将卷积神经网络应用于势场源表面（PFSS）磁图以预测太阳风速度

Rong Lin[1],**Zhekai Luo**[1],**Jiansen He**[1],**Lun Xie**[1],**Chuanpeng Hou**[1],**Shuwei Chen**[2]

[1]北京大学地球与空间科学学院，中国北京，100871 [2]南京大学人工智能学院，中国南京，210023

arXiv:2304.01234v1 [astro-ph.SR] 3 Apr 2023

要点：

- 训练了一种基于卷积神经网络的模型，用于预测地球上游的太阳风速度。
- 该模型使用预测前3天、4天、5天和6天的四幅势场源表面（PFSS）磁图作为输入。
- 该模型在连续测试数据集上的表现为相关系数=0.52，均方根误差为=80.8 km/s。

通讯作者：Jiansen He，jshept@pku.edu.cn

摘要

准确的太阳风速度模型对于空间天气预测、灾害性事件预警以及其他涉及太阳风—磁层相互作用的问题至关重要。本研究基于卷积神经网络（CNN）和势场源表面（PFSS）磁图构建模型，并将太阳风源表面设为 $R_{\rm SS} = 2.5R_{\odot}$，旨在预测日地系统日地拉格朗日1点（L1）处的太阳风速度。模型输入由 $R_{\rm SS}$时刻的四幅势场源表面（PFSS）磁图组成，分别对应目标时刻前7、6、5和4天。为提高模型效率，采用了降采样磁图。我们使用全球振荡网络组（GONG）的光球磁图和势场外推模型，生成源表面处的PFSS磁图。在八折验证训练方案中，该模型对连续测试数据集的预测平均相关系数（CC）为0.52，均方根误差（RMSE）为80.8 km/s，数据的时间分辨率最短可达一小时。该模型还能够预测太阳风高速流，其总体威胁评分为0.39。

通俗摘要

太阳风的动压是太阳活动影响地球空间天气的关键条件。太阳风动压的强度取决于太阳风速度。因此，预测地球上游的太阳风速度是空间天气研究的重要课题之一。太阳日冕磁场的分布是调节太阳风速度的重要因素。在本研究中，我们探究了源表面处外推得到的太阳日冕磁场变化与日地系统日地拉格朗日1点（L1）处太阳风速度变化之间的映射关系。在源表面处，假定开放磁力线沿径向延伸，并与新生的太阳风流方向一致。我们利用全球振荡网络组（GONG）的光球磁图，将日冕磁场外推至源表面。我们基于具有五个隐藏层的卷积神经网络（CNN）构建了预测模型。结果证明，该映射关系可靠，并且在预测太阳风速度开始上升的时间方面具有优势。

1 引言

太阳风是从太阳日冕持续流出的超音速等离子体流，充斥于太阳与包括地球在内的各行星之间的行星际空间，并促成日球层的形成。太阳风携带行星际磁场（IMF），并与地球磁场相互作用，形成地磁层顶，将受激波压缩的太阳风与地球磁层分隔开来。

太阳风具有高度结构化且动态变化的特征。根据径向速度，太阳风通常可分为两类：高速流（HSS）和低速流（LSS）（Schwenn，1983）。高速流的起源被普遍认为是日冕洞（Wilcox & Howard，1968年；Altschuler & Newkirk，1969年；Hollweg，2002年），而低速流则有多种源区（Antiochos 等，2011年；Abbo 等，2016年；Sanchez-Diaz 等，2019年）。太阳风活动会显著影响近地空间。在行星际空间中，高速流会压缩低速流，形成流相互作用区（SIRs）和共转相互作用区（CIRs）（Gosling 等，1978年；Smith & Wolfe，1976年）。一些 CIRs 可持续数个卡林顿自转周，引发反复发生的磁暴，并进而导致辐射带中的电子加速（Miyoshi & Kataoka，2005年；I. Richardson 等，2006年）。在空间天气领域，太阳风状况的变化

是预测地磁活动强度的模型的一项关键输入（Joselyn，1995年；Luo 等，2017年；Sexton 等，2019年）。太阳风作为日冕物质抛射（CMEs）的背景，会通过气动阻力显著调节日冕物质抛射的传播（Gopalswamy 等，2000年；Subramanian 等，2012年）。因此，准确模拟太阳风速度是空间天气领域的一项基础任务。

太阳风模型通常可分为两类：物理模型和经验模型。物理模型利用弹道学、流体动力学（HD）和磁流体动力学（MHD）等机制（Fry 等，2001；Odstrcil，2003；T´oth 等，2005年；Feng 等，2010；M. Owens 等，2020年）。经验模型旨在构建行星际空间中的太阳风参数与太阳观测参数之间的关系，例如 Wang-Sheeley（WS）模型、日冕洞边界距离模型（DCHB）和 Wang-Sheeley Arge（WSA）模型（Wang & Sheeley Jr，1990；Arge & Pizzo，2000；Riley 等，2001；Arge，2003），这些模型在太阳上的主要参数包括距日冕洞边界的角距离、源表面处日冕磁场的膨胀因子等。

近几年来，机器学习（ML）技术，尤其是神经网络（NNs），迅速发展。机器学习的优势恰好满足了构建经验模型的需求，能够发现观测输入与目标输出之间隐含的关系。机器学习已应用于空间天气的多个领域，包括辐射带建模（Smirnov 等人，2020年）、日冕物质抛射到达时间估计（Liu 等人，2018年）以及地磁活动指数预报（Tan 等人，2018年；Siciliano 等人，2021年）。Camporeale（2019年）发表的一篇综合综述展示了机器学习在空间天气领域的进展，并指出了空间天气领域特有的挑战和问题。对于近地太阳风的预测任务，通常以日地系统拉格朗日 L1 点测得的太阳风来代表近地太阳风，目前已有多项成功研究。Yang 等人（2018年）使用具有单个隐藏层的全连接人工神经网络，建立了太阳活动周四个阶段的太阳风速度参数模型，并在随机分布的测试集上取得了总体良好的表现，相关系数为 $= 0.73$ （相关系数的定义将在下文给出），均方根误差为$= 68$公里/秒（均方根误差的定义将在下文给出）。Yang 等人的模型输入包括历史太阳风速度观测值、根据观测到的偏振亮度反演得到的日冕数密度，以及若干由源表面磁场推导出的参数。全球振荡网络组（GONG）的磁图作为势场源表面（PFSS）算法（Altschuler & Newkirk，1969年；Schatten 等人，1969年）的输入，用于生成源表面处的磁图（距太阳~2.5 个太阳半径），这对 WSA 等其他模型也很有帮助。考虑到高速流与日冕洞之间的高度相关性，太阳动力学观测台（SDO）利用大气成像组件（AIA）拍摄的极紫外图像自然成为预测模型的候选输入（Lemen 等人，2011年）；这类模型旨在将图像数据映射到相应的目标。

在机器学习领域，卷积神经网络（CNN）广泛用于处理结构化数据，尤其是图像，以提取有用特征。LeCun（Lecun 等，1998年）最初提出了这一方法，用于完成手写识别任务。此后，许多研究沿用了这一思路。例如，Upendran 等（2020年）将预训练的卷积神经网络与长短期记忆神经网络（Hochreiter 和 Schmidhuber，1997年）相结合，利用 AIA 193 和 211 $^{\circ}$A图像构建预测模型。采用交叉验证方案时，该模型的相关系数为$= 0.55$。我们指出，Yang 等人（2018年）的研究并不完全优于 Upendran 等（2020年）的研究，因为 Yang 等人（2018年）使用了四个模型来拟合太阳活动周的不同阶段，而且这两项研究采用了不同的模型评估方案，即是否使用交叉验证。继 Upendran 等（2020年）之后，Raju 和 Das（2021年）证明，仅使用较简单的卷积神经网络和 AIA 193 $^{\circ}$A图像，也能达到与 Upendran 等（2020年）相当的性能；Brown 等人（2022年）则使用基于注意力的模型提升了性能，使均方根误差降低了 11.1%，预测相关性提高了 17.4%。不过，我们尚未将 PFSS 磁图与卷积神经网络集成。正如上文所述，PFSS 磁图包含丰富的信息，可用于预测太阳风速度。我们预计卷积神经网络能够增强其能力，并帮助建立从日冕磁场到地球上游背景太阳风的直接映射。因此，在本研究中，我们将卷积神经网络与 PFSS 磁图结合，构建一个预测近地太阳风速度的模型。该模型足够简洁，能够捕捉 PFSS 磁图中的必要信息，并强调了源表面磁图对于太阳风预测任务的重要性。

使均方根误差降低了 11.1%，预测相关性提高了 17.4%。不过，我们尚未将 PFSS 磁图与卷积神经网络集成。正如上文所述，PFSS 磁图包含丰富的信息，可用于预测太阳风速度。我们预计卷积神经网络能够增强其能力，并帮助建立从日冕磁场到地球上游背景太阳风的直接映射。因此，在本研究中，我们将卷积神经网络与 PFSS 磁图结合，构建一个预测近地太阳风速度的模型。该模型足够简洁，能够捕捉 PFSS 磁图中的必要信息，并强调了源表面磁图对于太阳风预测任务的重要性。

本文以下部分由 3 节组成：第 2 节介绍我们的数据集和方法。第 3 节展示模型结果并进行分析。第 4 节总结全文并得出结论。

2 数据与方法

我们的模型由 PFSS 和卷积神经网络组成。PFSS模型首先根据 GONG 提供的光球磁图，获取源表面的磁场。随后，以源表面磁场为输入训练卷积神经网络模型，以预测近地太阳风速度，并将预测结果与 OMNI数据对齐比较。

2.1 OMNI太阳风速度数据

在本研究中，我们使用 OMNI数据库提供的太阳风速度数据，其时间分辨率为 1 小时，作为地球附近的上游/背景太阳风速度（Papitashvili & King，2020年）。OMNI数据库由美国国家航空航天局空间物理数据设施（SPDF）支持。该数据库整合了位于日地系统 L1点附近的不同卫星对太阳风等离子体和磁场的观测数据。为更好地表征到达磁层的太阳风状态，数据根据相关参数进行了时间移位，这些参数包括太阳风速度，以及航天器与地球之间沿日心径向的投影位移距离。数据可通过 https://omniweb.gsfc.nasa.gov 获取。

我们使用2006年9月至2020年11月的OMNI逐小时太阳风速度数据。根据I. G. Richardson和Cane（2010）的行星际日冕物质抛射数据库，剔除了与行星际日冕物质抛射穿越事件相对应的太阳风速度数据。

2.2 GONG磁图与势场源表面（PFSS）模型

如上所述，全球振荡网络组（GONG）的光球磁图是太阳风建模中常用的磁图。GONG团队在地球上设立了由六个天文台组成的网络，以全天测量光球磁场。自2006年起，GONG磁图便已开放使用。2006年9月至2012年11月，磁图的时间分辨率为四小时；自2012年11月起，时间分辨率为一小时。GONG提供 $180^\circ \times 360^\circ$ 完整卡林顿经度磁图，适用于PFSS模型。

PFSS模型是一种广泛用于外推全球日冕磁场的物理模型（Altschuler & Newkirk，1969年；Schatten 等人，1969年）。该模型假设太阳表面与源表面之间满足无电流条件，太阳风被认为从这里开始沿径向延伸的开放磁力线流出。模型通过求解拉普拉斯方程，并结合描述磁场径向方向的等势面外边界条件，以及受观测到的光球磁图约束的内边界条件来进行计算。在这项工作中，我们

将源表面的位置设定在距太阳中心 2.5 个太阳半径处，即 $R_{\rm SS}$ =2.5$R_{\odot}$。我们使用一个名为 *pfsspy*的 Python 软件包，该软件包实现了有限差分求解器，用于外推全球日冕磁场（Stansby 等人，2020年）。

2.3 卷积神经网络

模型的输入是通过 PFSS 获得的源表面磁图。考虑到太阳风速度通常为每秒 300 至 700 千米，对应的到达地球时间约为三至六天，因此我们采用距近地测量时刻不同天数的四幅磁图作为输入。它们分别是预测时刻前三、四、五和六天的磁图，即 $B_{\rm SS}$($t-3$天) $B_{\rm SS}$($t-4$天) $B_{\rm SS}$($t-5$ 天) 和 $B_{\rm SS}$($t-6$ 天)。这一设置与 Upendran 等（2020）的设置一致，该设置在其论文发表时取得了最佳性能。Upendran 等（2020）采用每日采样的 AIA 图像和每日观测到的太阳风速度序列来探究映射关系，而我们的研究采用的时间分辨率为一小时。

据我们所知，单幅源表面磁图所包含的信息并非全部都有助于预测黄道面某一位置（例如地球附近）的太阳风速度。在源表面磁图中，远离黄道面的极区部分，以及卡林顿经度远离源表面上地球足迹的区域，与近地太阳风速度的相关性较低，因此我们将其裁去，仅保留每幅磁图中心的 90×180 子磁图，作为卷积神经网络的直接输入。这样一来，输入数据量减少至原来的四分之一，使模型更轻量、效率更高。实验表明，使用完整磁图并不会带来显著差异；为简洁起见，此处不作展示。

卷积神经网络是一种常用于图像分析的人工神经网络。它通过二维卷积从图像数据中提取结构特征。卷积神经网络可以包含多个卷积层，以识别更复杂的结构和相关性。如图 1 所示，我们的卷积神经网络模型包含三个不同的卷积层。每个卷积层之后，我们都会对数据进行批归一化（Ioffe 和 Szegedy，2015），以加快收敛。经过这三层后，数据会通过两个全连接层，最终连接到一个单独的节点。除最后一层使用 Sigmoid 函数 $S(z)$ $= 1/[1+\exp(-z)]$ 外，每层使用的激活函数均为修正线性单元（ReLU），即 $R(z) = \max\{0, z\}$。为提升模型的泛化性能，我们在全连接层中使用 Dropout方法（ Srivastava 等人，2014）。图 2 概述了我们的模型，展示了用于生成输入 PFSS磁图的原始 GONG 数据、卷积神经网络的输入，以及我们使用的子磁图。

2.4 训练与验证方案

为了提高模型的性能，同时保持其泛化能力并防止过拟合，我们采用如下训练与验证方案。

我们采用基于准连续数据段的k折交叉验证方案（Dietterich，1998年；Upendran 等，2020年）。一个准连续数据段由480条连续的太阳风速度测量日志组成。当不剔除任何ICME数据且日志的时间分辨率为一小时（2012年之后）时，该数据段对应20天。此类数据段共120个。之所以进行分段，是因为太阳风速度数据具有很强的时间相关性（ Camporeale，2019年）。逐点随机划分将每次速度测量都视为来自统计总体的独立样本，因此可能导致训练集、验证集和测试集相似，因为在高度相关的时间序列中，短时间内的任意两个样本往往都很相似。

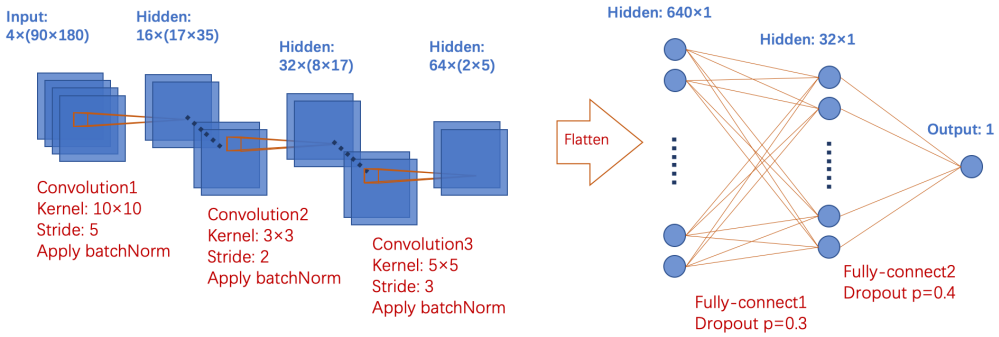

图 1. 卷积神经网络结构。深蓝色图标和橙色图标分别表示数据和数据操作，与数据或操作颜色相同的文字则是相关说明。除最后一层使用 Sigmoid 函数外，各层均使用修正线性单元（ReLU）作为激活函数。

在这种相关时间序列中，这种相似性可能会在采用传统验证方案时带来相当理想的训练结果。然而，如果测试集并非连续数据段，那么测试集上的表现只能反映模型对某个连续数据段中太阳风的预测能力，而该数据段的规模与测试集中连续数据段的一般规模相近。换言之，逐点随机划分往往无法推广到连续预测，因此也无法模拟太阳风速度的变化，这并非我们所希望的。分段后，我们将各段随机分配到八个折中，即在k折交叉验证方案中有 $k = 8$ 。在每个训练周期中，我们将其中一折数据用作验证集，另一折用作测试集，其余数据用作训练集。这样，这些数据集既具有随机性，也具有连续性，适合用于泛化评估和公平评价。

我们采用梯度下降法训练模型。应用于训练数据集的损失函数由均方误差（MSE）和卷积权重的一阶范数组成。该损失项即为 L1 惩罚，用于抑制仅存在于训练数据集中的不必要关系，从而增强泛化能力（Girosi et al., 1995）。另一种有助于提升泛化能力的方法是 Dropout 方法，这是神经网络中常用的方法。我们已在第 2.3 节中介绍模型的具体 Dropout 参数。梯度下降法用于最小化训练集的损失函数。同时，通过比较观测值与预测值计算得出的验证集和测试集的均方误差先减小，随后出现波动。我们保存验证集上均方误差最低的模型，并根据该模型在测试集上的表现评估模型。由于采用了 k 折交叉验证，我们得到了八个优化模型。性能指标为均方根误差（RMSE）和皮尔逊相关系数（CC），其定义如下：

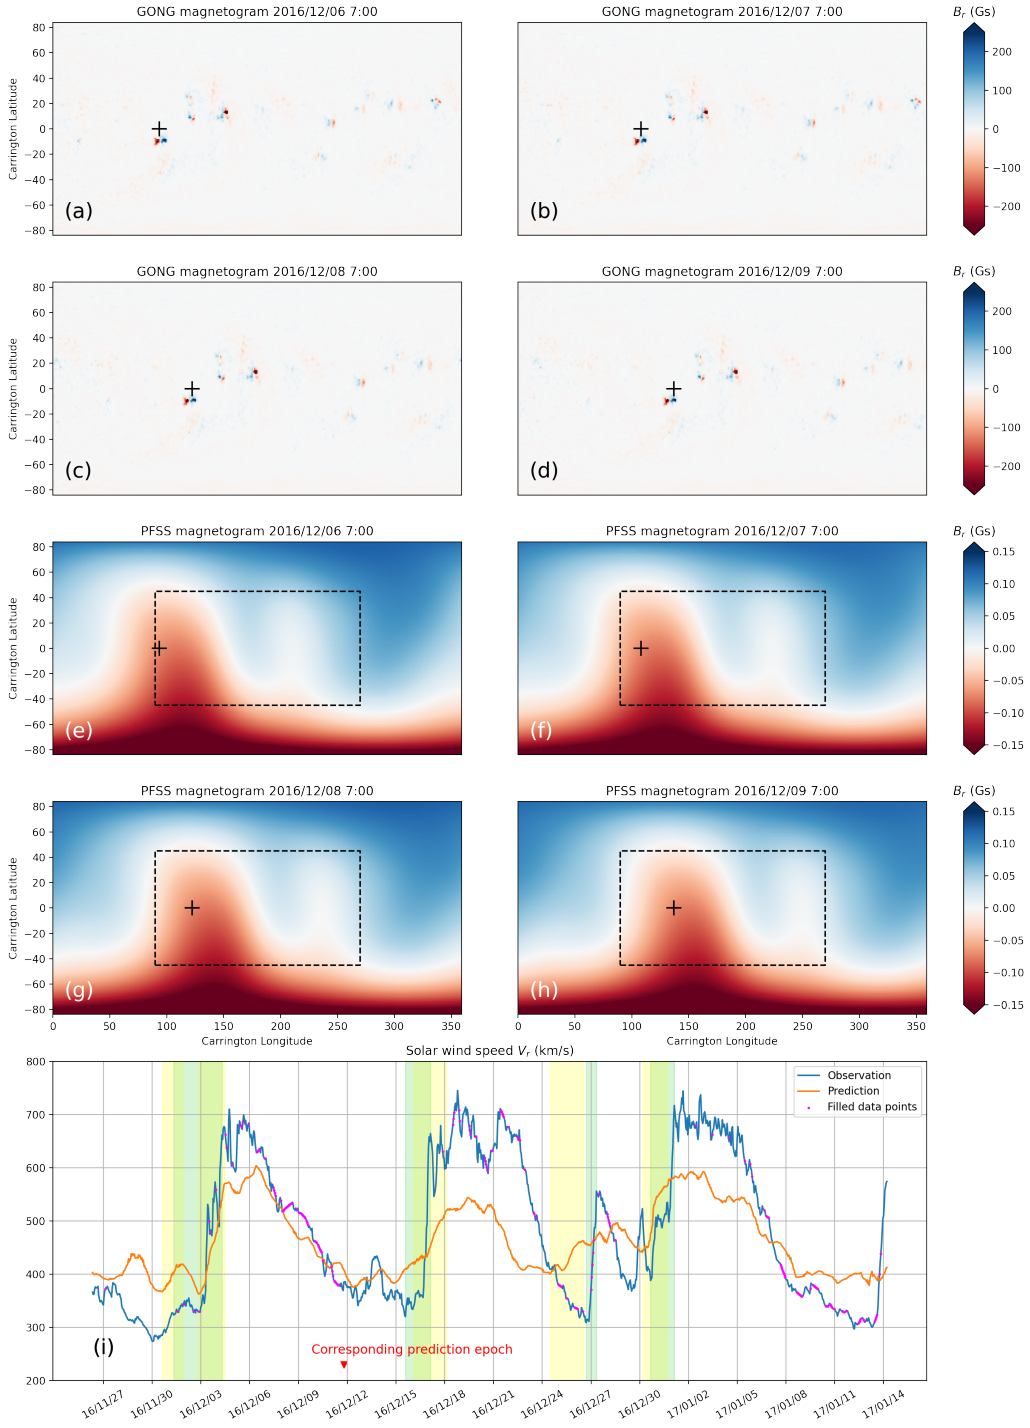

图 2. 模型概述。(a-d)：用于生成 PFSS 磁图的 GONG 磁图。(e-h)：PFSS 磁图，即 B_{SS}（$t-3$ 天）B_{SS}（$t-4$天） B_{SS}（$t-5$ 天）和B_{SS}（$t-6$ 天）。面板 (a-h) 中的黑色十字表示相应时刻地球在卡林顿坐标系中的位置。黑色虚线矩形表示作为卷积神经网络输入的缩减子磁图。(i)：观测和预测太阳风速度的时间序列。红色倒三角表示与 (a-h) 对应的预测时刻 t 。(i) 中横轴标注具体日期的时刻对应于该日协调世界时 12:00。绿色阴影区域表示根据观测到的太阳风诊断出的高速增强（HSE）事件（定义见第 3 节），黄色阴影区域表示根据预测结果诊断出的 HSE 事件。洋红色圆点表示通过线性插值补入观测到的太阳风数据点，以实现

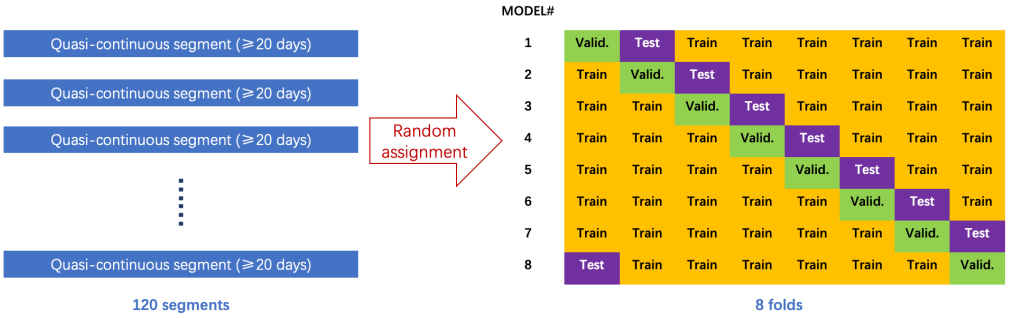

图3. k折交叉验证的设置。首先将数据划分为120个准连续片段，然后随机分配到八折中。训练验证过程重复八次，每次使用不同的折作为训练集、验证集和测试集，从而生成八个优化模型。

$$\mathrm{RMSE}(\boldsymbol{x},\boldsymbol{y}) = \frac{1}{n}\sqrt{\sum_{i=1}^{n}(x_i - y_i)^2}, \tag{1}$$

and,

$$\mathrm{CC}(\boldsymbol{x},\boldsymbol{y}) = \frac{\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x})^2}\sqrt{\sum_{i=1}^{n}(y_i - \bar{y})^2}}, \tag{2}$$

其中， $\boldsymbol{x}$ 和 $\boldsymbol{y}$ 是n维向量， $\bar{x}$ 是 $\boldsymbol{x}$的算术平均值。因此，RMSE($\boldsymbol{v}_{\mathrm{obs}}, \boldsymbol{v}_{\mathrm{model}}$)表示预测的总体偏差，而CC($\boldsymbol{v}_{\mathrm{obs}}, \boldsymbol{v}_{\mathrm{model}}$)表示模型预测变化趋势的能力。

图3展示了k折验证方案示意图。以第7折为例，图4展示了训练集、验证集和测试集中太阳风的分布。

3 结果

八折的平均总体相关系数($\boldsymbol{v}_{\mathrm{obs}}$， $\boldsymbol{v}_{\mathrm{model}}$)为 0.52 ± 0.06，均方根误差($\boldsymbol{v}_{\mathrm{obs}}$， $\boldsymbol{v}_{\mathrm{model}}$)为 80.8 ± 4.8km/s。这一性能优于两种常用基准模型——WSA和27天持续性模型（PS27）（M. J. Owens 等，2013），且与基于 AIA 图像的卷积神经网络模型的性能非常接近，表明PFSS磁图包含较丰富的信息，可用于太阳风速度预报，并可作为集合预报网络的候选模型（Reiss 等，2019）。值得注意的是，我们的模型时间分辨率高于Upendran等（2020）和Raju 和 Das（2021）的模型，其时间分辨率分别为一天和两小时。以第7折为例，其模型性能如图5所示。测试数据集上的比较表明，我们的模型较为保守，不太

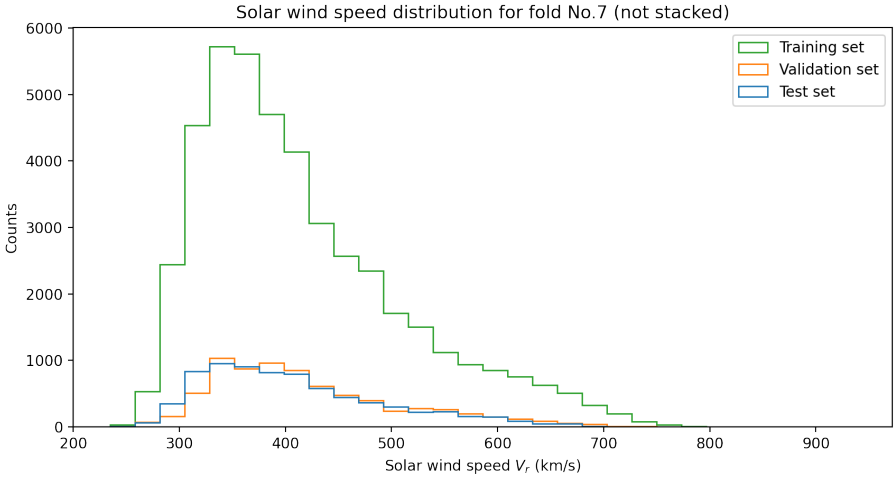

图4. 展示第7折训练集（绿色）、验证集（橙色）和测试集（蓝色）中太阳风分布的直方图。这些直方图未进行堆叠。

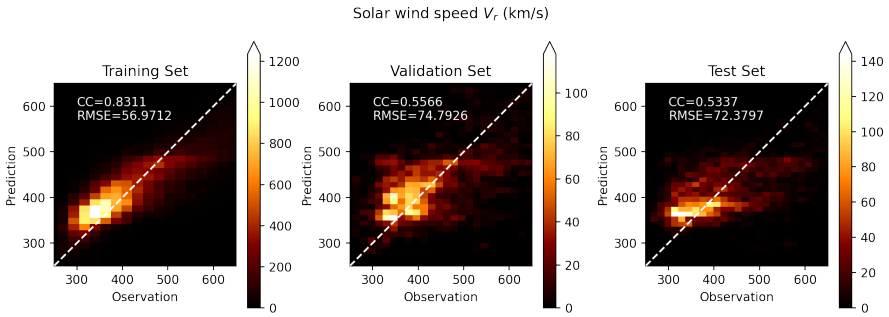

图5. 第7折训练集、验证集和测试数据集中观测值与模型预测值的比较。

容易生成高速流，这可能是由训练数据的速度分布所致（见图4）。在该分布中，速度超过550 km/s和低于300 km/s的尾部样本分别仅占总体的10.7%和4.4%；计算损失函数时，这些样本的贡献较小，因此拟合效果较差。

另一个重要的模型性能指标是基于高速流事件（HSE）的评估。我们采用根据 Jian 等（2015）的标准简化而来的判据来诊断 HSE，该判据与 Raju 和 Das（2021）所用的相同：

1. 找出所有与前一天相比速度差大于 50 km/s 的点。2. 将连续的数据段归为高速增强事件（HSEs）。计算 HSEs 的开始和结束时间，并剔除所有孤立点。3. 如果持续时间小于 0.5 天，则剔除该 HSE。4. 对于识别出的 HSEs，在开始时间前两天内找出最低速度，并将其标记为 $V_{\min}$。

5. 从 HSE 的开始时间到 HSE 结束后一天内，找出最大速度，并将其标记为 $V_{\max}$。6. 找出最后一次达到 $V_{\min}$ 和第一次达到 $V_{\max}$ 的时间。此持续时间标记为流相互作用区（SIRs）。7. 重新分组 SIRs，并再次找出每个 SIR 的 $V_{\min}$ 和 $V_{\max}$。剔除冗余的 SIRs。8. 若 SIRs 的 $V_{\min}$ 大于 500 km/s 且 $V_{\max}$ 小于 400 km/s，或 $V_{\max}$ 与 $V_{\min}$ 之差小于 100 km/s，则剔除这些 SIRs。

在观测时间序列中识别出所有 HSEs 后，我们采用与上述略有不同的标准，在预测时间序列中识别 HSEs。由于该模型倾向于生成较为保守的预测结果，我们将步骤 1 中的速度差阈值改为 35 km/s，并将步骤 8 修改为："与 $V_{\max}$ 和 $V_{\min}$ 之间的差值小于 50 km/s 的 SIRs 将被舍弃"。

观测速度序列中的 HSEs 与预测速度序列中的 HSEs 的匹配状态可分为三类：

1. 命中（Hit）。当预测 SIR 的开始时间与实际 SIR 的开始时间相差不超过两天时，我们将其标记为命中。2. 漏报（Miss）。当某个实际 SIR 没有对应的命中时，我们将其标记为漏报。3. 虚警（False alarm）。当不存在能够与某个预测 SIR 匹配命中的实际 SIR 时，我们将其标记为虚警。

这里，我们在图2(i)和图6(i)中展示了两个片段的预测结果及其基于事件的性能。这两个片段分别来自第0折和第4折的测试集，其性能均优于平均水平。在这两幅子图中，我们欣喜地看到，所有高速增强事件均被命中，尽管预测仍然偏保守，且模型总是低估峰值速度。我们发现，模型预测的高速增强事件中，流相互作用区的起始时间通常早于实际起始时间，但大多数起始时间对的差值小于一天。其他片段和预测结果（此处未展示）也存在这一情况。流相互作用区的预测持续时间通常与实际持续时间相近，其他片段亦是如此，这可能是两个因素相互平衡的结果，即模型预测的变化相对平缓，以及峰值速度被低估。

有一些参数可根据命中、漏报和虚警的数量，量化基于事件的性能，并对整个数据集进行统计评估。这些参数分别为偏差、阳性预测值（PPV）、虚警率（FAR）和威胁评分（TS），其定义如下

$$\text{Bias} = \frac{\text{Hits} + \text{Misses}}{\text{Hists} + \text{False alarms}}, \tag{3}$$

$$\text{PPV} = \frac{\text{Hits}}{\text{Hists} + \text{False alarms}}, \tag{4}$$

$$\text{FAR} = \frac{\text{False alarms}}{\text{Hists} + \text{False alarms}} = 1 - \text{PPV}, \tag{5}$$

and

$$\text{TS} = \frac{\text{Hits}}{\text{Hists} + \text{Misses} + \text{False alarms}}. \tag{6}$$

优秀的模型应具有接近 1.0 的低偏差、接近 100% 的高阳性预测值，以及接近 100% 的高威胁评分。我们的模型的偏差为=1.52，阳性预测值为=71%，虚警率为=29%，威胁评分为=0.39。其威胁评分介于 Upendran 等（2020）模型（威胁评分为=0.35）与 Raju与Das（2021）模型（威胁评分为=0.46）的表现之间，而偏差优于 Raju 的模型

（偏差为=2.15），这表明我们的模型总体上具有相当的高速流预报潜力。然而，该模型的阳性预测值距离 100% 仍有差距，因此在实际业务中必须谨慎对待其预测，并结合日冕保持区回归等其他方法（Bu 等人，2019年）。

4 总结与讨论

通过构建卷积神经网络模型，我们证明，源表面磁场与近地太阳风速度之间的映射关系有助于预测任务。我们根据光球磁场测量并采用势场假设计算源表面磁图，并使用卷积神经网络构建神经网络架构。我们选取一系列连续四幅降采样后的源表面磁图作为输入。数据经过卷积层和全连接层，以提取并汇集磁图中的结构信息，这些信息与近地太阳风速度的信息相关。模型的表现令人满意。

我们的模型具有以下优点：

1. 模型使用整个太阳活动周的观测数据进行训练，因此仅凭这个训练好的模型，就可以在太阳活动周的多个阶段，根据源表面磁场预测太阳风速度。在具体应用中，也可以像 Yang 等人（2018年）的研究那样，针对一个太阳活动周的不同阶段开发多个模型。我们预计这种多模型方法会取得更好的效果。2. 该模型可以处理时间分辨率为一小时的数据，并能够预测通常备受关注的高速增强事件的起始时间和持续时间。3. 这些模型使用源表面的降采样子磁图；一旦获得更多非椭圆观测数据，便有望开发用于预测高纬度太阳风速度的非椭圆模型。

我们的模型的主要局限在于受数据分布影响而表现得较为保守，但迄今为止，这一领域尚未出现突破。除这种保守性外，预报偏差可能还有其他成因。首先，GONG 观测和 GONG 日面磁图存在误差。GONG 使用合成算法估算太阳背面的磁场，这可能会引入误差。其次，势场日冕这一假设并不完善，恒定的 R_{SS} 为 2.5 个太阳半径可能并不符合实际（Schulz，1997年）。最后，简单的卷积神经网络架构可能不如更先进的神经网络设置强大，例如能够更好地提取图像信息的“Transformer”。我们期待未来将我们的思路与更先进的机器学习技术相结合。采用不同模型组成、并纳入我们模型的集成方法也是一个发展方向。我们非常欣喜地看到，过去对太阳风建模贡献良多的源表面磁场，能够在空间天气预报的人工智能新时代找到自己的位置。

5 开放研究

数据可用性：原始数据由美国国家航空航天局空间物理数据设施（SPDF）的 OMNI数据库以及全球振荡网络组（GONG）的数据库提供。如需分析后的数据，请联系作者。

致谢

作者感谢 OMNI 和 GONG 团队提供数据，并感谢 pfsspy 团队开发该程序。北京大学的相关工作

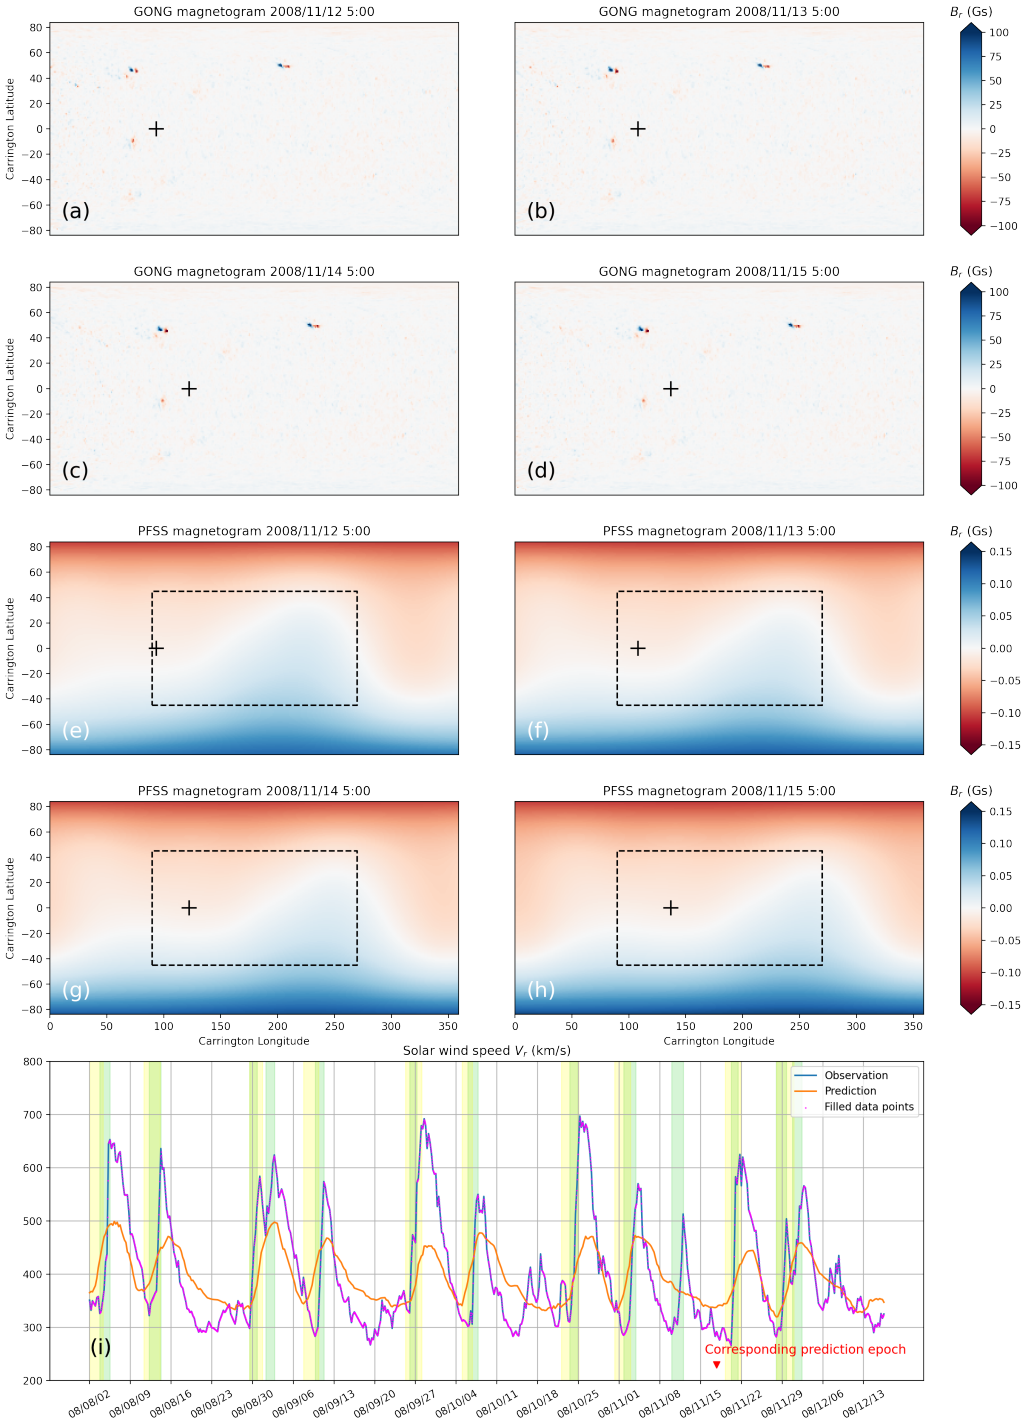

图 6. 与图 2 类似的图，用于展示 2008年8月至12月 数据的模型输入和输出，以供比较。需要指出的是，2012年11月之前，GONG 数据的时间分辨率为 4 小时，因此面板 (i) 中的片段覆盖了数个月，且日志数量与图 2(i) 中的片段相同，同时还有更多数据点需要填补。

本研究得到中国国家航天局（D050106）、中国国家重点研发计划（2021YFA0718600 和 2022YFF0503800）以及国家自然科学基金委员会（42241118、42174194、42150105 和 42204166）的资助。

本研究使用了国家太阳天文台综合同步观测计划的数据。该计划由天文学研究型大学协会运营，并依据与美国国家科学基金会签订的合作协议开展工作，同时获得美国国家海洋和大气管理局、美国国家航空航天局及美国空军的额外资金支持。全球振荡网络的仪器由大熊湖太阳天文台、高空天文台、利尔蒙斯太阳天文台、乌代布尔太阳天文台、加那利群岛天体物理研究所和托洛洛山美洲际天文台承载。

参考文献

Abbo, L., Ofman, L., Antiochos, S., Hansteen, V., Harra, L., Ko, Y.-K., . . . 等(2016年)。慢太阳风：观测与建模。《空间科学评论》,*201*, 55–108。Altschuler, M. D., & Newkirk, G. (1969年, 9月)。磁场与太阳日冕的结构。《太阳物理学》, *9*(1), 131–149。检索自 https://doi.org/10.1007/bf00145734 doi: 10.1007/bf00145734 Antiochos, S. K., Miki´c, Z., Titov, V. S., Lionello, R., & Linker, J. A. (2011年, 3月)。慢太阳风源区模型。《天体物理学杂志》, *731*(2), 112。检索自 https://doi.org/10.1088/ 0004-637x/731/2/112 doi: 10.1088/0004-637x/731/2/112 Arge, C. N. (2003)。改进太阳附近太阳风速度指定方法。载于 *AIP*会议论文集。AIP。检索自 https://doi.org/10 .1063/1.1618574 doi: 10.1063/1.1618574 Arge, C. N., & Pizzo, V. J. (2000年, 5月)。利用近实时太阳磁场更新改进太阳风状况预测。《地球物理研究杂志：空间物理》, *105*(A5), 10465–10479。检索自 https://doi.org/10.1029/1999ja000262 doi: 10.1029/1999ja000262 Brown, E. J. E., Svoboda, F., Meredith, N. P., Lane, N., & Horne, R. B. (2022年, 3月)。利用太阳极紫外图像进行太阳风速度预报的注意力机器视觉模型与技术。《空间天气》, *20*(3)。检索自 https://doi.org/10.1029/2021sw002976 doi: 10.1029/2021sw002976 Bu, X., Luo, B., Shen, C., Liu, S., Gong, J., Cao, Y., & Wang, H. (2019年, 7月)。基于太阳极紫外图像预报高速太阳风流。《空间天气》。检索自 https://doi.org/10.1029/ 2019sw002186 doi: 10.1029/2019sw002186 Camporeale, E. (2019年, 8月)。空间天气机器学习的挑战：临近预报与预测。《空间天气》, *17*(8), 1166–1207。检索自 https://doi.org/10.1029/2018sw002061 doi: 10.1029/2018sw002061 Dietterich, T. G. (1998年, 10月)。用于比较监督分类学习算法的近似统计检验。《神经计算》, *10*(7), 1895–1923。检索自 https://doi.org/10.1162/089976698300017197 doi: 10.1162/089976698300017197 Feng, X., Yang, L., Xiang, C., Wu, S. T., Zhou, Y., & Zhong, D. (2010年, 10月)。通过采用六分量网格的SIP-CESE磁流体力学模型开展从太阳到地球的三维太阳风建模。《天体物理学杂志》, *723*(1), 300–319。检索自 https://doi.org/10.1088/0004-637x/723/1/300 doi: 10.1088/0004-637x/723/1/300 Fry, C. D., Sun, W., Deehr, C. S., Dryer, M., Smith, Z., Akasofu, S.-I., . . . Kojima, M. (2001年, 10月)。改进用于空间天气预测的HAF太阳风模型。《地球物理研究杂志：空间物理》, *106*(A10), 20985–21001。检索自 https://doi.org/10.1029/

2000ja000220 doi: 10.1029/2000ja000220 Girosi, F., Jones, M., & Poggio, T. (1995年, 3月)。正则化理论与神经网络架构。《神经计算》, *7*(2), 219–269。检索自 https://doi.org/10.1162/neco.1995.7.2.219 doi: 10.1162/neco.1995.7.2 .219 Gopalswamy, N., Lara, A., Lepping, R. P., Kaiser, M. L., Berdichevsky, D., & Cyr, O. C. S. (2000年, 1月)。日冕物质抛射的行星际加速。《地球物理研究快报》, *27*(2), 145–148。检索自 https://doi.org/10.1029/1999gl003639 doi: 10.1029/1999gl003639 Gosling, J. T., Asbridge, J. R., Bame, S. J., & Feldman, W. C. (1978年)。太阳风流界面。《地球物理研究杂志》, *83*(A4), 1401。检索自 https://doi.org/10.1029/ja083ia04p01401 doi: 10.1029/ja083ia04p01401 Hochreiter, S., & Schmidhuber, J. (1997年, 11月)。长短期记忆。《神经计算》, *9*(8), 1735–1780。检索自 https://doi.org/10 .1162/neco.1997.9.8.1735 doi: 10.1162/neco.1997.9.8.1735 Hollweg, J. V. (2002)。快速太阳风的产生：着重讨论共振回旋相互作用的综述。《地球物理研究杂志》,*107*(A7)。检索自 https://doi.org/10.1029/2001ja000270 doi: 10.1029/2001ja000270 Ioffe, S., & Szegedy, C. (2015年, 7月7–9日)。批归一化：通过减少内部协变量偏移加速深度网络训练。载于 F. Bach & D. Blei (编),《第*32*届国际机器学习会议论文集》(第37卷, 第448–456页)。法国里尔：PMLR。检索自 https://proceedings.mlr.press/v37/ioffe15.html Jian, L. K., MacNeice, P. J., Taktakishvili, A., Odstrcil, D., Jackson, B., Yu, H.-S., . . . Evans, R. M. (2015年, 5月)。地球太阳风预测验证：比较CCMC部署的日冕与日球层模型。《空间天气》, *13*(5), 316–338。检索自 https://doi.org/10.1002/ 2015sw001174 doi: 10.1002/2015sw001174 Joselyn, J. A. (1995)。地磁活动预报：现状。《地球物理学评论》, *33*(3), 383。检索自 https://doi.org/10.1029/ 95rg01304 doi: 10.1029/95rg01304 Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998)。应用于文档识别的基于梯度的学习。《*IEEE*会刊》, *86*(11), 2278–2324。检索自 https://doi.org/10.1109/5.726791 doi: 10.1109/5.726791 Lemen, J. R., Title, A. M., Akin, D. J., Boerner, P. F., Chou, C., Drake, J. F., . . . Waltham, N. (2011年, 6月)。太阳动力学观测台（SDO）上的大气成像组件（AIA）。《太阳物理学》, *275*(1-2), 17–40。检索自 https://doi.org/10.1007/s11207-011-9776-8 doi: 10.1007/s11207-011-9776-8 Liu, J., Ye, Y., Shen, C., Wang, Y., & Erd´elyi, R. (2018年, 3月)。利用机器学习算法预测日冕物质抛射到达时间的新工具：CAT-PUMA。《天体物理学杂志》, *855*(2), 109。检索自 https://doi.org/ 10.3847/1538-4357/aaae69 doi: 10.3847/1538-4357/aaae69 Luo, B., Liu, S., & Gong, J. (2017年, 3月)。用于Kp短期预报的两种经验模型。《空间天气》, *15*(3), 503–516。检索自 https://doi .org/10.1002/2016sw001585 doi: 10.1002/2016sw001585 Miyoshi, Y., & Kataoka, R. (2005年)。日冕物质抛射和共转相互作用区驱动的地磁暴期间的环电流离子与辐射带电子。《地球物理研究快报》, *32*(21)。检索自 https://doi.org/10.1029/2005gl024590 doi: 10.1029/2005gl024590 Odstrcil, D. (2003年, 8月)。三维太阳风结构建模。《空间研究进展》, *32*(4), 497–506。检索自 https://doi.org/10.1016/s0273 - 1177(03)00332-6 doi: 10.1016/s0273-1177(03)00332-6

Owens, M., Lang, M., Barnard, L., Riley, P., Ben-Nun, M., Scott, C. J., . . . Gonzi, S.（2020年3月）。一种计算效率高、随时间变化的太阳风模型，可用作三维数值磁流体力学模拟的替代模型。《太阳物理学》，*295*(3)。检索自 https://doi.org/10.1007/s11207-020-01605-3 doi: 10.1007/s11207-020-01605-3 Owens, M. J., Challen, R., Methven, J., Henley, E., & Jackson, D. R.（2013年5月）。近地太阳风状况的27天持续性模型：一种提前期较长的预报及动力学模型的基准。《空间天气》，*11*(5), 225–236。检索自 https://doi.org/10.1002/swe.20040 doi: 10.1002/swe.20040 Papitashvili, N. E., & King, J. H.（2020）。*OMNI*逐小时数据集。NASA空间物理数据中心。检索自 https://hpde.io/NASA/NumericalData/OMNI/PT1H doi: 10.48322/1SHR-HT18 Raju, H., & Das, S.（2021年9月）。用于太阳风预报的基于CNN的深度学习模型。《太阳物理学》，*296*(9)。检索自 https://doi.org/10 .1007/s11207-021-01874-6 doi: 10.1007/s11207-021-01874-6 Reiss, M. A., MacNeice, P. J., Mays, L. M., Arge, C. N., M¨ostl, C., Nikolic, L., & Amerstorfer, T.（2019年2月）。利用数值模型预报背景太阳风。I. 关于运行框架的实施。《天体物理学杂志增刊系列》，*240*(2), 35。检索自 https://doi.org/10.3847/1538-4365/aaf8b3 doi: 10.3847/1538-4365/aaf8b3 Richardson, I., Webb, D., Zhang, J., Berdichevsky, D., Biesecker, D., Kasper, J., . . . 等（ 2006 ）。由共转相互作用区产生的强地磁暴（ dst$_{leq}$- 100 nt ）。《地球物理研究杂志：空间物理》，*111*(A7)。Richardson, I. G., & Cane, H. V.（2010年5月）。第23太阳活动周（1996–2009年）期间的近地行星际日冕物质抛射：目录及其特性概要。《太阳物理学》，*264*(1), 189–237。检索自 https://doi.org/10.1007/s11207-010-9568-6 doi: 10.1007/s11207-010-9568-6 Riley, P., Linker, J. A., & Miki´c, Z.（2001年8月）。一种由经验驱动的太阳日冕和内日球层全球磁流体力学模型。《地球物理研究杂志：空间物理》，*106*(A8), 15889–15901。检索自 https://doi .org/10.1029/2000ja000121 doi: 10.1029/2000ja000121 Sanchez-Diaz, E., Rouillard, A. P., Lavraud, B., Kilpua, E., & Davies, J. A.（2019年9月）。扇区边界附近变化的慢太阳风的原位测量。《天体物理学杂志》，*882*(1), 51。检索自 https:// doi.org/10.3847/1538-4357/ab341c doi: 10.3847/1538-4357/ab341c Schatten, K. H., Wilcox, J. M., & Ness, N. F.（1969年3月）。行星际磁场和日冕磁场模型。《太阳物理学》，*6*(3), 442–455。检索自 https://doi.org/10.1007/bf00146478 doi: 10.1007/bf00146478 Schulz, M.（1997）。日球层的非球形源表面模型：标量形式。《地球物理年鉴》，*15*(11), 1379–1387。检索自 https://angeo.copernicus.org/articles/15/1379/1997/ doi: 10.1007/s00585-997-1379-1 Schwenn, R.（1983）。内日球层中的平均太阳风：结构和缓慢变化。*JPL*第五届太阳风会议。Sexton, E. S., Nykyri, K., & Ma, X.（2019）。利用循环神经网络进行Kp指数预报。《空间天气与空间气候杂志》，*9*, A19。检索自 https://doi.org/10.1051/swsc/2019020 doi: 10.1051/swsc/2019020 Siciliano, F., Consolini, G., Tozzi, R., Gentili, M., Giannattasio, F., & Michelis, P. D.（2021年2月）。SYM-H指数预报：长短期记忆网络与卷积神经网络的比较。《空间天气》，*19*(2)。检索自 https://doi.org/10.1029/2020sw002589 doi: 10.1029/2020sw002589

Smirnov, A. G., Berrendorf, M., Shprits, Y. Y., Kronberg, E. A., Allison, H. J., Aseev, N. A., . . . Effenberger, F.（2020年10月）。地球外辐射带中的中能电子通量（MERLIN）：一种机器学习模型。《空间天气》，*18*（11）。检索自 https://doi.org/10.1029/ 2020sw002532 doi: 10.1029/2020sw002532 Smith, E. J., & Wolfe, J. H.（1976年3月）。1至5天文单位范围内的相互作用区和共转激波观测：先驱者10号和11号。《地球物理研究快报》，*3*（3），137–140。检索自 https://doi.org/10.1029/ gl003i003p00137 doi: 10.1029/gl003i003p00137 Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R.（2014）。Dropout：一种防止神经网络过拟合的简单方法。《机器学习研究杂志》，*15*（1），1929–1958。Stansby, D., Yeates, A., & Badman, S.（2020年10月）。pfsspy：用于势场源表面建模的 Python 软件包。《开放源代码软件杂志》，*5*（54），2732。检索自 https://doi.org/10.21105/joss.02732 doi: 10 .21105/joss.02732 Subramanian, P., Lara, A., & Borgazzi, A.（2012年10月）。太阳风黏性阻力能否解释日冕物质抛射的减速?《地球物理研究快报》，*39*（19），n/a–n/a。检索自 https://doi.org/10.1029/ 2012gl053625 doi: 10.1029/2012gl053625 Tan, Y., Hu, Q., Wang, Z., & Zhong, Q.（2018年4月）。使用长短期记忆网络预测地磁指数 Kp。《空间天气》，*16*（4），406–416。检索自 https://doi.org/10.1002/2017sw001764 doi: 10.1002/2017sw001764 T´oth, G., Sokolov, I. V., Gombosi, T. I., Chesney, D. R., Clauer, C. R., Zeeuw, D. L. D., . . . K´ota, J.（2005年）。空间天气建模框架：空间科学界的新工具。《地球物理研究杂志》，*110*（A12）。检索自 https://doi.org/10.1029/2005ja011126 doi: 10.1029/2005ja011126 Upendran, V., Cheung, M. C. M., Hanasoge, S., & Krishnamurthi, G.（2020年9月）。使用深度学习进行太阳风预测。《空间天气》，*18*（9）。检索自 https://doi.org/10.1029/2020sw002478 doi: 10.1029/2020sw002478 Wang, Y.-M., & Sheeley Jr, N.（1990）。太阳风速度与日冕磁通管膨胀。《天体物理学杂志》，*355*，726–732。Wilcox, J. M., & Howard, R.（1968年12月）。太阳磁场中的大尺度模式。《太阳物理学》，*5*（4），564–574。检索自 https://doi .org/10.1007/bf00147021 doi: 10.1007/bf00147021 Yang, Y., Shen, F., Yang, Z., & Feng, X.（2018年）。使用人工神经网络预测1天文单位处的太阳风速度。《空间天气》，*16*（9），1227-1244。检索自 https://agupubs.onlinelibrary.wiley.com/doi/abs/ 10.1029/2018SW001955 doi: https://doi.org/10.1029/2018SW001955