# 基于深度学习的太阳活动区检测与跟踪方法研究\*

朱健<sup>1</sup>,杨云飞<sup>1,2</sup>,苏江涛<sup>2</sup>,刘海燕<sup>1</sup>,李小洁<sup>1</sup>,梁波<sup>1</sup>,冯松<sup>1</sup> (1.昆明理工大学信息工程与自动化学院/云南省计算机技术应用重点实验室,云南 昆明 650500; 2. 中国科学院太阳活 动重点实验室,北京 100101)

摘要:太阳活动区是各类太阳活动的主要能量来源,剧烈的太阳活动会直接影响人类的 生存环境,因此准确地检测与跟踪太阳活动区对监控和预报空间天气非常重要。本文基于深 度学习框架的 YOLOv3-spp 和 DeepSort 提出了一种太阳活动区检测和跟踪方法(Active Regions Detection and Tracking Method, ARDTM),该方法较好地解决了传统图像处理方法易 将一个太阳活动区误检测为多个,或者多个太阳活动区误检测为一个活动区的问题;及时捕 获到新产生的太阳活动区和终止跟踪消失的太阳活动区,有效地提高了太阳活动区的跟踪准 确率。实验结果表明该方法可以较好地检测和跟踪不同望远镜、不同时间间隔序列图像中的 太阳活动区。

关键词:太阳活动区; 检测与跟踪; 深度学习; YOLOv3-spp; DeepSort 中图分类号: TP391.413

太阳活动区是太阳强磁场区域,是太阳活动的主要能量来源。剧烈的太阳活动会导致恶 劣的空间天气,比如耀斑和日冕物质抛射等,会对地球上电磁通信、电力系统、无线电传输 等产生不利影响。因此对太阳活动区进行检测与跟踪,分析其演化规律,对人类的空间探索 和地球生活有着重要的意义<sup>[1,2]</sup>。

目前用来解决太阳活动区检测与跟踪的方法主要采用传统的图像处理技术<sup>[1-11]</sup>。比如检测主要采用强度阈值法或区域生长等方法,这些方法一般需要设置参数,比如强度阈值、开闭算子阈值和区域生长的边界阈值。这些参数对于这些传统的方法来说至关重要,文[2,6]对参数进行了详细讨论,并给出了设置参数的一些准则。跟踪太阳活动区则主要根据纬向较差自转定律来预测其位置,然后根据欧式距离或特征的相关性进行目标关联<sup>[3,4]</sup>。

这些方法虽然较好地实现了太阳活动区的检测与跟踪,但是仍存在一些问题。比如,文 [2-4]的方法容易导致一个太阳活动区被误检测为多个,或者多个相邻的太阳活动区被误检 测为一个,从而导致误跟踪;SolarMonitor<sup>[11]</sup>使用的太阳活动区美国国家海洋和大气管理局 (National Oceanic and Atmospheric Administration, NOAA)编号被广泛使用,但存在未 能及时标注新浮现的太阳活动区和仍标注了已经在全日面像上消失的太阳活动区等现象。

近年来,随着深度学习<sup>[12]</sup>的普及和CNN等神经网络的发展,一些基于深度学习的目标检测和跟踪的算法被提了出来。比如,典型目标检测算法有:R-CNN<sup>[13]</sup>、Faster R-CNN<sup>[14]</sup>、YOLO<sup>[15]</sup>、YOLOv3<sup>[16]</sup>等。其中,YOLOv3借鉴残差网络的思想采用了新的特征提取网络Darknet-53,并结合多尺度特征进行目标检测,取得了较好的检测性能。典型多目标跟踪方法有:EAMTT<sup>[17]</sup>、STAM<sup>[18]</sup>、DeepSort<sup>[19]</sup>等。其中,DeepSort具有较好的跟踪性能和较高的实时性能。在天文领域的研究中,越来越多的深度学习方法被采用<sup>[20-22]</sup>。

本文针对太阳活动区的演化特性,采用YOLOv3-spp作为检测算法和DeepSort作为跟踪算法并进行改进,提出了一种太阳活动区检测和跟踪方法(Active Regions Detection and

<sup>\*</sup> 基金项目: 国家自然科学基金(11763004, 11573012, 11803085, U1931107); 中国科学院太阳活动重点实验室开放课题 (KLSA201815)资助.

作者简介:朱健,男,硕士.研究方向:图像处理.Email: zhujian2019@foxmail.com

通讯作者:杨云飞,女,副教授.研究方向:图像处理与数据分析. Email: yangyf@escience.cn

Tracking Method, ARDTM)。该算法可以有效地检测并跟踪不同时间间隔序列图像中的太阳 活动区。第一节介绍了所使用的数据和制作的数据集,第二节简述了ARDTM方法,第三节是 实验结果与分析,第四节对本文进行总结与展望。

#### 1 数据和数据集

本文采用了太阳动力学天文台(Solar Dynamics Observatory, SDO)卫星的日震及磁场 成像仪(Helioseismic and Magnetic Imager, HMI)与日球天文台(Solar and Heliospheric Observatory, SOHO)的迈克逊多普勒成像仪(Michelson Doppler Imager, MDI)两个设备的 太阳全日面纵向磁图作为数据来源,制作了太阳活动区检测与跟踪的深度学习的训练和验证 数据集。

表1列出了分别用于太阳活动区检测与跟踪的数据集。D1 共选取了 3017 张全日面图像 用作制作太阳活动区检测网络的训练和验证集,共选取了 16 361 个太阳活动区样本,其中 80%作为训练样本用于训练深度学习网络模型,20%作为验证样本在训练过程中用于防止过拟 合的验证。D2 共选取了 33 515 个太阳活动区样本用于跟踪过程中重识别网络的训练和验证, 将太阳活动区局部区域缩放为 128×128 像素尺寸,同样 80%用于训练,20%用于验证。本文 根据 SolarMonitor 网站上标注的太阳活动区 NOAA 编号,结合人工辅助判断的方式,采用 labelImg 标注软件标注了数据集。

Table	1 The dat	aset of	active re	egions detection and track	ing
数据用途	数据集编号	设备来源	目的	时间/间隔	样本数量
训练/验证 - 集	D1	HMI	检测	2011. 01. 01-2017. 12. 31	16 361
	D2 HM	имт	阳空	2011.11.01-2011.11.30/12分钟	22 515
		пмт	正民亡不	2017.03.20-2017.04.20/12 分钟	22 212

表1 太阳活动区检测和跟踪数据集

### 2 方法

ARDTM 算法主要分为两个部分: 检测与跟踪。在检测部分,本文采用了 YOLOv3-spp 模 型。该模型的网络结构如图 1 所示,由 Darknet-53(图 1.a)与 volo 层(图 1.b)两部分组成, 分别用于提取图像特征与多尺度预测。方法步骤主要如下:(1)将全日面图像压缩为 608× 608 的尺寸输入网络。(2)输入图像经过一个卷积单元(Convolutioanl)得到 32 个 608×608 的特征图。卷积单元包含卷积、批量归一化和 leaky relu 激活函数三个部分。(3)特征图经 过步长为 2、64 个卷积核的卷积单元实现降采样,得到 64 个 304×304 的特征图,然后送入 残差单元(Residual),输出 64个 304×304 的特征图(1x 残差块)。1x 表示此残差块由1个 残差单元组成。残差单元是将输入与两个卷积单元进行残差操作。(4)上一步得到的特征图 经过降采样和 2x 残差块得到 128 个 152×152 的特征图。其中 2x 表示此残差块由 2 个残差 单元组成。(5)接下来依次执行降采样、8x 残差块、降采样、8x 残差块、降采样,4x 残差 块操作。三个残差块依次得到 256 个 76×76、512 个 38×38 和 1024 个 19×19 的特征图。 (6)将8x、8x和4x三个残差块的结果送入 volo 层(图 1.b)。(7)19×19的特征图经过金字 塔卷积集(convolutional-spp Set)等操作得到第一次的检测结果(Output1);同时,将金字 塔卷积集的结果上采样至 38×38 与第四个残差块的 38×38 的特征图融合,经过卷积集 (Convolutional Set)等操作得到第二次的检测结果(Output2);依次类推,得到第三次的检 测结果(Output3)。其中,卷积集操作包含5个卷积单元;金字塔卷积集是在卷积集基础上 添加了空间金字塔池化<sup>[23]</sup>。(8)将以上三次的检测结果使用非极大抑制算法去除交并比较大 的预测框,保留置信得分较高的预测框作为太阳活动区的检测结果。该网络的损失值由三个 部分合成:目标定位偏移量损失、目标置信度损失和目标类别损失。其中,目标置信度损失 和类别损失采用了二元交叉熵损失,目标定位损失则采用了均方误差进行计算。



图 1 Yolov3-spp 网络结构示意图

Fig. 1 YOLOv3-spp network structure diagram

在跟踪部分,本文基于 DeepSort 算法对其进行改进,主要步骤如下:

(1)根据太阳活动区的特性改进了 DeepSort 的特征提取网络,本文将其称之为太阳活动 区重识别网络,如图 2 所示。首先将检测到的太阳活动区缩放为 128×128,经过 2 次 3×3 的卷积、1 次最大池化以及 6 个残差块,特征图的大小减小到 16×16,再经过一个全连接层 得到 128 维的全局特征向量,最后采用 L2 归一化得到特征向量。在训练过程中,采用 Cosine Softmax 函数得到分类结果,采用交叉熵计算损失值。需要说明的是检测部分的网络和太阳 活动区重识别网络虽然都提取太阳活动区的特征,但是作用不同。检测部分的网络主要用于 检测太阳活动区,而太阳活动区重识别网络主要为了判定太阳活动区在演化过程中的特征相 似性。

(2)用太阳活动区重识别网络提取己跟踪到的太阳活动区(称为轨迹,假设数量为L)和 当前帧检测到的太阳活动区(假设数量为J)的特征向量,计算之间的余弦距离,得到关联矩 阵 C<sub>L×J</sub>。然后,根据前一帧所有太阳活动区的位置,采用纬向较差自转<sup>[24,25]</sup>预估在当前帧的 位置。接着,计算所有预测位置和所有检测位置的欧氏距离,若过大则将关联矩阵中对应的 值设置为无穷大。

(3)对关联矩阵 C<sub>L×J</sub>采用匈牙利匹配算法<sup>[26]</sup>,得到三类匹配结果:匹配到检测结果的轨迹、未匹配到轨迹的检测结果和未匹配到检测结果的轨迹。对于匹配到检测结果的轨迹则继续跟踪;未匹配到轨迹的检测结果则为之分配一个新的轨迹,当新轨迹连续3帧匹配到检测结果时,则认为该太阳活动区产生,否则,删除该轨迹。对于未匹配到检测结果的轨迹则提取使用纬向较差自转预测结果的特征向量,与前一帧对应的特征向量计算余弦距离。若其值在一定范围内(本文实验结果为 0.7)则采纳该预测结果作为轨迹的一部分,否则该活动区结束。但如果连续3帧均为预测结果则也判定该活动区结束。



图 2 太阳活动区重识别网络网络结构示意图

Fig. 2 Active regions re-identification network structure diagram

# 3 实验结果与分析

本文采用 HMI 和 MDI 的四组全日面序列图像进行了测试。这四组数据分别代表了不同的 观测设备和活动区数量。表 2 列出了数据的基本信息,为了便于描述,分别用 D3—D6 表示。 其中,D3 和 D4 选取了 MDI 纵向磁图,D5 和 D6 选取了 HMI 纵向磁图。D4 和 D6 选取了太阳 活动区数量较多的序列图像,而 D3 和 D5 选取了活动区数量较少的序列图像。由于时间间隔 较长的数据太阳活动区的特征变化大,跟踪难度较高,因此四组数据均采用时间间隔较长的 序列图像(为了便于与 SolarMonitor 结果进行比较,数据与 SolarMonitor 提供的数据时间 基本一致)。

表 2 列出了四组数据集的跟踪结果,并与 NOAA 进行了对比。包括 SolarMonitor 上标注 的 NOAA 活动区数量、ARDTM 方法标注的太阳活动区数量、ARDTM 结果与 NOAA 结果相同的活 动区的数量(ARDTM∩NOAA)、NOAA 活动区数量与交集的差值(NOAA-(ARDTM∩NOAA))、ARDTM 活动区数量与交集的差值(ARDTM-(ARDTM∩NOAA))、交集与 NOAA 活动区数量的百分比 ((ARDTM∩NOAA)/NOAA)。NOAA 一共标注了 806 个活动区, ARDTM 标注了 872 个, 两者的交集 为755个。ARDTM 方法标注的活动区比 NOAA 的多一些,主要由以下四种情况产生:(1) ARDTM 及时标注了新出现的活动区,而 NOAA 存在未能及时标注的现象;(2) ARDTM 较完整地标注了 活动区的演化末期,而 NOAA 已经提前结束了对其标注;(3) ARDTM 标注了一些没有被 NOAA 标注的活动区,这些活动区的特点均为磁场强度较弱、磁结构特征不太明显,但日面已有黑 子产生且持续了3帧以上;(4)一些已具有磁场特征但未形成黑子的活动区被ARDTM误跟踪。 这三种情况所占比例分别为 52%、10%、32%和 6%。这意味着一半以上的情况是 ARDTM 及时标 注了新出现的活动区。反过来,NOAA标注的活动区比交集多了51个,这意味着 ARDTM 没有 标注 51 个被 NOAA 标注的活动区。造成此情况的主要原因有:(1)太阳活动区的特征已经在纵 向磁图上消失但仍被 NOAA 标注;(2) ARDTM 漏标注一些磁场强度较弱且特征不明显的活动区。 两种情况所占比例分别为 88%和 12%。在这四组数据中, NOAA 在 D4 数据集上及时地跟踪了 新活动区和终止跟踪消失的活动区,所以本文方法和 NOAA 的结果相似度最高。

为了说明以上几种情况,表3详细列出了D6测试集中前十天的跟踪结果,第2—6列的数据含义与表2相同,第7列详细列出了ARDTM方法与NOAA标注结果不同的具体情况。比较典型的是AR12185于10月5日出现,但NOAA于7日才开始标注;AR12183左侧有个活动区,于10月5日形成了黑子,一直到14日才消失,但该活动区一直未被NOAA标注;AR12173已于10月3日消失于日面,但NOAA仍做了标注。

		Table 2	me t	racking	g resul	ts		
数据 集编 号	数据 来源	时段	NOAA 结果	ARDTM 结果	ARDTM ∩ NOAA	NOAA- (ARDT M∩NOAA)	ARDTM− (ARD TM ∩ NOAA)	(ARDTM∩ NOAA)/NO AA
D3	MDI	2005.03.01-2005.03.31/24 小时	68	72	62	6	10	91.18%
D4	MDI	2000.07.12-2000.08.11/24 小时	410	415	398	12	17	97.07%
D5	HMI	2010.11.05-2010.12.04/24 小时	103	108	91	12	17	88.35%
D6	HMI	2014. 10. 01-2014. 10. 31/24 小时	225	277	204	21	73	90.67%
合计			806	872	755	51	117	91.82%

表 2 跟踪结果 able 2 The tracking result

表 3	D6 数据集部分跟踪结果

		la	ole 3	The trackin	g results o	i Do dataset
H #0	NOAA	ARDTM	ARDTM	NOAA-(ARDTM	ARDTM-(ARDTM	M Nor
日期	结果	结果	$\cap$ NOAA	$\cap$ NOAA)	$\cap$ NOAA)	<b>奋</b> 壮
0014 10 1	10	10	0	1	1	AR12171 已从全日面消失, NOAA 仍标记; NOAA
2014-10-1	10	10	9	1	1	未及时标注 AR12182;
9014 10 9	0	9	8	1	1	AR12175 已从全日面消失, NOAA 仍标记; NOAA
2014-10-2	9					未及时标注 AR12182;
2014-10-2	0	10	7	1	2	AR12173 已从全日面消失, NOAA 仍标记; NOAA
2014-10-5	0	10	ſ	1	J	未及时标注 AR12182、AR12183、AR12184;
2014-10-4	10	9	9	1	0	AR12172 已从全日面消失, NOAA 仍标记;
	2014-10-5 9 10 8 1 2		AR12176 已从全日面消失,NOAA 仍标记; NOAA			
2014-10-5		10	8	1	2	未及时标注 AR12185; ARDTM 标注但 NOAA 未标
			注1个活动区			
2014-10-6	9	9	7	2	2 2	AR12176 和 AR12180 已从全日面消失, NOAA 仍
						标记; NOAA 未及时标注 AR12185; ARDTM 标注但
						NOAA 未标注1个活动区;
2014-10-7	8	10	8	0	9	NOAA 未及时标注 AR12186; ARDTM 标注但 NOAA
2011 10 1	0	10	0	<u> </u>	2	未标注1个活动区;
2014-10-8	9	10	9	0	1	ARDTM 标注但 NOAA 未标注 1 个活动区
2014-10-9	8	8	7	1	1	AR12181 已从全日面消失, NOAA 仍标记; ARDTM
2011 10 5	0	0		1		标注但 NOAA 未标注 1 个活动区
2014-10-10	-10-10 7 6 5 2 1	1	AR12178 和 AR12179 已从全日面消失, NOAA 仍			
2017 10 10	'	U	5	2	1	标记; ARDTM 标注但 NOAA 未标注 1 个活动区
合计	87	91	77	10	14	

ARDTM 较好地解决了文[4]中提到的一个太阳活动区被误检测为多个,或者多个太阳活动区被误检测为一个活动区的问题。图 3(a)采用了文[4]图 11(a)的 MDI 同时间数据(2002 年 5 月 4 日 12:48UT),红色实线框为 ARDTM 的检测结果,蓝色虚线框为文[4]的结果。其中,

1 和 2 两个区域分别为 AR09934 和 AR09936,而文[4]误把他们识别成了一个活动区。(b)为 HMI 的 2010 年 11 月 12 日数据。同样,3 和 4 分别为 AR11123 和 AR11121,而用文[4]方法 误识别成了一个活动区。(c)为 HMI 的 2010 年 11 月 7 日的 AR11120, ARDTM 顺利检测为一个 活动区,但采用文[4]方法将其检测成了两个活动区。



图 3 ARDTM 的检测结果图。

Fig.3 The detection results images diagram of ARDTM

图4展示了D6数据集中连续三帧的跟踪结果(a)、(b)和(c),时间分别是2014年10月20日 22:48UT、21日23:00UT和22日22:48UT。图中粗框代表了检测到的太阳活动区匹配到了轨迹; 虚框表示该区域未被检测或未被跟踪匹配,而采用预测机制填补的结果。跟踪框的左上角数 字表示ARDTM对太阳活动区的跟踪编号。通过与对应时间的NOAA对比,ARDTM具有良好的跟踪 结果。比如,(1)ARDTM及时捕获到了新的活动区。ARDTM在(a)及时捕获了AR12194,而NOAA 在(c)才被标注,ARDTM比NOAA提前了2天。NOAA中AR12183、AR12186、AR12189、AR12190、 AR12191、AR12192和AR12195这几个活动区,ARDTM均比NOAA更早检测到并及时开始跟踪。 (2)ARDTM及时终止跟踪消失的活动区。ARDTM在22日(c)及时终止跟踪AR12189,而NOAA直到 26日才终止跟踪该活动区。同样,(a)图的AR12186也是类似的情况。(3)预测机制较好地弥 补了检测算法漏检带来的漏跟踪或误跟踪问题。ARDTM在(a)和(b)都通过预测机制连续跟踪 了AR12189。(4)ARDTM检测并跟踪到了NOAA漏检的活动区。(a)图中编号为23和29的活动区和 (b)中编号为33的活动区,在演化过程中都形成了黑子,生命期分别为8、6和6帧,但都未被 NOAA标注。



图 4 ARDTM 在 D6 数据集中连续 3 帧的跟踪结果。(a) 2014 年 10 月 20 日 22:48UT;(b) 2014 年 10 月 21 日 23:00UT;(c) 2014 年 10 月 22 日 22:48UT。

Fig. 4 ARDTM tracking results of three consecutive frames in the D6 dataset. (a) Oct. 20, 2014 22:48UT; (b) Oct. 21, 2014 23:00UT; (c) Oct. 22, 2014 22:48UT.

图 5 展示了图 4 中 AR12194 以及 D4 数据集中 AR09093 两个活动区的完整跟踪结果。(a) 到(1)子图是 AR12194 从出现到消失的跟踪过程,时间从 2014 年 10 月 20 日 22:48:00UT 到 31 日 19:48:00UT。该活动区穿越了整个日面,磁场结构和面积变化都非常大。(n)到(t)子 图是 AR09093 从出现到消失的跟踪结果,时间从 2000 年 7 月 16 日 12:48:00UT 到 22 日

12:48:00UT。(m)和(u)是 AR09093 产生的前一帧和消失的后一帧对应位置图。该活动区演化 周期时间较短,特征变化也很大。ARDTM 及时捕获且及时停止了跟踪该活动区。其中,(t) 时刻通过预测机制填补了漏检,(u)时刻及时停止了跟踪。图6显示了图5中AR09093和 AR12194两个活动区的磁通量和面积的变化曲线(均已进行了投影改正),可以看出其磁通量 和面积都具有较强的渐变性。



Fig. 5 From (a) to (k) is the complete tracking result of the number AR12194 in D6 dataset. From (n) to (t) is the

complete tracking result of the number AR09093 in D4 dataset.



Fig. 6 (a) The change of magnetic flux of the AR12194; (b) The change of magnetic flux of the AR09093.

# 4总结与展望

本文基于深度学习提出了一种太阳活动区检测与跟踪的方法 ARDTM。该方法首先使用 YOLOv3-spp 网络检测太阳活动区,然后结合较差自转改进 DeepSort 算法跟踪太阳活动区。 经过网络训练后,本文分别用四组数据进行了测试,并与 NOAA 的结果进行了比较,ARDTM 跟踪标注的结果与 NOAA 的交集约为 NOAA 的 92%。

本文的训练集只采用了 HMI 数据,但无论是测试 HMI 的数据,还是 MDI 的数据,都能很 好地检测和跟踪太阳活动区,表现出了较好的泛化性。为了与 SolarMonitor 的结果进行逐 一比较,本文主要采用与 SolarMonitor 网站公布的数据时间基本吻合的数据进行了测试, 时间间隔约为 24 小时。本文还对不同时间间隔的 HMI 序列图像进行了测试,时间间隔选取 为 12 分钟、1 小时、4 小时……,一直到 48 小时。总体来说,间隔为 12 分钟的数据由于活 动区特征变化不大,跟踪结果最好;一直到 24 小时的时间间隔跟踪效果都还不错;超过 24 小时的时间间隔就会出现较多的误跟踪现象。总的来说,该方法较好地解决了传统方法中一 个太阳活动区被误检测为多个,或者多个相邻的太阳活动区被误检测为一个的问题。而且, 该方法能及时捕获到新出现的活动区,亦能及时终止跟踪消失的活动区,并且通过预测机制 弥补检测算法漏检带来的误跟踪或漏跟踪问题。当然,该方法也还存在一定的问题,比如由 于单一地根据磁场结构的特征检测和跟踪活动区,会导致一些具有磁场结构但未形成黑子的 特征被误跟踪情况。在未来的工作中,拟考虑结合其他波段观测的图像进一步提高算法的准 确率。

### 参考文献:

- QAHWAJI R, COLAK T. Automatic detection and verification of solar features [J]. International Journal of Imaging Systems & Technology, 2005, 15(4):199-210.
- [2] ZHANG J, WANG Y, LIU Y. Statistical properties of solar active regions obtained from an automatic detection system and the computational biases [J]. The Astrophysical Journal, 2010, 723(2):1006-1018.
- [3] CABALLERO C, ARANDA M C. Automatic tracking of active regions and detection of solar flares in solar EUV images [J]. Solar Physics, 2014, 289(5):1643-1661.
- [4] HIGGINS P A, GALLAGHER P T, MCATEER R T J, et al. Solar magnetic feature detection and tracking for space weather monitoring [J]. Advances in Space Research, 2011, 47(12):2105-2117.
- [5] TURMON M, PAP J M, MUKHTAR S. Statistical pattern recognition for labeling solar active regions: application to, SOHO, MDI imagery [J]. The Astrophysical Journal, 2002, 568(1):396-407.
- [6] ZHARKOVA V V, ABOUDARHAM J, ZHARKOV S, et al. Solar feature catalogues in EGSO [J]. Solar Physics, 2005, 228, 361-375.
- [7] MCATEER R T J, GALLAGHER P T, IRELAND J, et al. Automated boundary-extraction and region-growing techniques applied to solar magnetograms [J]. Solar Physics, 2005, 228(1-2):55-66.
- [8] COLAK T, QAHWAJI R. Automated mcIntosh-based classification of sunspot groups using MDI images [J]. Solar Physics, 2008, 248(2):277-296.
- [9] COLAK T, QAHWAJI R. Automated solar activity prediction: a hybrid computer platform using machine learning and solar imaging for automated prediction of solar flares [J]. Space Weather-the International Journal of Research & Applications, 2009, 7(6):-.
- [10] LABONTE B J, GEORGOULIS M K, RUST D M. Survey of magnetic helicity injection in regions producing X-class flares [J]. Astrophysical Journal, 2008, 671(1):955.
- [11] GALLAGHER P T, MOON Y J, WANG H. Active-region monitoring and flare forecasting I. Data processing and first results
  [J]. Solar Physics, 2002, 209(1):171-183.
- [12] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521: 436-444.
- [13] GIRSHICK R, DONAHUE J, DARRELLAND T, et al. Rich feature hierarchies for object detection and semantic segmentation [C]// 2014 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2014.
- [14] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 39(6):1137-1149.
- [15] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [J]. 2015.

- [16] REDMON J, FARHADI A. YOLOv3: an incremental improvement [J]. 2018.
- [17] WOJKE N, BEWLEY A, PAULUS D. Simple online and realtime tracking with a deep association metric [C]. IEEE International Conference on Image Processing. IEEE, 2017:3645-3649.
- [18] SANCHEZ-MATILLA R, POIESI F, CAVALLARO A. Online multi-target tracking with strong and weak detections [M]// Computer Vision - ECCV 2016 Workshops. Springer International Publishing, 2016.
- [19] CHU Q, OUYANG W, LI H, et al. Online multi-object tracking using CNN-based single object tracker with spatial-temporal attention mechanism [J]. 2017.
- [20] 付小娜, 廖成武, 白先勇, et al. 基于 LeNet-5 卷积神经网络的太阳黑子检测方法 [J]. 天文研究与技术, 2018, v.15; No.59(03):87-93.
- [21] 刘辉,季凯帆,金振宇. 机器学习在太阳物理中的应用 [J]. 中国科学: 物理学 力学 天文学, 2019, 49, 109601.
- [22] 崔顺, 许允飞, 苏丽颖, et al. 基于卷积神经网络的全天空地基云图分类研究 [J]. 天文研究与技术, 2019, 16(02):98-108.
- [23] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 37(9):1904-16.
- [24] HOWARD R. The rotation of the sun [J]. Reviews of Geophysics, 1978, 16(4):721-732.
- [25] HOWARD R F, HARVEY J W, FORGACH S. Solar surface velocity fields determined from small magnetic features [J]. Solar Physics, 1990, 130(1-2):295-311.
- [26] KUHN H W. The hungarian method for the assignment problem [J]. Naval Research Logistics, 1955, 2(1-2):83-97.

# A Detection and Tracking Method for Active Regions Based on Deep Learning

Zhu Jian<sup>1</sup>, Yang Yunfei<sup>1,2</sup>, Su Jiangtao<sup>2</sup>, Liu Haiyan<sup>1</sup>, Li Xiaojie<sup>1</sup>, Liang Bo<sup>1</sup>, Feng Song<sup>1</sup>

(1. School of Information Engineering and Automation/Key Laboratory of Applications of Computer Technology of the Yunnan Province, Kunming University of Science and Technology, Kunming 650500, China;

2. Key Laboratory of Solar Activity, Chinese Academy of Sciences, Beijing 100101, China)

**Abstract:** Active regions(ARs) are the primary source of energy for various solar activities. The violent solar activities adversely affect human living environment. Therefore, accurate detection and tracking of ARs are very important for monitoring and forecasting the space weather. In this paper, we propose an AR detection and tracking method (ARDTM) based on the deep learning model comprising of the YOLOv3-spp and DeepSort. This paper solves the problem that one AR is mis-detected as multiple ARs, or multiple ARs are mis-detected as an AR. Besides that, it captures the new ARs and terminates the disappeared ARs in time. The method improves the precision and recall of detecting and tracking ARs. It can be used for detecting and tracking ARs in the solar full-disk longitudinal magnetograms observed from different telescopes, or different time interval series-images.

Keywords: active regions; detection and tracking; deep learning; YOLOv3-spp; DeepSort