

基于神经网络的双折射窄带滤光器型磁像仪 观测波长点的定标

胡兴^{1,3,4}, 杨尚斌^{1,3,4*}, 季凯帆^{2,4}, 林佳本^{1,3,4}, 邓元勇^{1,3,4}, 白先勇^{1,3,4}, 朱晓明^{1,3}, 白阳^{1,3}, 王全^{1,3,4}

¹中国科学院国家天文台, 北京 100101;

²中国科学院云南天文台, 云南 昆明 650217;

³中国科学院太阳活动重点实验室, 北京 100101;

⁴中国科学院大学, 北京 100049

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

关键词 测量; 滤光器型磁像仪; 波长点定标; 预处理; 机器学习

中图分类号 P111.2

文献标志码 A

DOI: 10.3788/CJL221432

1 引言

太阳活动对人类活动和日地空间天气有着重要的影响,而太阳磁场是太阳活动的重要观测物理量^[1]。目前,基于双折射窄带滤光器的磁像仪是测量太阳矢量磁场的主要设备之一。怀柔太阳观测基地全日面矢量磁像仪(SMAT)是中国第一台投入常规观测的滤光器型全日面矢量磁像仪^[2-3]。SMAT使用的双折射窄带滤光器在固定温度下工作,在夫琅禾费吸收线 Fe I 532.419 nm 偏离线心 -0.008 nm 处进行观测获得偏振信息,然后通过定标过程获得太阳矢量磁场^[4-5]。在日常观测中,滤光器因受到温度和机械误差(比如齿隙)等因素的影响,使观测的谱线发生相对漂移,导致偏振信号减弱或消失,从而影响太阳矢量磁场测量的精确性。因此,滤光器所在观测谱线波长点位置定标的准确性十分重要。

当前采用的波长点定标方法需要先进行观测谱线轮廓扫描,进而完成观测波长点的定标。常用的谱线定标方法是进行多项式拟合或者分段拟合^[6-8]。SMAT 观测的 Fe I 532.419 nm 谱线的等值宽度是

0.0334 nm,中心剩余强度是 0.1315(中心剩余强度指线心与线翼强度的比值,比值越低,吸收越强),是一条较宽和较强的吸收线^[9-11]。目前的波长定标方案是从蓝翼 -0.03 nm 以 0.002 nm 的步长逐步移动滤光器透过带位置到红翼 +0.03 nm,共拍摄 31 张图像,然后通过拟合图像中心强度与对应的波长点位置得到谱线轮廓,进而获得线心位置,最后通过机械旋转波片使滤光器到观测波长点处进行观测。这种定标方法花费较多的时间,减少了观测数据的数量和时间分辨率,且频繁的机械旋转导致滤光器寿命降低,进一步影响磁场数据的稳定、高质量获取。此外,现有的波长点定标方法也无法形成一个对观测波长点位置进行判断和控制的实时闭环系统。

针对以上问题,本文在分析 SMAT 数据特点的基础上,首先总结了一套新的数据预处理的流程,然后借助机器学习中有监督学习的方法,提出了一套基于神经网络的观测波长点定标方案。该方案建立起了单帧图像和对应波长点的关系,从而可以根据单帧图像快速判断观测波长点位置。实验结果表明该方案比传统的定标方法快了 100 多倍,并且可支持实时快速调节

收稿日期: 2022-11-18; 修回日期: 2022-12-19; 录用日期: 2023-01-06; 网络首发日期: 2023-02-07

基金项目: 国家自然科学基金(11427901, 12073040)、国家重点研发计划(2022YFF0503800, 2021YFA1600500)、中国科学院空间科学战略性先导科技专项(XDA15320102, XDA15320302, XDA15010700)、中科院青促会项目(2019059)

通信作者: *yangshb@nao.cas.cn

滤光器所在的波长点位置。此外,通过判断预测值和标签值的残差大小和变化趋势,为判断磁像仪运行状态稳定性提供了一种有效的检测方法。

2 数据分析及预处理流程

2.1 数据来源

本文的数据来自怀柔太阳观测基地 SMAT,该磁像仪于 2005 年底投入运行使用^[4]。它的主要任务是通过观测偏振像来获得全日面矢量磁场,基于此对光球活动,特别是活动区的磁场演化展开研究。此外,该磁像仪还为空间天气预报提供基础数据。SMAT 在 Fe I 532.419 nm 这条谱线进行观测,滤光器的透过带宽是 0.001 nm,工作在 $(42 \pm 0.01)^\circ\text{C}$ 温度范围。通过加不同电压控制 KD*P 晶体来获得不同的偏振像,通过定标过程,进一步获得太阳矢量磁场。电荷耦合器件 (CCD) 像元尺寸为 $7.4 \mu\text{m} \times 7.4 \mu\text{m}$,面阵大小为 $992 \text{ pixel} \times 992 \text{ pixel}$,帧频为 30 frame/s,最大传输速率可达 60 Mbit/s。获得磁图的空间分辨率优于 $5''$ ^[3-4],获得一组偏振像的时间小于 3 min。

本文使用的是 SMAT 观测数据中的谱线扫描数据。谱线扫描数据是指在符合观测条件的情况下,从蓝翼 -0.03 nm 到红翼 $+0.03 \text{ nm}$ 以 0.002 nm 的步长逐步移动滤光器透过带位置拍摄的 31 张单色像。通过拟合图像中心强度和采集位置的关系获得谱线轮廓,并根据此轮廓找到线心位置,然后移动滤光器到谱线的固定观测波长点(线翼 -0.008 nm)进行观测。下文所称波长,除有特别说明外,均指以 532.419 nm 为零点的偏移值。图 1 所示为谱线数据拟合示例。在当前坐标下,该组数据拟合得到的线心为 0.0171 nm ,滤光器向蓝翼移动 0.0091 nm 进行偏振成像观测,从而进一步得到太阳矢量磁场。




图 1 数据拟合得到的谱线轮廓

Fig. 1 Spectral line profile obtained by fitting of data

本文挑选了 2018 年和 2019 年的数据进行实验,全波段数据一共 206 组(每组 31 张图像,共 6386 张图像)。数据的分配上,取 70% 作为训练集,30% 作为测试集,在训练集中取 15% 作为验证集。方法验证实验

中,将所有的数据打乱后随机分配数据。为了分析系统稳定性对算法的影响,本文又以滤光器和电机的维修时间作为分界点来选取数据进行实验,将以上数据重新分为 5 组,每组取 70% 的数据作为训练集,取 30% 的数据作为测试集,在训练集中取 15% 作为验证集,对每组数据进行相同的实验。最后针对系统偶尔维修需重新训练网络的问题,进行了克服系统变化实验,实验中使用更小波带范围数据进行网络训练和测试,数据分配方法与前两次实验一致。

2.2 数据分析和预处理

首先需要进行数据筛选。选取可以拟合出光滑谱线轮廓的数据,拟合的谱线轮廓如图 1 所示。同时剔除亮度饱和数据,选取线心位置处于 $(0.016 \pm 0.004) \text{ nm}$ 之间的数据,以进一步减小系统观测谱线轮廓拟合误差。

其次,对于筛选出来的图像需要进行 P 角改正和波长改正。进行 P 角改正,是由于太阳自转轴和天赤道存在夹角,需要将图像调整为北上南下;波长改正则是指将所有谱线线心重置为 0,依次改正每一张图像对应的波长。

对于 532.419 nm 谱线观测的太阳光球层而言,观测到的太阳像在空间位置上主要有三种特征:首先是大尺度特征;其次是中等空间尺度的特征,主要包括黑子、谱斑等;最后是小空间尺度的特征,如米粒等^[12]。大尺度特征主要由临边昏暗轮廓和太阳自转等因素导致的波长漂移所致。临边昏暗在图像上表现出来日面中心亮逐步到边缘暗的特点,太阳自西向东自转产生的多普勒速度对图像的影响表现出大尺度灰度分布不均匀(一边亮一边暗)的特点。当滤光器逐步从谱线蓝翼到红翼不同波长点处拍摄图像时,受多普勒速度的影响,图像随拍摄位置由左亮右暗逐步变化到左暗右亮,如图 2 所示。

由多普勒速度所引起的大尺度图像差异体现了图像对应的不同观测波长点位置,而临边昏暗同样作为大尺度的特征不具有明显的区分性,是一种干扰信息,




图 2 谱线不同点上太阳自转的多普勒速度对图像的效应

Fig. 2 Effect of Doppler velocity of solar autorotation on images at different points of spectral line

而且会叠加在图像差异特征上,如图 3(a)和图 3(b)所示。因此,在数据预处理时,需要去除临边昏暗。对去除临边昏暗后的数据,采用图像除以自身中心强度的方式进行归一化。完成处理后的数据如图 3(c)和图 3(d)所示。图 3 中用日面纬度 0° (中红线标志) 的数

据来展示图像的亮暗变化,图像对应的波长值标注在各图上方。可以看出,做完临边昏暗去除和数据归一化后,不同波长点位置的图像大尺度差异变得非常明显:从蓝翼到红翼,图像由左亮右暗逐步变化到左暗右亮。

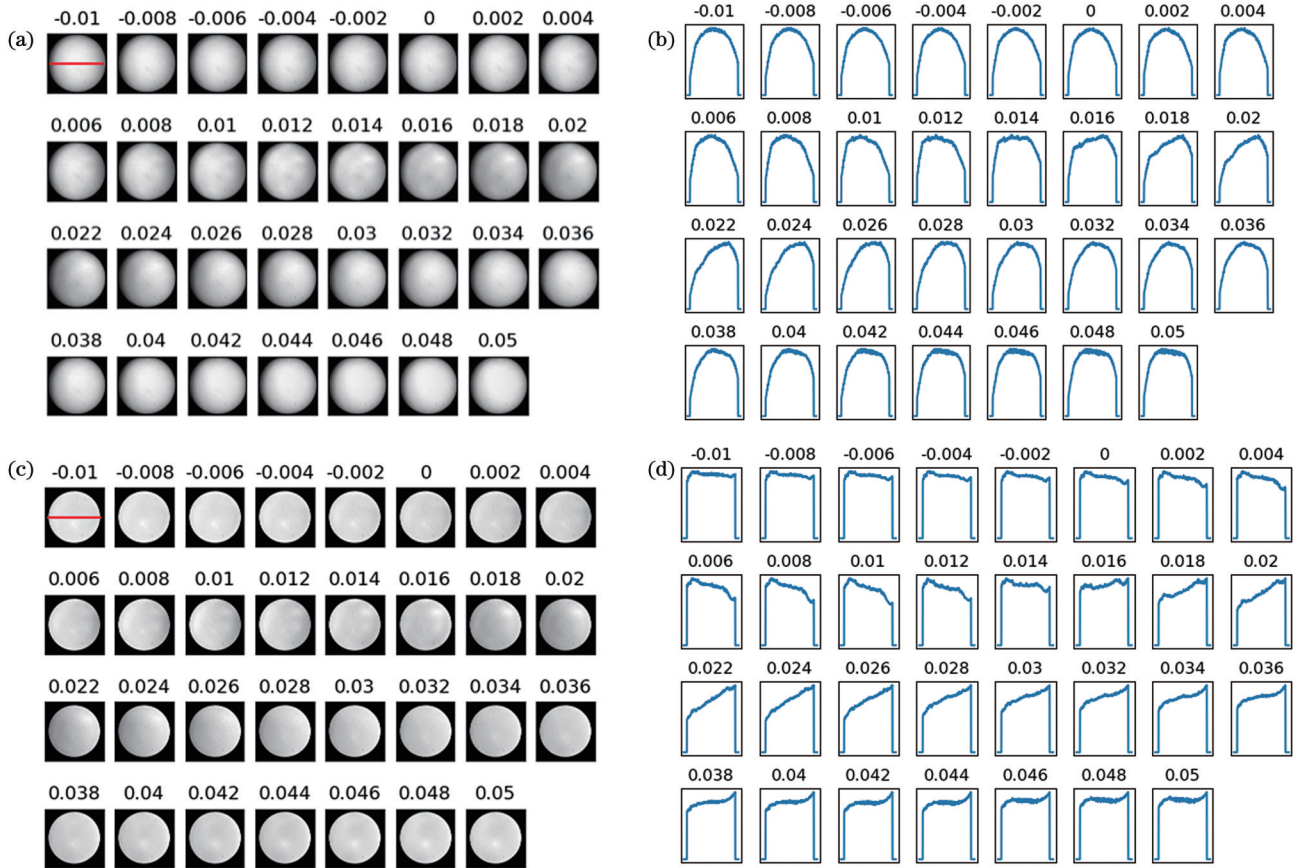


图 3 数据处理前后的对比(波长单位:nm)。(a)原始图像;(b)原始图像的灰度变化图;(c)去除临边昏暗后图像;(d)去除临边昏暗后的灰度变化图

Fig. 3 Comparison before and after data processing (wavelengths in nm). (a) Original images; (b) grayscale change of original images; (c) images after edge dimming is removed; (d) grayscale change after edge dimming is removed

此外,日面外的数据是一种无效信息,也需要去除。本文使用极坐标转换的方式去除日面边缘的数据,同时缩小图像,以在保留大尺度信息的同时减少运算量。在实际的操作中,图像大小由 $992 \text{ pixel} \times 992 \text{ pixel}$

变为 $45 \text{ pixel} \times 50 \text{ pixel}$,如图 4(a)和图 4(b)所示。 45 pixel 是角度方向, 50 pixel 是半径方向,如图 4(b)所示。在半径方向取 $1 \sim 22 \text{ pixel}$ 保留日面部分数据,如图 4(c)所示。




图 4 去除日面外数据。(a)原图;(b)极坐标变换后的图;(c)日面部分

Fig. 4 Removing information outside solar circle. (a) Original image; (b) image after polar coordinate transformation; (c) solar part

最后,对数据进行主成分分析(PCA)。PCA 是一种无监督学习算法,通过 PCA 将原始数据变换为一组各维度线性无关的数据,然后提取数据的主要特征分量,一方面可以去除小的干扰信号,另一方面可以使训练的网络轻量化,加快迭代。本文将所有的数据整合之后进行 PCA,最终将每一张图像变为一个 1 维数组,该 1 维数组即图像通过 PCA 降维后映射的主成分。具体操作步骤如下:

(1) 将极坐标转换后去掉日面外的图像[如图 4(c)所示,大小为 $22 \text{ pixel} \times 45 \text{ pixel}$]展平为一维向量 $[1, m]$, $m=990=22 \times 45$ 。

(2) 将所有的数据整合为 $[n, m]$ 的二维数组,此处 n 表示图像的数量。

(3) 选择降维阶数,完成数据的降维。

图 5 和图 6 分别展示了在 PCA 降维过程中贡献率随阶数的变化和降维前后图像重构的对比。本文选用不同阶数进行实验,当阶数为 20 时,贡献率达到了 99.4%,所以本文选用 PCA 降维后的主成分为 $[1, 20]$ 的数组(长度为 20 的一维数组),该数组代表图像的主要特征。同时也可以看出,使用 PCA 降维后的图像比之前平滑,重构后的图像大尺度特征与降维前的图像没有差异,说明 PCA 降维步骤非常成功。




图 5 PCA 分解贡献率

Fig. 5 PCA decomposition contribution rate




图 6 20 阶重构前后图像对比

Fig. 6 Image comparison before and after 20th-order reconstruction

综合本节内容,图像预处理方案的整个流程如图 7 所示。

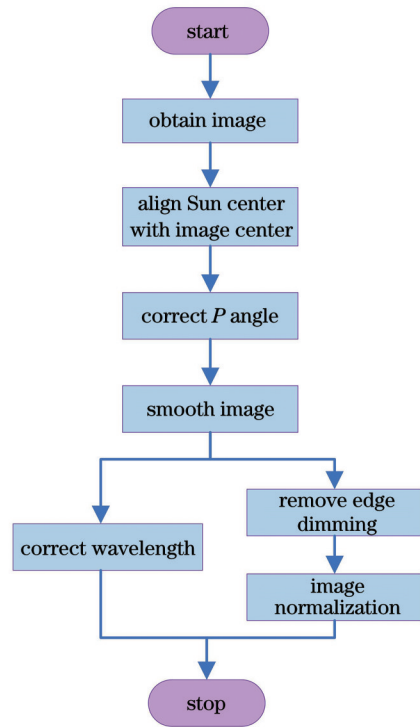


图 7 图像预处理流程

Fig. 7 Image pre-processing process

3 基于反向传播神经网络的观测波长点定标方法

反向传播(BP)网络的拓扑结构包括一个输入层、多个隐藏层和一个输出层^[13-14]。BP 网络的训练过程由正向传播和反向传播两个部分构成。正向传播时,输入信号通过隐藏层作用于输出节点,经过非线性变换产生输出信号。计算正向传播输出的信号与给定信号的误差,转入反向传播过程。在反向传播过程中,误差会由输出节点在隐藏层中逐层反传,并将误差分摊给各层的所有单元,各单元获得误差信号后,将其作为权值调整的依据。通过反复学习训练,确定最小误差下对应的网络参数,完成网络的训练。

BP 神经网络训练过程本质上采用的是一种全局逼近的方法,它具有良好的泛化能力,可以作为一种一般性质的非线性输入-输出映射模型^[14-15]。

3.1 基于 BP 神经网络的观测波长点定标算法设计

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

本文所提出的基于 BP 的波长定标网络是一个多层感知机(MLP)的回归网络,输入为一个 $[1, 20]$ 的一维数组(预处理后的数据),隐藏层一共 8 层(1000, 1000, 500, 500, 300, 300, 200, 100),输出为一个 $[1, 1]$ (数组的大小为 1×1)的数(波长)。网络结构如图 8 所示。这里使用均方误差(MSE, E_{MS})作为损失函数,计




图 8 MLP 回归网络

Fig. 8 MLP regression network

算公式如下：

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

在隐藏层中,使用 ReLU 函数^[16]作为激活函数。通常意义下,该函数指代数学中的斜坡函数,即

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

ReLU 函数作为神经元的激活函数,定义了该神经元在线性变换 $\mathbf{w}^T \mathbf{x} + \mathbf{b}$ 之后的非线性输出结果。使用激活函数 ReLU 之后,对于来自上一层神经网络的输入向量 \mathbf{x} ,其输出为 $\max(0, \mathbf{w}^T \mathbf{x} + \mathbf{b})$,输出至下一层神经元或作为整个网络的输出。与使用其他激活函数的网络相比,使用 ReLU 激活函数的网络具有更快的训练速度。

网络参数的初始化采用随机初始化的方式。初始阶段的学习率设为

$$r_1 = 0.001. \quad (3)$$

只要损失在不断下降,就保持当前的学习率。所有的数据完成一次训练记为一个 epoch,当两个 epoch 之间的损失小于 1×10^{-7} 或者验证分数增长小于 1×10^{-7} 时,通过下式更新当前的学习率:

$$r_1^* = 0.2r_1. \quad (4)$$

如果连续 10 个 epoch 中的验证分数增长小于 1×10^{-7} ,则终止训练。为了防止程序一直训练下去,训练的最大迭代次数设为 5000。

基于 BP 神经网络的观测波长点定标算法的总流程如图 9 所示。



图 9 BP 神经网络对观测波长点进行定标的总流程

Fig. 9 General process of calibration of observing wavelength points using BP neural network

磁像仪拍摄到图像后,按图 7 所示流程对图像数据进行预处理,将预处理图像数据按图 9 所示处理流程输入图 8 所示神经网络进行预测,获得图像对应的观测波长点,完成滤光器观测波长点的定标。

3.2 算法实现平台

本算法的软件环境在 Windows 系统下使用 Python 基于 Scikit-learn 框架搭建实现。Scikit-learn 是一个开源的、简洁高效的数据挖掘和数据分析工具,它涵盖了机器学习常用的模块,可供开发者非常方便地自建网络。硬件环境涉及的主要信息如表 1 所示。

表 1 实验硬件环境

Table 1 Experimental hardware environment

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

4 实验结果与分析

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

4.1 方法验证

本文使用 2018 年和 2019 年的数据进行实验,从所有的数据中随机取出 70% 作为训练集,30% 作为测试集。实验结果如图 10 所示,横纵坐标分别代表实际波长值和预测波长值。

从实验结果来看,训练集和测试集的均方误差分别为 0.0003 和 0.0005,说明训练集和测试集分别有 99.73% 的数据误差小于 0.0009 nm 和 0.0015 nm。

4.2 分组测试实验

磁像仪的维修会影响系统的稳定性。考虑主要与滤光器和机械结构的维修相关的系统变化因素,按照维修节点将数据分为 5 个实验组开展分组测试实验,保证每个实验组的数据在相对稳定的系统下观测得到。对按照维修节点分配好的每一组数据,分别进行相同实验。实验中的训练集和测试集按照观测时间来分配,取前 70% 作为训练集,后 30% 作为测试集。取第一个实验组的结果予以展示,如图 11 所示。

图 11(a)和图 11(b)展示了训练集和测试集的均方误差,训练集的 MSE 为 0.0002,测试集的 MSE 为 0.0027。测试集的残差和每组残差均方差随时间的变化如图 11(c)和图 11(d)所示。可以看出,时间上靠近训练集的测试集,预测结果的误差小,说明了本方法的




图 10 方法验证实验的训练集和测试集相关图。(a)训练集;(b)测试集

Fig. 10 Correlation diagram of training set and test set for method validation experiment. (a) Training set; (b) test set

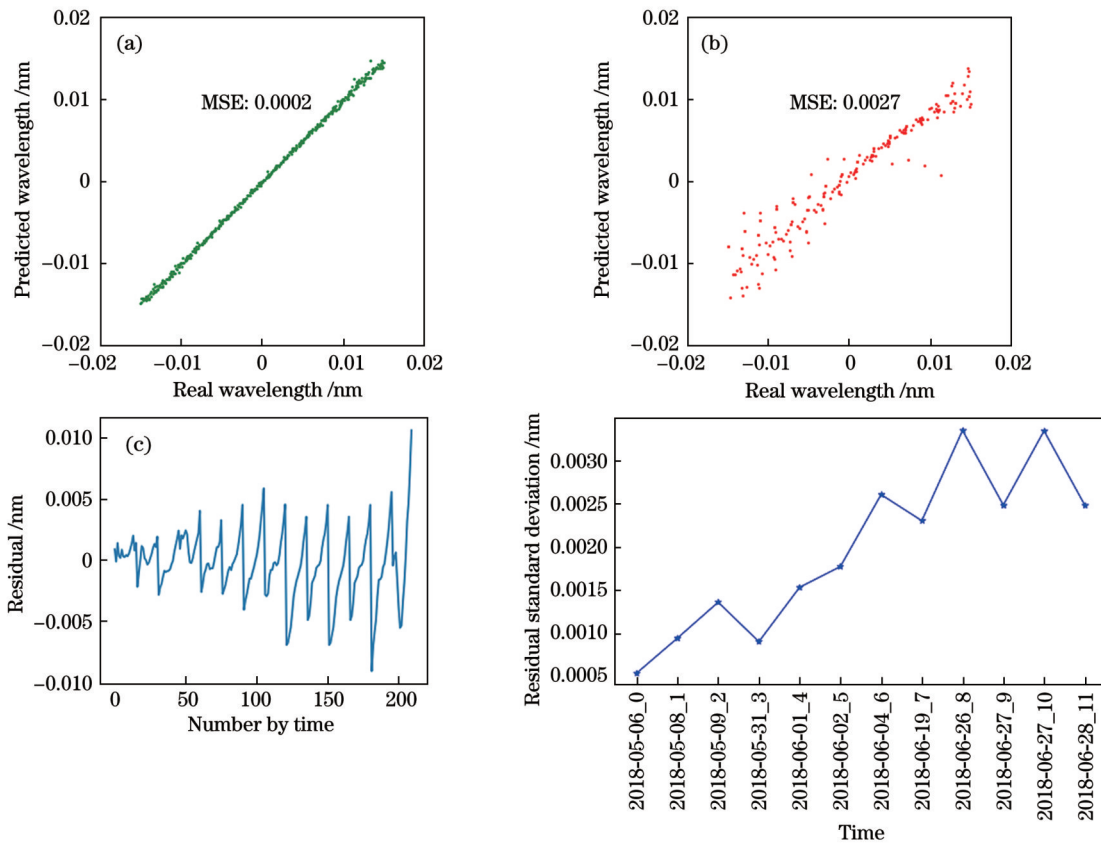


图 11 分组测试实验中第一个实验组的测试结果。(a)训练集相关图;(b)测试集相关图;(c)每个数据预测结果的残差;(d)每日残差均方差随时间的变化

Fig. 11 Results of group 1 of grouping test experiment. (a) Correlation diagram of training set; (b) correlation diagram of test set; (c) residual of each data prediction result; (d) variation of residual standard deviation of each day with time

有效性;时间上远离训练集的训练集,预测结果的误差逐渐增大,这种误差随时间增大的现象符合系统由稳定到不稳定变化的实际情况。

其他实验组的测试集误差变化如图 12 所示,同样符合误差随时间逐渐增大的特点,同时也对应系统随时间变化由稳定到不稳定的实际情况。

4.3 克服系统变化实验

从上述实验结果看,在线心处的预测误差受系统变化的影响较小,因此做了以下实验:对所有数据不加

分组,选取 $[-0.006 \text{ nm}, 0.006 \text{ nm}]$ 波带范围的数据进行实验。取 2018 年和 2019 年上半年的数据作为训练集,2019 年下半年的数据作为测试集,结果如图 13 所示。

图 13 结果显示,从相关性来看,训练集和测试集都有很强的相关性。测试集的相关性较训练集差,分析原因,一方面可能是由于测试集数据量少;另一方面,系统随时间发生变化,使用之前训练的数据无法学习到这些信息,导致测试集的相关性较差。训练集和

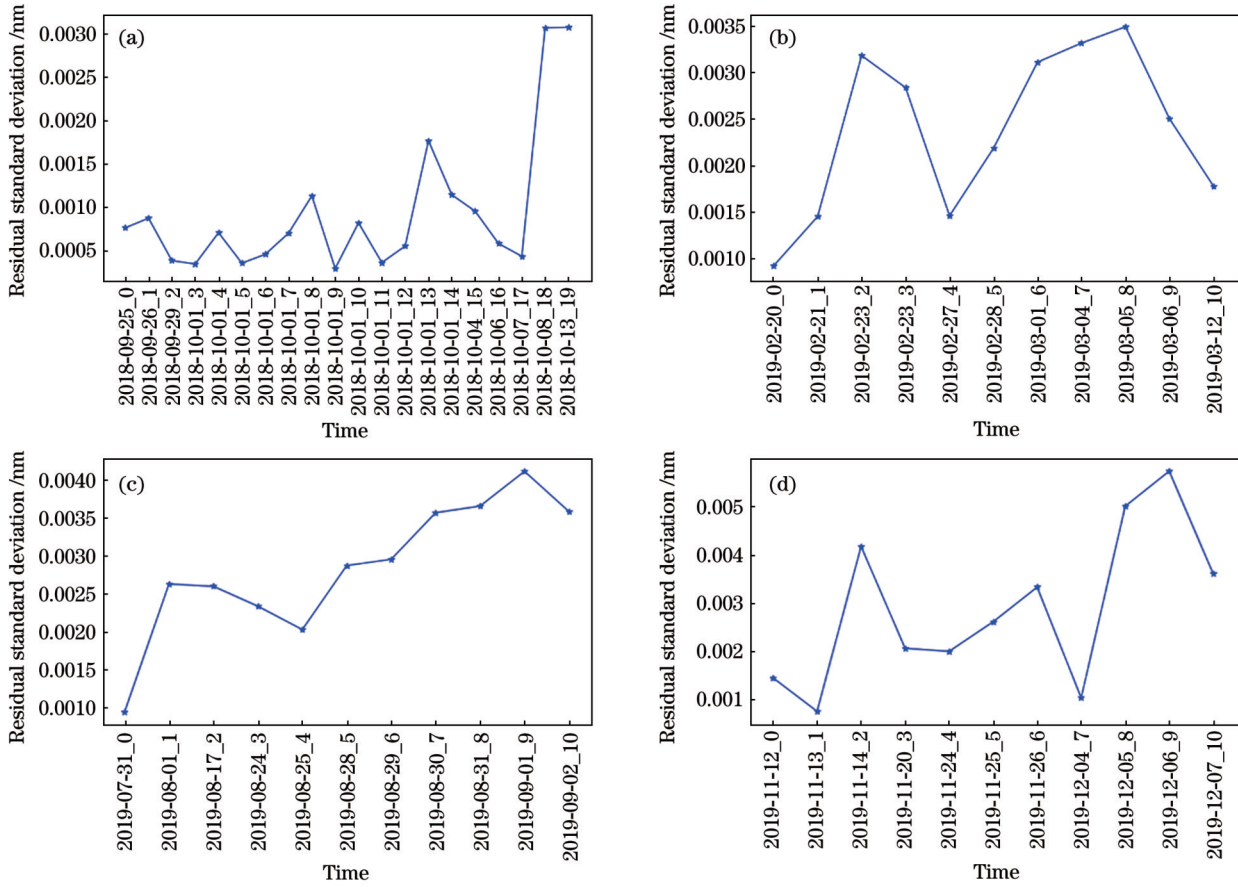


图 12 分组测试实验中不同实验组的残差均方差随时间的变化。(a)第二组;(b)第三组;(c)第四组;(d)第五组

Fig. 12 Variation of residual standard deviation of different groups of grouping test experiment. (a) Group 2; (b) group 3; (c) group 4; (d) group 5




图 13 $[-0.006 \text{ nm}, 0.006 \text{ nm}]$ 范围下的试验结果

Fig. 13 Test results in range of $[-0.006 \text{ nm}, 0.006 \text{ nm}]$

测试集的均方误差分别为 0.0001 和 0.0006, 说明训练集和测试集分别有 99.73% 的数据误差小于 0.0003 nm 和 0.0018 nm。可以看出, 使用缩小波带范围的数据进行网络训练, 可以有效克服系统不稳定性影响。对比 $[-0.015 \text{ nm}, 0.015 \text{ nm}]$ 的结果, 本实验中线心附近的数据受到系统变化的影响较小, 分析其原因, 可能是由于线心附近的数据容易受到光球大尺度变化的影响, 因此在数据预处理的前提下, 这部分数据受系统干扰较少。

4.4 与传统方法效率对比

怀柔全日面矢量磁像仪基于 Windows 系统计算机平台, 通过软件对磁像仪的机械结构进行控制, 移动滤光器的位置拍摄 31 张图像, 拟合图像中心强度和观测位置之间的关系得到谱线轮廓, 进而得到观测波长的位置。在仪器正常工作的情况下, 对不同时间段的 20 组数据进行了统计, 传统方法定标所需的时间为 15~20 min。使用本文提出的网络进行线心定标, 程序运行时间小于 7 s, 相对于传统的方法, 速度提高了

100 多倍。具体定标时间对比如表 2 所示。定标时间的大幅缩短意味着定标效率大大提高,故可在日常观

测中引入一种反馈机制,实时调整观测点的位置,以保证高质量数据的稳定输出。

表 2 传统定标方法和机器学习定标方法时间比较

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

Traditional method			Machine learning method		
Image acquisition time	Spectral line fitting time	Total time	Image acquisition time	Time for obtaining corresponding wavelength	Total time
14-19 min	About 60 s	15-20 min	5 s	2 s	7 s

5 总结和展望

SMAT 在观测波带位置定标时,由于温度变化和机械误差等诸多因素导致波长漂移,进而致使偏振信号测量不准。本文从这一实际问题出发,使用传统定标方案下积累的数据训练网络,提出了一种基于机器学习的波带定标方案。在合理遴选数据的基础上,对数据进行了由于波长位置不同所造成的图像大尺度结构信息提取的预处理,采用 PCA 完成了非常有效的降维。提出了基于 BP 神经网络的 MLP 回归网络机器学习方案,对方案进行了可行性验证、分组实验测试和克服系统变化实验,并与传统方法进行了耗时对比。实验结果显示本方法快速、可靠、有效。

方法验证实验结果中,训练集和测试集分别有 99.73% 的数据误差小于 0.0009 nm 和 0.0015 nm。在实际观测中,定标误差小于 0.002 nm 则可满足定标需求,说明了该方法的有效性。

在实际测试实验中,按观测时间划分训练集和测试集。分组实验的结果表明该方法满足应用需求,但是观测时间远离训练集的测试结果误差较大,并且误差随时间推移而继续逐渐增大。这个结果符合仪器系统由稳定到不稳定变化的实际情况,并且启发我们可以使用该网络对仪器的运行状况进行判断,即:对同一组数据进行定标,判断预测值和标签值的残差大小和变化趋势来分析磁像仪是否稳定运行。

从速度上来看,本文提出的基于机器学习的定标方法比传统的定标方法快 100 多倍,极大地提高了定标效率。

本文对双折射窄带滤光器型磁像仪观测波长点的定标问题展开研究,以机器学习的方法为解决怀柔全日面矢量磁像仪观测点定标问题提供了一种可行的方案。在未来的应用中,可考虑通过该方案在滤光器波带调节中引入一种实时闭环反馈机制,例如应用到多通道二维实时光谱仪中^[17],以支持滤光器位置的自动化实时调控,保证高质量观测数据的稳定输出。本文在方法验证实验和分组测试实验中,网络预测结果存在差异,还需要进一步分析原因。此外,该方法还可用于无滤光器透过带扫描轮廓的历史数据,确定全日面的观测波长位置,提高磁场定标系数的精度,从而提高全日面历史矢量磁场观测数据的准确性和可靠性。

参 考 文 献

- [1] 邓元勇, 甘为群, 颜毅华, 等. 太阳磁场探测现状与展望[J]. 红外与激光工程, 2020, 49(11): 20200278.
Deng Y Y, Gan W Q, Yan Y H, et al. Current situation and prospect of solar magnetic field exploration[J]. Infrared and Laser Engineering, 2020, 49(11): 20200278.
- [2] 艾国祥, 胡岳风. 太阳磁场望远镜的工作原理[J]. 天文学报, 1986, 27(2): 173-180.
Ai G X, Hu Y F. On principle of solar magnetic field telescope[J]. Acta Astronomica Sinica, 1986, 27(2): 173-180.
- [3] 林佳本. 高分辨太阳观测方法的研究[D]. 北京: 中国科学院国家天文台, 2009: 15-16.
Lin J B. Study on high-resolution solar observation method[D]. Beijing: National Astronomical Observatories, Chinese Academy of Sciences, 2009: 15-16.
- [4] Zhang H Q, Wang D G, Deng Y Y, et al. Solar magnetism and the activity telescope at HSOS[J]. Chinese Journal of Astronomy and Astrophysics, 2007, 7(2): 281-288.
- [5] Yang X, Zhang H Q, Gao Y, et al. A statistical study on photospheric magnetic nonpotentiality of active regions and its relationship with flares during solar cycles 22-23[J]. Solar Physics, 2012, 280(1): 165-181.
- [6] Sánchez S F. Techniques for reducing fiber-fed and integral-field spectroscopy data: an implementation on R3D[J]. Astronomische Nachrichten, 2006, 327(9): 850-861.
- [7] Balona L A. Wavelength calibration of arc spectra using intensity modelling[J]. Monthly Notices of the Royal Astronomical Society, 2010, 409(4): 1601-1605.
- [8] 叶根红, 叶中付, 祝佳. 基于分段拟合的 LAMOST 波长定标方法[J]. 天文学报, 2013, 54(5): 478-488.
Ye G H, Ye Z F, Zhu J. A new wavelength calibration method for LAMOST based on piecewise fitting[J]. Acta Astronomica Sinica, 2013, 54(5): 478-488.
- [9] 玄伟佳, 王东光, 邓元勇, 等. 双折射滤光器的误差分析与性能优化[J]. 光学精密工程, 2010, 18(1): 52-59.
Xuan W J, Wang D G, Deng Y Y, et al. Error analysis and performance optimization of birefringent filter[J]. Optics and Precision Engineering, 2010, 18(1): 52-59.
- [10] 艾国祥, 李威, 张洪起. Fe I λ 5324.19 Å 在太阳磁场中的形成和太阳磁场望远镜的理论定标[J]. 天文学报, 1982, 23(1): 39-48.
Ai G X, Li W, Zhang H Q. Fe I λ 5324.19 Å line forms in the solar magnetic field and the theoretical calibration of the solar magnetic field telescope[J]. Acta Astronomica Sinica, 1982, 23(1): 39-48.
- [11] Gurtovenko E A, Fedorchenko G L, Kondrashova N N. The empirical determination of damping constants in the solar photosphere[J]. Solar Physics, 1982, 77(1): 291-297.
- [12] 白先勇, 邓元勇, 王怡然, 等. 利用太阳自转提取全日面太阳望远镜的平场和偏振本底[J]. 科学通报, 2018, 63(3): 301-310.
Bai X Y, Deng Y Y, Wang Y R, et al. The measurement of flat fields and polarization offset from the routine observation data of a solar rotation[J]. Chinese Science Bulletin, 2018, 63(3): 301-310.
- [13] Mitchell T M. Machine learning[M]. New York: McGraw-Hill,

- 1997.
- [14] Haykin S. *Neural networks and learning machines*[M]. New York: Prentice Hall, 2009.
- [15] Wilhelm C. *Theorie der linearen wechselstrom schaltungen*[M]. Jägerberg: Akademie, 1954.
- [16] Nair V, Hinton G E. Rectified linear units improve restricted Boltzmann machines[C]//*Proceedings of the 27th International Conference on Machine Learning*, June 21-24, 2010, Haifa, Israel. New York: ACM Press, 2010: 807-814.
- [17] 艾国祥, 胡岳风. 多通道双折射滤光器: I. 原理和视频光谱仪[J]. *中国科学: A 辑*, 1986, 16(8): 889-896.
- Ai G X, Hu Y F. Multichannel birefringent filters I: principle and video spectrometer[J]. *Science in China, Ser A*, 1986, 16(8): 889-896.

Calibration of Observing Wavelength Points of Birefringent Narrow Band Filter-Type Magnetograph Based on Neural Network

Hu Xing^{1,3,4}, Yang Shangbin^{1,3,4*}, Ji Kaifan^{2,4}, Lin Jiaben^{1,3,4}, Deng Yuanyong^{1,3,4},

Bai Xianyong^{1,3,4}, Zhu Xiaoming^{1,3}, Bai Yang^{1,3}, Wang Quan^{1,3,4}

¹*National Astronomical Observatories, Chinese Academy of Sciences, Beijing 100101, China;*

²*Yunnan Observatories, Chinese Academy of Sciences, Kunming 650217, Yunnan, China;*

³*Key Laboratory of Solar Activity, Chinese Academy of Sciences, Beijing 100101, China;*

⁴*University of Chinese Academy of Sciences, Beijing 100049, China*

Abstract

Objective The filter-type magnetograph is one of the main devices for measuring the solar vector magnetic field. SMAT in Huairou, a solar magnetograph, is initially used for conventional observation in China. It obtains polarization information at a fixed temperature and wavelength point, and then acquires the solar vector magnetic field through the calibration process. Due to the changeable factors such as temperature variation and mechanical errors (e.g., tooth gap), the wavelength points observed by the filter would be altered, which weakens or removes the polarization signal. It would finally affect the accuracy of solar vector magnetic field measurement. The current method of wavelength point calibration takes more time, less data and lower temporal resolution by scanning the spectral line profile and locating wavelength points. In addition, the frequent mechanical rotation lowers the lifetime of filter, which further impedes the acquisition of stable and high-quality data. Last but not least, the current method could not form a real-time and closed-loop system to distinguish and control the wavelength points. In view of this, based on the analysis of the data characteristic of SMAT, we summarize a new data pre-processing way, employ the supervised learning of machine learning and then propose a neural-network-based observation scheme of wavelength point calibration. This scheme has established the relationship between a single frame image and the corresponding wavelength point, which shortens the time of locating the position of wavelength point by a single frame image.

Methods The present study uses the spectral line scan data from SMAT, which are 31 monochromatic images obtained by moving the filter from the blue to the red side of the spectral line, subject to the observation conditions. We first analyze the data characteristics. It is found that the Doppler velocity generated by the rotation of the Sun from west to east causes the image to exhibit a large scale uneven distribution of grayscale (brighter on one side and darker on the other). Therefore, when the filter gradually takes images from the blue side to the red side of the spectrum at different wavelength points, the image gradually changes from bright left and dark right to dark left and bright right with the shooting position (Fig. 2). Then, the data are pre-processed: selecting the data that can be fitted with a smooth spectral profile, and performing P -angle correction, edge dimming removal, and normalization on these data. Next, the information outside the solar circle is removed by polar coordinate transformation, and the image size is also decreased. Then, principal component analysis (PCA) is used to reduce the dimensionality of the data, so as to eliminate the interference of small signals and avoid problems caused by high-dimensional features. Based on this, a regression multilayer perceptron (MLP) network based on back propagation (BP) algorithm is proposed. As for the neural network, we took 70% of the data as the training set and 30% as the test set, and carried out the method validation experiment, grouping test experiment, and experiment to overcome system change, respectively. Finally, we propose the general flow of the observing wavelength point calibration algorithm and select data of different time periods to compare the traditional method and the present method in time consumption, and the results show that the method can greatly save the calibration time.

Results and Discussions The results of the method validation experiment show that the mean square errors (MSEs) of the training set and the test set are 0.0003 and 0.0005 (Fig. 10), indicating that 99.73% of the data have the error of less than 0.0009 nm and 0.0015 nm, respectively. In the grouping test experiment, to ensure that the data of the experimental set were observed under a relatively stable system, all data were divided into five experimental sets according to the maintenance records. The MSEs of the training set and the test set are 0.0002 and 0.0027 [Figs. 11(a) and 11(b)], and the test set that is close to the training set in time has a small error in the prediction results [Fig. 11(c)], which illustrates the effectiveness of the method. The gradual increase in error in the

test set far from the training set in time is consistent with the actual change of the system from stable to unstable. The experimental results of the other groups are also consistent with this situation (Fig. 12). To overcome the systematic variation in reality, we narrowed the band range and the standard deviation of the errors in the training and test sets were 0.0001 and 0.0006, respectively, indicating that 99.73% of the data had the error of less than 0.0003 nm and 0.0018 nm (Fig. 13). This result indicates that using data with a smaller band range for training the network can effectively overcome the effect of system instability. In terms of time consumption, the time required for calibration by the traditional method is 15–20 min, while that of the proposed method is less than 7 s, showing a 100 times improvement of the proposed method in calibration speed (Table 2).

Conclusions In this paper, we investigate the calibration of the observing wavelength points of a birefringent narrow band filter-type magnetograph. Firstly, an effective pre-processing scheme of data is proposed based on the reasonable analysis of image data. And then, the BP-based MLP regression network calibration scheme is put forward. Afterwards, this scheme is tested by feasibility verification, grouping test experiment and the experiment to overcome system change. In addition, the scheme is compared with traditional methods in efficiency. At last, the experimental results show that this scheme is more than 100 times faster with reliable and effective data than the traditional method, so it can be regarded as a more efficient method for the calibration of observing wavelength points. Meanwhile, the regression network can be used to judge the operating condition of the instrument, namely, calibrating the same set of data with the network can give the information whether the magnetometer is stably operated or not by the residuals and variation trend of the predicted value and tag value. This method can effectively reduce the shortening of working life of the filter due to the frequent motor rotation during calibration. It can also increase the efficiency and stability of the observation on terrestrial and space solar magnetic field measurements. In the future application, this scheme could support the automatic real-time regulation of the filter position by introducing a real-time closed-loop feedback mechanism in the filter band adjustment, which could ensure the stable and high-quality output of observation data.

Key words measurement; filter-type magnetograph; wavelength point calibration; pre-processing; machine learning