

基于轻量级模型的森林火灾图像协同识别方法

刘润滋¹, 柳辰伟¹, 吴伟华², 夏文超³, 王燕妮¹, 张琰⁴

(1. 西安建筑科技大学信息与控制工程学院, 陕西 西安 710399; 2. 陕西师范大学物理学与信息技术学院, 陕西 西安 710119;
3. 南京邮电大学通信与信息工程学院, 江苏 南京 210003; 4. 西安电子科技大学通信工程学院, 陕西 西安 710071)

摘要: 基于物联网的环境监测体系是森林火灾早期预警的重要基础设施, 对遏制灾害蔓延具有决定性作用。然而, 部署于野外的监测终端存在通信带宽受限、计算能力弱、能源供给有限的问题, 使其既难以将大量高清图像实时回传, 又无法在设备端部署并运行复杂的神经网络模型。为此, 本文设计了一种基于“端-云”协同的森林火灾识别方法。通过在监测终端上部署轻量级识别模型和卸载模型, 终端采集到的大部分图像可以在边缘侧完成本地识别; 仅当轻量级模型难以准确识别的少量图像, 才通过物联网网络卸载到森林防火指挥中心进行云端识别, 从而在满足物联网应用对低延迟、低带宽和低能耗核心需求的同时, 兼顾了识别准确性。所设计的轻量级森林火灾图像识别模型结合了 Ghost Module 和 ShuffleNetv2, 并引入 ECA (Efficient Channel Attention) 注意力模块, 显著降低了对计算和存储资源的需求。为了提高卸载决策在动态物联网环境下的有效性, 提出了一种融合噪声网络的双缓冲区近端策略优化算法 (Noisy Double Proximal Policy Optimization, NDPPO) 来训练卸载模型。通过对比实验验证了所提出的面向物联网的轻量级森林火灾协同识别方法的有效性。

关键词: 森林火灾识别; 轻量级模型; 协同识别; 策略优化算法; 物联网监测终端

中图分类号: TP391

文献标志码: A

doi: 10.11959/j.issn.2096-3750.XXXX.

Collaborative Forest Fire Identification: A Lightweight Model-Based Approach

LIU Runzi¹, LIU Chenwei¹, WU Weihua², XIA Wenchao³, WANG Yanni¹, ZHANG Yan⁴

1. College of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710399, China

2. School of Physics and Information Technology, Shaanxi Normal University, Xi'an 710119, China

3. School of Telecommunications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

4. School of Telecommunications Engineering, Xidian University, Xi'an 710071, China

Abstract: IoT-based environmental monitoring systems are crucial infrastructure for early forest fire warnings, playing a decisive role in preventing disaster spread. However, field-deployed terminals face limitations in communication bandwidth, computational power, and energy supply, hindering both real-time transmission of high-resolution images and on-device deployment of complex neural networks. This paper proposes an edge-cloud collaborative forest fire recognition method. Lightweight recognition and offloading models are deployed on terminals. Most images are processed locally at the edge; only images challenging for the lightweight model are offloaded via the IoT network to a cloud center for recog-

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 吴伟华, whwu@snnu.edu.cn

基金项目: 国家自然科学基金项目 (No.61701365); 中国科协青年人才托举工程项目 (No.2022QNRC001); 陕西省重点研发计划项目 (No.2025CY-YBXM-063); 陕西省自然科学基金基础研究计划项目 (No.2025JC-YBMS-791)

Foundation Items: The National Natural Science Foundation of China (No.61701365), Young Elite Scientists Sponsorship Program by CAST (No.2022QNRC001); Key Research and Development Program of Shaanxi Province (No.2025CY-YBXM-063); Natural Science Basic Research Program of Shaanxi (No.2025JC-YBMS-791)

nition. This balances recognition accuracy with the core IoT requirements of low latency, low bandwidth, and energy efficiency. The designed lightweight fire recognition model integrates Ghost Module and ShuffleNetv2, enhanced with an Efficient Channel Attention (ECA) module, significantly reducing computational and storage demands. To improve offloading decision effectiveness in dynamic IoT environments, a Noisy Double Proximal Policy Optimization (NDPPO) algorithm is proposed to train the offloading model. Comparative experiments validate the effectiveness of this lightweight collaborative recognition approach for IoT-based forest fire monitoring.

Key words: forest fire identification, lightweight model, collaborative identification, strategy optimization algorithm, IoT monitoring terminal

0 引言

森林在生态系统中扮演着至关重要的角色，不仅为人类提供了丰富的资源，还通过其独特的生态功能，吸收大气中的二氧化碳，在对抗全球气候变化中发挥着不可忽视的作用^[1]。然而森林中树木茂密，地面覆盖着厚厚的枯枝落叶等易燃物质，容易由于气候、人为等因素引发火灾。根据国家统计局官方网站的统计，我国在2020-2024年间共计发生3098次森林火灾，森林受害面积超24507.5公顷。其中于2020年四川凉山州西昌市发生的“3·30”森林火灾，造成了22名扑火人员伤亡^[2]。森林火灾如果在初期没有及时发现，就会难以控制，从而产生较大的经济损失和人员伤亡。因此，及时准确地发现火灾并预警具有十分重要的研究和现实意义，森林火灾监测部门需要实时监测森林火灾情况并迅速做出反应。

传统的森林火灾监测方法包括由护林员及森林专业防火人员对林区进行地面巡逻，这种方式可以深入森林内部，但存在盲区大、响应慢等局限，物联网技术的引入实现了森林火险从“被动应对”到“主动预防”的革命性转变。例如，利用卫星遥感技术进行大范围的火情监测^[3]，覆盖面积大，数据采集快，但遥感卫星的分辨率有限且机动灵活性差，难以实现连续监测。目前，近地视频监控技术^[4]凭借其实时性、高分辨率、自动化识别能力以及灵活的部署方式，在森林火灾监测中展现出显著的优势。视频监控通过部署在关键区域的固定摄像头或其他物联网监测终端，对林区进行不间断的实时监测，能够快速捕捉火灾的早期迹象，从而实现对火灾的及时预警和响应。文献[5]提出了一种基于卷积神经网络的轻量级模型来进行森林火灾识别，但对火灾识别的准确率不佳。文献[6]通过使用模型服务器框架来提升检测和预警森林火灾的精度，

但由于模型复杂度较高，无法部署在资源受限的物联网监测终端上，需要通过物联网无线信道回传到指挥中心（云端）再进行识别，导致识别的实时性降低。

为了兼顾监测实时性和识别准确率，本文提出了一种基于“端-云”协同的森林火灾识别方法。通过在物联网监测终端（端）上部署轻量级识别模型和卸载模型，实现了边缘侧本地识别和云端卸载识别的互补。具体而言，所设计的轻量级森林火灾识别模型使用 Ghost Module 生成具有足够表达能力的特征图，并使用 ShuffleNetv2 的通道分离和重排操作在减少计算量的同时提升特征图的表达能力。随后，引入 ECA 注意力模块，通过强化 Ghost Module 和 ShuffleNetv2 中不同分组间的通道信息交互来进一步提升模块的特征提取能力，显著降低了对物联网终端计算和存储资源的需求。同时，提出了一种引入噪声网络的双缓冲区近端策略优化算法（NDPPO）来训练卸载模型，在基于动态物联网网络环境下的无线信道传输状态控制卸载率的同时保障了协同识别的准确性。最后通过对 Flame Vision 和 FIRE 等多个数据集整合进行验证实验。实验结果表明，本文提出的轻量级识别模型在维持低计算复杂度的前提下取得了良好的识别性能。除此之外，物联网监测终端（端）和森林防火指挥中心（云）的协同模式既保证较低的卸载率又提高了识别的准确率。

1 相关工作

传统的火灾检测算法主要通过物理传感器采集火灾数据进行火灾监测，但是检测准确性和实时性得不到保证。随着计算机技术不断发展，利用深度学习辅助实现自动目标检测的方法得到了广泛的关注^[7-10]。文献[7]中的工作在轻量级设备上部署了基于深度学习的双异构卷积神经网络（Bi-CNN），该

方法针对视频数据，提取空间和时间信息，用于确定视频属于哪个类别。文献[8]开发设计了一个森林火灾探测和监测的监视系统，由机器学习平台分析数据集以及使用移动应用程序向用户发出警报。该监视系统的探测和监测任务并行执行，并整合形成一个完整的森林火灾探测应用程序。YOLO从2016年被提出就受到广泛关注，作为目标检测算法也被应用于森林火灾检测^[9-10]。文献[9]首次使用基于大规模YOLOv3网络的火灾检测算法，然后将该算法应用于森林火灾探测平台。在文献[9]的平台中，采集到的图像被传回地面站，通过所提出的YOLOv3算法对图像进行实时高精度处理。文献[10]改进了YOLOv5算法，通过集成新颖的部分卷积（PConv）来增强YOLOv5架构，以减少模型参数并提高处理速度。尽管上述文章中使用深度学习模型实现了自动目标检测，但由于轻量级设备的计算资源有限，这些方法很难直接部署在此类设备上。

在识别任务中，监测设备在采集图像的同时又要对图像进行识别，在这种应用场景下往往需要轻量级网络模型来实现高效的计算和快速的响应，以适应资源受限的环境。文献[11]通过在卷积神经网络中引入深度可分离卷积和倒残差结构的方法实现了模型的轻量化。文献[12]提出了一种基于YOLOv5的轻量级目标检测模型，该模型基于YOLOv5的整体结构，采用MobileNetv3作为主干网络，用半监督知识蒸馏（SSL）进行训练，提高了模型的收敛速度和精度。文献[13]提出了一种结合Ghost模块和MobileNetv3的新型轻量级网络，通过改变卷积层的数量，降低了网络计算的成本。Kang等人开发了一种基于图像感知和通道条件的轻量级语义块传输模型^[14]，并使用深度强化学习来探索各种通道条件下对云分类器贡献最大的语义块。但是上述的工作仍然没有实现识别精度和模型复杂度的平衡。本文设计了一个轻量级森林火灾识别模型，在准确率和轻量化方面都取得了良好的表现。目前监测设备搭载轻量级识别模型完成特定的识别任务，取得了一定实时性和识别精度的保障。但是在森林火灾识别的场景中，仅仅由轻量级模型识别火灾的精度可能无法达到当前的场景所需的标准。目前的一种解决方案是将监测设备采集到的图像卸载到远程处理后台。比如，文献[15]设计了一

个任务调度策略，在考虑到能源容量限制下，最大限度的减少所有任务的卸载和计算延迟。文献[16]在天地空一体化网络中，通过解决约束马尔可夫决策过程问题做出信道访问和任务卸载决策，其目的是最小化长期平均能耗来降低延迟。文献[17]采用不同的图像识别算法，并使用深度Q网络（Deep Q-Network, DQN）算法作为任务卸载决策模块，以获得更高的平均值识别准确率。在上述工作所设计的算法没有考虑到图像卸载过程中的通信条件。本文所提出的轻量级识别模型已经达到了一定的精度，同时又设计了卸载算法，在强化学习环境中引入噪声网络，增强模型的探索能力进一步提升火灾图像的识别精度。

2 轻量级的森林火灾协同识别方法




图1 协同识别场景

本文考虑如图1所示的森林火灾识别场景，其由若干分布在森林中的监测站点和一个森林防火指挥中心构成。监测站点顶端装有摄像头、计算单元以及无线通信模块，其中摄像头负责对监测站四周森林持续成像，计算单元负责装载轻量级识别模型判断所获取的图像是否有火灾现象，无线通信模块负责将图像识别出的火灾信息传输到森林防火指挥中心。防火指挥中心负责识别接收监测站的图像，并根据识别结果和监测站上报的火灾信息调度消防人员灭火。

图1所示场景中，由于监测站装备计算单元能力的限制，其部署的轻量级模型的识别准确性有限，未能达到森林火灾识别场景所需精度。虽然森林防火指挥中心具有足够高的识别精度，但由于无线信道传输能力的限制无法支持多机位高分辨率图像的实时传输。为了实现两种识别方式的优势互补，本文设计了一种轻量级森林火灾协同识别方

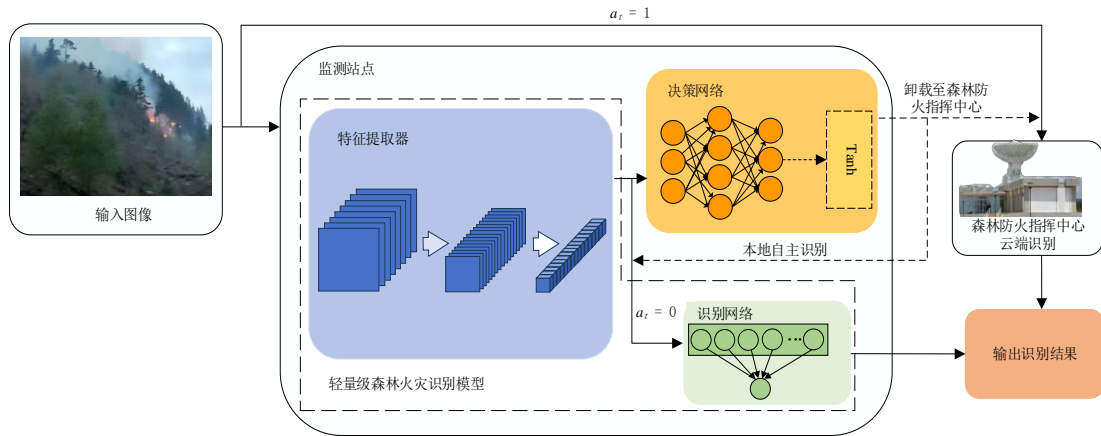


图2 轻量级的森林火灾协同识别方法

法。如图2所示，监测站点将采集到的图像传入特征提取网络。随后，卸载决策网络根据图像特征和无线信道传输状态做出决策， t 时刻的决策 a_t 定义为：

$$a_t = \begin{cases} 0, & \text{本地自主识别} \\ 1, & \text{卸载至森林防火指挥中心} \end{cases} \quad (1)$$

如果卸载决策网络输出的决策为 $a_t = 0$ ，特征

图被传入识别网络进行火灾识别。反之，如果决策网络输出决策为 $a_t = 1$ ，监测站点将图像发送到防火指挥中心，由云端出识别结果。上述方法通过决策网络将少量轻量级模型不易识别准确的图像卸载至防火指挥中心云端识别，大多数容易识别的图像保留至本地识别，从而既保障了识别准确率又避免了回传数据量过大超过无线链路的传输能力。

3 轻量级森林火灾识别模型

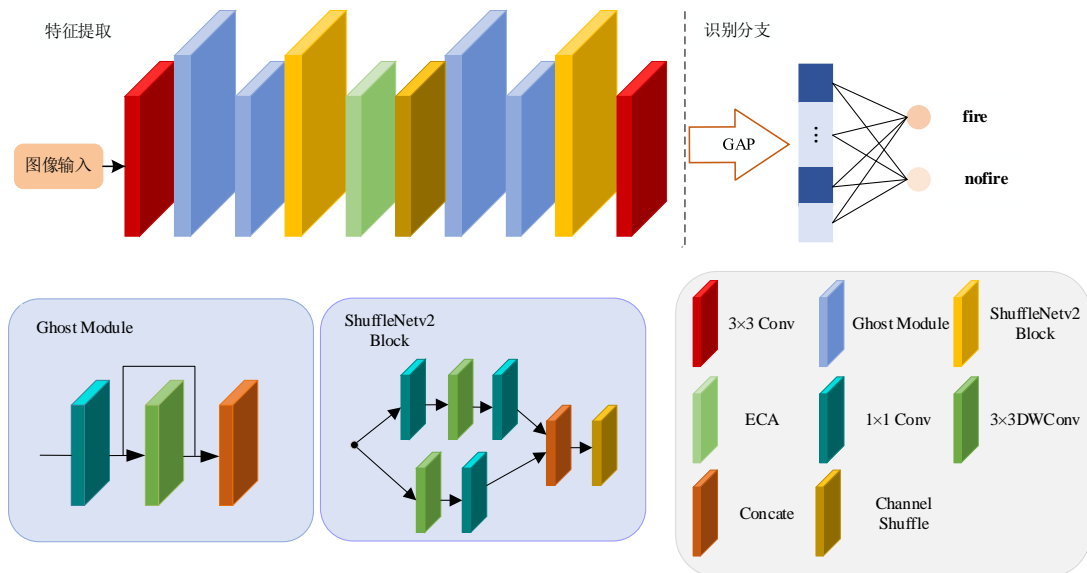


图3 轻量级森林火灾识别模型

针对轻量级设备计算资源受限的问题，本文设计了一种轻量级网络模型用于对监测摄像头采集到的图像进行实时推理。如图3所示，该模型融合了GhostNet^[18]中的Ghost Module模块与ShuffleNetv2^[19]的架构优势，通过优化特征提取与通道处理机制，在保证识别精度的同时显著降低了模型复杂度，使

其更适合在资源受限的边缘设备上部署。在所设计的模型中，Ghost Module模块可以在少量的“本征”特征图上应用简单的线性变换来生成更多的“幽灵”特征图。同时，为了提升特征图的表达能力，本文在Ghost Module模块和ShuffleNetv2模块中引入ECA注意力机制，其可以通过动态调整不

同通道的特征权重，使网络能够更关注重要的特征通道，从而提升模型性能。为了识别模型能够在资源受限的边缘设备上部署，本文在 ShuffleNetv2 模块中引入了通道分离和重排操作来实现特征的重用，其能够在减少计算量的同时保证网络的性能，使其更符合轻量化的标准。

假设轻量级网络的输入是摄像头采集到的照片 x_t 。本文将 softmax 和交叉熵损失结合起来作为损失函数。softmax 函数的表达式如下：

$$p_{i,t} = \frac{e^{f(x_t)_i}}{e^{f(x_t)_{fire}} + e^{f(x_t)_{nofire}}} \quad (2)$$

其中 $i \in \{fire, nofire\}$ ， $f(x_t)_i$ 是轻量级网络模型对 t 时刻输入图像 x_t 属于第 i 个类别的 logit 输出， $p_{i,t}$ 是对应的预测概率。通过这种方式，网络模型可以为每张输入图像输出一个概率分布，表示图像属于各个类别的概率。然后，使用交叉熵损失函数来衡量模型预测的概率分布与真实标签之间的差异。对于一个样本 x_t ，其交叉熵损失 G_t 计算如下：

$$G_t = - \sum_{i \in \{fire, nofire\}} y_{i,t} \log(p_{i,t}) \quad (3)$$

其中 $y_{i,t}$ 表示 x_t 是否属于类别 i ，即若 x_t 属于类别 i ，则 $y_{i,t} = 1$ ，否则 $y_{i,t} = 0$ 。计算所有样本的平均交叉熵损失，得到总损失函数 G ，其表达式为：

$$G = - \frac{1}{N} \sum_{t=1}^N \sum_{i \in \{fire, nofire\}} y_{i,t} \log(p_{i,t}) \quad (4)$$

其中 N 是样本总数。模型的训练目标是 minimized G ，使得模型对训练数据的预测尽可能接近真实标签。在确定损失函数作为衡量模型预测与实际结果差异的指标后，使用 Adam 优化器根据计算得到的梯度更新网络模型参数，减少损失函数的值。Adam 的更新公式为：

$$O_{t+1} = O_t - \eta \cdot \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \quad (5)$$

其中 O_t 和 O_{t+1} 分别是更新前后的参数值， η 是学习率， ϵ 是为了保持数值稳定性而添加的小常数。 m_t 和 v_t 分别为在训练到第 t 步时梯度的指数加权平均值和梯度平方的指数加权平均值，即一阶矩估计和二阶矩估计，表示为：

$$m_t = \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t \quad (6)$$

$$v_t = \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2 \quad (7)$$

其中 β_1 和 β_2 分别为一阶矩和二阶矩的衰减率，用于控制过去梯度信息的保留程度， g_t 是第 t 步的梯度。由于一阶矩和二阶矩的估计在初始阶段会受到初始

值的影响，因此式 (5) 中使用偏差校正后的一阶和二阶矩估计 \hat{m}_t 和 \hat{v}_t ，其分别表示为：

$$\hat{m}_t = \frac{m_t}{1 - \beta_1} \quad (8)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2} \quad (9)$$

4 基于改进 PPO 的卸载决策模型

所提出的森林火灾协同识别方法中，决策网络根据当前图像特征做出是否卸载的决策。由于无线信道的传输能力有限，如何精确卸载轻量级识别模型无法正确识别的图像，以提高卸载正确率，对整个协同方法的性能十分重要。为解决这一问题，本文将卸载决策过程建模为强化学习问题，并在近端策略优化算法中引入噪声网络进行求解从而得到卸载决策模型。

4.1 强化学习模型设计

针对当前任务场景中的火灾图像卸载决策问题，本文采用马尔可夫决策过程 (Markov Decision Process, MDP) 进行建模^[20]。MDP 框架由五元组 $\langle S, A, P, R, \gamma \rangle$ 构成，其中：

1) S 代表状态空间， t 时刻的状态 $s_t \in S$ 定义为轻量级模型输出得到的图像特征和当前信道传输系数，即 $s_t = [f(x_t), u_t]$ 。 u_t 表示在 t 时刻的无线信道传输系数，用于衡量当前无线信道的传输条件，其表达式为：

$$u_t = w_t \times \left(1 + \frac{\sum_{\tau=0}^t D_\tau}{\sum_{\tau=0}^t T_\tau} \right) \quad (10)$$

其中 w_t 为 t 时刻监测站点与防火指挥中心之间的回程传输速率。 T_τ 是 τ 时刻向地面卸载图像的数量， D_τ 是 τ 时刻卸载图像中获得正向奖励的数量。

2) $A = \{0, 1\}$ 为动作空间， a_t 为 t 时刻智能体 (监测站点) 根据状态 s_t 输出的动作 ($a_t = 0$ 表示本地自主识别， $a_t = 1$ 表示卸载至防火指挥中心)。

3) P 是转移概率，描述了智能体在采取某个动作后，从当前状态转移到下一个状态的概率。

4) γ 是用于权衡当前奖励与未来奖励重要性的折扣因子。

5) R 为奖励函数，用来衡量智能体在某个状态下所做动作好坏程度的函数。

智能体学习的目标是通过与环境交互来最大化积累获得的奖励，因此奖励函数的设计对智能体十

分重要。为了使所设计的协同识别方法兼顾识别准确性与实时性，既需要鼓励卸载轻量化模型识别不准确图像，又需要控制卸载率以避免超过无线信道的传输能力。因此，奖励函数设计为：

$$R_t(s_t, a_t) = \begin{cases} 0 & a_t = 0 \\ \zeta_1 & a_t = 1 \wedge u_t > M \wedge y_t \neq \hat{y}_t \\ \zeta_2 & a_t = 1 \wedge u_t > M \wedge y_t = \hat{y}_t \\ \zeta_3 & a_t = 1 \wedge u_t < M \wedge y_t \neq \hat{y}_t \\ \zeta_4 & a_t = 1 \wedge u_t < M \wedge y_t = \hat{y}_t \end{cases} \quad (11)$$

其中， ζ_1 和 ζ_3 为正数， ζ_2 和 ζ_4 为负数，且有 $\zeta_1 > |\zeta_2| > \zeta_3 > |\zeta_4|$ 。 y_t 代表真实标签， \hat{y}_t 代表轻量化模型的预测标签。 M 是判断无线信道的传输系数的门限值。监测站点执行是否要卸载决策之前，会先计算当前无线信道传输系数，如果 $u_t > M$ ，表示当前设备传输效率良好，适合采取卸载策略从而能够获得更多的奖励值，如果 $u_t < M$ ，表示当前设备传输效率较差，采取卸载策略获得奖励也会降低。这种方式可以有效限制监测站点为了获得奖励而导致的卸载率过高。除此之外，从式(11)中可以得到，当 $a_t = 0$ 时，不会卸载至防火指挥中心，因此没有奖励或惩罚。此外，如果监测站点预测的结果与防火指挥中心相同，则会因占用传输设备而受到惩罚。但是，为了防止监测站点为了避免惩罚而盲目选择 $a_t = 0$ ，本文所设计的惩罚值低于奖励值。总而言之，奖励函数的设计是鼓励监测站点将高风险火灾图像卸载至森林防火指挥中心，从而实现对火灾事件是否发生的准确判断。

4.2 PPO算法

为了有效解决解决本环境定义的状态和动作空间下的卸载决策问题，本文选择近端策略优化(Proximal Policy Optimization, PPO)^[21]作为基础算法框架，并在下一节对传统PPO进行改进。PPO融合了策略梯度方法与价值函数方法的优势，通常由策略网络(Actor)和价值网络(Critic)组成，两个网络的输入都是监测站点在环境中的状态 s 。策略网络的输出是一个概率分布，表示在给定状态 s 下选择不同动作的概率，记作 $\pi_\theta(a|s)$ ，监测站点将根据这个概率分布来选择是否进行图像卸载的动作。价值网络的输出是一个标量值，表示在给定策略 π_θ 下，从当前状态 s 开始的期望奖励。这个值帮助监测站点评估当前状态的好坏，从而指导策略网络做出更好的决策，记作 $V_{\pi_\theta}(s)$ 。PPO通过与环境

交互来收集数据，并记录下每一步的交互信息，包括状态、动作、奖励和下一个状态。收集到的数据会存储在缓冲区中，用于计算策略网络和价值网络的更新。

PPO算法的目标是最大化期望奖励，同时保持策略的更新的稳定性。目标函数是：

$$L^{CLIP+VF+S}(\theta) = \mathbb{E}_t \left[L_t^{CLIP}(\theta) - c_1 L_t^{VF}(\theta) + c_2 S[\pi_\theta](s_t) \right] \quad (12)$$

其中 $\mathbb{E}_t[\cdot]$ 是一个期望算子，表示对所有时隙的样本平均值， c_1 和 c_2 是超参数，用于平衡价值函数损失和策略熵在总目标函数中的权重。该目标函数主要由三个部分组成：剪裁目标函数 $L_t^{CLIP}(\theta)$ 、价值函数 $L_t^{VF}(\theta)$ 、熵奖励 $S[\pi_\theta](s_t)$ 。分别表示为：

$$L^{CLIP}(\theta) = \mathbb{E}_t \left[\min \left(r_t(\theta) \hat{A}_t, \text{clip} \left(r_t(\theta), 1 - \epsilon, 1 + \epsilon \right) \hat{A}_t \right) \right] \quad (13)$$

其中 $\text{clip}(r_t(\theta), 1 - \epsilon, 1 + \epsilon)$ 是裁剪函数，将 $r_t(\theta)$ 的值限制在 $[1 - \epsilon, 1 + \epsilon]$ 范围内，从而增加学习过程的稳定性和鲁棒性。 $r_t(\theta)$ 和 \hat{A}_t 分别为策略概率比率和优势函数，分别为：

$$r_t(\theta) = \frac{\pi_\theta(a_t|s_t)}{\pi_{\theta_{old}}(a_t|s_t)} \quad (14)$$

$$\hat{A}_t = -V(s_t) + r_t + \gamma r_{t+1} + \gamma^2 r_{t+2} + \dots + \gamma^{(T-t+1)} r_{T-1} + \gamma^{T-t} V(s_T) \quad (15)$$

其中 $r_t(\theta)$ 衡量了在特定状态下采取特定动作的概率在新策略和旧策略之间的变化，为了不让策略突然改变，所以采用裁剪函数限制其值。 $\hat{A}_t > 0$ 是估计的优势， $-V(s_t)$ 是估计的初始状态值， $\gamma^{T-t} V(s_T)$ 是估计的终末状态值，中间部分是过程中观测到的累计奖励。在学习过程中如果获得了更高的累积奖励，则 $\hat{A}_t < 0$ ，将更有可能在这种状态下采取行动。相反，如果期望更高的奖励但得到的奖励更小，则 $\hat{A}_t < 0$ ，将降低在此步骤中采取行动的可能性。 $L_t^{VF}(\theta)$ 是价值网络训练中的关键组成部分，它通过最小化预测价值和真实价值之间的差异来优化价值网络的参数，表示为：

$$L^{VF}(\theta) = \mathbb{E}_t \left[\left(V^\theta(s_t) - (r_t + \gamma V^\theta(s_{t+1})) \right)^2 \right] \quad (16)$$

这里 r_t 是在第 t 步获得的奖励， $V^\theta(s_t)$ 是在状态 s_t 的价值估计。最后，熵奖励 $S[\pi_\theta](s_t)$ 是策略 π_θ 在状态 s_t 的熵，鼓励探索并防止策略过早收敛到次优

解，其表示为：

$$S[\pi_\theta](s_t) = -\sum_a \pi_\theta(a|s_t) \log \pi_\theta(a|s_t) \quad (17)$$

4.3 融合噪声网络的双缓冲区策略优化算法

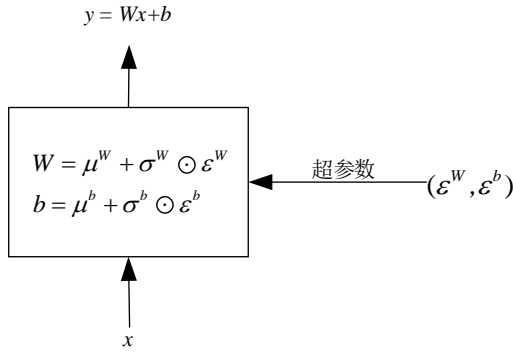


图4 融合噪声网络的决策网络线性层

本文在PPO算法的基础上引入了缓冲区和噪声网络^[22]用来训练卸载模型。将引入将噪声网络的策略网络定义为决策网络，其线性层如图4所示。通过引入噪声网络，使参数在带噪声的情况下进行学习从而增强智能体探索能力和网络泛化性，提升算法鲁棒性。改进前的决策网络线性层公式为：

$$y = Wx + b \quad (18)$$

其中 $x \in \mathbb{R}^p$, $W \in \mathbb{R}^{q \times p}$ 是权重矩阵, $b \in \mathbb{R}^q$ 是偏差。为在决策网络中引入噪声网络, 定义可学习参数 $\mu^w, \sigma^w \in \mathbb{R}^{q \times p}$, $\mu^b, \sigma^b \in \mathbb{R}^q$, 随机噪声 $\varepsilon \sim N(0, 1)$ 。使用 $\mu^w + \sigma^w \odot \varepsilon^w$ 和 $\mu^b + \sigma^b \odot \varepsilon^b$ 分别代替式(18)中的 W 和 b , 得到引入噪声网络的决策网络的线性层：

$$y = (\mu^w + \sigma^w \odot \varepsilon^w)x + \mu^b + \sigma^b \odot \varepsilon^b \quad (19)$$

在决策网络中引入噪声网络的基础上, 本文利用经验缓冲区 B_1 的数据构建了一个监督缓冲区 B_2 , 用于通过监督学习的方式优化决策网络。监督缓冲区中的每个元组表示为 $\langle s_t, H[r_t > 0] \rangle$, 其中 s_t 表示特征数据, 标签数据通过指示函数 $H[r_t > 0]$ 生成, 即当奖励 $r_t > 0$ 时返回 1, 否则返回 0。只有当 $a_t = 1$ 时, 才将对应时刻的状态 s_t 及其标签添加到监督缓冲区中, 即监督缓冲区表示为

$$B_2 = \{ \langle s_t, H[r_t > 0] \rangle | a_t = 1, \langle s_t, a_t, r_t, s_{t+1} \rangle \in B_1 \} \quad (20)$$

本文采用经验区和缓冲区结合来训练卸载模型, 其算法流程图如图5所示。监测站点首先与强化学习环境进行交互, 并将每组交互数据 $\langle s_t, a_t, r_t, s_{t+1} \rangle$ 记录并存入经验区中。当 B_1 填满时, 进行策略

迭代和价值迭代, 计算 $r_t(\theta)$, $L^{CLIP}(\theta)$, $S[\pi_\theta]$, $L^{VF}(\theta)$, 采用 Adam 依次更新决策网络和价值网络的参数。当 B_2 数据填满时, 首先计算交叉熵损失函数, 随后通过反向传播算法计算损失相对于模型参数的梯度, 并利用优化器更新决策网络的参数。训练完成的轻量级识别模型除了可以对森林火灾进行识别外, 还为卸载模型提供图像特征提取。最后通过经验区和缓冲区中的数据交替训练卸载模型。

5 实验结果及分析

5.1 数据集准备

本文将 Flame Vision 数据集、FIRE 数据集和 Forest Fire 数据集用于训练和测试轻量级森林火灾模型和卸载模型。Flame Vision 数据集是一个全面的航空图像数据集, 专门用于检测和分类林火。它总共由 8600 张高分辨率图像组成, 其中 5000 张描绘了火灾, 其余 3600 张描绘了非火灾场景。FIRE 数据集是由 Ahmed Saied 团队在 2018 年 NASA 太空应用挑战赛期间创建, 包含 755 张室外火灾图像, 其中一些包含浓烟, 另外是非火灾图像包含 244 张自然图像。Forest Fire 数据集主要由烟雾图像组成。为了进一步验证模型在不同场景下的泛化性能, 本文从三个基准数据集中分别选取部分样本构建增强数据集 (Forest Flame)。考虑到原始数据来源于视频帧截取, 为避免时序冗余, 采用等间隔采样策略 (采样间隔为 10 帧) 进行数据筛选并整合至扩展数据集。该数据增强方法有效模拟了森林火灾监测中可能出现的多模态场景变化, 包括不同光照条件、烟雾浓度及火焰形态等因素, 从而为模型鲁棒性评估提供更全面的测试基准。图6是部分数据示例。

5.2 轻量级森林火灾识别模型性能验证

为验证本文提出的轻量级模型的有效性, 在识别阶段, 将其与当前主流的轻量级网络模型 (包括 GhostNet、ShuffleNetV2、MobileNetV2^[23]、MobileNetV3^[24] 和 Mnasnet^[25]) 进行了对比实验。实验在 Flame Vision、FIRE、Forest Fire 以及自建数据集 Forest Flame 四个基准数据集上进行, 具体性能对比结果如表1所示。

由表1可以看出, 本文所提出的轻量化网络模型在火灾识别任务中展现出一定优势。该模型在 Forst Flame 数据集上取得了 82.13% 的准确率和 92.38% 的召回率, 较次优模型 GhostNet 分别显著

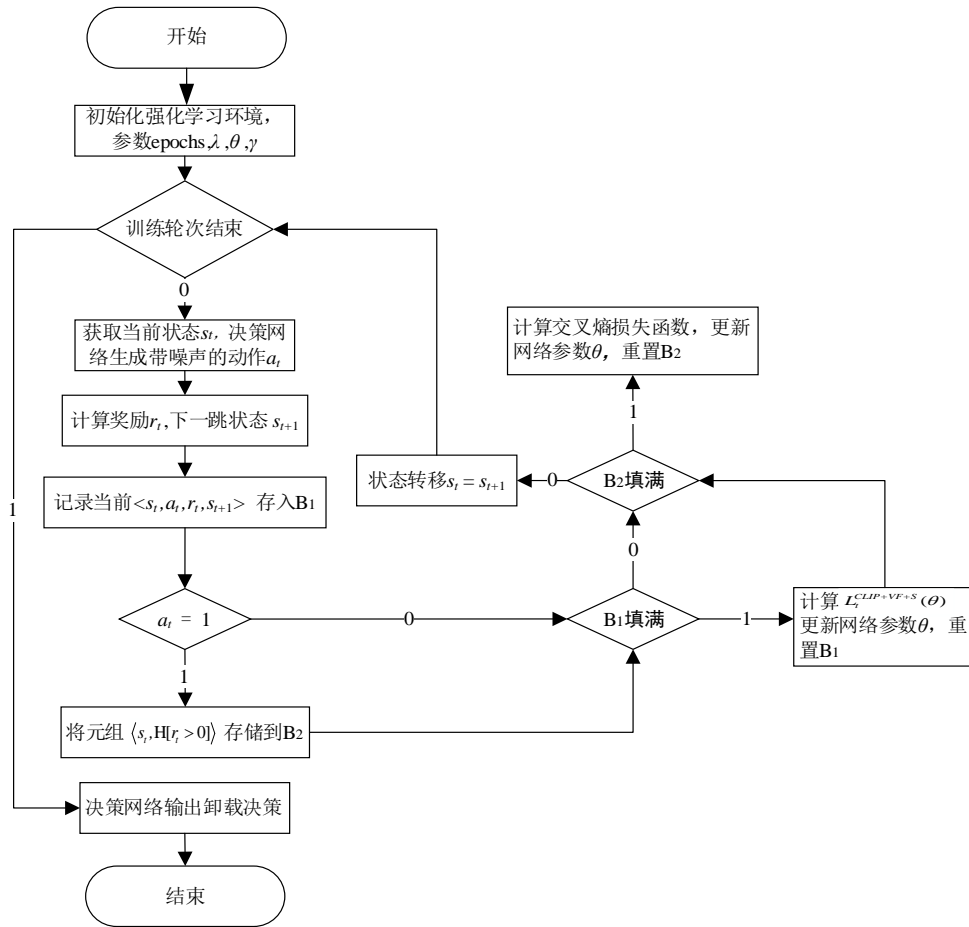


图5 融合噪声网络的双缓冲区策略优化算法流程




图6 数据实例

提升 7.44 和 4.75 个百分点。在 Forest Fire 数据集

上，所提出的模型以 82.54% 的准确率和 95.48% 的召回率领先其他模型，其中召回率指标较 ShuffleNetV2 提升 1.48 个百分点，充分展现了其在降低漏报率方面的突出优势。此外，在 Flame Vision 数据集上，本文方法以 84.55% 的准确率超越所有对比模型，同时保持 86.72% 的高召回率。尽管在 FIRE 数据集上的准确率略低于最优模型，但其召回率仍保持较高水平。综合四个数据集的平均表现，本文所提出的轻量级模型实现了 81.63% 的平均准确率和 89.13% 的平均召回率，适合对漏检率要求严苛

表1 不同网络模型识别性能对比

模型名称	Forest Flame		Flame Vision		FIRE		Forest Fire	
	准确率	召回率	准确率	召回率	准确率	召回率	准确率	召回率
GhostNet	74.69%	87.63%	79.75%	82.82%	76.45%	89.34%	77.75%	81.01%
ShuffleNetV2	68.10%	69.36%	78.40%	86.86%	85.78%	87.82%	82.35%	94.38%
MobileNetV2	76.48%	79.35%	71.51%	70.84%	67.95%	82.01%	69.46%	75.16%
MobileNetV3	64.21%	78.02%	74.10%	80.11%	67.33%	80.97%	79.14%	92.81%
Mnasnet	75.77%	81.49%	83.53%	93.29%	79.97%	83.68%	76.35%	87.86%
Ours	82.13%	92.38%	84.55%	86.72%	77.28%	81.92%	82.54%	95.48%

的森林火灾监测场景。这些结果充分验证了所提模型在识别精度和可靠性方面的优势。

为了全面评估轻量级模型在森林火灾识别任务中的分类性能，本文采用 Receiver Operating Characteristic (ROC) 曲线和 Precision-Recall (PR) 曲线两种评估方法进行深入分析。ROC 曲线反映了模型整体分类能力，主要通过真正例率 (TPR) 与

假正例率 (FPR) 的权衡关系来体现；而 PR 曲线则更侧重于关注正样本 (火灾) 的识别精度，是由精确率和召回率之间的关系所决定的。这些评价指标对于样本分布不均衡的火灾识别任务来说至关重要。通过基于这两种曲线的综合分析，可以更全面地验证模型在实际应用场景中的有效性。

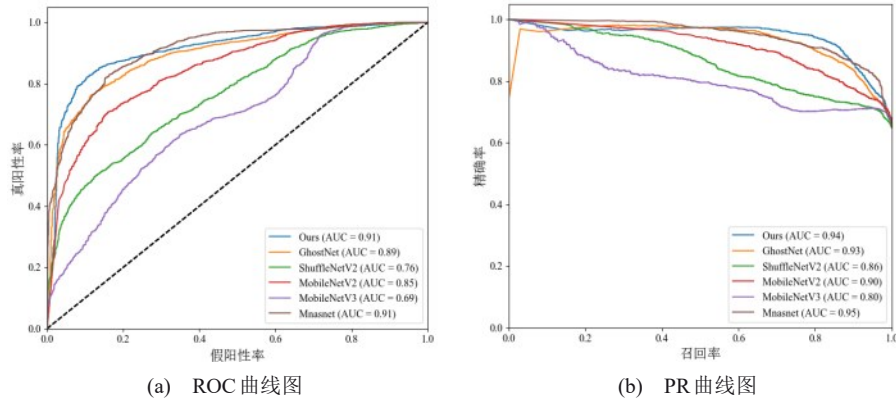


图7 不同轻量级网络模型的性能

图7展示了不同轻量级模型在 Forest Flame 数据集上的 ROC 和 PR 曲线^[26]及其对应的曲线下面积 AUC (Area Under the Curve)^[27]。如图7(a)所示，本文所提模型 ROC 曲线中 AUC 达 0.91，优于其他模型。这表明该模型在区分正负样本方面具有明显优势，能够更有效地处理各类样本，从而在火灾识别场景中实现更准确的分类。从图7(b)可以看出，在高召回率条件下，本文所提模型仍能保持较高的精确率，而其他模型的精确率则显著下降。同时，该模型 PR 曲线中的 AUC 为 0.94，在所有模型中表现最佳，充分证明其在平衡精确率与召回率方面表现优异，尤其在需要高度关注正样本 (火灾) 的场景下。综合 ROC 与 PR 曲线的性能表现，该模型在森林火灾识别任务中展现出更强的适用性。总体而言，本研究设计的轻量级模型有效利用了轻量级网络模块的优势，在测试集上实现了良好的准确度。

为验证本文提出的轻量化模型的有效性，选取计算量 (MFLOPs)、推理时延 (ms) 和模型大小 (MB) 三个关键指标，将所提模型与其他轻量级网络进行对比实验，以评估其在资源受限环境下的实际部署优势。

从表2的对比数据可以看出，本文提出的模型

表2 不同网络模型复杂度与效率对比

模型名称	计算量 (MFLOPs)	推理时延 (ms)	模型大小 (MB)
GhostNet	196.61	28.60	16.12
ShuffleNetV2	151.69	25.09	4.85
MobileNetV2	327.49	24.33	13.50
MobileNetV3	271.13	28.49	10.32
Mnasnet	410.37	26.44	45.74
Ours	153.68	23.70	0.35

在轻量化设计上展现出显著优势。在计算效率方面，所提出的模型以 153.68 MFLOPs 的计算量实现了 23.7ms 的最优推理速度，较同类轻量模型 ShuffleNetV2 (151.69 MFLOPs/25.09ms) 在保持计算量相当的同时推理速度提升 5.5%，这表明本文提出的模型在计算效率上具有明显优势，能够以更少的计算资源完成任务。除此之外，所提出的模型大小为 0.35 MB，这使得它在存储和部署方面具有极大的便利性，更适合应用于火灾检测等对实时性和资源消耗敏感的场景。

5.3 协同识别性能验证

在协同识别阶段，首先将提出的卸载算法与其他算法在进行比较，包括：

PPO：近端策略优化算法。

DDQN (Dueling Deep Q-Network)：DDQN

的状态空间、动作空间和奖励函数的定义与提出的算法一致^[28]。DDQN结合了深度学习和强化学习的思想，通过引入双网络结构来提高Q值估计的准确性和稳定性。

A2C (Advantage Actor-Critic): 一种同步版本的Actor-Critic算法，结合了策略梯度方法和价值函数方法^[29]。通过Actor网络学习策略，即在给定状态下选择动作的概率分布，同时通过Critic网络评估这些动作的价值。

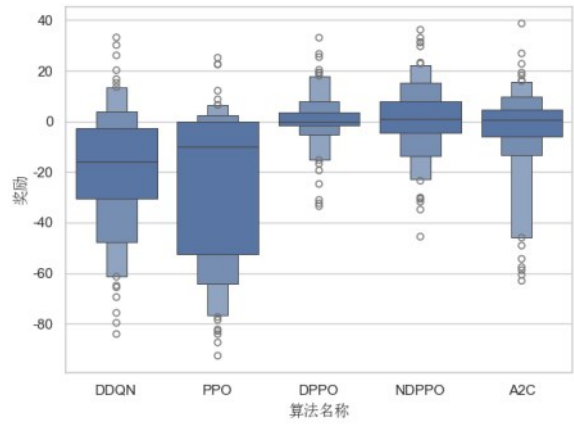
DPPO (Double buffer Proximal Policy Optimization): 在近端策略优化算法的基础上，采用双缓冲区的方法训练卸载模型。

NDPPO: 本文提出的使用噪声网络的双缓冲区近端策略优化算法。


在强化学习过程中，本文将每个回合设置为包含3000张图像，并迭代100个回合来评估算法的性能。由于算法所获得的奖励会随着强化学习环境状态不同而波动，因此选择箱线图^[30]来反映不同算法性能。箱线图中间的横线是数据的中位数，最宽的矩形包含50%的数据，圆圈块是异常值，每个扩展矩形包含剩余数据的一半。

图8是不同卸载算法在当前强化学习环境中所获得的奖励和图像卸载率对比。根据图8(a)中的总体奖励箱线图，可以看出本文所提出的NDPPO算法所获得奖励中位数明显高于DDQN和PPO算法，中间50%数据也分布高于DPPO和A2C算法。并且所提出的算法通过引入噪声网络，获得的正向奖励样本更多也更加集中。根据图8(b)的实验结果，传统的PPO算法和DDQN算法卸载率过高，这可能导致模型盲目地进行图像卸载，从而浪费通信资源。然而，NDPPO算法能够将卸载率维持在0.2以下，表现出更好的资源利用率。DPPO算法由于其策略更新机制较为保守，导致在任务卸载场景中，任务卸载率过低，无法充分利用资源。A2C算法的任务卸载率虽然主要集中在0.2以下，但其他数据分布较为分散，缺乏一致性，这表明A2C算法在某些情况下可能过于激进，导致结果不稳定。最终，结合图8(a)的分析结果，本文提出的NDPPO算法在当前强化学习场景中表现出更高的适配性，相较于其他强化学习算法具有显著优势。

表3展示了协同识别方法与单一监测站点在Forest Flame测试集上的性能对比结果。实验数据



(a) 奖励对比箱线图



(b) 卸载率对比箱线图

图8 不同卸载算法的性能

表3 协同前后识别性能对比

数据集	仅由监测站点识别		监测站点与森林防火指挥中心协同识别		
	准确率	召回率	准确率	召回率	卸载率
Forest Flame	82.13%	92.38%	86.29%	94.11%	18.63%

表明，通过引入森林防火指挥中心的协同计算框架，在仅18.63%的卸载率条件下，系统识别准确率从82.13%显著提升至86.29%，召回率由92.38%提高至94.11%。这一改进验证了所提出的协同识别机制能够在保持较低通信开销的同时显著提升火灾识别的可靠性。特别值得注意的是，协同模式在仅增加有限计算负担（卸载率<20%）的情况下，实现了准确率4.16个百分点的提升和召回率1.73个百分点的改进。实验结果表明，所提出的协同框架在识别精度和计算效率之间取得了良好的平衡，具有重要的实际应用价值。

6 结束语

本文提出了一种用于森林防火的监测站点和防火指挥中心协同识别方法，旨在提升森林火灾识别性能。具体来说，本文基于GhostNet的Ghost Module模块和ShuffleNetv2模块，开发了一种轻量级森林火灾识别模型，适用于计算资源有限的监测设备，以在FLOPs和识别性能之间实现平衡。此外，本文在轻量级识别模型上扩展了一个卸载模型，能

够有选择性地将图像卸载到森林防火指挥中心。同时，本文对PPO算法进行了改进，提出了NDPPO算法。通过与强化学习环境的交互，NDPPO算法优化了数据卸载策略，从而显著提高了交互数据的利用率。经过实验验证，本文设计的轻量级模型实现了更高的准确率和召回率。所提出的监测站点与防火指挥中心协同森林火灾识别方法以18.63%的卸载率为代价，将准确率提高了4.16%，召回率提高了1.73%。

王燕妮(1975-)，女，博士，西安建筑科技大学教授，主要研究方向为计算机图形学、信号检测与识别。

张琰(1983-)，男，博士，西安电子科技大学教授，主要研究方向为无线网络智能组网、无线智能通信大模型。



参考文献：

- [1] Zhao J, Yue C, Wang J, et al. Forest fire size amplifies postfire land surface warming[J]. Nature, 2024, 633(8031): 828-834.
- [2] 凉山州西昌市“3·30”森林火灾事件调查结果公布[J]. 中国消防, 2021(1): 66 - 67.
Investigation results of the "3·30" fire incident in Xichang City, Liangshan Prefecture[J]. China Fire Rescue, 2021(1): 66 - 67.
- [3] Chuvieco E, Aguado I, Salas J, et al. Satellite remote sensing contributions to wildland fire science and management[J]. Current Forestry Reports, 2020, 6: 81-96.
- [4] Bonilla-Ormachea K, Cuizaga H, Salcedo E, et al. ForestProtector: An IoT Architecture Integrating Machine Vision and Deep Reinforcement Learning for Efficient Wildfire Monitoring[J]. arXiv preprint arXiv:2501.09926, 2025.
- [5] Chen Y, Zhang Y, Xin J, et al. UAV image-based forest fire detection approach using convolutional neural network[C]//2019 14th IEEE conference on industrial electronics and applications (ICIEA). IEEE, 2019: 2118-2123.
- [6] Zhang A, Zhang A S. Real-time wildfire detection and alerting with a novel machine learning approach[J]. International Journal of Advanced Computer Science and Applications, 2022, 13(8).
- [7] Zheng J, Cao X, Zhang B, et al. Bi-heterogeneous Convolutional Neural Network for UAV-based dynamic scene classification[C]//2017 Integrated Communications, Navigation and Surveillance Conference (ICNS). IEEE, 2017: 5B4-1-5B4-12.
- [8] Allauddin M S, Kiran G S, Kiran G S S R, et al. Development of a surveillance system for forest fire detection and monitoring using drones[C]//IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2019: 9361-9363.
- [9] Jiao Z, Zhang Y, Mu L, et al. A yolov3-based learning strategy for real-time uav-based forest fire detection[C]//2020 Chinese control and decision conference (CCDC). IEEE, 2020: 4963-4967.
- [10] Yang H, Wang J, Wang J. Efficient Detection of Forest Fire Smoke in UAV Aerial Imagery Based on an Improved Yolov5 Model and Transfer Learning[J]. Remote Sensing, 2023, 15(23): 5527.
- [11] 袁海英, 成君鹏, 曾智勇, 等. Mobile_BLNet: 基于 Big-Little Net 的轻量级卷积神经网络优化设计[J]. 电子学报, 2023, 51(1): 180-191.
YUAN H Y, CHENG J P, ZENG Z Y, et al. Mobile_BLNet: Optimized design of lightweight convolutional neural network based on Big-Little Net[J]. Acta Electronica Sinica, 2023, 51(1): 180-191.
- [12] Zhou M, Wu L, Liu S, et al. UAV forest fire detection based on

- lightweight YOLOv5 model[J]. *Multimedia Tools and Applications*, 2024, 83(22): 61777-61788.
- [13] Xu L, Yang Q, Qin M, et al. Collaborative human recognition with lightweight models in drone-based search and rescue operations [J]. *IEEE Transactions on Vehicular Technology*, 2023, 73(2): 1765-1776.
- [14] Kang X, Song B, Guo J, et al. Task-oriented image transmission for scene classification in unmanned aerial systems[J]. *IEEE Transactions on Communications*, 2022,70(8): 5181-5192.
- [15] Zhou C, Wu W, He H, et al. Deep reinforcement learning for delay-oriented IoT task scheduling in SAGIN[J]. *IEEE Transactions on Wireless Communications*, 2020, 20(2): 911-925.
- [16] Zhou C, Wu W, He H, et al. Delay-aware IoT task scheduling in space-air-ground integrated network[C]//2019 IEEE Global Communications Conference (GLOBECOM). IEEE, 2019: 1-6.
- [17] Yan K, Shan H, Sun T, et al. Reinforcement learning-based mobile edge computing and transmission scheduling for video surveillance[J]. *IEEE Transactions on Emerging Topics in Computing*, 2021, 10(2): 1142-1156.
- [18] Han K, Wang Y, Tian Q, et al. Ghostnet: More features from cheap operations[C]// Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2020: 1580-1589.
- [19] Ma N, Zhang X, Zheng H T, et al. Shufflenetv2: Practical guidelines for efficient cnn architecture design[C]//Proceedings of the European conference on computer vision (ECCV). 2018: 116-131.
- [20] 丁瑞金, 高飞飞, 邢玲. 基于深度强化学习的物联网智能路由策略[J]. *物联网学报*, 2019,3(2):56-63.
- DING R J, GAO F F, XING L. Intelligent routing strategy in the Internet of things based on deep reinforcement learning. [J]. *Chinese journal on internet of things*, 2019, 3(2): 56-63.
- [21] Schulman J, Wolski F, Dhariwal P, et al. Proximal policy optimization algorithms[J]. *arXiv preprint arXiv:1707.06347*, 2017.
- [22] Fortunato M, Azar M G, Piot B, et al. Noisy networks for exploration[J]. *arXiv preprint arXiv:1706.10295*, 2017.
- [23] Sandler M, Howard A, Zhu M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 4510-4520.
- [24] Howard A, Sandler M, Chu G, et al. Searching for mobilenetv3 [C]//Proceedings of the IEEE/CVF international conference on computer vision. 2019: 1314-1324.
- [25] Tan M, Chen B, Pang R, et al. Mnasnet: Platform-aware neural architecture search for mobile[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2019: 2820-2828.
- [26] Saito T, Rehmsmeier M. The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets[J]. *PloS one*, 2015, 10(3): e0118432.
- [27] Ling C X, Huang J, Zhang H. AUC: a better measure than accuracy in comparing learning algorithms[C]//Conference of the canadian society for computational studies of intelligence. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003: 329-341.
- [28] Van Hasselt H, Guez A, Silver D. Deep reinforcement learning with double q-learning[C]//Proceedings of the AAAI conference on artificial intelligence. 2016, 30(1).
- [29] Mnih V, Badia A P, Mirza M, et al. Asynchronous methods for deep reinforcement learning[C]//International conference on machine learning. Pmlr, 2016: 1928-1937.
- [30] Yu C, Velu A, Vinitzky E, et al. The surprising effectiveness of ppo in cooperative multi-agent games[J]. *Advances in neural information processing systems*, 2022, 35: 24611-24624.