

电离层影响的太阳射电图像位置校正方法

戴昊鸣^{1,2} 邓丽¹

1 中国科学院国家空间科学中心 北京 100190

2 中国科学院大学 北京 100190

摘要 电离层的影响是低频射电天文数据处理过程中面临的主要挑战之一。由于电离层对射电信号产生的吸收、散射、法拉第旋转等影响，会使得地面望远镜获得的观测图像中目标源的位置发生偏移，低频段影响尤其显著。本文首先设计了一个基于 AE 模型的全连接网络，根据电离层影响的严重性，将望远镜观测图像分为好图和坏图。进而，开发了一种基于无监督学习的太阳中心位置识别、跟踪和校正算法。通过目标跟踪与校正网络，结合多次迭代验证模型，实现对受电离层影响发生目标源位置偏移的视频图像，进行位置校正。以 LOFAR 观测的太阳图像数据（105 个视频，23,292 张图像；频率范围 19.9~78.5 MHz）为例进行了实验，实验结果表明算法能够有效纠正位置偏差，平均在 7.17 次迭代内收敛，处理速度为 6.18 帧每秒（fps）。

关键词 电离层影响、太阳射电图像、位置校正、无监督跟踪网络

中图分类号 P352

Position Correction Method for Solar Radio Images under Ionospheric Influence

Haoming Dai^{1,2} Li Deng¹

1 National Space Science Center, CAS.

2 University of Chinese Academy of Sciences

Abstract The ionospheric influence is one of the major challenges in low-frequency radio astronomy data processing. Effects such as absorption, scattering, and Faraday rotation caused by the ionosphere can lead to positional shifts of target sources in images obtained by ground-based telescopes, with the impact being particularly significant at low frequencies. This paper first designs a fully connected network based on an Autoencoder (AE) model to classify telescope observation images into "good" and "bad" categories. Subsequently, an

* 基金项目：正式的名称类型（编号）

投稿日期：

E-mail:

unsupervised learning-based algorithm for solar position identification, tracking, and correction is developed. Through a target tracking and correction network combined with an iterative validation model, this algorithm performs position correction on video images where the target source position is shifted due to ionospheric effects. Experiments conducted on LOFAR solar image sequences (105 videos, 23,292 images; frequency range 19.9~78.5 MHz) demonstrate that the proposed algorithm effectively corrects ionospheric positional deviations. It converges within an average of 7.17 iterations at a processing speed of 6.18 frames per second (fps).

Key words Ionospheric effects, Solar radio images, position correction, Unsupervised tracking neural network

0 引言

电离层的影响是低频射电天文数据处理过程中面临的主要挑战之一^[1]。电离层是地球高层大气的电离部分，大约在距地面 50 ~ 1000 km 的高度。这些电子会对经过电离层的射电信号产生吸收、散射、法拉第旋转等影响，从而引起综合孔径望远镜可见度数据的相位变化，最终在成图的过程中引起源的位置偏移^[2]。为了避免干扰，有一些望远镜通过特殊选址来规避问题^[3,4]。电离层影响的校正算法也是研究的热点，文章^[5]提出了一种在天文观测中校正电离层影响的算法。

在太阳爆发期间，TEC 的变化不仅取决于太阳辐射的强度，还受到太阳爆发在太阳盘面上的位置、太阳天顶角、季节和太阳爆发发生时的当地时间等因素的影响。尽管当前对于电离层的扰动已经有建模方法，但是由于难以准确获得当时当地的电离层信息，仅能作为模型参考。

20MHz ~ 80MHz 的低频太阳观测是射电天文观测中的热点也是难点^[6,7]。在低频段由于受到电离层的影响，太阳射电图像中心位置会发生偏移；同时受望远镜阵列点源响应影响，太阳在图像中不是一个理想的圆，图像中太阳的大小难以明确界定。不同测量方法给出了不同的定义，导致尺寸测量结果各异^[8]。确定太阳视中心的常用的统计学方法有：半功率法^[9]、高斯拟合法^[10,11]、背景阈值法^[12]等。

本文针对低频太阳射电图像中的电离层影响，提出了一套结合图像分类与无监督跟踪的校正方法。本文使用的低频阵列（Low Frequency Array; LOFAR）数据集^[13,14]中，包含由于电离层扰动带来的图像。根据影响程度将图像划分为两类。一类是质量低无法正常使用的图像（后文简称“坏图”）和影响较小仍可开展科学分析的图像（后文简称“好图”）。本文首先设计了一个基于自编解码器的网络用于分类，区分出好图和坏图；然后针对筛选出的好图，开发了一种基于无监督学习的太阳位置识别、跟踪和校正算法，校正太阳的中心位置，回到图像中心。

1 电离层影响的太阳射电图像预分类

1.1 电离层影响及图像特征分析

选取 LOFAR 数据集，观测频率范围为 19.9–78.5 MHz，数据集中的图像均受到电离层影响。根据图像形态大致分为 4 类，如图 1 所示。（1）图像内全是噪声，无有效信息。（2）图像受影响导致变形，能观测到爆发和噪声，但不能有效定位。（3）图像受影响有较大噪声，但是依然可以有效定位太阳。（4）受影响小的高质量图像，既可以观测到太阳的轮廓，也可以看到爆发的位置。在实际工作中，通过设计分类算法，有效排除前两种图像，保留后两种图像开展研究。




图 1 现有 LOFAR 数据集中的典型图片

Fig. 1 Typical Image Examples in the LOFAR Dataset

1.2 基于 AE 方法的图像分类网络

分类网络设计包括两个部分：用于降维的自编码器（AutoEncoder; AE）和用于分类的全连接网络。输入图像像素为 512×512 ，为避免分类任务过拟合，先对图像进行降维，然后再进行分类。图像 I 在输入前先进行一次正则化得到 I_{reg} 。正则化方法见公式(1)，其中 μ_I , σ_I 是 I 的均值和标准差。

$$I_{reg} = \frac{I - \mu_I}{\sigma_I} \quad (1)$$

网络结构如图 2。AE 模型编码器输入为 $512 \times 512 \times 1$ 的正则化图像，每层采用卷积核为 3×3 、滑动步长为 2 的卷积神经网络，最后展平至 128 维的编码向量。AE 模型解码器选取卷积核为 3×3 、滑动步长为 2 的逆卷积神经网络，最终输出 $512 \times 512 \times 1$ 的解码结果。全连接层使用编码器的 128 维向量作为输入进行分类，输出最终的分类结果。




图 2 用于综合孔径望远镜成像结果的 AE 分类网络

Fig. 2 Architecture of the AE-based Classification Network for Synthesized Aperture Telescope Imaging Results.

网络的损失函数由两部分组成：AE 模块的输入与输出之间的均方差损失 $AE Loss$ 和分类器预测与真实标签之间的交叉熵损失 $CLS Loss$ 。损失函数计算见公式(2)，其中 α, β 为损失函数的权重系数。

$$Loss = \alpha AE loss + \beta CLS loss \quad (2)$$

$$AE Loss = Mse(input, output) \quad (3)$$

$$CLS Loss = CrossEntropyLoss(Classification, LabelGT) \quad (4)$$

同时，为避免分类损失过拟合，本文设计了动态权重调整机制。在前期热身阶段依靠分类损失快速训练，热身阶段后依靠自编码器损失进行结构的深度学习以应对更复杂的情况。损失函数动态调整的伪代码如下：

```

FOR Epoch in range(0,maxEpoch)
  IF Epoch <= Warmup:
    Process = Epoch
    Alpha = 0.1 + Process*0.4
    Beta = 1.0 - Process*0.5
  ELSE
    Process = Epoch - Warmup
    Alpha = 0.5 + Process*0.5
    Beta = 0.5 - Process*0.4
  END IF
END FOR

```

在实验时测试了三组参数：1) 无 Warmup, maxEpoch=10; 2) Warmup=3, maxEpoch=10; 3) Warmup=5, maxEpoch=20。比较三组实验中训练集损失和验证集损失的差值，最终选择差值最小的 Warmup=3, maxEpoch=10 作为训练的实际参数。

2 射电图像的太阳位置校正

为校正电离层影响带来的太阳位置偏移，本文设计了一个名为 swUDT 的跟踪与校正网络。训练阶段，该网络通过前向和反向跟踪相结合的方式实现无监督训练。跟踪阶段，网络使用训练好的前向跟踪流程跟踪太阳位置。由于数据集是连续观测的图像序列，网络可通过在线更新权重矩阵的方式，充分利用连续运动的信息，实现目标高效跟踪。在一次定位跟踪完成后，将太阳位置平移至视场中心（FOV），再次应用前向跟踪方法进行多次迭代，直至收敛。网络工作流程如图 3 所示。




图 3 swUDT 训练和跟踪流程图

Fig. 3 Flowchart of swUDT Training and Tracking

2.1 网络训练阶段

本文提出的 swUDT(Space Weather Unsupervised Deep Tracker)算法基于 UDT 网络^[15]，进行训练。首先，使用 CNN 网络提取特征，对一个已有初始标签的模板帧，使用前向跟踪（Forward）网络预测搜索帧的太阳位置。然后，使用这个位置作为伪标签，结合搜索帧，使用反向跟踪（Backward）算法重新预测模板帧的太阳位置。最后，网络通过比较两次位置预测的差异，计算损失函数并训练网络。如图 4 所示。

2.1.1 跟踪与校正网络设计




图 4 两帧(a)和多帧(b)的 swUDT 示意图。

Fig. 4 Schematic Diagram of swUDT for 2 Frame(a) and multi-Frame(b)

在前向（反向）跟踪中，算法通过特征图和伪标签（或预测标签）计算相关矩阵。然后使用相关矩阵和下一帧（上一帧）进行相关计算，得到响应图。响应图中的最大值即为新的预测标签。下面将介绍前向跟踪和反向跟踪过程的具体计算过程。

（1）前向跟踪

前向跟踪中先用伪标签和模板帧计算出太阳的相关矩阵，然后将相关矩阵与搜索帧再进行相关计算，提取搜索帧中的太阳位置，具体计算公式如下。记 $\mathbf{T}$ 是模板帧，目标相关矩阵 $\mathbf{W}_T$ 计算如下

$$\mathbf{W}_T = \mathcal{F}^{-1} \left(\frac{\mathcal{F}(\varphi_\theta(\mathbf{T})) \odot \mathcal{F}^*(\mathbf{Y}_T)}{\mathcal{F}^*(\varphi_\theta(\mathbf{T})) \odot \mathcal{F}(\varphi_\theta(\mathbf{T})) + \lambda} \right) \quad (5)$$

其中 $\varphi_\theta(\cdot)$ 是参数为 θ 的 CNN 网络， $\mathbf{Y}_T$ 是帧 $\mathbf{T}$ 的初始标签， λ 是正则化参数， $\mathcal{F}$ 表示傅里叶变换， $\mathcal{F}^{-1}$ 是傅里叶逆变换， $\odot$ 表示逐元素乘法， $\star$ 代表共轭转置。虽然这里需要一个初始标签，但是实验表明算法中的初始标签不必严格标记，使用视场中心即可。在 $\mathbf{W}_T$ 计算后，对于搜索帧 $\mathbf{S}$ 的响应矩阵 $\mathbf{R}_S$ 如下计算：

$$\mathbf{R}_S = \mathcal{F}^{-1} \left(\mathcal{F}^*(\mathbf{W}_T) \odot \mathcal{F}(\varphi_\theta(\mathbf{S})) \right) \quad (6)$$

如果有搜索图像块 $\mathbf{S}$ 的真实高斯标签，可以通过计算 $\mathbf{R}_S$ 与真实标签之间的 MSE Loss 来训练网络 $\varphi_\theta(\cdot)$ 。不同于有监督框架，无需任何标签，通过反向跟踪来训练网络。

（2）反向跟踪

反向跟踪将前向跟踪中的模板帧和搜索帧位置对调，将 $\mathbf{R}_S$ 中最大值点 $\mathbf{Y}_S$ 作为新的伪标签，得到模板帧 $\mathbf{T}$ 的响应矩阵 $\mathbf{R}_T$ 。

$$\mathbf{W}_S = \mathcal{F}^{-1} \left(\frac{\mathcal{F}(\varphi_\theta(\mathbf{S})) \odot \mathcal{F}^*(\mathbf{Y}_S)}{\mathcal{F}^*(\varphi_\theta(\mathbf{S})) \odot \mathcal{F}(\varphi_\theta(\mathbf{S})) + \lambda} \right) \quad (7)$$

$$\mathbf{R}_T = \mathcal{F}^{-1}(\mathcal{F}^*(\mathbf{W}_S) \odot \mathcal{F}(\varphi_\theta(\mathbf{T}))) \quad (8)$$

注意，算法在前向和反向两步跟踪中的 CNN 网络参数 θ 是相同的。

2.1.2 两帧和多帧损失函数

算法可以通过两帧或者多帧计算损失函数，相较于两帧模型，多帧模型会更有优势。两帧模式如图 4 (a) 所示，多帧模型如图 4 (b) 所示。

(1) 两帧模型

在完成前向和反向跟踪后，算法得到响应图 $\mathbf{R}_T$ 。理想情况下， $\mathbf{R}_T$ 应是一个以初始目标位置为中心的高斯标签。算法目标是 $\mathbf{R}_T$ 应与最初给定的标签 $\mathbf{Y}_T$ 尽可能相似。因此，可以通过最小化如下重构误差来以无监督方式训练表示网络 $\varphi_\theta(\cdot)$ ，损失函数定义为 $\mathbf{R}_T$ 和 $\mathbf{Y}_T$ 的均方差 (MSE) 损失。

(2) 多帧模型

相较于两帧模型，多帧模型即使前向跟踪结果不好，反向跟踪也可能根据错误模型得到一个接近原始标签的位置，使得模型效果差但误差小。多帧模型出现学习不足的情况会少于两帧模型。本文选择使用多帧图像训练，更容易获取真实的损失。图 4(b)展示了基于多帧图像的误差累计的学习方法，通过多次前向跟踪和一次反向跟踪累加跟踪误差，使得模型更容易发现帧中间的差异，引导模型训练。本文最终选取多帧组合模型损失函数，综合了两帧模型的短视特点和多帧模型的累计误差能力。

模型训练过程中，太阳是否运动影响训练的权重。为了更好地跟踪太阳位置，训练时需要位移较大的帧赋予高权重。对于应用一个原始帧和两个搜索帧的情况，第 i 个训练数据的权重 A_{motion}^i 由 $\mathbf{R}_{S_1}^i$ 和 $\mathbf{Y}_T^i$ 的二范数距离以及 $\mathbf{R}_{S_2}^i$ 和 $\mathbf{Y}_{S_1}^i$ 的二范数距离计算，这里 S_1, S_2 是搜索帧的编号， T 代表模版帧。

同时，由于存在少量数据是成像失败的图像，这些图像中训练效果很差，应当将其排除。设置参数 A_{drop}^i ，表示将 A_{motion}^i 过大的数据排除。第 i 个实例的权重 A_{norm}^i ，在 A_{motion}^i 过大时为 0，其余情况为归一化后的 A_{motion}^i 。对于 k 个搜索帧的训练过程，第 i 张图对应的损失函数 $\mathcal{L}_k^i$ 计算如下：

$$\mathcal{L}_k^i = \|\mathbf{R}_{(S_k \rightarrow T)}^i - \mathbf{Y}_T^i\|_2^2 \quad (9)$$

其中 $\mathbf{R}_{(S_k \rightarrow T)}^i$ 是从 $S_k \rightarrow T$ 进行反向跟踪得到的响应图。将拥有 1, 2, 3 个搜索帧的损失函数按照权重 A_{norm}^i 加权求和，得到组合损失函数。其中 N 是训练样本数量， M 取 3 表示最多使用 3 个搜索帧。

$$\mathcal{L}_{\text{final}} = \frac{1}{N} \sum_{k=1}^M \sum_{i=1}^N A_{\text{norm}}^i \cdot \mathcal{L}_k^i \quad (10)$$

2.2 网络跟踪阶段

在离线无监督学习完成后，算法在线跟踪时只需按照前向跟踪方式进行跟踪即可得到下一帧的标签。为了适应太阳的连续变化和可能的爆发场景，算法对关联矩阵 $\mathbf{W}$ 进行在线更新，即采用 $\alpha_t \in [0,1]$ 的线性插值系数进行滑动平均操作。关联矩阵的更新可有效抑制信噪比低的帧对太阳位置识别的影响，提升抗干扰能力。

本文将 swUDT 模型多次应用在原始数据图像上进行迭代。即每一轮结束之后，都进行一次位置平移，将模型识别出的太阳中心平移至视场中心。然后将新的图像作为模型的输入，再进行迭代，直至两次迭代前后图像识别位置不在发生显著变化。最后，定量计算迭代收敛

所需的次数和误差用于评估。

3 实例分析

本实验使用 LOFAR 数据集中^①86317 张图像组成的 357 个太阳视频。探测频率范围为 19.9MHz-78.4MHz, 原始图像的分辨率为 512*512 像素, 每像素对应 30 角秒, 积分时间 0.167 秒。

3.1 图像预分类

实验共使用 44720 张 512*512 的图像。其中好图标签 24844 个, 坏图标签 19876 个, 数据集标签为人工分类, 数据集选取基本平衡。训练集选取其中 80%, 即 35776 张图像。测试集选取其中 20%, 即 8944 张图像。将预分类神经网络应用于上述 LOFAR 中的数据集进行训练。然后将训练后的模型应用于测试集上进行测试, 结果见表 1。其训练过程和损失函数变化情况见图 5。

表 1 电离层干扰分类算法结果

Table 1 Results of the Ionospheric Interference Image Classification Algorithm.

数据集	准确率	精确率	回撤率	F1-score
LOFAR	97.28%	97.34%	97.79%	97.56%

表 1 的结果表明, AE 网络可以有效的划分好图和坏图, 准确率、精确率、回撤率都大于 97%附近。




图 5 AE 分类网络训练集和测试集上的损失函数和准确率变化图

Fig. 5 Loss and Accuracy Curves of the AE Classification Network on Training and Test Sets.

图 5 结果表明, 训练过程中 AE 损失和 CLS 损失逐渐下降。虽然分类损失上存在较小的过拟合(图 5 (c)), 但是通过调整损失函数的权重, 总损失函数在测试集和训练集上基本保持一致。方法的准确率约为 97%, 但并未随损失函数减小而提高。

下面我们对分类错误的图像进行分析, 见图 6。其中第一行(a)(b)(c)(d): 标记为好图(1), 网络输出为坏图(0)。第二行(e)(f)(g)(h): 标记为坏图, 网络输出为好图。

^① 数据集来源 https://spaceweather.astron.nl/SolarKSP/data/atdb_process/solar_target_imaging/




图 6 网络分类错误的图像示意图。

Fig. 6 Examples of Misclassified Images by the Network.

上述图像，虽然能初步识别太阳轮廓，但同时伴随噪声和变形。这些个例很难判断是好图还是坏图，属于分类的模糊地带。失败案例代表数据集需要更好的清洗，但算法本身是有效的。

3.2 图像跟踪和校正

通过图片预分类后，将标记为好图的 23292 张图像作为跟踪和校正网络的输入。这些图像来自 LOFAR 望远镜 2013 年 5 月至 8 月期间记录的 105 个观测视频，覆盖了子频带 SB000 至 SB012。每个子频带的带宽为 195.3 kHz，每个子带对应的频率分别为 SB000: 19.9, SB001: 24.8, SB002: 29.7, SB003: 34.6, SB004: 39.5, SB005: 44.3, SB006: 49.2, SB007: 54.1, SB008: 59.0, SB009: 63.9, SB010: 68.7, SB011: 73.6, SB012: 78.5。经实验，105 个视频结果的处理帧率，迭代误差，终止步数统计见表 2。

表 2 实验结果的帧率，迭代误差，终止步数统计表

Table 2 Statistical Table of FPS, Iteration Error, and Termination Step Count for Experimental Results

统计量	帧率 fps	迭代误差 (像素)	终止步数
均值	6.18	1.92	7.17
标准差	1.56	9.99	3.44
中位数	5.8	0.8	7
最小值	3.2	0.3	2
最大值	10.6	103.1	19

本文仅展示视频 L142438_SAP000_SB008 的定位和跟踪结果。该视频于 2013 年 6 月 2 日使用 LOFAR 核心站从 10:00:00.6 至 13:58:59.1 的观测，频率为 59.0 MHz。对该观测应用 swUDT 算法后的结果见图 7 和图 8。




图 7 L142438_SAP000_SB008 的十幅关键帧。

Fig. 7 Results for Ten Key Frames from Video L142438_SAP000_SB008.

图 7 展示了算法结果。其中红圈标记了识别后的太阳位置，折线图表示上一次迭代与本次迭代之间的中心位置差随迭代次数的变化趋势。折线图上的红色虚线作为收敛水平的参考，选取 1 个像素为参考线。实验表明，算法在 4 轮迭代后收敛，为了展示收敛后的状态，算法迭代到第 9 步停止。




图 8 视频 L142438_SAP000_SB008 的逐帧位移(a)、逐帧差异(b)、逐帧 PSNR(c)以及迭代误差(d)。

Fig. 8 Per-frame Analysis of Video L142438_SAP000_SB008: (a) Displacement, (b) Difference, (c) PSNR, (d) Iteration Error.

图 8 是对视频 L142438_SAP000_SB008 的逐帧分析。图 8(a)表示太阳位置和视场中心的偏移距离,可见每帧图像的位移大小;图 8(b)表示最后一次迭代和倒数第二次的差异。视频共 239 帧,有 237 帧差异小于 2 个像素,仅有 2 帧差异大于 2 个像素。图 8(c)为每帧图像的 PSNR。图 8(d)为迭代的收敛过程,其中蓝线表示平均每帧迭代间差异,红色虚线作为收敛水平的参考,选取 1 个像素为参考线。Step=0 位置表示初始平均偏离,算法在 4 次迭代后达到收敛。

图 7 和图 8 呈现的结果证实,尽管存在电离层影响,swUDT 算法通过迭代优化,能够有效地重新识别并跟踪太阳位置,实现收敛。尽管在某些噪声较大的情况下可能存在识别错误,但该方法仍然可以被认为是可行的。

4 结论

本文设计了一个基于 AE 模型的太阳图像分类方法,方法准确率为 97.28%。同时,设计了 swUDT 的无监督学习网络,利用前向和反向结合的方法训练,有效解决电离层影响图像准确标记难的问题;使用在线跟踪方式,充分利用目标移动的连续性特点进行定位,实现算法快速迭代收敛。实验表明,所有实验平均迭代次数为 7.17 次,处理速度为 6.18 帧/秒 (fps)。swUDT 可推广应用到 LOFAR 之外的其他射电望远镜数据。本文研究重点是给受电离层影响发生中心位置偏移的太阳射电图像提供一种位置校正方法,未来将进一步结合电离层理论模型或实测数据,进行量化的影响分析和量化修正。

参考文献

- [1] CHEGE J K, JORDAN C H, LYNCH C, *et al.* Simulations of ionospheric refraction on radio interferometric data[J]. *Publications of the Astronomical Society of Australia*, 2021, **38**: e028. DOI: 10.1017/pasa.2021.22
- [2] PAL S K, DATTA A, MAZUMDER A. Ionospheric effect on the synthetic Epoch of Reionization observations with the SKA1-Low[J]. *Journal of Cosmology and Astroparticle Physics*, 2025, **2025**(2): 58. DOI: 10.1088/1475-7516/2025/02/058
- [3] YANG W J, WANG Z, WANG M Y, *et al.* A novel low-frequency radio astronomical observation array (1 ~ 90 MHz) and its first light[J]. *Research in Astronomy and Astrophysics*, 2023, **23**(12): 125007. DOI: 10.1088/1674-4527/acf6b1
- [4] BALE S D, SLOSAR A. LuSEE Night: the lunar surface electromagnetics experiment[C]//Proceedings of SPIE 13092, Space Telescopes and Instrumentation 2024: Optical, Infrared, and Millimeter Wave. Yokohama: SPIE, 2024: 130922O. DOI: 10.1117/12.3019515
- [5] GROENEVELD C, VAN WEEREN R J, OSINGA E, *et al.* Characterization of the decametre sky at subarcminute resolution[J]. *Nature Astronomy*, 2024, **8**(6): 786-795. DOI: 10.1038/s41550-024-02266-z
- [6] ZHANG P J, OFFRINGA A R, ZUCCA P, *et al.* RFI flagging in solar and space weather low frequency radio observations[J]. *Monthly Notices of the Royal Astronomical Society*, 2023, **521**(1): 630-637. DOI: 10.1093/mnras/stad491
- [7] ZHANG P J, MOROSAN D E, ZUCCA P, *et al.* Imaging spectroscopy of a spectral bump in a type II radio burst[J]. *Astronomy & Astrophysics*, 2024, **684**: L22
- [8] ZHANG P J, ZUCCA P, KOZAREV K, *et al.* Imaging of the quiet sun in the frequency range of 20–80 MHz[J]. *The Astrophysical Journal*, 2022, **932**(1): 17
- [9] AUBIER M, LEBLANC Y, BOISCHOT A. Observations of the quiet sun at decameter wavelengths - effects of scattering on the brightness distribution[J].

Astronomy and Astrophysics, 1971, **12**: 435

[10] MELNIK V N, SHEPELEV V A, POEDTS S, *et al.* Interferometric observations of the quiet sun at 20 and 25 MHz in May 2014[J]. *Solar Physics*, 2018, **293**(6): 97. DOI: 10.1007/s11207-018-1316-3

[11] RAMESH R, NATARAJ H S, KATHIRAVAN C, *et al.* The equatorial background solar corona during solar minimum[J]. *The Astrophysical Journal*, 2006, **648**(1): 707-711. DOI: 10.1086/505677

[12] SHARMA R, OBEROI D. Propagation effects in quiet sun observations at meter wavelengths[J]. *The Astrophysical Journal*, 2020, **903**(2): 126

[13] VAN HAARLEM M P, WISE M W, GUNST A W, *et al.* LOFAR: the low-frequency array[J]. *Astronomy & Astrophysics*, 2013, **556**: A2

[14] VAN DIEPEN G, DIJKEMA T J, OFFRINGA A. DPPP: default pre-processing pipeline[CP/OL]. (2018) [2026-02-01]. <https://ascl.net/1804.003>

[15] WANG N, SONG Y B, MA C, *et al.* Unsupervised deep tracking[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach: IEEE, 2019: 1308-1317

戴昊鸣，男，2021年4月生于北京市海淀区，现为中国科学院大学，国家空间科学中心硕士研究生。主要研究方向为综合孔径望远镜图像处理。

邓丽，女，1981年10月出生于湖北省荆州市，现为中国科学院国家空间科学中心研究员，博士生导师，主要研究方向为分布式系统信息处理、射电探测技术。