

DOI: 10.19650/j.cnki.cjsi.J2514188

基于知识蒸馏与强化学习的孔探损伤检测方法*

何 超¹, 陈 果², 康玉祥²

(1. 南京航空航天大学民航学院 南京 211106; 2. 南京航空航天大学通用航空与飞行学院 溧阳 213300)

摘 要:在航空发动机运维领域,孔探损伤检测是保障设备安全运行的关键环节,然而传统检测方法常面临实时性与精度难以兼顾的问题,针对此问题,提出了一种基于知识蒸馏与强化学习融合的孔探损伤检测模型训练方法。首先,设计了一种简单且高效的排名损失函数,该函数通过对教师模型输出的损伤特征优先级进行排序,确保学生模型在学习过程中能精准捕捉关键损伤信息,有效避免次要特征对检测精度的干扰;其次,为进一步提升模型适应性,引入了强化学习机制,用于自适应调整知识蒸馏函数中的核心参数,动态优化参数配置,无需人工干预即可适配不同类型的孔探损伤,上述优化过程无需修改目标检测网络的基础结构,大幅降低了工程应用中的部署难度;然后,为验证方法有效性,在 Pascal VOC 2007 通用目标检测数据集上完成基础验证,排除了数据集特异性对实验结果的干扰,证实了方法的通用性;最后,针对实际航空发动机孔探图像数据集,采用 YOLOv8-n 轻量化目标检测网络进行对比试验,结果显示,在未增加模型参数量与推理耗时的前提下,该训练方法使 YOLOv8-n 的孔探损伤检测精度提升了 6.93%。试验充分证明了其在工程实践中的应用价值,为航空发动机孔探检测的实时化、高精度化提供了可靠技术方案。

关键词: 孔探图像;损伤检测;深度学习;知识蒸馏;强化学习;YOLOv8 模型

中图分类号: TH744 V263.6 **文献标识码:** A **国家标准学科分类代码:** 590.6530

Borescope damage detection based on the knowledge distillation and reinforcement learning method

He Chao¹, Chen Guo², Kang Yuxiang²

(1. College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China;

2. College of General Aviation and Flight, Nanjing University of Aeronautics and Astronautics, Liyang 213300, China)

Abstract: The borescope damage detection is a key link to ensure the safe operation of equipment in the field of aero-engine operation and maintenance, which often faces the problem of balancing real-time performance and accuracy. To address this issue, this study proposes a training method of borescope damage detection model based on the fusion of knowledge distillation and reinforcement learning. First, this paper designs a simple and efficient ranking loss function, which prioritizes the damage features output by the teacher model and ensures that the student model can accurately capture key damage information during the learning process as well as effectively avoid the interference of secondary features on detection accuracy. Additionally, in order to further improve the model's adaptability, a reinforcement learning mechanism is introduced to adaptively adjust the core parameters of knowledge distillation function and dynamically optimize the parameter configuration. This allows for the adaptation to different types of borescope damage without manual interventions. The optimization process does not require modifying the basic structure of object detection network, significantly reducing the deployment difficulty in the engineering applications. Furthermore the basic validation is performed on the Pascal VOC 2007 general object detection dataset in order to verify the effectiveness of the method, which eliminates the interference of dataset specificity on the experimental results and confirms the generality of the method. Finally, the comparative experiments are conducted using the YOLOv8-n lightweight object detection network on a real aero-engine borescope image dataset. The results show that, this training method improves the borescope damage detection accuracy of YOLOv8-n by 6.93% without increasing the number of model parameters or inference time.

收稿日期:2025-06-26 Received Date: 2025-06-26

* 基金项目:国家自然科学基金项目(52272436)资助

The experiment fully demonstrated its application value in the engineering practice, providing a reliable technical solution for the real-time and high-precision borescope inspection of aero-engines.

Keywords: borescope image; damage detection; deep learning; knowledge distillation; reinforcement learning; YOLOv8 model

0 引言

近年来,航空机队数量不断扩增,但安全问题一直是航空飞行的重中之重,而航空发动机作为飞机的“心脏”,保证其正常运行具有重要意义。通常针对航空发动机使用无损探伤的方法进行检测,即孔探检测,孔探检测是使用孔探设备将孔探探头从小孔中伸入到航空发动机内部当中,将航空发动机内部的损失图像传递到孔探设备上,以便机务工作人员查看与检查航空发动机内部损伤。

在机务工作人员查看孔探图像后,若在图像中发现发动机损伤,则按照相关的规章手册进行相应的处理。但是长期以来孔探检测过程存在自动化和智能化程度低的问题,孔探检测过于依赖人为经验与人工操作进行判断。针对该问题,基于深度学习方法已经被广泛引入,文献[1]基于深度学习中的 Faster R-CNN (faster region-based convolutional neural network) 与 SSD (single shot multi-box detector) 两种目标检测网络模型,对航空发动机内部的3类损伤进行了检测,检测速度近乎达到了实时检测的效果。文献[2]基于 YOLOv4 (you only look once version 4) 添加了深度可分离卷积模块,在颈部结构中引入了深度可分离卷积,减少了网络中的冗余结构,针对304张孔探图像中的凹痕数据,提升了检测精度与检测速度。文献[3]通过添加空间通道注意力模块与对颈部网络修改得到了改进的 YOLO 网络,提高了网络检测精度。文献[4]基于 YOLOv5 (you only look once version 5) 网络添加了协调注意力模块,并将颈部网络修改为 Bi-FPN (bi-directional feature pyramid network),同时采用了 EIoU (efficient intersection over union) 损失函数,精度较原网络提升了6.3%。文献[5]引入了引入双通道注意力模块 (convolutional block attention module, CBAM),使原网络模型对故障识别准确率提高了2.83%,达到了90.83%。文献[6]介绍了以深度学习为例的缺陷检测方法,使用网络结构为8层的 U-Net 可以使缺陷检测准确率达到96.87%,比5层 U-Net 提高了3.87%。文献[7]针对航空发动机内部损伤实时检测问题,提出了基于 YOLOv4 框架下的目标识别网络模型,该网络模型具有检测精确度高,推理速度快的优点,实现了发动机内部损伤的实时检测。

但上述方法往往需进行网络结构修改,针对此问题,文献[8]提出了一种基于知识蒸馏的自适应图像融合方法,大大减少了模型的参数量,模型推理时间仅为0.95 ms。文献[9]通过知识蒸馏和数据增强的方法,使

得 YOLOv5 模型在红外数据集上的精度提升了6.6%。文献[10]通过知识蒸馏对轻量化模型再次浓缩,提高了 YOLOv7-tiny (you only look once version 7-tiny) 模型对检测红外目标的准确性。文献[11]提出了一种基于多尺度注意力机制的蒸馏算法,使得教师网络的知识更好地流向学生网络,提升了 YOLOv4 网络精度。

在知识蒸馏的基础上,通过结合强化学习的方法自适应调整参数可进一步加强蒸馏效果,文献[12]提出离线多智能体强化学习框架,该框架利用先前收集的数据,无需额外在线收集数据即可提升网络性能。文献[13]提出了一种新的框架,使用知识蒸馏和提示学习来学习紧凑、快速的目标检测网络,以提高其准确性。文献[14]提出了 DIODE (deep inversion for object detection),以实现在对象检测任务上训练的神经网络的无数据知识提取。

为提高航空发动机内部损伤的检测精度,使用了一种基于知识蒸馏与强化学习的孔探损伤检测模型训练方法,该方法无需更改目标检测网络结构,能够直接提升目标检测模型的检测精度,并提出了排名损失函数,能够有效改善知识蒸馏过程的性能,在 Pascal VOC (visual object classes) 2007 数据集^[15]验证了方法的有效性,最后针对实际发动机孔探损伤图像数据集,使用 YOLOv8 (you only look once version 8) 目标检测算法进行试验验证,充分验证了所提方法的有效性。

1 基于目标检测的孔探损伤实时检测方法

1.1 孔探图像实时检测问题的提出

目前基于深度学习的孔探图像检测若要达到实时检测,孔探设备需要具备高性能 GPU (graphics processing unit),而在实际孔探检测环境中难以配备高性能 GPU,若减小目标检测模型规模,使用轻量网络,虽能在低资源 CPU (central processing unit) 上完成实时检测,但其检测精度会同时下降。本文所提方法旨在不改变目标检测网络结构的情况下,提升网络模型的检测精度,降低对计算机硬件的依赖,为工程实际应用奠定基础。

1.2 研究总体流程图

研究方案总体流程如图1所示。首先,将孔探损伤图像按9:1的比例,划分为训练集与测试集;然后,对训练集基于目标检测网络,使用知识蒸馏的方法进行训练,通过计算教师模型 YOLOv8-m (you only look once version 8-medium) 与学生模型 YOLOv8-n (you only look once version 8-nano) 的差异值来计算蒸馏损失,并在知识蒸馏

过程中采用强化学习的方法,对知识蒸馏损失函数中的参数进行选择;最后,通过对比不同方法所训练的模型在测试集上测试的指标,选择最优的模型。图 1 中 mAP 表示平均精确度 (mean average precision), 后文同此。




图 1 方案总体流程

Fig. 1 Overall flow chart of the program

1.3 关键技术

1) 知识蒸馏

知识蒸馏^[16] (knowledge distillation, KD) 是一种深度学习模型的训练方法。在一般情况下,越复杂的模型相应的性能越好,但随着模型的复杂度提升,模型所需的代价越大,例如计算量等均有显著提高,会消耗大量的时间进行计算,难以部署在便携式电脑等低资源设备中。而知识蒸馏将复杂模型包含的“暗知识”蒸馏到轻量模型中,提升轻量模型的性能^[17],而提升性能后的轻量模型

则相较复杂模型更容易部署,满足低资源硬件要求。

在知识蒸馏过程中,通常选择复杂模型作为教师模型,选择轻量模型作为学生模型^[18],教师模型将自身包含的知识“教授”到学生模型中,学生模型接受知识,提高自身性能。通常知识蒸馏方法为计算教师模型与学生模型之间的差异,将两者之间差异作为蒸馏损失与原本训练中的一般损失加权相加,增加损失中包含的信息,进而调整模型。进行知识蒸馏的模型训练流程如图 2 所示。




图 2 基于知识蒸馏的模型训练流程

Fig. 2 Model training flow chart of knowledge distillation

2) 强化学习

强化学习^[19-22] 又称增强学习,主要使用智能体与环境交互,通过环境返回的状态与奖赏,决定智能体的行动。在使用知识蒸馏进行模型训练时,需要人为设置参数,而参数的最佳值往往随着应用场景的变化而变化,一般通过人工调整的方法确定一个经验值。

将上述调整过程中的调整参数视为强化学习中的动作 s ,当前的参数值视为状态 a ,将训练过程中损失值的负相关值作为奖赏。于是对于给定的动作与状态,如式(1)所示定义了在某状态 s 时采取动作 a 后期望的总奖赏。

$$Q(s, a) = E[R(s, a) + \gamma \sum_{s'} P(s' | s, a) V(s')] \quad (1)$$

其中, $R(s, a)$ 是在状态 s 采取动作 a 所获得的及时奖赏, γ 是折扣因子, 表示未来奖赏的价值。 $P(s' | s, a)$ 是从状态 s 采取动作 a 转移到状态 s' 的概率, 并通过 Q 学习使智能体学习最优策略, 如式(2)所示。

$$Q(s, a) \leftarrow Q(s, a) + \alpha(R(s, a) + \gamma \max_{a'} Q(s', a') - Q(s, a)) \quad (2)$$

其中, $\max_{a'} Q(s', a')$ 表示在下一个状态 s' 下可能采取的最佳动作的 Q 值, α 为学习率。最终可建立一个基于强化学习调整参数的智能体。在上述智能体中的参数主要包括以下5项: (1) 动作空间: 决定了所建立智能体能够选择的动作空间大小; (2) 学习率: 控制 Q 值的更新速度, 越高的学习率更新速度越快, 其中 Q 值是在智能体在特定状态下选择某个动作后, 预计能够获得的总奖励的期望值; (3) 折扣因子: 将未来奖赏折现到当前时刻, 越高的折扣因子代表智能体对未来奖赏的重视程度越高; (4) 探索率: 决定智能体在选择动作时进行探索的概率, 越高的探索率值代表智能体会进行更多探索; (5) 探索率衰减因子: 决定探索率如何随时间减小, 使智能体逐渐更多地利用已有的知识。

3) 损失函数

(1) 一般损失

该网络训练时的一般损失由分类损失与回归损失组成, 分别记作 L_{cls} 、 L_{reg} , 而回归损失 L_{reg} 包括 IoU (intersection over union) 损失与 DFL (distributed focal loss) 损失^[23], 分别记作 L_{box} 、 L_{dfl} 。记一般损失为 L , 其计算方法如式(3)所示。

$$L = a \cdot L_{\text{box}} + b \cdot L_{\text{dfl}} + c \cdot L_{\text{cls}} \quad (3)$$

其中, a 、 b 和 c 分别为权重参数, 文中分别取值为 7.5、1.5 和 0.5。

IoU 损失为 CioU (complete intersection over union)^[24], 其计算方法如式(4)所示。

$$L_{\text{box}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{(c_w)^2 + (c_h)^2} + \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right) \quad (4)$$

其中, IoU 代表预测框和真实框的交集占其并集的比值, $\rho^2(b, b^{\text{gt}})$ 代表预测框与真实框的几何中心点间的欧氏距离, h 与 w 代表预测框的高度和宽度, h^{gt} 与 w^{gt} 代表真实框的高度和宽度, c_h 和 c_w 代表最小闭包预测框和真实框的矩形框的高度和宽度。

L_{dfl} 的计算方法如式(5)所示。

$$L_{\text{dfl}} = -((y_{i+1} - y) \log(s_i) + (y - y_i) \log(s_{i+1})) \quad (5)$$

其中, s_i 与 s_{i+1} 为网络通过 sigmoid 后的输出, y 为真实标签, y_i 与 y_{i+1} 分别为 y 的向下取整与向上取整的数值。

对于其中的分类损失 L_{cls} 采用二值交叉熵损失, 所有

的正负样本均参与计算, 交叉熵损失的计算公式如式(6)所示。

$$L_{\text{cls}} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p(y_i)) + (1 - y_i) \log(1 - p(y_i))] \quad (6)$$

(2) 蒸馏损失

KL (Kullback-Leibler) 散度^[25-27] 是一种和衡量两个概率分布差异的算法, 可作为知识蒸馏时的损失函数。KL 散度的数值随着两个概率分布的差异程度增大而增大, 特别地, 当两个概率分布相同时, KL 散度的数值为 0。假设两个连续随机变量概率分布分别为 $\mathbf{P}$ 和 $\mathbf{Q}$, 概率密度函数为 $p(x)$ 和 $q(x)$, 则 $q(x)$ 近似 $p(x)$ 的 KL 散度计算方法如式(7)所示。

$$KL(\mathbf{P} \parallel \mathbf{Q}) = \int p(x) \log \frac{p(x)}{q(x)} dx \quad (7)$$

JS (Jensen-Shannon) 散度^[28-30] 是基于 KL 散度修改而来, JS 散度具有对称性, 定义如式(8)所示。设 $\mathbf{R} = \frac{\mathbf{P} + \mathbf{Q}}{2}$ 则有:

$$JS(\mathbf{P} \parallel \mathbf{Q}) = \frac{1}{2} KL(\mathbf{P} \parallel \mathbf{R}) + \frac{1}{2} KL(\mathbf{Q} \parallel \mathbf{R}) \quad (8)$$

当 $\mathbf{P}$ 与 $\mathbf{Q}$ 两个分布完全没有重叠时, 可得到 KL 散度为无穷大, JS 散度的值为常数 $\log 2$, 两者均无法完成反向传播。Wasserstein 距离^[31] 解决了上述存在的问题, 该距离用于度量两个概率分布之间的距离, 定义如式(9)所示。

$$W(\mathbf{P}, \mathbf{Q}) = \inf_{\gamma \in \Pi(\mathbf{P}, \mathbf{Q})} E_{(x, y) \sim \gamma} [\|x - y\|] \quad (9)$$

其中, $\Pi(\mathbf{P}, \mathbf{Q})$ 为分布 $\mathbf{P}$ 与分布 $\mathbf{Q}$ 能够组合的所有可能的联合分布的集合, 从该集合中的任意一个联合分布 γ 采样 $(x, y) \sim \gamma$ 得到样本 x 与 y , 并计算出样本 x 与 y 的距离 $\|x - y\|$, 进而可计算所选联合分布 γ 中样本距离的期望值 $E_{(x, y) \sim \gamma} [\|x - y\|]$, 在所有的联合分布中, 取得期望的最小值即为 Wasserstein 距离。

上述方法存在一个共同的问题, 即上述方法均考虑整体的差异度, 导致对差异较大项的关注度不足, 且计算了较多的冗余损失, 使得提升效果不明显。现有的知识蒸馏如 L_2 排名损失或 KL 散度通常基于平方误差, 对所有样本产生密集梯度, 导致对小样本类别过拟合。

针对此问题, 提出了一个简单有效的损失函数, 排名损失 (Ranking Loss) 函数, 设置了一个排名参数 k , 仅考虑排名为前 k 项的差异, 若某差异排名大于 k , 则此差异不参与损失计算, 通过 TopK 选择机制实现梯度稀疏性与自适应聚焦, 即仅对前 k 个最大差异关键样本回传梯度, 并且降低了计算复杂度, 降低了网络模型训练所需时间。

设分布 $\mathbf{P} = (p_1, p_2, \dots, p_n)$ 与分布 $\mathbf{Q} = (q_1, q_2, \dots, q_n)$, 则计算公式如式(10)所示。

$$L_{rl} = \frac{1}{k} \sum_{i=1}^k [\max_i |\mathbf{P} - \mathbf{Q}|] \quad (10)$$

其中, $\max_i$ 为矩阵中从大到小排列, 排名为 i 对应的数值, k 为设置的排名参数。特别地, 当 k 的值为 1 时, 该式简化为求矩阵中元素的最大值。在本文的训练过程中, 计算公式如式 (11) 所示。

$$L_{rl} = \frac{1}{k} \sum_{i=1}^k \max_i |\mathbf{y}_t - \mathbf{y}_s| \quad (11)$$

其中, $\mathbf{y}_t$ 为教师网络对目标的识别结果矩阵, $\mathbf{y}_s$ 为学生网络每一轮训练后的模型对目标的识别结果矩阵, $\max_i$ 代表取矩阵中元素从大到小排列, 排名为 i 的数值。

设预测概率分布 $\mathbf{P} = (\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_n)$, 目标概率分布 $\mathbf{Q} = (\mathbf{q}_1, \mathbf{q}_2, \dots, \mathbf{q}_n)$, 则差异向量 $\boldsymbol{\delta} = \mathbf{P} - \mathbf{Q} = [\boldsymbol{\delta}_1, \boldsymbol{\delta}_2, \dots, \boldsymbol{\delta}_n]$, 排名损失函数可重写为如式 (12) 所示。

$$L(\mathbf{P}, \mathbf{Q}) = \frac{1}{k} \sum_{i=1}^n w_i \cdot |\boldsymbol{\delta}_i| \quad (12)$$

$$w_i = \begin{cases} 1, & \text{rank}(|\boldsymbol{\delta}_i|) \leq k \\ 0, & \text{其他} \end{cases}$$

其中, $\text{rank}(|\boldsymbol{\delta}_i|)$ 表示 $|\boldsymbol{\delta}_i|$ 在 $\boldsymbol{\delta}$ 中的降序排名。对预测概率 p_j 求偏导, 结果如式 (13) 所示。

$$\frac{\partial L}{\partial p_j} = \frac{w_j}{k} \text{sign}(\boldsymbol{\delta}_j) + \sum_{i=1}^n |\boldsymbol{\delta}_i| \frac{\partial w_i}{\partial p_j} \quad (13)$$

其中, 由于 w_i 的离散性, 第 2 项为 0, 实际梯度如式 (14) 所示。

$$\nabla_p L = \frac{1}{k} [w_1 \text{sign}(\boldsymbol{\delta}_1), \dots, w_n \text{sign}(\boldsymbol{\delta}_n)]^T \quad (14)$$

不难看出, 其梯度幅度值恒定为 $\frac{1}{k}$, 与误差大小无关, 避免了对异常值的过度敏感。并且所有活跃项的更新步长相同, 防止头部类别主导优化过程, 对长尾分布下的类别平衡有重要意义。梯度下降更新方程如式 (15) 所示。

$$p_j^{(t+1)} = p_j^{(t)} - \eta \cdot \frac{w_j}{k} \text{sign}(\boldsymbol{\delta}_j) \quad (15)$$

其表现为, 若 $p_j > q_j$ 则 p_j 递减, 反之则 p_j 递增, 步长固定为 $\frac{k}{\eta}$ 。在小样本或长尾分布场景下, 排名损失会引入一部分偏差, 在本文中通过强化学习自适应聚焦来缓解这个问题, 例如在训练初期 k 较大以捕捉全局分布, 后期逐步减小 k 强化头部优化。

(3) 总训练损失

总损失即一般损失与蒸馏损失的和, 记作 L_{all} , 计算如式 (16) 所示。

$$L_{\text{all}} = \alpha \cdot L + (1 - \alpha) \cdot L_{\text{kd}} \quad (16)$$

其中, L_{kd} 为蒸馏损失, α 为权重参数, 其取值为人为设定的值, 以此来平衡两个损失的权重, 本文中该参数取

值为 0.5, 即认为两者权重是相同的, 此时可简化为如式 (17) 所示。

$$L_{\text{all}} = L + L_{\text{kd}} \quad (17)$$

1.4 基于 Pascal VOC 2007 数据集的验证

本节将使用 YOLOv8 网络^[32], 在 Pascal VOC 2007 公开数据集^[15]来对本文模型进行评估, 并对上述试验数据内容进行说明。然后介绍试验环境、训练策略、评估指标等, 最后进行对比试验, 验证方法的有效性。

1) Pascal VOC 2007 数据集

Pascal VOC 2007 数据集是由欧洲计算机视觉会议发起项目中的公开数据集, 主要用于目标检测、图像分类等任务。Pascal VOC 2007 数据集中一共包含 9 963 张图片, 训练集为 5 011 张, 测试集为 4 952 张, 包含飞机、自行车、鸟、船、瓶子等 20 余类。Pascal VOC 2007 数据集图像部分样例图如图 3 所示。




图3 Pascal VOC 2007 图像示例

Fig. 3 Pascal VOC 2007 image examples

2) 试验环境与训练策略

本文中的试验环境包含操作系统、编程语言、CPU 与 GPU 等, 详细信息如表 1 所示。

表 1 环境参数

Table 1 Environmental parameters

环境参数	值
操作系统	Windows 10
编程语言	Python 3.7.16
CPU	12th Gen Intel Core i5-12400F
GPU	RTX 3060Ti (8 GB)
运行内存	16 GB

在进行训练之前, 需将 Pascal VOC 2007 数据集与自建孔探图像数据集划分为训练集与测试集。其中 Pascal VOC 2007 提供的训练集为 5 011 张, 提供的测试集为 4 952 张, 将所提供的训练集中的 9/10 划分为训练集, 即 4 509 张作为训练集, 1/10 划分为验证集, 即 502 张作为验证集; 其中孔探图像数据集的训练集为 4 856 张, 测试集为 539 张, 将训练集中的 9/10 划分为训练集, 即 4 371 张作为训练集, 1/10 划分为验证集, 即 485 张作为验证集。

在正式进行训练前,首先对 COCO-2017 (common objects in context)数据集进行了训练,获得了对应的目标检测模型,通过迁移学习的方法,使用该模型引导在新数据集上的训练,一方面能够获得一部分原模型强大的特征提取能力,避免在小数据集上过拟合,大大增强网络的鲁棒性,另一方面能够加快网络收敛,提升训练速度。

在训练初期,冻结主干 50 轮次,保留迁移模型的权重,仅对特征提取网络的参数进行调整;后 50 轮时解冻主干进行训练,此时主干特征网络的参数也将参与调整。通过上述先冻结后解冻的训练策略,能够有效避免初始化随机参数过差导致网络训练收敛慢的问题,同时还能大大增强网络的鲁棒性,避免在小数据集上的过拟合。

训练时的参数如表 2 所示。

表 2 参数设置
Table 2 Parameter settings

参数	设置
总轮次	100
冻结轮次	50
批次大小	8
图像大小	320×320
初始学习率	0. 01
最终学习率	0. 000 1
学习率衰减策略	余弦退火衰减
优化器	SGD
动量	0. 937
权重衰减	0. 000 5
数据增强策略	Mosaic
种子	11

3) 评估指标

对模型评估的指标一般为精确率 (precision, P)、召回率 (recall, R)、平均精确率 (average precision, AP)、所有类别的 mAP 。

精确率与召回率的计算公式如式 (18) 与 (19) 所示。

$$P = \frac{TP}{TP + FP} \times 100\%$$
 (18)

$$R = \frac{TP}{TP + FN} \times 100\%$$
 (19)

其中, TP (true positive) 代表目标被正确检测出的数量, FP (false positive) 代表背景被检测成目标的数量, FN (false negative) 代表目标被检测成背景的数量。

AP 和所有类别的 mAP 的计算方法如式 (20) 与 (21) 所示。

$$AP = \int_0^1 P(r) dr$$
 (20)

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$
 (21)

其中, AP_i 为第 i 个种类的平均精确率, N 为所有类别的数量, 在 Pascal VOC 数据集的目标检测任务中 $N=20$, 在孔探图像数据集的目标检测任务中 $N=6$ 。

4) 试验结果

该试验基于 Pascal VOC 2007 数据集进行研究, 基于上述提到的蒸馏方法, 对比不同蒸馏方法之间的效果, 验证本文所提方法的有效性。为保证试验的公平性, 训练参数在所有训练过程中保持一致。

首先使用 YOLOv8-m 与 YOLOv8-n 分别对 Pascal VOC 2007 训练集进行 5 次训练, 训练参数如表 2 所示。YOLOv8-m 与 YOLOv8-n 的各项数据对比如表 3 所示。

表 3 YOLOv8-m 与 YOLOv8-n 对比
Table 3 Comparison between YOLOv8-m and YOLOv8-n

网络结构	参数量/M	计算量/G	模型大小/KB
YOLOv8-n	3. 011	2. 049	11 933
YOLOv8-m	25. 857	19. 766	101 308

可以看出, YOLOv8-m 相比 YOLOv8-n 结构更复杂, 参数量与计算量更大。YOLOv8-m 与 YOLOv8-n 相比, 参数量约为其 8. 6 倍, 计算量约为其 9. 6 倍, 模型大小约为其 8. 5 倍。

上述训练结束后, $mAP_{0.5}$ 、 $mAP_{0.75}$ 与 $mAP_{0.5:0.95}$ 结果的均值如表 4 所示。

表 4 Pascal VOC 2007 测试集效果对比
Table 4 Comparison of Pascal VOC 2007 test set results (%)

网络结构	$mAP_{0.5}$	$mAP_{0.75}$	$mAP_{0.5:0.95}$
YOLOv8-n	72. 61	52. 11	49. 14
YOLOv8-m	80. 59	63. 43	58. 96

从表 4 中可得, 与 YOLOv8-m 相比, YOLOv8-n 的 $mAP_{0.5}$ 落后 7. 98%, $mAP_{0.75}$ 落后 11. 32%, $mAP_{0.5:0.95}$ 落后 9. 82%, 在不同的标准下, 均远远落后。故选择 YOLOv8-m 为教师模型, YOLOv8-n 为学生模型进行后续知识蒸馏试验。

使用 YOLOv8-m 作为教师网络, YOLOv8-n 作为学生网络进行知识蒸馏, 分别使用 KL 散度、JS 散度、Wasserstein 距离、与本文所提排名损失 ($k=1$) 作为蒸馏损失, 进行对比试验。并在本文排名损失的基础上加入

智能体进行强化学习的知识蒸馏,与目前先进的知识蒸馏方法解耦知识蒸馏(decoupled knowledge distillation, DKD)^[33]进行对比试验。智能体的参数如表 5 所示。

表 5 智能体的参数设置
Table 5 Agent parameter settings

参数名称	参数大小
动作空间	100
学习率	0. 01
折扣因子	0. 95
探索率	1. 00
探索率衰减因子	0. 99

动作空间大小设置为 100,即为 100 个不同 k 值的动作,通过反馈给智能体损失值倒数的奖赏,进而使得智能体自适应做出动作,选择当前的参数,无需手动调整,对比试验结果如表 6 所示,表中数据均为训练 5 次取均值得到。

表 6 不同知识蒸馏方法对比
Table 6 Comparison of different knowledge distillation methods (%)

使用方法	mAP0. 5	mAP0. 75	mAP0. 5 : 0. 95
不使用知识蒸馏	72. 61 (+0)	52. 11 (+0)	49. 14 (+0)
KL 散度	75. 57 (+2. 96)	55. 11 (+3. 00)	51. 59 (+2. 45)
JS 散度	75. 48 (+2. 87)	54. 61 (+2. 50)	51. 31 (+2. 17)
Wasserstein 距离	75. 23 (+2. 62)	54. 71 (+2. 60)	51. 31 (+2. 17)
DKD	75. 94 (+3. 33)	55. 18 (+3. 07)	51. 77 (+2. 63)
排名损失	76. 13 (+3. 52)	55. 24 (+3. 13)	51. 73 (+2. 59)
强化学习的排名损失	76. 19 (+3. 58)	54. 80 (+2. 69)	51. 65 (+2. 51)

从表 6 中可以看到,使用本文所提排名损失结合强化学习的方法在 mAP0. 5 上提升幅度达到最大值,在 mAP0. 5 上提升了 3. 58%。

mAP0. 5、mAP0. 75 与 mAP0. 5 : 0. 95 的对比柱状图如图 4~6 所示,其中从左到右为表格中从 KL 散度到强化学习的排名损失所一一对应的顺序。

不难看出,在图 4 的 mAP0. 5 提升幅度柱状中,使用本文强化学习的排名损失方法提升幅度达到最大,为 3. 58%;在图 5 的 mAP0. 75 提升幅度柱状图中,使用本文排名损失的方法提升幅度达到最大,为 3. 13%;在图 6 的 mAP0. 5 : 0. 95 提升幅度柱状图中,使用 DKD 的方法提升幅度达到最大,为 2. 63%。




图 4 mAP0. 5 提升对比柱状图
Fig. 4 Bar chart of mAP0. 5 improvement comparison




图 5 mAP0. 75 提升对比柱状图
Fig. 5 Bar chart of mAP0. 75 improvement comparison




图 6 mAP0. 5 : 0. 95 提升对比柱状图
Fig. 6 Bar chart of mAP0. 5 : 0. 95 improvement comparison

为验证所提方法的提升幅度在统计学上具有显著性,求得表 6 对应训练 5 次的标准差数值如表 7 所示。

通过显著性检验得到使用蒸馏方法相对于不使用知识蒸馏的 T-test 显著性检验的 p 值如表 8 所示。

表 7 不同知识蒸馏方法的标准差
Table 7 Standard deviation of different knowledge distillation methods

使用方法	mAP0.5	mAP0.75	mAP0.5:0.95
	标准差/ 10^{-3}	标准差/ 10^{-3}	标准差/ 10^{-3}
不使用知识蒸馏	4.349	2.743	1.176
KL 散度	2.705	2.424	1.570
JS 散度	2.866	3.775	2.228
Wasserstein 距离	3.297	2.427	1.910
DKD	4.966	2.035	2.483
排名损失	3.196	1.722	1.267
强化学习的排名损失	2.875	2.935	2.089

表 8 不同知识蒸馏方法的 T-test 显著性检验 p 值
Table 8 T-test significance test p -value of different knowledge distillation methods

使用方法	mAP0.5	mAP0.75	mAP0.5:0.95
KL 散度	1.222×10^{-6}	8.099×10^{-8}	2.948×10^{-9}
JS 散度	1.762×10^{-6}	2.148×10^{-6}	5.534×10^{-8}
Wasserstein 距离	4.991×10^{-6}	2.501×10^{-7}	2.232×10^{-8}
DKD	3.448×10^{-6}	3.907×10^{-8}	2.406×10^{-8}
排名损失	4.773×10^{-7}	2.196×10^{-8}	6.870×10^{-10}
强化学习的排名损失	3.201×10^{-7}	3.913×10^{-7}	1.174×10^{-8}

不难看出各个方法 p 值均远小于 0.05,表明两组数据存在统计学上的显著差异。由此可见,本文所提方法在 Pascal VOC 2007 数据集上有效地提升了学生网络的性能,在测试集测试到的 mAP0.5、mAP0.75、mAP0.5:0.95 提升幅度为分别为 3.58%、2.69%、2.51%,取得了在 mAP0.5 上的最大幅度提升。

2 孔探图像损伤实时检测

2.1 孔探图像数据集

使用孔探图像设备对某型航空发动机内部进行拍摄视频或图像,截取视频或图像中包含孔探损伤的图像,并人工对图像中包含的损伤类型进行标定,即可获得对应损伤类型的航空发动机孔探损伤图像,部分孔探损伤图像示例如图 7 所示。

孔探图像数据集主要用于目标检测任务,包含裂纹、掉块、凹坑、撕裂、卷边、涂层脱落 6 种损伤,孔探图像来源于某型航空发动机数据,数据一共包含 1 079 张原始图像,进行图像增强后共计 5 395 张图像,按照训练集与测试集比例为 9:1 的比例划分数据集。损伤训练集与测试集的数量如表 9 所示。




图 7 孔探损伤图像示例

Fig. 7 Borescope damage image examples

表 9 孔探数据集中 6 类损伤的数量
Table 9 Number of six types of damage in the borescope dataset

类别	训练集	测试集	合计
裂纹	959	106	1 065
掉块	3 141	349	3 490
凹坑	329	36	365
撕裂	518	57	575
卷边	995	110	1 105
涂层脱落	374	41	374

2.2 孔探图像数据集检测结果

相似地,使用 YOLOv8-m 与 YOLOv8-n 目标检测网络对自建孔探图像数据集进行训练与测试,训练参数等条件如表 2 所示保持不变,同时使用 COCO 数据集的模型进行迁移训练,最终在测试集上进行测试。在孔探图像数据集中,主要以 mAP0.5 为精度指标,通过训练得到的 YOLOv8-n 模型的 mAP0.5 为 62.64%,YOLOv8-m 模型的 mAP0.5 为 89.95%。与 YOLOv8-m 相比,YOLOv8-n 的 mAP0.5 落后 27.31%。故选择 YOLOv8-m 为教师模型,YOLOv8-n 为学生模型进行后续知识蒸馏试验。

使用 YOLOv8-m 作为教师网络,YOLOv8-n 作为学生网络进行知识蒸馏,分别使用 KL 散度、JS 散度、Wasserstein 距离与本文所提排名损失($k=1$)作为蒸馏损失,进行对比试验。并在本文排名损失的基础上加入智能体进行强化学习的知识蒸馏,强化学习的参数如表 5 所示,最终与解耦知识蒸馏方法进行对比试验。试验结果如表 10 所示。

从表 10 中可以看到,使用本文所提排名损失结合强化学习的方法在 mAP0.5 均超出上述其他方法的最大值,在 mAP0.5 上提升了 6.93%。不同方法,提升幅度的柱状图对比如图 8 所示,图 8 中从左到右依次为表 10 中 KL 散度到强化学习的排名损失的提升幅度。

表 10 不同知识蒸馏方法对比

Table 10 Comparison of different knowledge distillation methods (%)

使用方法	mAP0.5
不使用知识蒸馏	62.64 (+0)
KL 散度	66.74 (+4.10)
JS 散度	68.03 (+5.39)
Wasserstein 距离	66.07 (+3.43)
DKD	68.22 (+5.58)
排名损失	68.39 (+5.75)
强化学习的排名损失	69.57 (+6.93)




图 8 mAP0.5 提升对比柱状图

Fig.8 Bar chart of mAP0.5 improvement comparison

为验证本文方法的提升幅度在统计学上具有显著性,求得表 10 对应训练 5 次的标准差数值,与通过显著性检验得到使用蒸馏方法相对于不使用知识蒸馏的 T-test 显著性检验的 p 值如表 11 所示。

表 11 不同知识蒸馏方法的标准差与 T-test 显著性检验 p 值

Table 11 The standard deviation and T-test significance test p -value of different knowledge distillation methods

使用方法	标准差/ 10^{-3}	T-test 的 p 值
不使用知识蒸馏	7.948	
KL 散度	3.307	$1.205\ 26\times10^{-5}$
JS 散度	6.714	$6.527\ 04\times10^{-6}$
Wasserstein 距离	7.634	$2.504\ 63\times10^{-4}$
排名损失	2.058	$6.542\ 67\times10^{-7}$
DKD	6.690	$4.947\ 40\times10^{-6}$
强化学习的排名损失	2.500	$1.719\ 29\times10^{-7}$

不难看出各个方法 p 值均远小于 0.05,表明两组数据存在统计学上的显著差异。由此可见,本文所提方法在孔探图像数据集上有效地提升了学生网络的性能,在

测试集测试得到的 mAP0.5 提升幅度为 6.93%,取得了在 mAP0.5 上的最大幅度提升。

3 结 论

针对航空发动机中的孔探图像检测任务,提出了一种基于知识蒸馏与强化学习的孔探检测模型训练方法,该方法能够不改变网络结构的情况下直接提升网络检测精度。使用 YOLOv8 目标检测网络,在标准数据集 Pascal VOC 2007 数据集与进行训练测试,试验结果表明,通过上述方法训练的目标检测模型 YOLOv8-n,在不修改网络结构的情况下,mAP0.5 提升了 3.58%。最终在孔探图像数据集进行了应用研究,使用上述相同的方法使得 mAP0.5 提升了 6.93%,在一定程度上解决了轻量模型检测精度低的问题,达到了很好的应用效果,所提方法为孔探图像的实时检测提供了重要的理论支撑。

参考文献

[1] 旷可嘉. 深度学习及其在航空发动机缺陷检测中的应用研究[D]. 广州: 华南理工大学,2017.

KUANG K J. Research on deep learning and its application on the defects detection for aero engine[D]. Guangzhou: South China University of Technology, 2017.

[2] 蔡舒舒,闫子砚. 基于改进 YOLOv4 的航空发动机小目标损伤检测研究[J]. 航空动力学报, 2023, 38(2): 445-452.

CAI SH Y, YAN Z Y. Research on small target damage detection of aero-engine based on improved YOLOv4[J]. Journal of Aerospace Power, 2023, 38(2): 445-452.

[3] 何宇豪,曹学国,刘信良,等. 基于 SW-YOLO 模型的航空发动机叶片损伤实时检测[J]. 推进技术,2024, 45(2):197-203.

HE Y H, CAO X G, LIU X L, et al. Real time detection of aircraft engine blade damage based on SW-YOLO model[J]. Journal of Propulsion Technology, 2024, 45(2):197-203.

[4] 赵崇林,朱江,胡永进,等. 融合注意力和多尺度特征的航空发动机缺陷检测[J]. 北京航空航天大学学报, 2025,51(3):892-903.

ZHAO CH L, ZHU J, HU Y J, et al. Aero-engine defect detection based on fusing attention and multi-scale features[J]. Journal of Beijing University of Aeronautics and Astronautics,2025,51(3):892-903.

[5] 吕游,郑茜,齐欣宇,等. 基于改进 EfficientNet 的红外图像光伏组件故障识别研究[J]. 仪器仪表学报, 2024,45(4):175-184.

- LYU Y, ZHENG X, QI X Y, A study on fault recognition of photovoltaic module with infrared images based on improved efficientnet[J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 175-184.
- [6] 刘传洋, 吴一全, 刘景景. 基于视觉的输电线路金具锈蚀缺陷检测方法研究进展[J]. 仪器仪表学报, 2024, 45(3): 286-305.
- LIU CH Y, WU Y Q, LIU J J. Research progress of vision-based rust defect detection methods for metal fittings in transmission lines [J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 286-305.
- [7] 何超, 陈果, 王雨薇. 基于深度学习的航空发动机内部损伤实时检测方法[J]. 航空动力学报, 2023, 38(8): 1857-1864.
- HE CH, CHEN G, WANG Y W. Real-time detection method of aero-engine internal damage based on deep learning [J]. Journal of Aerospace Power, 2023, 38(8): 1857-1864.
- [8] 童小钟, 赵宗庆, 苏绍璟, 等. 基于知识蒸馏自适应 DenseNet 的无人机对地目标可见光与红外图像融合[J]. 仪器仪表学报, 2024, 45(5): 20-32.
- TONG X ZH, ZHAO Z Q, SU SH J, et al. Fusion of visible and infrared images of ground targets by unmanned aerial vehicles based on knowledge distillation adaptive DenseNet[J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 20-32.
- [9] 李北明, 金荣璐, 徐召飞, 等. 基于特征蒸馏的改进 Ghost-YOLOv5 红外目标检测算法[J]. 郑州大学学报(工学版), 2022, 43(1): 20-26.
- LI B M, JIN R L, XU ZH F, et al. An improved Ghost-YOLOv5 infrared target detection algorithm based on feature distillation[J]. Journal of Zhengzhou University (Engineering Science), 2022, 43(1): 20-26.
- [10] 许晓阳, 高重阳. 改进 YOLOv7-tiny 的轻量级红外车辆目标检测算法[J]. 计算机工程与应用, 2024, 60(1): 74-83.
- XU X Y, GAO CH Y. Improved YOLOv7-tiny lightweight infrared vehicle target detection algorithm[J]. Computer Engineering and Applications, 2024, 60(1): 74-83.
- [11] 楚玉春, 龚航, 王学芳, 等. 基于 YOLOv4 的目标检测知识蒸馏算法研究[J]. 计算机科学, 2022, 49(S1): 337-344.
- CHU Y CH, GONG H, WANG X F, et al. Study on knowledge distillation of target detection algorithm based on YOLOv4 [J]. Computer Science, 2022, 49(S1): 337-344.
- [12] TSENG W CH, WANG T H J, LIN Y CH, et al. Offline multi-agent reinforcement learning with knowledge distillation[J]. Advances in Neural Information Processing Systems, 2022, 35: 226-237.
- [13] CHEN G B, CHOI W, YU X, et al. Learning efficient object detection models with knowledge distillation[C]. 31st International Conference on Neural Information Processing Systems, 2017, 742-751.
- [14] CHAWLA A, YIN H X, MOLCHANOV P, et al. Data-free knowledge distillation for object detection[C]. 2021 IEEE/CVF Winter Conference on Applications of Computer Vision, 2021: 3289.
- [15] TONG K, WU Y Q. Rethinking PASCAL-VOC and MS-COCO dataset for small object detection[J]. Journal of Visual Communication and Image Representation, 2023, 93: 103830.
- [16] LI ZH H, XU P F, CHANG X J, et al. When object detection meets knowledge distillation: A survey [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(8): 10555-10579.
- [17] DE RIJK P, SCHNEIDER L, CORDTS M, et al. Structural knowledge distillation for object detection[J]. Advances in Neural Information Processing Systems, 2022, 35: 3858-3870.
- [18] MATHE S, PIRINEN A, SMINCHISESCU C. Reinforcement learning for visual object detection[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016: 2894-2902.
- [19] UZKENT B, YEH C, ERMON S. Efficient object detection in large images using deep reinforcement learning[C]. 2020 IEEE/CVF Winter Conference on Applications of Computer Vision, 2020: 1824-1833.
- [20] PIRINEN A, SMINCHISESCU C. Deep reinforcement learning of region proposal networks for object detection[C]. 2018 IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6945-6954.
- [21] KÖNIG J, MALBERG S, MARTENS M, et al. Multi-stage reinforcement learning for object detection [C]. Science and Information Conference. Cham: Springer International Publishing, 2019: 178-191.
- [22] LI X, WANG W H, WU L J, et al. Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection [J]. Advances in Neural Information Processing Systems, 2020, 33: 21002-21012.
- [23] BOCHKOVSKIY A, WANG CH Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv preprint arXiv:2004.10934, 2020.
- [24] KIM T, OH J, KIM N Y, et al. Comparing kullback-

- leibler divergence and mean squared error loss in knowledge distillation[J]. ArXiv preprint arXiv:2105.08919, 2021.
- [25] HUANG T, YOU SH, WANG F, et al. Knowledge distillation from a stronger teacher [J]. Advances in Neural Information Processing Systems, 2022, 35: 33716-33727.
- [26] WU T Q, TAO CH F, WANG J H, et al. Rethinking kullback-leibler divergence in knowledge distillation for large language models [J]. ArXiv preprint arXiv:2404.02657, 2024.
- [27] FANG G F, BAO Y F, SONG J, et al. Mosaicking to distill: Knowledge distillation from out-of-domain data[J]. Advances in Neural Information Processing Systems, 2021, 34: 11920-11932.
- [28] WEN Y Q, LI Z CH, DU W Y, et al. F-divergence minimization for sequence-level knowledge distillation [C]. 61st Annual Meeting of the Association for Computational Linguistics, 2023: 10817-10834.
- [29] XU X H, LI M, TAO CH Y, et al. A survey on knowledge distillation of large language models [J]. ArXiv preprint arXiv:2402.13116, 2024.
- [30] CHEN L Q, WANG D, GAN ZH, et al. Wasserstein contrastive representation distillation [C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 16296-16305.
- [31] LYU J M, YANG H Y, LI P H. Wasserstein distance rivals Kullback-Leibler divergence for knowledge distillation[C]. Advances in Neural Information Processing Systems, 2024, 37: 65445-65475.
- [32] WANG G, CHEN Y F, AN P, et al. UAV-YOLOv8: A small-object-detection model based on improved YOLOv8 for UAV aerial photography scenarios [J]. Sensors, 2023, 23(16): 7190.
- [33] ZHAO B R, CUI Q, SONG R J, et al. Decoupled knowledge distillation[C]. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 11953-11962.

作者简介



何超, 2019 年于南京航空航天大学获得学士学位, 2022 年于南京航空航天大学获得硕士学位, 现为南京航空航天大学博士在读, 主要研究方向为深度学习。

E-mail: agatsumazenitsu@nuaa.edu.cn

He Chao received his B.Sc. and M.Sc. degrees both from Nanjing University of Aeronautics and Astronautics (NUAA) in 2019 and 2022, respectively. He is currently pursuing his Ph.D. degree at NUAA. His main research interest includes deep learning.



陈果 (通信作者), 1994 年于西南交通大学获得学士学位, 1997 年于西南交通大学获得硕士学位, 2000 年于西南交通大学获得博士学位, 现为南京航空航天大学教授, 主要研究方向为航空发动机整机振动及转子动力学分析、航空发动机转子轴承系统故障

诊断技术等。

E-mail: cgzyx@263.net

Chen Guo (Corresponding author) received his B.Sc., M.Sc. and Ph.D. degrees all from Southwest Jiaotong University (SWJTU) in 1994, 1997 and 2000, respectively. He is currently a professor in the School of NUAA. His main research interests include vibration of aero-engine whole machine and rotor dynamics analysis, fault diagnosis technology of aero-engine rotor-bearing system, etc.