doi:10.6041/j.issn.1000-1298.2026.09.025

基于空间深度转换域自适应学习的小麦赤霉病无监督检测方法

鲍文霞　胡芳妹　胡根生　梁　栋

（安徽大学农业生态大数据分析与应用技术国家地方联合工程研究中心，合肥 230601）

摘要：利用无人机遥感监测小麦赤霉病时，随着无人机飞行高度的增加，所采集到的图像中病斑尺寸也会越来越小。这些小目标会增加数据标注的难度，且需要耗费更多的时间和人工成本。针对该问题，本文提出了一种无监督的无人机小麦图像赤霉病检测方法——空间深度转换域自适应检测网络（Space-to-depth domain adaptation detection network，SPD－DANet），通过对抗思想学习源域数据的知识，并将其迁移至无标注的目标域从而实现小麦赤霉病无监督检测。首先，针对无人机小麦图像中赤霉病病斑较小的问题，设计了空间深度转换特征提取器（Space-to-depth feature extractor，SPD－FE），将无人机图像的空间信息转换为深度信息，使得网络能更加有效地学习小目标病斑的特征。其次，利用 SPD－FE 构建基于对抗的分类自适应和边界框回归自适应模块，让检测网络分别从分类和边界框回归 2 个步骤依次进行域自适应学习，从而利用源域数据的知识实现目标域的无监督检测。实验结果表明，本文所提出的方法相较于其他目标检测方法，如 DETR、YOLO v5 等，检测精度（AP50）提高 5.3～20.5 个百分点，在小麦赤霉病的无监督检测任务中表现最佳，且与基线网络相比其检测精度（AP50）提高 6.5 个百分点。本文的研究结果能够为小麦赤霉病的无监督检测提供技术支撑。

关键词：小麦赤霉病；目标检测；域自适应；无监督学习

中图分类号：S127　　**文献标识码**：A　　**文章编号**：1000-1298(2026)09-0270-08　　**OSID**：

Unsupervised Detection of Wheat Scab Based on Space-to-depth Domain Adaptation Learning

BAO Wenxia　HU Fangmei　HU Gensheng　LIANG Dong

(*National & Local Joint Engineering Research Center for Agricultural Ecological Big Data Analysis and Application Technology*, *Anhui University*, *Hefei* 230601, *China*)

Abstract: When using UAV remote sensing to monitor wheat scab, the size of the object in the captured images decreases as the UAV's flight altitude increases. This makes data annotation more challenging, requiring more time and labor. To address this issue, an unsupervised UAV-based wheat scab detection method was proposed. The method proposed a space-to-depth domain adaptation detection network (SPD－DANet), which learned the knowledge of the source domain data through the adversarial idea and transfered it to the unlabeled target domain thereby realizing unsupervised wheat scab detection. Firstly, to tackle the issue of small scab lesions in UAV-captured wheat images, a spatial-to-depth feature extractor (SPD－FE) that transformed spatial information into depth information was designed. This enabled the network to learn features of small scab objects more effectively. Secondly, using SPD－FE, adversarial-based classification adaptation and bounding box regression adaptation modules for the detection network were constructed. This enabled domain adaptation learning sequentially in classification and bounding box regression steps, leveraging source domain knowledge for unsupervised detection in the target domain. The experimental results showed that the proposed method improved the detection accuracy (AP50) by 5.3～20.5 percentage points compared with other object detection methods such as DETR,

收稿日期：2024－08－24　修回日期：2024－09－30

基金项目：安徽省自然科学基金项目(2208085MC60)、安徽省科学技术厅高校科研计划项目(2023AH050084)和国家自然科学基金项目(62273001、32372632)

作者简介：鲍文霞(1980—)，女，教授，博士，主要从事农业与生态视觉分析与模式识别研究，E-mail：bwxia@ahu.edu.cn

通信作者：梁栋(1963—)，男，教授，博士，主要从事农业生态大数据分析与应用研究，E-mail：dliang@ahu.edu.cn

YOLO v5, etc., and performed the best on the unsupervised detection task of wheat scab, and its detection accuracy AP50 was improved by 6.5 percentage points compared with that of the baseline network. The research can provide some support and help for the unsupervised detection of wheat scab.
Key words: wheat scab; object detection; domain adaptation; unsupervised learning

0　引言

小麦作为一种常见的禾本科植物，是仅次于水稻和玉米的第三大消费谷物，具有广泛的食用用途[1-2]。小麦赤霉病[3]是影响小麦产量和质量的主要因素之一，快速有效地检测赤霉病能够帮助农耕人员定位赤霉病的发病区域并采取有效防治措施，阻断赤霉病传播，提高小麦产量和品质。

随着深度学习的发展，越来越多的学者将其应用于农业病虫害检测，以实现快速准确检测。尽管此类方法在农业病虫害检测领域已获得显著进展[4-7]，但在检测小麦赤霉病时，处理小目标会面临检测精度不足和漏检率高的问题。因此，如何有效提高小目标检测的精度，已成为当前研究的关键课题。

虽然针对小目标检测的研究已经取得了显著进展[8-11]，并提升了小目标检测的精度。但理想的目标检测场景需要大量标记的训练实例，并且训练数据与测试数据需要具有相同的分布。然而收集大量的训练数据通常成本昂贵且耗时，并且训练数据与测试数据之间不可避免地存在一定差异。对此，域自适应迁移学习[12]提供了一个有效的解决方案。域自适应迁移学习通过将存在差异的不同数据特征映射到同一个特征空间，利用已有的标注数据来增强对无标注数据的训练效果[13-14]。域自适应学习在目标检测领域取得了显著进展。例如 GANIN 等[15]提出的 DANN 在图像级和实例级 2 个层面上处理域移位，从而构建域自适应组件以减少域差异。HUANG 等[16]设计的 DDA-Faster 首先使模型聚焦于图像中具有较高定位概率的区域，以增强前景和背景之间的区分度，然后在类别上对源图像和目标图像进行对齐，通过 2 个对立的感兴趣区域分类器学习类不变特征，从而实现域自适应的目标检测。HE 等[17]研究的 TDD 通过将源域和目标域的检测分支集成到一个统一的师生学习方案中，生成可靠的监督，有效减少了域偏移。CHEN 等[18]提出的 PT 通过利用不确定性引导的一致性训练来促进类别适应和定位适应，从教师网络中捕捉未标记目标数据的不确定性，从而实现域自适应。

但利用无人机遥感监测小麦赤霉病时，随着飞行高度的增加，采集图像中的病斑尺寸变小，增加了标注难度。而这种目标尺度的差异会导致检测器无法直接对新的数据进行检测，重新标注这些数据又需要大量时间和人工成本。为了解决这一问题，本文引入域自适应迁移学习方法，将从源域学习的知识迁移至只有未标注数据的目标域中，从而在减少标注成本的同时有效提高检测器在无标注数据上的检测性能。具体而言，以 Faster R-CNN[19]作为基准检测网络，设计一种适用于小目标的特征提取器，以应对无人机图像中难以检测的极小病斑。然后基于该特征提取器，分别在分类和边界框回归 2 个步骤设计对应的域自适应模块，从而实现目标域的无监督检测。最终，通过与 YOLO v5 和 DETR[20]等模型进行对比，验证所提出方法的有效性。

1　材料与方法

1.1　数据采集

本文实验所用的小麦图像样本采集于安徽省合肥市巢湖市坝镇(117°36′18.3″E，31°16′23.9″N)。采集时间为 2021 年 5 月，此时小麦正处于灌浆期，图像采集设备为大疆 Mavic Air 2 型无人机，拍摄图像的分辨率为 6 000 像素×8 000 像素。采集地点信息见图 1。在数据采集过程中通过飞行软件调整摄像头的角度，以获取不同方向的小麦图像。采集的部分无人机图像如图 2 所示。

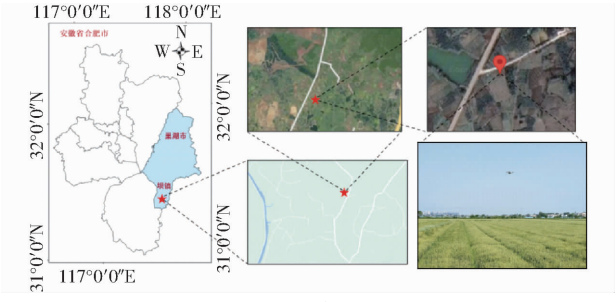

图 1　采集地点

Fig. 1　Collection location

1.2　数据集构建

从图 3a 中可以看出，由于光照等因素的影响，赤霉病病斑并不明显。为了提高赤霉病的检测精度，本文对所得到的图像进行数据增强，以突出病斑的特征。

为了突出病害区域，将采集图像的 R、G、B 3 个通道的像素值分别变换再归一化处理[21]。计算公式为



图 2 拍摄图像示例

Fig. 2 Example of captured images



(a) 数据增强前



(b) 数据增强后

图 3 数据增强效果对比图

Fig. 3 Data augmentation effect comparison charts

$$\begin{cases} V_r = r^3(x,y) \\ V_g = g^3(x,y) \\ V_b = b^3(x,y) \end{cases} \tag{1}$$

$$V'_{\{r,g,b\}} = \frac{V_{\{r,g,b\}}(x,y) - \min(V_{\{r,g,b\}}(x,y))}{\max(V_{\{r,g,b\}}(x,y)) - \min(V_{\{r,g,b\}}(x,y))} \times 255 \tag{2}$$

式中 V_r、V_g、V_b——立方拉伸后的 R、G、B 通道像素值

x——图像中像素点的横坐标

y——图像中像素点的纵坐标

$r(x,y)$、$g(x,y)$、$b(x,y)$——R、G、B 通道像素值

$V_{\{r,g,b\}}$、$V'_{\{r,g,b\}}$——各个通道变换前、后的像素值

经过公式(1)、(2)的映射后图像中病斑部位像素值与其他部位像素值差别更大,病斑特征更为突出。经处理后的图像如图 3b 所示。

本文将所拍摄的高度 4 m 和 6 m 的无人机图像均以重叠裁剪的方法裁剪为 416 像素 ×416 像素,重叠率为 0.15,并按照上述数据增强方法进行处理。由于高度 4 m 的无人机图像中赤霉病病斑较 6 m 的易于标注,因此本文将高度 4 m 获取的无人机图像作为域自适应迁移学习的源域,高度 6 m 的图像作为目标域。最终得到源域数据图像 1 248 幅,目标域数据图像 1 326 幅,并将目标域按照比例 3∶1分为训练集和测试集,图 4 展示了部分源域和目标域数据。本文采用 LabelImg 标注软件对源域图像进行标注。

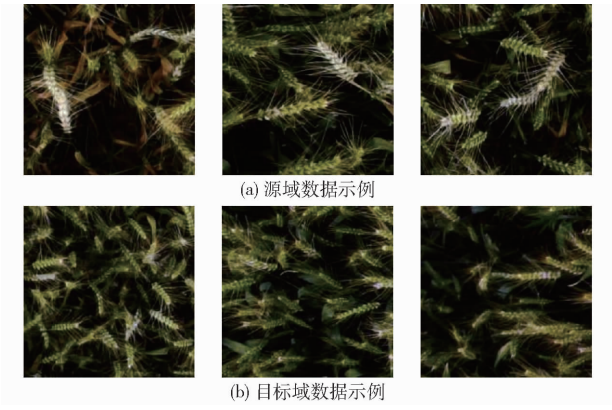

(a) 源域数据示例

(b) 目标域数据示例

图 4 源域与目标域数据示例

Fig. 4 Examples of source and target domain data

2 研究方法

本文以双阶段检测网络 Faster R - CNN 作为基准网络,构建 SPD - DANet。基于 Faster R - CNN 两阶段检测器的优势,在分类和边界框回归步骤中分别引入域自适应学习,以生成相应的伪标签[22],从而提升检测网络在目标域的性能。

2.1 空间深度转换域自适应检测网络

SPD - DANet 主要由 3 个模块组成:检测模块(Faster R - CNN)、分类自适应模块(SPD-classify adaptor)、边界框回归自适应模块(SPD-bbox adaptor)。其中检测模块的主要功能是生成候选框以用于后续训练,自适应模块的目的是为检测网络生成目标域的对应伪标签。2 个自适应模块之间保持着级联关系:分类自适应模块接收检测网络生成的候选框进行训练,生成较为准确的前景候选框用于边界框回归模块的训练。检测网络与 2 个自适应模块之间形成自反馈回路:检测网络生成候选框用于训练自适应模块。高质量的候选框能够提升自适应模块的域自适应性能,从而生成更优质的伪标签,进一步用于检测网络的训练。高质量的伪标签提升了检测网络的性能,进而生成更精确的候选框,完善域自适应过程。

为了形成良好的上述自反馈回路,首先需要使用源域标签对检测网络进行预训练,使其具备检测小麦赤霉病的能力。然后利用预训练的检测网络分别获取源域候选框 D_s^{prop} 和目标域候选框 D_t^{prop}。基于所生成的候选框,可以对 2 个自适应模块进行训练。训练完成后,自适应模块将为目标域生成相应的类别伪标签 y_t^{cls} 和边界框伪标签 b_t^{reg}。这些伪标签将用于训练检测网络,从而提升其在目标域无监

督检测任务中的性能。

本文针对无人机小麦图像中赤霉病病斑较小的问题，设计了适用于小目标的空间深度转换特征提取器（Space-to-depth feature extractor，SPD－FE），该模块通过用更有效的信息提取卷积层 SPD－Conv[23] 替换 Resnet101[24] 中部分卷积层，从而提取出更多有用的特征，提升小目标的检测能力。该特征提取器被应用于 2 个域自适应模块，以更精确地提取有用特征，从而生成高质量的伪标签。图 5 为 SPD－DANet 网络整体结构图。

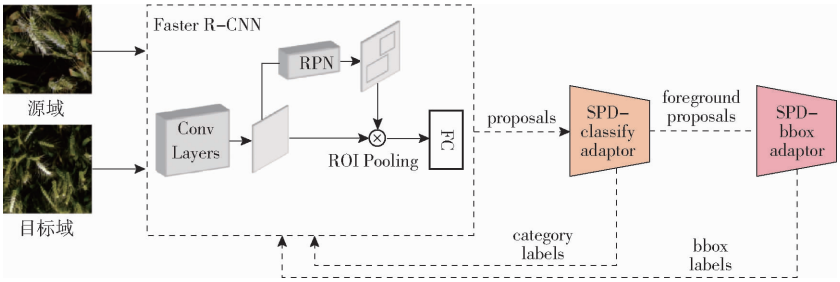

图 5　SPD－DANet 整体结构图

Fig. 5　SPD－DANet structure

2.2　空间深度转换自适应

2.2.1　分类自适应模块

分类自适应的主要目的是利用有标注的源域数据来获得无标注目标域数据相对准确的分类预测。如图 6 所示，SPD－classify adaptor 由特征提取器 SPD－FE 和域分类器 D 组成[15]，域分类器的目的是将每个类的源域候选框和目标域候选框分开，而特征提取器则需提取特征欺骗域分类器，使其将目标域数据视为源域数据。训练阶段主要有 2 个任务：首先，特征提取器需要提取能够欺骗域分类器的特征；其次，需要混淆源域数据和目标域数据，以最大化域分类误差。为应对域分类器与特征提取器任务的不同，使用梯度反转层（GRL）在两者之间形成对抗关系，从而优化分类自适应的训练。最终，域分类器的目标是

$$\max_{D} L_{\text{adv}}^{\text{cls}} = E_{x_s \sim D_s^{\text{prop}}} \omega(c_s) \lg D(f_s, g_s) + E_{x_t \sim D_t^{\text{prop}}} \omega(c_t) \lg(1 - D(f_t, g_t)) \tag{3}$$

式中　$\omega(c)$——与置信度呈正相关的权重

f_s、f_t——源域和目标域特征表示

g_s、g_t——源域和目标域对应的类别预测

$E_{x_s \sim D_s^{\text{prop}}}$、$E_{x_t \sim D_t^{\text{prop}}}$——源域和目标域候选框分布期望

$L_{\text{adv}}^{\text{cls}}$——域分类器损失函数

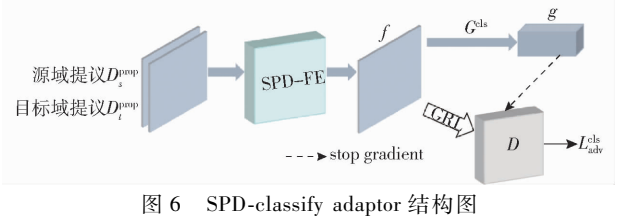

图 6　SPD-classify adaptor 结构图

Fig. 6　Architecture of SPD-classify adaptor

特征提取器 SPD－FE 的目的是学习域不变特征以欺骗域分类器，使其无法区分所输入的特征是来自源域还是目标域。经过训练后的 SPD-classify adaptor 能够为目标候选框 $x_t \in D_t^{\text{prop}}$ 生成对应的类别伪标签 y_t^{cls}，并生成前景候选框参与后续 SPD-bbox adaptor 的训练。

2.2.2　边界框自适应模块

目标检测的域自适应通常比分类任务更具挑战性，因为它包含分类和定位 2 个部分，而以往的研究主要集中在类别适应。为使检测任务的域自适应更加全面，本文在分类自适应的基础上，进一步引入边界框回归的自适应模块[25]。

边界框自适应的主要目的是利用有标注的源域数据来为无标注的目标域数据生成边界框伪标签。由于目标域没有真实标签，本文采用分类自适应步骤获得的预测来训练 SPD-bbox adaptor。如图 7 所示，SPD-bbox adaptor 由特征提取器 SPD－FE 和 2 个回归器网络 G^{reg} 和 $G_{\text{adv}}^{\text{reg}}$ 构成[25]。该部分所接收的输入为类别适应器所得到的前景候选框 D^{fg}，特征提取器 SPD－FE 接收候选框并提取可用的特征用于回归器网络。SPD-bbox adaptor 采用与分类自适应类似的对抗思想，对抗性回归器 $G_{\text{adv}}^{\text{reg}}$ 的目标是最大化其与目标域主要回归器（G^{reg}）的差异，同时最小化与源域主要回归器的差异。即引导对抗性回归器在源域上正确预测，并在目标域上尽可能地犯错误，从而鼓励特征提取器 SPD－FE 提取域不变特征。因此对抗性回归器的损失函数为

$$\max_{G_{\text{adv}}^{\text{reg}}} L_{\text{adv}}^{\text{reg}} = E_{(x_t, y_t) \sim D_t^{fg}} \text{smooth}_{\text{L1}}(t_{\text{adv}}^{y_t^{\text{cls}}}, t^{y_t^{\text{cls}}}) + E_{(x_s, y_s) \sim D_s^{fg}} \text{smooth}_{\text{L1}}(t_{\text{adv}}^{y_s^{gt}}, t^{y_s^{gt}}) \tag{4}$$

式中　$E_{(x_t, y_t) \sim D_t^{fg}}$、$E_{(x_s, y_s) \sim D_s^{fg}}$——目标域和源域的前景样本分布期望

$t_{\text{adv}}^{y_t^{\text{cls}}}$——目标域基于预测类别的对抗性边界框偏移量

$\text{smooth}_{\text{L1}}$——平滑 L1 损失函数

$t_i^{y^{\text{cls}}}$——目标域基于预测类别的标准边界框偏移量

$t_{\text{adv}}^{y_s^{gt}}$——源域基于真实类别的对抗性边界框偏移量

$t^{y_s^{gt}}$——源域基于真实类别的标准边界框偏移量

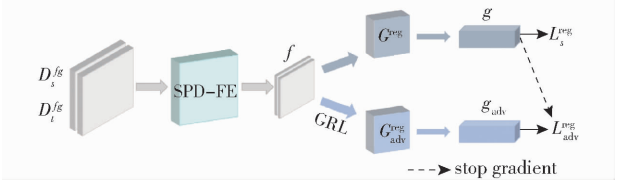

图 7 SPD-bbox adaptor 结构图

Fig. 7 Architecture of SPD-bbox adaptor

因为目标域并无真实标签,因此目标域上的 $\text{smooth}_{\text{L1}}$ 损失与预测类别相关,而源域上的 $\text{smooth}_{\text{L1}}$ 损失则与真实标签相关。经过训练后的 SPD-bbox adaptor 能够为目标域数据生成对应的边界框伪标签。经过分类和边界框回归 2 个步骤的域自适应学习后,能够为目标域生成伪标签用于检测网络的训练,从而实现对目标域的无监督检测。

2.2.3 空间深度转换特征提取器

为了更好地提取到源域和目标域的共同特征,本文选用与 Faster R-CNN 骨干网络一致的 Resnet101[24] 作为特征提取器。考虑到 Resnet 网络中使用了多个跨步卷积(即步长为 2 的卷积)可能会导致细粒度信息的丢失,并使网络学习到不够有效的特征,因此本文选择使用 SPD-Conv[23] 替换 Resnet 中的跨步卷积。

如图 8 所示,SPD-Conv 由一个空间深度转换(space-to-depth)层和一个非跨步卷积层(stride 为 1)组成。空间深度转换(SPD)层是一个简单的拆分与组合操作,它将特征图沿着宽度和高度的方向隔像素拆分,然后沿着通道方向进行拼接形成新的特征图。本文选择使用 SPD-Conv 替换 Resnet101 中步长为 2 的卷积,即每个 bottleneck block 中的跨步卷积。图 8 中,s 和 c 分别为特征图的尺度和通道维度,c' 为拼接后特征图的通道维度。

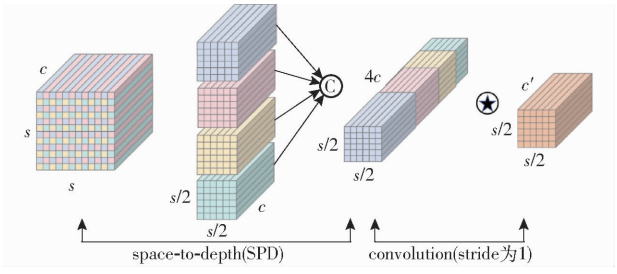

图 8 SPD-Conv 原理图

Fig. 8 Schematic of SPD-Conv

最终得到的 SPD-FE 的具体结构如表 1 所示。与 Resnet 类似,其卷积层代表 SPD-FE 中的各个层名,SPD-FE 结构代表各个层所对应的结构。

表 1 SPD-FE 结构

Tab. 1 Structure of SPD-FE

卷积层	SPD-FE 结构
Conv1	7×7,64,stride 为 2
	3×3 max pool,stride 为 2
Conv2_x	$\begin{bmatrix}1\times1 & 64\\3\times3 & 64\\1\times1 & 256\end{bmatrix}\times3$
	SPD-bottleneck block
Conv3_x	$\begin{bmatrix}1\times1 & 128\\3\times3 & 128\\1\times1 & 512\end{bmatrix}\times3$
	SPD-bottleneck block
Conv4_x	$\begin{bmatrix}1\times1 & 256\\3\times3 & 256\\1\times1 & 1\,024\end{bmatrix}\times22$
	SPD-bottleneck block
Conv5_x	$\begin{bmatrix}1\times1 & 512\\3\times3 & 512\\1\times1 & 2\,048\end{bmatrix}\times2$

3 实验及结果分析

本文模型训练参数设置为:学习率为 0.005,训练轮数为 16 轮,批量大小为 2,权重衰减为 0.000 1。实验的硬件条件为:Intel(R) Xeon(R) Gold 6226 CPU@2.70 GHz,NVIDIA GeForce GTX 3080。为确保数据中涵盖多个角度的病害图像,在进行训练时,网络会对所输入数据进行随机角度旋转[21] 等增强操作,以丰富学习信息。实验时首先利用源域对检测网络进行预训练,然后在无标注的目标域中使用预训练得到的权重进行域自适应迁移学习。由于域自适应模块与检测器不共享参数,因此在域自适应训练完成后,可以丢弃这 2 个域自适应模块,直接使用检测器对目标域进行检测。

3.1 常用目标检测网络对比结果

表 2 给出了常用目标检测网络在源域中训练然后在目标域中检测的对比结果。结果显示,在未进行域自适应迁移学习的情况下,网络难以有效利用源域学习到的知识,目标尺度的差异会导致检测网络在目标域上表现不佳。其中表现最好的检测网络为 Faster R-CNN + FPN,其检测精度为 62.6%(AP50),表现最差的为 Retinanet,其检测精度为 47.4%(AP50),相较于本文所提出方法的 67.9%(AP50)分别低 5.3、20.5 个百分点。本文方法在目标域无监督检测中获得最佳结果,且比基线检测网

表 2　不同检测网络对目标域检测结果

Tab. 2　Detection results of different detection networks on target domain

检测网络	AP50/%	推理速度/(f·s^{-1})	参数量
Retinanet	47.4	15	5.490×10^7
DETR	54.7	30	4.128×10^7
YOLO v8	56.4	34	3.000×10^6
YOLO v5	54.6	38	1.760×10^6
Faster R－CNN＋FPN	62.6	14	6.024×10^7
Faster R－CNN	61.4	17	5.190×10^7
SPD－DANet	67.9	17	5.190×10^7

络(Faster R－CNN)提高 6.5 个百分点。综上,本文方法检测精度的显著提升验证了其在目标域无监督检测任务中的有效性,但其推理速度(17 f/s)和参数量(5.19×10^7)略逊色于其他高效网络(如 YOLO v5 和 YOLO v8),因此关于实现域自适应迁移学习模型的轻量化有待进一步研究。

图 9 展示了不同检测网络在经过源域训练后,对目标域检测的可视化结果对比。可以看出,经过引入域自适应迁移学习后,检测网络有效利用了源域训练中获得的知识,从而显著提升了其在目标域上的检测性能。

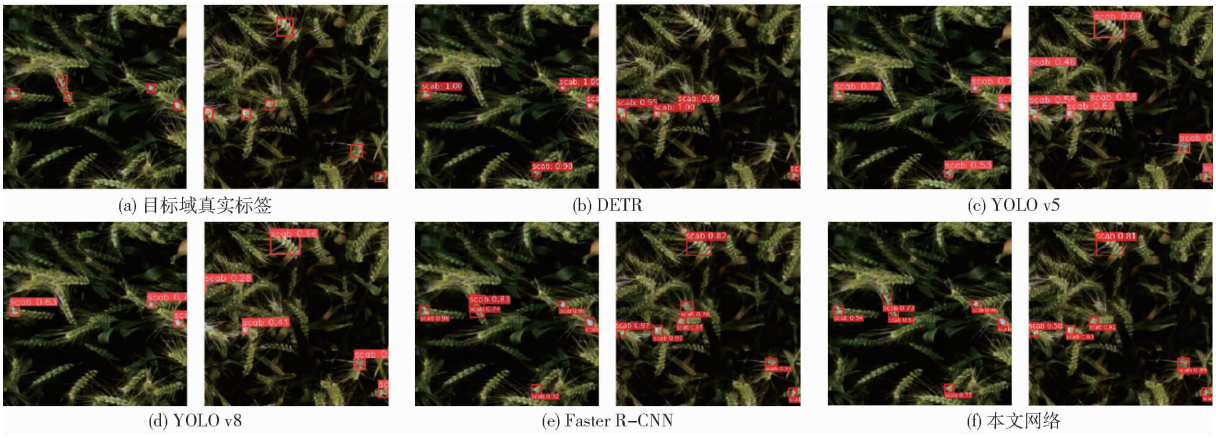

图 9　不同网络检测结果的可视化图像

Fig. 9　Visualization images of different network detection results

3.2　基于域自适应迁移学习的目标检测网络对比结果

图 10 展示了不同域自适应网络在目标域的无监督检测结果。从图 10 可以看出,本文方法在目标域上表现出最佳的检测性能。相比之下,添加了特征金字塔网络(FPN)的 Faster R－CNN 在域自适应中的效果并不理想,原因在于特征金字塔的引入会导致源域和目标域之间的特征偏移,使得检测网络难以将源域训练中获得的知识迁移到目标域,从而增加了域自适应的难度。此外,基于 Faster R－CNN 的 PT[17]模型在进行域自适应后,其检测精度反而有所下降,成为所有模型中的最低值。这主要是因为 PT 模型将 Faster R－CNN 增强为概率检测器,即将类别和定位标签表示为概率分布,这种处理方式不适合用于小麦赤霉病这样的小目标数据集。并且该模型并未像本文的方法那样将域自适应模块与检测网络解耦,而是直接对检测网络中骨干网络提取的特征进行域自适应,这种强行拉近源域和目标域的操作在一定程度上影响了检测网络的性能。尽管 Decoupled 网络同样采用了解耦结构的设计理念,但其网络架构缺乏针对小目标检测的针对性优化。因此,在小麦赤霉病无监督检测任务中,其检测精度略

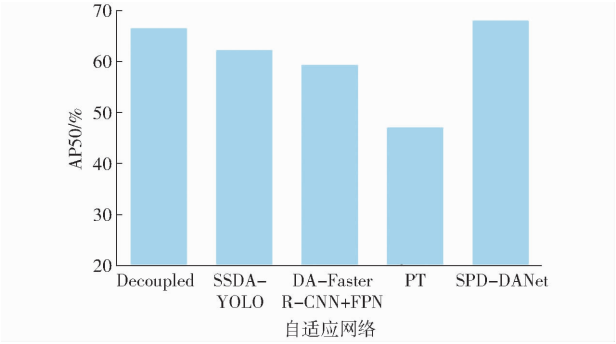

图 10　不同域自适应网络结果比较

Fig. 10　Comparison of results from different domain adaptive networks

逊于本文方法。最后,SSDA－YOLO[26]是基于单阶段检测网络 YOLO v5 的域自适应方法,并未对小目标问题进行专门处理,因此在面对本文所研究的小麦赤霉病检测问题时效果并不理想。

3.3　不同农作物及病害检测方法对比结果

图 11 展示了本文方法与其他农作物及病害检测方法的对比结果。其中文献[27]中提出的基于无人机遥感图像的轻量级小麦赤霉病检测网络,使用混合深度卷积(MixConv)监测田间环境中的小麦赤霉病。文献[28]介绍了一种新颖的高密度高层次合成检测变换器方法,能够有效实现水稻鞘枯病、

稻瘟病和亚麻斑病 3 种病害的检测。文献[29]提出高精度端到端网络 WH－DETR,该网络基于增强版的 RT－DETR 架构,实现了对麦穗的精确检测。对比结果显示,文献[29]提出的 WH－DETR 网络表现优异,该方法采取多种数据增广方式来提高模型的泛化能力,因此在目标域上获得了较好的检测结果。本文方法在检测模型基础上引入域自适应学习,使得模型能更好地从有足够标记训练数据的源域迁移至仅有未标注数据的目标域,从而实现最佳检测效果。

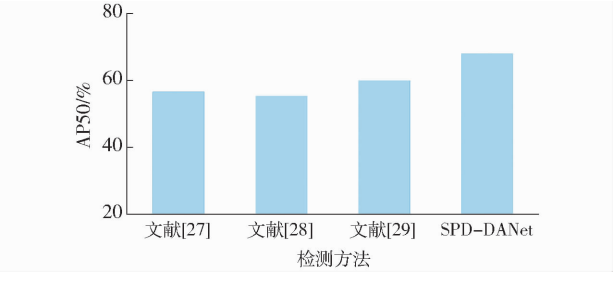

图 11 不同农作物及病害检测方法对比

Fig. 11 Comparison of different crops and disease detection methods

3.4 消融实验

为了验证本文方法的有效性,进行了消融实验,结果如表 3 所示。由表 3 可知,未添加域自适应模块 SPD-classify adaptor 和 SPD-bbox adaptor 时,仅依靠源域训练的检测网络在目标域上的检测效果不理想。然而,添加这 2 个模块后,目标域的检测精度提高 6.5 个百分点,无监督目标检测性能得到了显著改善。此外,通过逐步添加这 2 个模块进行实验,进一步验证了它们在提升检测精度方面的有效性。

引入域自适应迁移学习后,尽管检测网络不需要目标域的标注数据进行训练,但目标域的图像数据仍然是域自适应训练过程中的必要组成部分。因此,参与训练的图像数据规模成为一个重要的研究问题。本文对此进行了实验,验证了不同规模的图像数据对域自适应结果的影响。实验结果表明,减少训练图像的规模会影响检测网络在目标域上的预测以及域自适应模块的训练效果,从而降低检测网络在目标域的整体检测性能。

表 3 消融实验结果

Tab. 3 Results of ablation experiments

SPD-classify adaptor	SPD-bbox adaptor	AP50/%
×	×	61.4
√	×	63.7
√	√	67.9

注:“√”表示使用此模块,“×”表示不使用此模块。

4 结束语

针对无人机采集数据中随着飞行高度增加而导致目标尺度减小、标注难度加大的问题,本文提出了 SPD－DANet 网络。该方法通过引入域自适应迁移学习,使检测网络能够在仅有源域标注的情况下,实现对目标域的无监督检测,从而显著减少标注工作量。通过与不同检测网络的对比,验证了域自适应迁移学习的有效性。针对无人机小麦图像赤霉病的检测,创建了有标注的源域数据集,将其作为无标注目标域进行域自适应迁移学习的知识来源。为实现目标域的无监督检测,在检测网络基础上添加了 2 个域自适应模块(SPD-classify adaptor 和 SPD-bbox adaptor),使检测网络能够学习源域的知识并应用于目标域检测。此外,为解决无人机图像中小麦赤霉病病斑较小的问题,设计了适用于小目标的特征提取器 SPD－FE。实验结果表明,本文所提出的模型在赤霉病无监督检测任务中取得了最佳性能,其 AP50 达到 67.9%,均优于所对比的各类检测网络与域自适应方法。此外,消融实验系统地验证了模型中各模块的有效性。

参 考 文 献

[1] FIGUEROA M, HAMMOND-KOSACK K E, SOLOMON P S. A review of wheat diseases—a field perspective[J]. Molecular Plant Pathology, 2018, 19(6): 1523－1536.

[2] HELLEMANS T, LANDSCHOOT S, DEWITTE K, et al. Impact of crop husbandry practices and environmental conditions on wheat composition and quality: a review[J]. Journal of Agricultural and Food Chemistry, 2018, 66(11): 2491－2509.

[3] LEGRAND F, PICOT A, COBO-DÍAZ J F, et al. Challenges facing the biological control strategies for the management of fusarium head blight of cereals caused by F. graminearum[J]. Biological Control, 2017, 113: 26－38.

[4] 杜海顺, 张春海, 安文昊, 等. 基于多层信息融合和显著性特征增强的农作物病害识别[J]. 农业机械学报, 2023, 54(7): 214－222.
DU Haishun, ZHANG Chunhai, AN Wenhao, et al. Crop disease recognition based on multi-layer information fusion and saliency feature enhancement[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7): 214－222. (in Chinese)

[5] SHI Y, HAN L, KLEEREKOPER A, et al. Novel cropdocnet model for automated potato late blight disease detection from unmanned aerial vehicle-based hyperspectral imagery[J]. Remote Sensing, 2022, 14(2): 396.

[6] 袁培森, 欧阳柳江, 翟肇裕, 等. 基于 MobileNetV3Small－ECA 的水稻病害轻量级识别研究[J]. 农业机械学报, 2024,

55(1)：253－262.
YUAN Peisen, OUYANG Liujiang, ZHAI Zhaoyu, et al. Lightweight identification of rice diseases based on improved ECA and MobileNetV3Small[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 253－262. (in Chinese)

[7] 鲍文霞, 孙庆, 胡根生, 等. 基于多路卷积神经网络的大田小麦赤霉病图像识别[J]. 农业工程学报, 2020, 36(11)：174－181.
BAO Wenxia, SUN Qing, HU Gensheng, et al. Image recognition of wheat scab in field based on multiplexed convolutional neural network[J]. Transactions of the CSAE, 2020, 36(11): 174－181. (in Chinese)

[8] HU G, YE R, WAN M, et al. Detection of tea leaf blight in low-resolution UAV remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 1－18.

[9] BAO W, LIU W, YANG X, et al. Adaptively spatial feature fusion network: an improved UAV detection method for wheat scab[J]. Precision Agriculture, 2023, 24(3): 1154－1180.

[10] ZHAO J, YAN J, XUE T, et al. A deep learning method for oriented and small wheat spike detection (OSWSDet) in UAV images[J]. Computers and Electronics in Agriculture, 2022, 198: 107087.

[11] 李就好, 林乐坚, 田凯. 改进 Faster R－CNN 的田间苦瓜叶部病害检测[J]. 农业工程学报, 2020, 36(12)：179－185.
LI Jiuhao, LIN Lejian, TIAN Kai. Detection of leaf diseases of balsam pear in the field based on improved Faster R－CNN[J]. Transactions of the CSAE, 2020, 36(12): 179－185. (in Chinese)

[12] 田青, 朱雅喃, 马闯. 基于深度学习的域适应方法综述[J]. 数据采集与处理,2022,37(3):512－541.
TIAN Qing, ZHU Ya'nan, MA Chuang. A review of domain adaptation methods based on deep learning[J]. Journal of Data Acquisition & Processing,2022,37(3):512－541. (in Chinese)

[13] CHEN Y, LI W, SAKARIDIS C, et al. Domain adaptive faster R－CNN for object detection in the wild[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 3339－3348.

[14] SAITO K, USHIKU Y, HARADA T, et al. Strong-weak distribution alignment for adaptive object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 6956－6965.

[15] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks[J]. Journal of Machine Learning Research, 2016, 17(59): 1－35.

[16] HUANG J, SHEN S, ZHOU Z, et al. Discriminative distribution alignment for domain adaptive object detection[J]. Neurocomputing, 2022, 474: 48－59.

[17] HE M, WANG Y, WU J, et al. Cross domain object detection by target-perceived dual branch distillation[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 9570－9580.

[18] CHEN M, CHEN W, YANG S, et al. Learning domain adaptive object detection with probabilistic teacher[J]. arXiv Preprint, arXiv:2206.06293, 2022.

[19] 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 and Machine Intelligence, 2016, 39(6): 1137－1149.

[20] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]// European Conference on Computer Vision. Cham: Springer International Publishing, 2020: 213－229.

[21] BAO W, HUANG C, HU G, et al. Detection of Fusarium head blight in wheat using UAV remote sensing based on parallel channel space attention[J]. Computers and Electronics in Agriculture, 2024, 217: 108630.

[22] LEE D H. Pseudo-label: the simple and efficient semi-supervised learning method for deep neural networks[C]// Workshop on Challenges in Representation Learning, ICML, 2013.

[23] SUNKARA R, LUO T. No more strided convolutions or pooling: a new CNN building block for low-resolution images and small objects[C]// Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Cham: Springer Nature Switzerland, 2022: 443－459.

[24] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770－778.

[25] JIANG J, CHEN B, WANG J, et al. Decoupled adaptation for cross-domain object detection[J]. arXiv Preprint, arXiv: 2110.02578, 2021.

[26] ZHOU H, JIANG F, LU H. SSDA－YOLO: semi-supervised domain adaptive YOLO for cross-domain object detection[J]. Computer Vision and Image Understanding, 2023, 229: 103649.

[27] YIN N, BAO W, YANG R, et al. LWSDNet: a lightweight wheat scab detection network based on UAV remote sensing images[J]. Remote Sensing, 2024, 16(15): 2820.

[28] YANG H, DENG X, SHEN H, et al. Disease detection and identification of rice leaf based on improved detection transformer[J]. Agriculture, 2023, 13(7): 1361.

[29] YANG Z, YANG W, YI J, et al. WH－DETR: an efficient network architecture for wheat spike detection in complex backgrounds[J]. Agriculture, 2024, 14(6): 961.