表示了不同的密度分布,红色代表密度大。红线为45°线。可以看出每个波长点的结果基本都在45°线两边集中分布,决定系数*R*<sup>2</sup>依次为[0.95 0.95 0.96 0.95 0.94],说明两者的相关性较高。

#### 6.2.3 纵场测试结果

图6.4展示了纵场的变波长模型在测试样本上的结果。从上至下即(a)到(e)图 分别对应[-0.105, -0.084, -0.063, -0.042, -0.021]5个波长点的测试结果。左侧 为反演的结果,中间为MagReses的结果,右侧为MagRes与反演结果的残差图。整体上来看,MagReses的结果与反演的结果很接近,一些细节结构很接近。由 残差图看,中间的-0.063波长位置的残差比两边的要更接近与0值,且约接近线 翼和线心的结果,残差图颜色更深的地方增多,说明残差大的区域增大。

图6.5显示了残差的直方图分布,从整体分布来看,基本以0为中心呈高斯分布的状态。图(a)和(b)稍有些偏斜,其它分布较平衡,且绝大部分残差值在±80G内。在5个波长位置的残差RMS依次为[42 39 38 42 51],残差的MAE结果为[19



图 6.1 横场在5个波长点的预测结果

Figure 6.1 The predicted results of transverse field at 5 wavelength points



图 6.2 横场在5个波长点的预测结果与反演数据的残差图

Figure 6.2 The residual errors of predicted results with inversion results of transverse field at

## 5 wavelength points



图 6.3 横场在5个波长点的预测结果与反演数据的散点图

# Figure 6.3 The scatter diagrams of predicted results with inversion results of transverse field at 5 wavelength points

17 17 19 23], MAE与RMS的比为[0.45 0.43 0.45 0.45 0.45]。由此可看中间波长点的结果最佳, 越靠两边结果越差, 但这个差别很小, 说明网络模型能够融合不同波长的信息来生成磁场。

图6.6显示了预测结果与反演结果的残差图,其中不同颜色表示了不同的密度分布,红线为45°线。可以看出每个波长点的结果基本都在45°线两边集中分布,决定系数*R*<sup>2</sup>依次为[0.98 0.98 0.98 0.98 0.97],说明两者的相关性还是比较高的。

6.3 与单波长定标比较

### 6.3.1 横场比较结果

图5.3为在-0.063位置上单波长训练的横场结果,它的MagRes与反演的残差的RMS为34G,MAE为22G,决定系数*R*<sup>2</sup>为0.98。多波长定标的结果,如图6.3所示横场的MagRes的结果与反演数据的残差RMS为51G,MAE为33G,单从这一个样本一个波长点来看,单波长定标的结果要比多波长定标结果要好。图6.4 MagRes 与反演的决定系数*R*<sup>2</sup>为0.96也要低于单波长模型的。



图 6.4 纵场在5个波长点的预测结果

Figure 6.4 The predicted results of longitudinal field at 5 wavelength points



图 6.5 纵场在5个波长点的预测结果与反演数据的残差图

Figure 6.5 The residual errors of predicted results with inversion results of longitudinal field at 5 wavelength points



图 6.6 纵场在5个波长点的预测结果与反演数据的散点图

# Figure 6.6 The scatter diagrams of predicted results with inversion results of longitudinal field at 5 wavelength points

#### 6.3.2 纵场比较结果

图5.2为在-0.063位置上单波长训练的纵场结果,它的MagRes与反演的残差的RMS为35G,MAE为17G,决定系数*R*<sup>2</sup>为0.99。多波长定标的结果,如图6.6所示纵场的MagRes的结果与反演数据的残差RMS为38G,MAE为17G,与横场不同,在纵场上,变波长模型的结果与单波长模型的结果非常接近,差别微小。 图6.7MagRes与反演的决定系数*R*<sup>2</sup>为0.98也至稍低于单波长模型的结果。因此,变波长模型在纵场上能够获得与单波长模型接近的性能。

#### 6.4 泛化能力测试

变波长定标是为了解决滤光器型磁像仪的波长漂移问题,由于波长漂移引 起的实际观测的数据是在某一段波长范围内。因此,模型的训练能够对这一 段范围内的数据都能够进行处理,下面采用5个波长点中间波长的样条插值(如 图6.8)产生的数据来测试模型的其它位置的性能。





Figure 6.7 Intermediate interpolation diagram of variable wavelength data

#### 6.4.1 测试结果

如图6.9和6.10所示分别为横场和纵场的预测结果。从图6.9看MagRes的结果 看出与反演的结果结构上直观上大体是一致的。从它们的残差图上来看,靠 近连续谱的残差图在黑子部分的颜色偏紫色,说明MagRes预测的结果倾向于 把磁场的数据往低了预测。靠近线心的残差数据在黑子区域的颜色偏绿,说 明MagRes预测的结果倾向于把磁场的数据往高了预测。图6.2中的残差图,虽然 也有这个趋势,但是并不像图6.9所示的差距如此明显。原因大概有三点:(1)越 靠近线心或者连续谱,谱线的磁敏感度发生了不同的变化。(2)所用的插值方法 不能完美的拟合*StokesIQUV*轮廓,导致插值数据的结果偏差较大(3)模型可能 更倾向于对中间波长数据的表示更强大,导致两边数据出现一定偏差。

从图6.10来看MagRes产生的结果与反演的结果符号上是一致的,宁静区一些小尺度结构也能够很好地预测出来。从残差图来看,中间的结果要比两边的结果要好,这点与横场的结果相似。但是总体来看残差的分布,并没有横场那么明显的两端一个预测偏小一个预测偏大。这个可能原因是由于纵场的精度更高,且纵场有正负之分。

图6.11为横纵场的残差图分布的结果,上图为横场的结果,下图为纵场的结果。横场的(a)和(d)图可以看出直方图具有明显的偏斜,中间两个效果比较好。在4个插值位置的残差RMS依次为[65 58 58 66],残差的MAE结果为[44 42 40 43],MAE与RMS的比为[0.67 0.72 0.69 0.65]。纵场的直方图分布更均衡更集中在0附近分布。其在4个插值位置的残差RMS依次为[53 45 43 47],残差的MAE结果为[25 21 19 22],MAE与RMS的比为[0.47 0.47 0.44 0.47]。无论横场还是纵场,插值的结果都是要比不插值的5个波长位置的结果稍差。

图6.12显示了预测结果与反演结果的残差图,上图为横场结果,下图为纵



图 6.8 横场在5个波长点的中间点的预测结果

Figure 6.8 The predicted results of transverse field at the points middle of 5 wavelength points



图 6.9 纵场在5个波长点的中间点的预测结果

Figure 6.9 The predicted results of longitudinal field at the points middle of 5 wavelength

points



图 6.10 横纵场在5个波长点中值的预测结果与反演数据的残差直方图。上图为横场的结果, 下图为纵场的结果。

Figure 6.10 The residual errors of predicted results with inversion results of longitudinal field at the middle of 5 wavelength points. The upper for the transverse field the lower for the longidual filed.



图 6.11 横纵场在5个波长点中值的预测结果与反演数据的散点图。上图为横场的结果,下 图为纵场的结果。

Figure 6.11 The scatter diagrams of predicted results with inversion results of longitudinal field at the middle of 5 wavelength points. The upper for the transverse field the lower for the longidual filed.

场结果。横场的结果在45°线左右的分布不均衡,偏斜较严重。纵场的散点图分 布基本在45°线两边集中分布,分布状态基本一致。横场决定系数*R*<sup>2</sup>依次为[0.93 0.94 0.94 0.93],均在0.95以下,比五个波长位置的样本结果较低,说明相关性比 五个波长位置的要。纵场的*R*<sup>2</sup>依次为[0.97 0.98 0.98 0.97],均在0.95以上,与5个 波长位置的样本基本没差别,说明纵场的在插值位置的相关性比横场好。

6.5 小结

变波长定标更符合空间滤光器型磁像仪常规观测下的磁场定标情况。采用Hinode/SP的5个波长点实测数据加随机插值进行模拟。建立了横纵的变波长定标模型。单从结果来看,最后的loss的值比ResNet单波长定标的结果高约20G;相比MLP的结果低约60G。说明神经网络模型能够融合不同波长的Stokes参量进行变波长磁场定标,且能够获得与单波长定标接近的结果。

## 第7章 总结与展望

虽然太阳磁场测量的理论方法已经发展百余年,但目前磁场测量还是主要 借助于塞曼效应来间接获得。在还不能直接测量太阳磁场的时代,如何更好更 快更准确的获得磁场是物理学家们一直以来的需求。磁场反演方法虽提供了较 精确的磁场参量,但其对假设模型依赖性较强,且反演过程较长。随着时代发 展,机器学习方法开始应用于多波段磁场反演,这类方法基本采用模拟数据进 行模型训练的,模拟数据的精确性很大程度上决定了该方法生成磁场的精确性, 且尚不能用在实际观测中。虽然其研究在初始阶段,但却有效的将磁场反演的 时间缩短到ms或s级别,提供一种可替代的方法。

线性定标方法存在磁饱和效应和波长漂移问题,随着空间滤光器型磁像仪 的发展和大数据时代的到来,依靠"数据驱动"的机器学习方法有希望解决磁 饱和和波长漂移问题,为传统滤光器型磁像仪提供一种可尝试的非线性磁场定 标方法。因此本文开展了机器学习在磁像仪数据处理中的可行性研究。下面对 取得一些成果进行总结,并展望一下未来的研究工作。

7.1 工作总结

对样本数据进行了介绍说明并进行了数据清洗等预处理。由于本研究基于实际观测情况开展的研究,因此选择了Hinode/SP实际观测的数据作为样本集进行模型训练与预测来进行非线性磁场定标研究。实际数据中包含很多噪声,且数据之间存在一些差异,通过数据挑选、归一化、去噪等进行了数据清洗等预处理,保证了数据的基本正确性和可靠性。数据预处理对机器学习来说是非常重要的,很大程度上决定了最终的模型的收敛程度。

2. 首先采用6301.5Å谱线的多波长点数据建立多波段的磁场反演模型,并 由16个波长点逐步减少到2个波长点,共建立16-8-4-2波长点数的机器学习模型。 结果显示这些模型都能够很好的预测磁场:虽然随着波长信息的减少,精度略 有下降,但直至2波长模型仍能够收敛,且预测结果接近反演结果。另外发现机 器学习方法具有一定的去噪功能。以上说明可以采用实际观测的数据进行机器 学习方法的多波段磁场定标,进一步说明机器学习方法是很有希望应用于单波

长磁场定标中。

3. 针对单波长定标中的磁饱和问题展开研究。通过选取偏离线心6301.5Å位 置-0.063Å波长点的StokesIQUV来模拟滤光器单波长观测,为机器学习方法提 供样本集。分别采用简单神经网络多层感知机MLP和卷积神经网络CNN开展单 波长的非线性磁场定标的研究,来论述机器学习方法解决磁饱和问题的可行性。 MLP是以一个像素为一个样本的,CNN是以一幅图像为样本的。

首先进行MLP方法的研究,综合考虑了多普勒速度场Vel、填充因子α、不同磁场分量等因素的影响,训练了12个相应模型进行多方面分析。得出以下结论:(1)有效的解决了磁饱和问题,与线性定标结果相比在黑子本影区域与目标值的残差平均要低700多高斯。(2)输入参数加入Vel会使网络模型精度更高,但不显著;考虑α的参数使磁场参数与Stokes参量的关系更加复杂,不考虑α的磁场参量具有明显更好的结果。(3)发现磁场反演数据中,倾角在宁静区存在很多"亮点"和"暗点",而MLP方法能够合理的预测它们,预测结果中没有这些点,再次说明机器学习方法具有去噪的功能。

然后采用深度学习方法之一CNN进行研究。CNN与MLP最大的不同在于, 不再把单独像素作为样本,而是考虑了相邻像素的空间关系。对于Vel和α的对 模型影响与MLP一致,没有再做具体分析。主要针对B<sub>t</sub>、B<sub>t</sub>和θ三维矢量磁场的 三个分量进行模型训练与分析。得出以下结论:(1)同样CNN网络在解决磁饱和 问题上表现良好。与MLP方法相比,在测试集样本中CNN网络对横纵场的预测 值与反演结果的残差 RMS 多数在50 G 以下,而CNN的结果多数在100G以上, 单从这方面来说,CNN网络模型能够具有更好的性能。(2)CNN网络模型不仅在 横纵场取得了较好的结果,在方位角上性能也比线性定标方法好。并且方位角 是一个周期量,在模型训练中针对这种周期量设计了一个单独的loss函数,使 其在0°和180°附近能够很好的收敛。(3)CNN网络产生的数据比反演的结果包含 更少的噪声数据,说明CNN具有一定的去噪能力。对于反演数据中倾角在宁静 区存在的很多"亮点"和"暗点"问题,由CNN模型产生的横纵场推断的倾角, 也能够去除。

 通过在单波长模拟观测波长点上下各选取两个波长点的方法来模拟波 长漂移问题进行变波长定标研究。变波长模型的建立更能近似的描述空间传统 滤光器型设备实际观测的情况。采用Hinode/SP的5个波长点实测数据进行波长

漂移数据模拟。建立了横、纵场的变波长定标模型。单从结果来看,最后模型 收敛的loss函数值比CNN单波长定标的结果稍高,但是还是比MLP单波长定标 的loss结果低,说明变波长模型能够较好收敛。通过对测试集的样本的预测结果 的分析,得出以下结论:(1)CNN网络模型能够兼容不同波长的Stokes参量进行 变波长磁场定标。(2)变波长模型相比单波长模型的结果精度上稍差,但这个差 别并不显著,说明变波长模型的性能并不会比单波长模型的结果差多少。(3)插 值的数据比实际观测的数据预测的结果要略差,插值方法还有待改进,从反面 说明如果全部采用实际观测的数据可能会获得更好的结果。总之,变波长模型 能够更好的为FMG的磁场定标方法提供了一个可供参考的非线性定标方法。

#### 7.2 未来展望

本文从多个方面对机器学习在磁像仪数据处理中的可行性进行了研究分析。 初步阐述了机器学习用于实测中磁场定标的可行性,但仍处于初步研究阶段, 还存在很多问题;距离真正用于实际观测中,用于空间磁像仪FMG中,还需要 做很多的工作。主要存在的问题和未来的一些计划如下:

(1)本文只针对Hinode/SP的数据进行研究,应用到其他磁像仪,比如FMG中, 它们具有不同的工作谱线、不同的视场、不同的观测流程和后期后期数据定标 过程,使其训练样本有很大差异性,不可能将现在的模型直接用于FMG中。需 要研究模型的迁移能力,不然就需要针对不同的实测样本进行重新训练。

(2)神经网络模型虽然有万有逼近定理支持,但其训练收敛后的模型,对人 来讲仍然是个黑盒子,生活应用中可以不去追究这个黑盒子到底是什么;但对 于科学应用来讲,本文虽尝试采用定标曲面来解释,但这也仅限于MLP模型, 对于CNN模型不能很好的说明。未来需要尝试把更多的物理机制加入到训练过 程中,比如在loss函数加入物理评判机制,用更多的理论支持,进行更缜密的证 明才能让科学家完全信服。

(3)CNN方法虽然在某些方面(比如残差RMS)优于MLP的结果,但CNN考虑 了空间关系也使它可能存在降低分辨率的可能性。目前还没有更完善的方法来 充分对比两种模型的结果。这是未来需要考虑的事情。

(4)机器学习模型训练依赖于磁场反演的数据,没有完全正确的样本可以使用,导致其先天不足。另外较高磁场区域数据量比较少,数据不均衡性严重。

这些都给机器学习方法的研究带来了困难。

总之,机器学习方法以其快速和强大的非线性逼近能力,虽受到太阳物理 学家的欢迎,但采用此方法推断的磁场结果因包含极少的物理机制也受到了不 少质疑。模型训练使用的训练数据大多来自数值MHD模拟的数据,与实测的数 据存在一定差异,虽在实际观测的样本中进行了测试验证也取得了较好的结果, 但离真正能够应用于实际观测还较远。

# 参考文献

- Aarts E, Korst J. Simulated annealing and boltzmann machines: A stochastic approach to combinatorial optimization and neural computing[J]. 2015.
- Ai G X, Hu Y F. Principles of a solar magnetic field telescope.[J]. Acta Astronomica Sinica, 1986, 27(2):173-180.
- Asensio Ramos A, Díaz Baso C J. Stokes inversion based on convolutional neural networks[J/OL]. aap, 2019, 626:A102. DOI: 10.1051/0004-6361/201935628.
- Auer L H, Heasley J N, House L L. The determination of vector magnetic fields from Stokes profiles. [J/OL]. solphys, 1977, 55(1):47-61. DOI: 10.1007/BF00150873.
- Bai X Y, Deng Y Y, Teng F, et al. Improved magnetogram calibration of Solar Magnetic Field Telescope and its comparison with the Helioseismic and Magnetic Imager[J/OL]. mnras, 2014, 445(1):49-55. DOI: 10.1093/mnras/stu1711.
- Bai X Y. The calibration of solar vector magnetic field in active region[D]. National Astronomy Observatories, Chinese Academy of Scirences, 2014.
- Bai X Y, Deng Y Y, Su J T. Calibration of vector magnetograms with the chromospheric mg b 2 line[J]. Solar Physics, 2013, 282(2):405-418.
- Borrero J M, Tomczyk S, Kubo M, et al. VFISV: Very Fast Inversion of the Stokes Vector for the Helioseismic and Magnetic Imager[J/OL]. solphys, 2011, 273(1):267-293. DOI: 10.1007/s11207-010-9515-6.
- Carroll T A, Staude J. The inversion of Stokes profiles with artificial neural networks[J/OL]. aap, 2001, 378:316-326. DOI: 10.1051/0004-6361:20011167.
- Cauer W. Theorie der linearen wechselstromschaltungen[J]. 1954, 1.
- Cavallini F. Ibis: A new post-focus instrument for solar imaging spectroscopy[J/OL]. Solar Physics, 2006, 236:415-439. DOI: 10.1007/s11207-006-0103-8.
- Chae J, Moon Y J, Park Y D, et al. Initial results on line-of-sight field calibrations of sp/nfi data taken by sot/hinode[J]. Publications of the Astronomical Society of Japan, 2007, 59(sp3):S619-S624.
- Cobo B, Iniesta J. Sir: Stokes inversion based on response functions[J]. Astrophysics Source Code Library, 2012:12008-.
- Collados M, López R, Páez E, et al. GRIS: The GREGOR Infrared Spectrograph[J/OL]. Astronomische Nachrichten, 2012, 333(9):872. DOI: 10.1002/asna.201211738.
- Cybenko G. Approximation by superpositions of a sigmoidal function[J/OL]. Mathematics of Control, Signals and Systems, 1989, 2(4):303-314. https://doi.org/10.1007/BF02551274.

- del Toro Iniesta J C. Introduction to spectropolarimetry[M/OL]. Cambridge University Press, 2003. DOI: 10.1017/CBO9780511536250.
- del Toro Iniesta J C, Ruiz Cobo B. Inversion of the radiative transfer equation for polarized light [J/OL]. Living Reviews in Solar Physics, 2016, 13(1):4. DOI: 10.1007/s41116-016-0005-2.
- Deng Y, Zhang H. Progress in space solar telescope[J]. Science in China Series G: Physics, Mechanics and Astronomy, 2009, 52(11):1655.
- Elmore D F, Lites B W, Tomczyk S, et al. 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: volume 1746 Polarization Analysis and Measurement. 1992: 22-33. DOI: 10.1117/12.138795.
- Foresee F D, Hagan M T. Gauss-newton approximation to bayesian learning[C]//International Conference on Neural Networks. 1997.
- Goldberg D. Genetic algorithm in search, optimization, and machine learning[J]. Addison-Wesley, Reading, Massachusetts, 1989, xiii.
- Goodfellow I, Bengio Y, Courville A. Deep learning[M]. MIT press, 2016.
- Hagyard M, Cumings N, West E, et al. The msfc vector magnetograph[J/OL]. Solar Physics, 1982, 80. DOI: 10.1007/BF00153422.
- Hagyard M J, Adams M L, Smith J E, et al. Effects of Faraday rotation observed in filter magnetograph data[J/OL]. solphys, 2000, 191(2):309-324. DOI: 10.1023/A:1005252108523.
- Hale G E. On the probable existence of a magnetic field in sun-spots[J]. The astrophysical journal, 1908, 28:315.
- Harvey J, Giampapa M, Henney C, et al. Early Results from SOLIS[C]//American Astronomical Society Meeting Abstracts: volume 204 American Astronomical Society Meeting Abstracts #204. 2004: 37.01.
- Haykin S. Neural networks and learning machines: number 10 neural networks and learning machines[M/OL]. Prentice Hall, 2009. https://books.google.com/books?id=K7P36IKzI\_QC.
- He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016.
- Hoeksema T, Scherrer P, Bush R, et al. The solar oscillations investigation: Michelson doppler imager[J]. 1992.
- Iglesias F A, Feller A. Instrumentation for solar spectropolarimetry: state of the art and prospects [J/OL]. Optical Engineering, 2019, 58:082417. DOI: 10.1117/1.OE.58.8.082417.
- Jin C L, Qu Z Q, Xu C L, et al. The Relationships of Sunspot Magnetic Field Strength with Sunspot Area, Umbral Area and Penumbra-Umbra Radius Ratio[J/OL]. apss, 2006, 306(1-2):23-27. DOI: 10.1007/s10509-006-9217-6.

- Jin C, Wang J. Stokes inversion of sunspots' magnetic field[J]. Progress in Astronomy, 2007, 25(4): 305-322.
- Kingma D P, Ba J. Adam: A Method for Stochastic Optimization[J]. arXiv e-prints, 2014: arXiv:1412.6980.
- Landi Degl'Innocenti E, Landi Degl'Innocenti M. Quantum Theory of Line Formation in a Magnetic Field[J/OL]. solphys, 1972, 27:319. DOI: 10.1007/BF00153104.
- Le Y. Cun: Generalization and network design strategies, connectionism in[C]//Steels, Elsevier Science Publishers Bv, North-holland. 1989.
- Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- Lecun Y, Bengio Y. Convolutional networks for images, speech, and time-series[C]//1995.
- Leka K, Mickey D, Uitenbroek H, et al. The imaging vector magnetograph at haleakala iv: Stokes polarization spectra in the sodium d-1 589.6 nm spectral line[J/OL]. Solar Physics, 2012, 278. DOI: 10.1007/s11207-012-9958-z.
- Lin Y. Introduction to solar physics[M]. 2001.
- Liu H, Xu Y, Wang J, et al. Inferring Vector Magnetic Fields from Stokes Profiles of GST/NIRIS Using a Convolutional Neural Network[J/OL]. apj, 2020, 894(1):70. DOI: 10.3847/1538-4357/ab8818.
- Liu H, Ji K F, Jin Z Y. Application of machine learning in solar physics[J]. Chinese science: physics, mechanics, astronomy, 2019(10):105-117.
- Liu P X, Ji K F, Deng H, et al. A global-shared and low-exchange parallel method of high resolution solar image reconstruction[J]. Chinese Science Bulletin, 2018, 63(2):181-188.
- Mcculloch W, Pitts W. A logical calculus of ideas immanent in nervous activity"bulletin of mathematical biophysics[J]. 1994.
- Mein P. The MSDP of THEMIS: Capabilities, first results and prospects[J/OL]. aap, 2002, 381: 271-278. DOI: 10.1051/0004-6361:20011418.
- Metcalf T R, Leka K D, Barnes G, et al. An Overview of Existing Algorithms for Resolving the 180 Ambiguity in Vector Magnetic Fields: Quantitative Tests with Synthetic Data[J/OL]. solphys, 2006, 237(2):267-296. DOI: 10.1007/s11207-006-0170-x.
- Milic I, Gafeira R. Mimicking spectropolarimetric inversion using convolutional neural networks [C]//American Astronomical Society Meeting Abstracts: volume 234 American Astronomical Society Meeting Abstracts #234. 2019: 226.05.
- Nair V, Hinton G E. Rectified linear units improve restricted boltzmann machines vinod nair[C]// Proceedings of the 27th International Conference on Machine Learning (ICML-10), June 21-24, 2010, Haifa, Israel. 2010.

- Nikulin N, Severny A, Stepanov V. The solar magnetograph of the crimean astrophysical observatory [J]. Krymsk. Astrofiz. Obs., Izvest., 1958, 19:3-20.
- Qu Z Q. A Fiber Arrayed Solar Optical Telescope (FASOT)[C]//Kuhn J R, Harrington D M, Lin H, et al. Astronomical Society of the Pacific Conference Series: volume 437 Solar Polarization 6. 2011: 423.
- Qu Z Q, Zhang X Y, Chen X K, et al. A Solar Stokes Spectrum Telescope[J/OL]. solphys, 2001, 201(2):241-251. DOI: 10.1023/A:1017978822648.
- Qu Z Q, Xu C L, Zhang X Y, et al. On the influence of magnetic fields on level populations[J/OL]. mnras, 2006, 370(4):1790-1796. DOI: 10.1111/j.1365-2966.2006.10598.x.
- Rachkovsky D. Magnetic rotation effects in spectral lines[J]. Izvestiya Ordena Trudovogo Krasnogo Znameni Krymskoj Astrofizicheskoj Observatorii, 1962, 28:259-270.
- Rees D E, López Ariste A, Thatcher J, et al. Fast inversion of spectral lines using principal component analysis. I. Fundamentals[J]. aap, 2000, 355:759-768.
- Rosenblatt F. A probabilistic model for visual perception[J/OL]. Acta Psychologica ACTA PSYCHOL, 1959, 15:296-297. DOI: 10.1016/S0001-6918(59)80143-8.
- Samanta T, Tian H, Yurchyshyn V, et al. Generation of Solar Spicules and Subsequent Atmospheric Heating[J]. arXiv e-prints, 2020:arXiv:2006.02571.
- Scharmer G, Narayan G, Hillberg T, et al. Crisp spectropolarimetric imaging of penumbral fine structure[J/OL]. The Astrophysical Journal Letters, 2008, 689:L69. DOI: 10.1086/595744.
- Schou J, Scherrer R, PH and Bush, WACHTER R, et al. Design and ground calibration of the helioseismic and magnetic imager (hmi) instrument on the solar dynamics observatory (sdo)[J]. Solar Physics, 2012, 275(1-2):229-259.
- Skumanich A, Lites B W. Stokes Profile Analysis and Vector Magnetic Fields. I. Inversion of Photospheric Lines[J/OL]. apj, 1987, 322:473. DOI: 10.1086/165743.
- Socas-Navarro H. Astronomical society of the pacific conference series: volume 236 Stokes Inversion Techniques: Recent Achievements and Future Horizons[M]. 2001: 487.
- Socas-Navarro H, López Ariste A, Lites B W. Fast Inversion of Spectral Lines Using Principal Components Analysis. II. Inversion of Real Stokes Data[J/OL]. apj, 2001, 553(2):949-954. DOI: 10.1086/320984.
- Solanki S K, Rueedi I, Livingston W. Infrared lines as probes of solar magnetic features. V The magnetic structure of a simple sunspot and its canopy[J]. aap, 1992, 263(1-2):339-350.
- Stenflo J O. Solar polarimetry with ZIMPOL . Plans for the future[J]. memsai, 2007, 78:181.

Stenflo J. Solar magnetic fields: volume 189[M/OL]. 1994. DOI: 10.1007/978-94-015-8246-9.

Su J T. The measurement of solar magnetic fields[D]. National Astronomy Observatories, Chinese Academy of Scirences, 2004.
- Su J T, Zhang H Q. Diagnosis of Faraday Rotation with the Video Vector Magnetograph at Huairou [J/OL]. solphys, 2004, 222(1):17-33. DOI: 10.1023/B:SOLA.0000036857.22150.37.
- Tao Y H, Cui C Z, Zhang Y X, et al. The application of deep learning in astronomy[J]. Progress in Astronomy, 2020, 38(02):168-188.
- Teng F. Application of kernel based machine learning to the inversion problem of photospheric magnetic fields[J]. Solar Physics, 2015, 290(10):2693-2708.
- Tsuneta S, Ichimoto K, Katsukawa Y, et al. The Solar Optical Telescope for the Hinode Mission: An Overview[J/OL]. Solar Physics, 2008, 249(2):167-196. DOI: 10.1007/s11207-008-9174-z.
- Unno W. Line Formation of a Normal Zeeman Triplet[J]. pasj, 1956, 8:108.
- Yu L, Feng S. Automated sunspot detection using morphological reconstruction and adaptive region growing techniques[J]. Fuxian Solar Observatory, 2014:7168-7172.
- Zhou Z H. Machine learning[M]. Tsinghua University Press, 2016.
- Zirin H. Evolution of weak solar magnetic fields[J/OL]. Australian Journal of Physics, 1985, 38. DOI: 10.1071/PH850961.

# 作者简历及攻读学位期间发表的学术论文与研究成果

作者简历

郭晶晶,山东省莘县人,中国科学院国家天文台博士研究生。

### 教育情况

- 1. 2012年9月至2015年5月,昆明理工大学,硕士,专业:计算机应用技术
- 2. 2017年9月至2020年12月,中国科学院国家天文台,博士,专业:天文技术与方法。

#### 已发表(或正式接受)的学术论文:

- Guo, J., Bai, X., Deng, Y. et al. A Non-Linear Magnetic Field Calibration Method for Filter-Based Magnetographs by Multilayer Perceptron. Sol Phys 295, 5 (2020).(第一作者)
- 2. **Guo, J.**, Bai, X.et al. A nonlinear solar magnetic field calibration method for the filter-based magnetograph by the residual network. A&A, 已录用。(第一作者)
- 陈垂裕,..,郭晶晶,等.FMG载荷地面试观测导行跟踪系统的设计与实现[J].天 文学报,2020(4):33-42.(通讯作者)
- 4. Jiang-Tao Su, Xian-Yong Bai, Jie Chen, **Jing-Jing Guo**.et al. Data reduction and calibration of the FMG onboard ASO-S. RAA, 2019, 11, 161-176
- Haiqing Xu, Jiangtao Su, Xianyong Bai, Jie Chen, Yu Gao, Suo Liu, Xiaofan Wang, Xiao Yang, Jingjing Guo & Yuanyong Deng. A Method to Correct the Intensity to Polarization Crosstalk in Measuring Full-Disk Solar Photospheric Vector Magnetic Fields. Sol Phys 294, 129 (2019).

### 联系方式

通讯地址:北京市朝阳区大屯路甲 20 号国家天文台 A 座

邮编: 100101

Email: guojingjing@bao.ac.cn

### 参加的研究项目及获奖情况:

- 1. 空间科学先导专项ASO-S卫星工程项目子课题《全日面矢量磁象仪(FMG)软件研发》
- 2. 空间科学先导专项ASO-S卫星工程项目子课题《FMG载荷数据采集系统与 处理系统方案设计》
- 3. 国家基金委(国家重大科研仪器研制项目)《用于太阳磁场精确测量的中红 外观测系统(AIMS)》
- 4. 横向课题《北京35中和上海青浦中学定天镜项目》
- 5. 横向课题《北京师范大学太阳塔二期建设项目》
- 6. 获得中国科学院大学2018年三好学生称号
- 7. 获得2020年博士研究生国家奖学金

## 致 谢

人生不过几十个春秋,在北京在国家天文台在怀柔太阳观测站的日子占据 了漫长的一段时光。时光知味,岁月沉香。有些人和事已随风而逝,渐渐淡出 记忆,而留下来的无论是忧是喜是梦是幻都是弥足珍贵的。记得初来北京初来 天文台初来怀柔站,便感受到天文学家们浓浓的浪漫情怀,他们怀着澎湃的情 感仰望天空,看日看月看星辰变换,满腔的热血都奉献给了我国天文事业,他 们的情怀与他们的无私奉献一直感染着我激励着我走过这一段磕磕绊绊的人生 旅途。除了天文学家们的浪漫与奉献令人触动之外,最令我感激的便是怀柔太 阳观测站这个大家庭所营造的科研成长环境,师长们的谆谆教诲让我在科研道 路上不断成长,怀柔站的后勤保障总是令人宾至如归,师兄师姐们的关心帮助 让我感受到无限温暖,师弟师妹们的陪伴让略显枯燥的科研生活多了不少欢声 笑语。点点滴滴流淌在时间的长河中,不曾忘记。临近毕业,借此之际,向我 最尊敬的师长们,最可爱可亲的人儿表达我最为真挚的感谢。

首先感谢我的博士生导师,我的科研领路人邓元勇研究员和林佳本高级工 程师。邓老师在生活中虚怀若谷、和蔼可亲,在学术上严谨治学、不言放弃,他 不断挑战前沿课题,时刻带领着、鞭策着我们不断进取。林老师平易近人、幽 默风趣,既有师长的典范又是生活的楷模,无论在生活上还是科研上都给与我 无微不至的关心和帮助,指引者我一路向前。感谢恩师给予我成长的空间,给 予我飞翔的机会。在这里要特别感谢云南天文台的季凯帆研究员。硕士期间便 有幸获得季老师的指引,博士课题的顺利开展更是很多得益于季老师的帮助和 指导。季老师在学术上可谓博学旁证、一丝不苟,生活中又严于律己、宽以待 人。总是循循善诱、不厌其烦地解答着我的疑惑,督促着我的学业,指正着我 的谬误,可谓良师益友,让我受益颇多。还要由衷的感谢白先勇博士,自老师 亦称白师兄,算是半师半友。称为师是因为他在我的博士课题开展期间不遗余 力地帮助我督促我指导我完成科研工作,称为友是因为他是同龄人,生活上和 学术上的烦恼都能够找他倾诉一二,他也总是耐心地开导,让人豁然开朗。感 谢各位老师帮助我引领我克服一个个困难,让我有勇气继续科研之路。

感谢张洪起研究员,给我答疑解惑让我对太阳磁场的认知更深一步;感谢

89

基地的首席科学家张枚研究员,每一次报告之后都能给我一些启发性的点拨; 感谢王东光研究员,每次技术讨论会上都耐心细致帮我梳理研究项目的技术路 线,使我逐步深入到课题研究中;感谢苏江涛研究员,在博士课题研究中提出 很多建议和帮助;感谢林钢华研究员,总是鼓励着我让我对科研充满信心。感 谢云南天文台的刘辉老师对我科研成长的关注和学业上的帮助;感谢毛信杰教 授,教授我们磁流体力学,每次都如沐春风。

感谢王丙祥工程师在电控技术上提供全力的帮助。感谢张志勇博士、孙英 姿博士、侯俊峰博士、张洋工程师、王建工程师等在望远镜结构以及光学原理 上的答疑解惑。感谢姜杰研究员、陈洁博士、杨尚斌博士、包兴明博士、王晓 帆博士、徐海清博士、刘锁博士、郭娟博士、郝娟博士、赵辉博士、高裕博士、 李坦达博士、杨潇博士、赵翠博士、腾飞博士、宋永亮博士等最优秀的老师们、 最可爱可亲的师兄师姐们的关心和帮助。

特别感谢杨潇师姐、孙英姿师姐、孙文君同学、段帷老师(CCD实验室)等在 生活上的关心和帮助。也特别感谢一起度过研究生生涯的同学、师兄师弟师妹 们:魏烨艳、张小敏、王刚、袁飞、佟立越、曾祥云、朱晓明、柯子博、于鹏 达、祝高飞、白阳、王全、吴玮、胡兴、黄威、沈宇樑、陈垂裕、王强、荀辉、 王雅琦、周明尧、李鑫、胡子尧、郑州、王怡然(空间中心)、熊建萍(LMOST)等 在学习和生活中互相交流帮助,与你们一起的时光是丰富而多彩的。感谢你们, 在学习上或在生活中给予我帮助和支持,才使我克服一个又一个疑惑与困难。 感谢我的室友们,你们的陪伴总是那么温暖。另外,还要感谢云南天文台的常 亮同学(老师)在一起修读博士英语期间的关心与照顾。

感谢王薏站长以及张鼎波、汪国萍、荆帅、阮文东、王立东、包亚东、杨 桂莲、苏海奇等台站运营保障工作人员。感谢您们给我们营造了一个舒适干净, 环境优美的生活、学习和工作之地,在站期间给与我多方面的照顾和帮助,让 我感受到家的温暖。感谢曾真、孙文君、罗琳、王璇、闫璐等老师帮忙处理了 很多报销等事务,使我安心科研。感谢朱丽佳老师让我见识到工程项目质量管 理的精妙之处。

感谢太阳活动重点实验室以及CDD重点实验室给予我各种关心和帮助的老师和同学。感谢美国大熊湖太阳观测站的杨煦博士(师兄)帮助我修改论文的英文语言表达,很大的提升了我文章的可读性。感谢文章论文的审稿人,你们的意

90

见语重心长,使我受益终生。感谢审阅我文章的杂志社编辑们,一句句的润色 我文章中的英文。感谢杜红荣老师、艾华老师、马怀宇老师、李响老师对我读 博期间学习生活上的照顾和帮助。感谢国家自然科学基金、中国科学院大学和 国家天文台在我读博期间的资助。

此外,还要感谢我的硕士生导师昆明理工大学的冯松教授以及杨云飞老师, 使你们让我有机会来到怀柔站这个大家庭,有幸在这里与最可敬最优秀的师长、 同学、朋友伴着一路科研一路成长。

最后感谢我的父母兄弟,以及支持我的亲朋好友们!你们的理解和支持, 我永远铭记在心,不再一一表述。

谨以此文献给我生命中最可敬最可爱最可亲的人儿!