第 50 卷 第 12 期：5229-5237 高电压技术 Vol.50, No.12: 5229-5237
2024 年 12 月 31 日 High Voltage Engineering December 31, 2024
DOI: 10.13336/j.1003-6520.hve.20231541

基于共有特征评分的解耦知识蒸馏输电线路金具检测方法

赵振兵[1,2,3]，吕雪纯[1]，苗思雨[1]，赵文清[2,4]，翟永杰[2,4]，张 珂[1,3]
（1. 华北电力大学电气与电子工程学院，保定 071003；2. 华北电力大学复杂能源系统智能计算教育部工程研究中心，保定 071003；3. 华北电力大学河北省电力物联网技术重点实验室，保定 071003；4. 华北电力大学控制与计算机工程学院，保定 071003）

摘 要：输电线路金具航拍图像具有目标占比小和背景过于复杂的特点，为了将对金具目标检测性能优越的教师网络性能迁移到学生网络，提出了一种基于共有特征评分的解耦知识蒸馏输电线路金具检测方法。首先，根据 Ground-truth 框将图像特征解耦为前景和背景区域，在前景区域对教师模型特征金字塔中每一层特征信息分类评分，聚合所有类别分类分数作为共有特征蒸馏掩码。其次，为了保证整幅图像的完整性，采用 GcBlock 模块捕获金具目标与背景、其他金具之间的关系，以此将教师模型生成的图像特征知识完整地迁移到学生网络。最后，通过自建金具图像检测数据集验证该文提出方法的有效性，实验结果表明：将该文方法应用于双阶段、单阶段模型均可大幅提升参数量小的网络检测性能，Faster R-CNN、RetinaNet 的学生网络交并比阈值为 0.5 的平均精度(mAP_50)分别提升了 25.9%、31.4%，有的甚至超过教师网络检测精度；针对防震锤、调整板、重锤目标，Cascade R-CNN 模型中学生网络的平均精度显著提升。该文研究方法实现了对金具目标的高效检测，达到了检测性能与资源消耗的平衡。

关键词：金具目标检测；知识蒸馏；教师模型；学生模型；共有特征评分

Inspection Method for Decoupled Knowledge Distillation Transmission Line Fittings Based on Shared Feature Scoring

ZHAO Zhenbing[1,2,3], LYU Xuechun[1], MIAO Siyu[1], ZHAO Wenqing[2,4], ZHAI Yongjie[2,4], ZHANG Ke[1,3]
(1. School of Electrical and Electronic Engineering, North China Electric Power University, Baoding 071003, China; 2. Engineering Research Center of Intelligent Computing for Complex Energy Systems, Ministry of Education, North China Electric Power University, Baoding 071003, China; 3. Hebei Key Laboratory of Power Internet of Things Technology, North China Electric Power University, Baoding 071003, China; 4. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China)

Abstract：Aerial images of transmission line fittings have the characteristics of small target proportion and excessively complex background. In order to transfer the performance of a teacher network which has excellent performance in detecting fitting targets to a student network, a decoupled knowledge distillation method based on shared feature scoring for transmission line fitting detection is proposed. Firstly, the image features are decoupled into foreground and background regions according to the Ground-truth box. In the foreground region, the feature information of each layer in the teacher model's feature pyramid is classified and scored, and the classification scores of all categories are aggregated as the common feature distillation mask. Secondly, in order not to maintain the integrity of the whole image, the GcBlock module is used to capture the relationship among the object of the fittings, the background and other fittings, so as to transfer the image feature knowledge generated by the teacher model to the student network completely. Finally, the validity of the proposed method is verified by a self-built fitting image detection data set. The experimental results show that, by applying this method to both two-stage and single-stage models, the detection performance of the network with a small number

基金资助项目：国家自然科学基金 (61871182, U21A20486)；河北省自然科学基金 (F2020502009, F2021502008, F2021502013)；中央高校基本科研业务费专项资金 (2023JC006)。
Project supported by National Natural Science Foundation of China (61871182, U21A20486), Natural Science Foundation of Hebei Province (F2020502009, F2021502008, F2021502013), Fundamental Research Funds for the Central Universities (2023JC006).

of participants can be greatly improved. The mean average precision of student network at 0.5 intersection over union of Faster R-CNN and RetinaNet can be improved by 25.9% and 31.4%, respectively, surpassing even the detection accuracy of the teacher network. The cascade R-CNN's student network has significantly improved targets for the shock hammer, adjustment board, and weight. The method in this paper can be adopted to realize the high efficiency detection of the fitting target, and to achieve the balance between detection performance and resource consumption.

Key words：fitting target detection; knowledge distillation; teacher model; student model; shared feature score

0 引言

输电线路故障是造成电网大面积停电事故的主要原因之一，金具是输电线路上广泛应用的金属部件，其在电网系统中主要起到支持、固定、连接、保护裸导线和导体的作用。因输电线路所处环境复杂，长期受到恶劣天气、负荷电力的影响，极易使金具出现冻裂、腐蚀和锈蚀等现象，严重威胁电网中输电线路的安全运行。因此，及时对输电线路航拍巡检图像进行金具目标自动检测，是状态检测和故障判断的基础，对电网安全输电意义重大[1]。传统的人工巡检已不能满足繁重的巡检要求，为安全起见目前主要采用无人机、直升机等巡检手段[2-4]。然而，无人机、直升机拍摄图像时有安全距离要求，拍摄图像背景复杂、成像距离及角度多变，导致金具隐藏在输电线路和背景中，目标渺小，背景信息干扰大，不易被准确检测。为提升模型检测性能，大部分图像目标检测研究在基础检测模型上结合多种针对性算法，以此构建更复杂的模型，这会对设备性能提出更高要求，训练时间相应增长[5]。文献[6]在特征提取及特征融合部分引入注意力机制来获得具有抗干扰能力的特征表示，首先使用分离注意力网络提取缺陷特征，其次利用非局部注意力机制对融合特征进行感受野内不同区域加权，构建的多注意力 Faster R-CNN(faster region-based convolutional network)网络对印刷电路板缺陷具有 92.4%的平均检测精度。为解决实际场景采集的船舶目标样本数量不平衡问题，文献[7]在关系网络中引入全局注意力机制，将关系网络提取到的原始特征，经过全局注意力机制平衡不均衡类别间的目标特征，再与原始特征融合进行特征距离度量，增强全局特征之间的一致性，有利于学习不变的目标特征。文献[8]在 YOLOv5 算法基础上融合卷积注意力机制模块，实现反向片靶标的广角镜头和靶标中心的长焦镜头精准照准。金具航拍图像视觉信息较差，为了提升检测准确率，同样构建针对性模块并添加到基础检测模型中。文献[9]将 Cascade R-CNN、Faster R-CNN 和 RetinaNet、YOLOv3 算法分别进行算法融合，得到连接金具检测模型和小金具识别模型。该模型分为两阶段进行：先对输入图片检测出连接金具；再在连接金具基础上识别小金具缺陷。为解决数据长尾问题挖掘金具组装关系信息提升检测精度，文献[10]设计了描述多类金具间共现关系的推理模块嵌入 Faster R-CNN 模型中。文献[11]先使用 Faster R-CNN 目标检测网络训练细小金具缺陷识别模型，再将 Faster R-CNN 中基于交叉熵的区域生成网络(region proposal network，RPN)分类损失替换为焦点损失(Focal Loss)，保留所有前景、背景 Anchors 来训练 RPN，以此提高细小金具在困难样本中的分类损失权重。

多种模块算法相结合提高了目标检测模型的精度，但不可避免地增加了模型复杂度，引入大量计算参数，耗费海量的计算资源和时间，使巡检任务效率降低，同时对计算设备提出了更高的要求。当前目标检测发展方向之一是能将目标检测算法部署到前端设备，实现快速高效检测，这将大大减少人工和时间成本。

Hinton 首次提出了知识蒸馏概念，将复杂度高、性能好的模型称为教师模型(参数量大，计算时间长的网络模型)；将结构简单，性能较差的模型称为学生模型(参数量小，计算时间短的网络模型)。将软目标作为总损失的一部分，使教师网络诱导学生网络学习自身性能，以提高学生网络的分类效果。目前，已有知识蒸馏算法用于目标检测网络，实现了真正的技术落地。文献[12]提取颈部特征图、分类头和回归头 3 部分的知识用于蒸馏，但将背景和前景平均地提取特征图信息会引入更多噪声。文献[13]提供了一种细粒度模拟蒸馏方法，为了提高前景目标检测精度，引导学生学习教师网络的 Ground-truth 框和预测 anchor 框构成 IOU map 掩码的分布范围，IOU map 掩码可以减少背景信息过多对前景目标造成的检测精度过低的影响。文献[14]采用高斯掩码提取前景目标所在区域特征进行蒸馏，该方法突出强调了目标的中心区域，减少了目标所在区域的背

景噪声。这样做虽然将蒸馏知识聚集到前景目标，但割裂了目标与背景之间的关系，极大地减少了背景的作用。上述蒸馏方法对公共数据集有很好的检测效果，但对输电线路金具数据集的检测准确度还有待提升。

知识蒸馏的目的是让教师模型将最利于目标检测的信息传递到学生网络[15]，以此提升学生网络的性能。本文针对金具航拍图像背景复杂、目标占比小，参数量小的模型检测性能较差等问题，提出了一种基于共有特征评分的解耦知识蒸馏输电线路金具检测方法，将金具航拍图像先按照 Ground-truth 框解耦成前景目标区域和背景区域，针对前景目标区域对特征评分，教师模型把评分高的特征信息用于指导学生网络训练；同时为了不割裂整幅图像特征信息的完整性，利用 GcBlock 模块来捕获金具目标和背景区域之间的关系，充分利用背景信息对金具目标检测的提示性作用。本文将知识蒸馏技术引入输电线路航拍图像金具目标检测任务中，在保证检测准确率的同时，大幅度降低计算资源的消耗，可将模型部署到前端嵌入式可移动设备，满足现场运维需求，减少人力物力消耗的同时提升效率。

1 金具图像目标检测知识蒸馏算法

知识蒸馏算法是轻量化网络算法之一，总体结构由教师网络和学生网络两部分构成。其中教师网络指对金具目标检测精度符合预期效果的网络，为了提升输电线路航拍图像目标检测准确度，大多添加复杂的模块、改变模型架构[16]，从而造成计算参数量增加，检测时间增长，难以满足随拍随检的要求；学生网络一般是指和教师网络相同结构模型，结构简单、参数量小、计算时间短、可以部署到前端移动设备的小模型，但目标检测精度较低。为满足巡检任务，快速高效进行目标检测，本文将用于输电线路金具目标检测的网络轻量化，将金具共有特征评分解耦知识蒸馏算法引入其中，促使教师网络能将最准确、最完整的金具特征知识迁移到学生网络。

知识蒸馏算法最重要目的是教师网络将有利于目标检测的特征知识迁移到学生网络，达到轻量化的目的[17]。输电线路金具航拍图像背景复杂多变，金具目标相对较小。特征知识若不加以筛选会包含大量的背景噪声，对提升学生网络性能并无实质性助益。因此先将图像特征解耦处理，针对前景目标区域，对每一层特征进行评分处理，相同种类的金具特征共同性较多，类别分类分数作为共有特征迁移掩码，对于同种金具检测效果提升具有显著性作用。同时金具安装在输电线路上，特有的安装环境、位置特征对用于网络解读金具目标位置有提示性作用[18-19]，采用 GcBlock[20]模块捕获金具目标与其他目标、金具与背景信息之间的关系。本文算法原理图如图 1 所示。

1.1 常规知识蒸馏检测方法

大部分目标检测模型添加特征金字塔网络(feature pyramid networks, FPN)[21]来充分提取不同分辨率的图像特征，在 FPN 输出的特征囊括了来自主干网络不同层次的语义信息和几何信息，教师网络在 FPN 处迁移特征信息处理能力，既不会增加学生模型参数量，又能提高其目标检测性能，如图 2 所示。通常，在 FPN 的特征蒸馏表述如式(1)所示。

$$L_{\text{fpn}}=\frac{1}{HWC}\sum_{i=1}^{W}\sum_{j=1}^{H}\sum_{k=1}^{C}(F^{\text{T}}_{k(i,j)}-f_{\text{adp}}(F^{\text{S}}_{k(i,j)}))^2 \tag{1}$$

式中：$F^{\text{T}}_{k(i,j)}$ 和 $F^{\text{S}}_{k(i,j)}$ 分别为教师网络和学生网络的

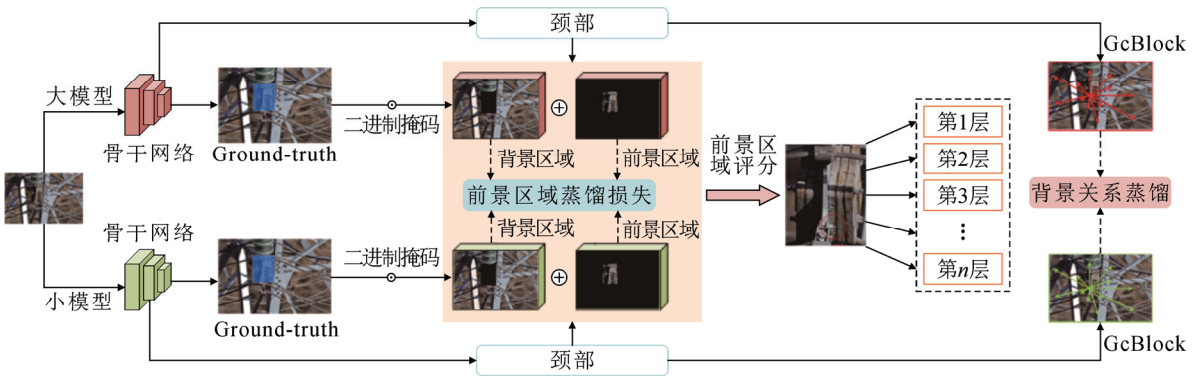


图 1 教师网络指导学生网络训练整体结构

Fig.1 Overall structure of the teacher network to guide the student network training

特征图；f_{adp} 为对齐学生网络和教师网络维度的适应函数；H 为网络生成特征图的高度；W 为特征图的宽度；C 为网络的通道数。

由金具航拍图像可知，图像中占比更大的是复杂多变的背景，金具目标隐藏在其中。将 FPN 每层特征信息毫无区分地用于教师网络指导学生网络，会导致学生网络没有学到最精确的特征处理能力，不能有效提升金具目标的检测能力。为使教师网络将金具特征知识以更准确的形式指导学生网络，将骨干网络输出的特征解耦处理，有助于模型将注意力集中到目标处，提高其在复杂背景中定位目标的能力。

1.2 金具目标特征评分蒸馏方法

输电线路大多处于野外环境中，巡检时无人机拍摄角度多变，为安全起见，无人机离高压线要有一定的安全距离，这样导致拍摄图像中背景占比大，金具目标渺小。为了减少背景信息对目标定位和分类的不利影响，将图像解耦区域蒸馏。受文献[22]启发，在背景复杂多变的航拍图像中为了把模型聚焦到金具目标区域，可用二进制掩码 M 解耦特征图为前景、背景区域。实验室数据集标注时如图 3 所示，Ground-truth 框紧贴检测目标标注，此区域的特征知识被认为是最主要的金具目标知识。

首先，判断 FPN 网络生成的特征图是否属于 Ground-truth 框内，进而解耦成前景目标区域和背景区域，如图 4 所示。用二进制掩码 M 来表示，如式(2)所示：

$$M_{(i,j)}=\begin{cases}1, & (i,j)\in G\\ 0, & (i,j)\notin G\end{cases} \tag{2}$$

式中：G 代表 Ground-truth 框；设(i,j)表示模型的特征金字塔网络生成特征图的水平和垂直方向的坐标。若(i,j)处于 Ground-truth 边界框内，认定这个特征属于前景目标区域，令掩码 $M_{(i,j)}$=1；若(i,j)不处于 Ground-truth 边界框内，则判定为背景区域的特征图，令 $M_{(i,j)}$=0。

在水平和垂直方向分别为(i,j)的特征图内随机抽选特征 f，这些特征是某个金具目标的条件概率 P，可描述为式(3)：

$$Y=M_{(i,j)}P(S|f) \tag{3}$$

式中：S 代表一个目标类别；Y 表示特征 f 是目标种类 S 的概率；$M_{(i,j)}$用来控制特征是否为前景目标区域。特征属于某个金具目标的条件概率 Y_S 使用深度神经网络计算得到。θ 表示为生成参数的模型，如式(4)所示，在教师网络的 FPN 中每一层都对特征图建立其条件概率 P，如图 5 所示。

$$Y_S=M_{(i,j)}P(S|f,\theta) \tag{4}$$

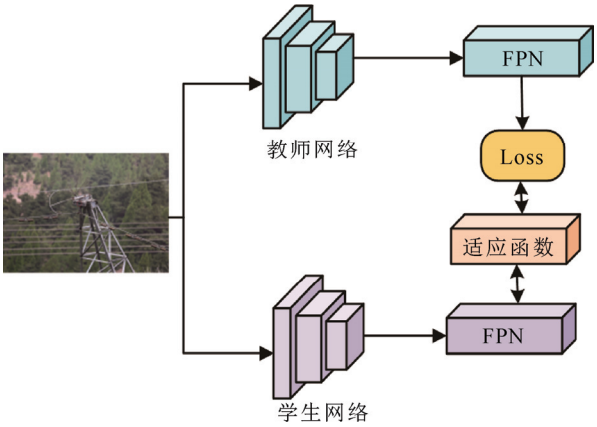


图 2 FPN 层特征蒸馏

Fig.2 FPN layer characteristic distillation



(a)示例 1 (b)示例 2

图 3 数据集标注示例

Fig.3 Example of dataset annotation

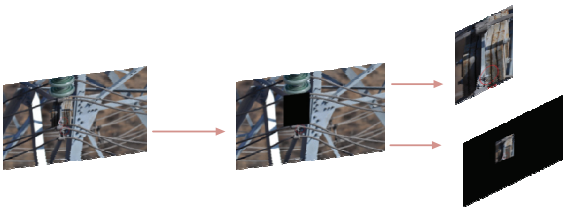


图 4 根据 ground-truth 框分离前景目标和背景区域

Fig.4 Separation of foreground target and background area according to the ground-truth box

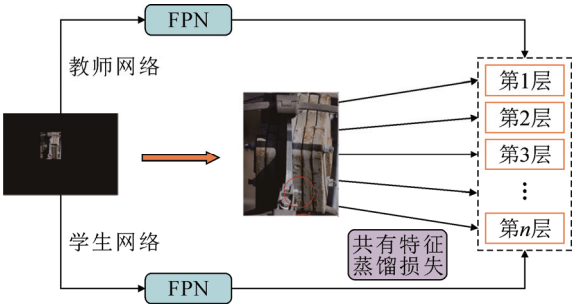


图 5 对前景区域特征评分

Fig.5 Scoring of foreground region features

提出的共有特征评分概念定义为这些特征属于某个金具目标的概率，概率越大，评分越高。为了对所有类别的金具种类进行汇总，本方法聚合所有类别的概率来获得共有特征评分，某些特征可能会判定为多个金具目标，在本文中使用概率最大值来聚合，如式(5)所示。

$$F_{\max}=\max_{S} Y_S=\max_{S} M_{(i,j)}P(S|f,\theta) \tag{5}$$

由于存在多种种类的金具对象，本文以 s 代表数据集中金具的所有种类的类别数，令 $s'\in[1,s]$，s' 作为样本来表示所有的金具对象 S。故所有金具种类的共有特征评分用 F_1 作为掩码表示，如式(6)所示。

$$F_1=\max_{1\le s'\le s} Y_{s'}=\max_{1\le s'\le s} M_{(i,j)}P(s'|f,\theta) \tag{6}$$

在蒸馏过程中把教师模型对金具的分类概率 $Y_{s'}^{\mathrm{T}}$ 作为共有特征评分标准，即为教师模型对特征的分类得分情况，认为已经训练过教师模型的分类结果是指导学生模型训练的分类标准。同时把已经训练过的教师模型分类头对金具的分类结果 θ^{T} 作为 θ 的具体生成参数的模型实例，f^{T} 是输入到教师模型分类头的特征。以此来用教师模型对特征的评分标准以掩码 F_{T} 的形式指导学生模型提取特征，如式(7)所示。

$$F_{\mathrm{T}}=\max_{1\le s'\le s} Y_{s'}^{\mathrm{T}}=\max_{1\le s'\le s} M_{(i,j)}P(s'|f^{\mathrm{T}},\theta^{\mathrm{T}}) \tag{7}$$

金具目标尺度变化差异大，特征图金字塔网络被提出用来处理多尺度目标检测问题。浅层网络特征图具有高分辨率，更适合检测小尺度目标；而深层网络特征图具有低分辨率，更适合检测大尺度目标。为完整地将教师网络对特征分类概率用于指导学生模型，对特征图金字塔网络的每一层生成共有特征评分掩码，指导学生网络训练。本文使用特征金字塔网络每一层的聚合分类得分图作为共有特征评分掩码，如式(8)所示。

$$F_k=\max_{1\le s'\le s} Y_{kC}^{\mathrm{T}} \tag{8}$$

式中：F_k 为教师模型的第 k 层特征图金字塔网络在通道 C 上的共有特征评分掩码；Y_{kC}^{T} 是教师模型在第 k 层、通道数为 C 特征金字塔网络的分类得分图。故在前景目标区域教师模型在特征图金字塔网络使用共有特征评分掩码指导学生模型，提取特征的蒸馏损失如式(9)所示。

$$L_{\mathrm{front}}=\sum_{k=1}^{n}\frac{1}{N_k}\sum_{i=1}^{W}\sum_{j=1}^{H}M_{(i,j)}F_{k(i,j)}\sum_{C=1}^{l}(F_{Ck(i,j)}^{\mathrm{T}}-f_{\mathrm{adap}}(F_{Ck(i,j)}^{\mathrm{S}}))^2 \tag{9}$$

式中：n 为特征图金字塔网络总的层数；$N_k=\sum_{i=1}^{W}\sum_{j=1}^{H}F_{k(i,j)}$；$F_{k(i,j)}$ 为位置(i,j)的共有特征评分掩码；函数 f_{adap} 是使教师模型和学生模型通道相适应的卷积函数；$F_{Ck(i,j)}^{\mathrm{T}}$ 和 $F_{Ck(i,j)}^{\mathrm{S}}$ 分别为教师模型和学生模型在特征图金字塔网络相应层、相应通道、同一位置特征图分类得分图。以此损失函数来使学生模型学习教师模型的分类能力。

1.3 目标与背景区域关系蒸馏

不同目标、目标与背景之间具有重要的关系，如果只是迁移前景目标区域的知识，将割裂整幅图像的整体性，使学生网络丧失对整幅图像的感知能力。1.2 节中，把目光集中到金具目标检测的最主要区域，但输电线路上的金具安装位置固定，周围环境信息对提高对金具安装位置的了解具有显著性的作用。故采用 GcBlock 捕获图像整体的关系信息。促使学生网络学习教师网络对关系信息的感知能力，如图 6 所示。整体图像关系损失的表示如式(10)。

$$L_{\mathrm{rela}}=\mu\sum(R(F^{\mathrm{T}})-R(F^{\mathrm{S}}))^2 \tag{10}$$

式中：μ 为默认的平衡损失函数的超参数；F^{T}、F^{S} 分别为教师模型和学生模型生成的特征图；R 函数为不同模型对某一金具目标捕获的金具目标和背景区域的关系信息，具体如式(11)所示。

$$R(F_i)=F_i+\boldsymbol{W}_{\mathrm{v}2}\mathrm{Relu}\left(\mathrm{LN}\left(\boldsymbol{W}_{\mathrm{v}1}\left(\sum_{j=1}^{N_{\mathrm{p}}}\frac{\mathrm{e}^{\boldsymbol{W}_kF_j}}{\sum_{k=1}^{N_{\mathrm{p}}}\mathrm{e}^{\boldsymbol{W}_kF_{\mathrm{M}}}}F_j\right)\right)\right) \tag{11}$$

式中：$\boldsymbol{W}_{\mathrm{v}1}$、$\boldsymbol{W}_{\mathrm{v}2}$、$\boldsymbol{W}_k$ 表示不同线性变换矩阵；F_i 作为一个输入实例的特征图；$\partial_j=\mathrm{e}^{\boldsymbol{W}_kF_j}/\sum_{k=1}^{N_{\mathrm{p}}}\mathrm{e}^{\boldsymbol{W}_kF_{\mathrm{M}}}$ 是全局注意力池化的权重；LN 表示归一化处理；N_{p} 为特征层的位置数目，对图像来说 $N_{\mathrm{p}}=HW$，e 为自然常数；F_{M} 为前景区域的生成的特征图；F_j 为图像中任意提取特征，$\delta(\cdot)=\boldsymbol{W}_{\mathrm{v}2}\mathrm{Relu}(\mathrm{LN}(\boldsymbol{W}_{\mathrm{v}1)}(\cdot))$ 表示捕获通道依赖关系的特征变换。GcBlock 模块包括用于上下文建模的全局注意力池化操作和瓶颈转换以捕获通道的相关性。

1.4 总的蒸馏损失

本文中采用前景目标区域蒸馏损失以及背景关系蒸馏损失之和对学生网络进行指导，如式(12)所示 α、β 为不同的平衡参数：

$$L=\alpha L_{\mathrm{front}}+\beta L_{\mathrm{rela}} \tag{12}$$

教师网络只在特征图上对学生网络进行知识迁移，故可以应用于单阶段、双阶段多种目标检测网络，将广泛用于金具目标检测的模型轻量化。

2 数据与实验准备

2.1 实验准备

本文选用实验室自建金具数据集中标签数最多的 5 种金具作为检测目标，包括防震锤、提包式悬垂线夹、挂板、调整板、重锤。数据集中图像共 1 149 张，其中训练集 919 张，测试集 115 张，评估集 115 张，数量比例为 8:1:1。共包含金具目标数 4 947 个，图 7 为数据标签统计。

本文所述模型采用 NVIDIA GeForce GTX 1080Ti 专业加速卡进行训练和测试；采用的操作系统为 Ubuntu16.04.6 LTS，利用 CUDA10.1 加速训练；使用的计算机语言为 Python3.7.11，网络开发框架为 Pytorch，所有程序均在 MMDetection2.16 工具箱基础上运行。本文采用目标检测模型中常用的评价指标平均精度均值(mean average precision, mAP)对模型进行评估，通过计算各类目标平均精度(average precision, AP)，以所有类目标的 AP 平均值作为目标检测模型的最终评价指标。

2.2 实验过程

实验采用统一的学习率为 0.000 1，教师网络的骨干网络采用 Resnet101，学生网络的骨干模型采用 Resnet50。训练轮次即 epoch 为 24；batch-size 为 50。

本文实验过程主要有 2 个步骤：

1）单独使用参数量大和参数量小的目标检测模型分别训练金具数据集，并统计准确率。

2）添加知识蒸馏算法模型的参数量小的学生模型训练金具数据集，并统计准确率。

3 实验结果分析

表 1 给出了教师网络、学生网络单独训练数据集测试结果，以及添加本文知识蒸馏算法后学生网络的训练检测结果。为验证本文提出蒸馏方法的普适应，选取了单阶段、双阶段的检测模型添加本方法验证。由数据可以看出，添加本文蒸馏方法后的学生网络检测准确度有很大提升，不仅超过学生网络单独检测的准确度，基于 Faster R-CNN[23]和 Retinanet[24]网络甚至超过了教师网络的性能。这是由于本文的蒸馏方法首先将有用特征主要锁定到 Ground-truth 框中，大大提高了模型在多变复杂的背景中搜寻金具目标的能力，提高了定位准确度；同时以共有特征作为分类准则，任意挑选的特征可能会属于不同的金具目标，选取评分最高的作为准

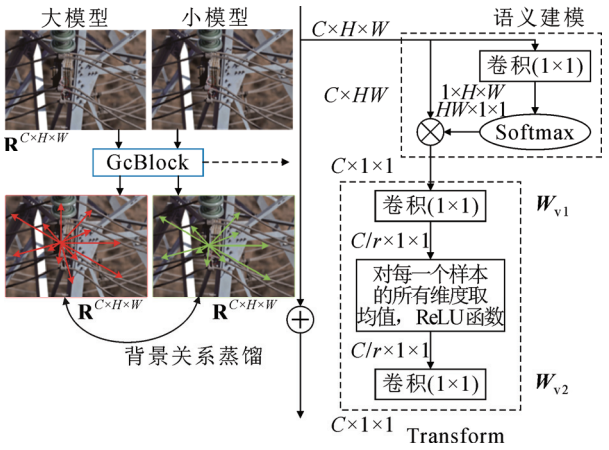


图 6 GcBlock 模块提取目标与背景之间关系

Fig.6 GcBlock module extracts the relationship between target and background

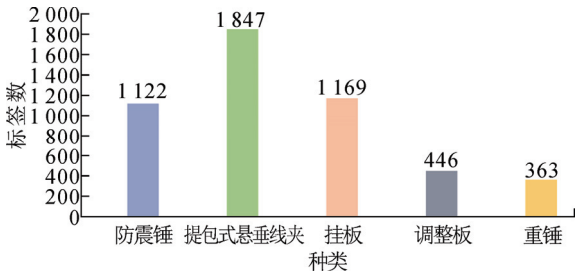


图 7 数据集标签统计

Fig.7 Dataset label statistics

表 1 不同模型以及添加知识蒸馏算法结果

Table 1 Results of different models and adding knowledge distillation algorithms

方法	mAP_50	防震锤	提包式悬垂线夹	挂板	调整板	重锤
Faster-Res101(教师网络)	0.692	0.892	0.912	0.281	0.511	0.862
Faster-Res50(学生网络)	0.511	0.757	0.790	0.105	0.317	0.588
Faster R-CNN+本章蒸馏方法	0.770	0.893	0.929	0.478	0.597	0.951
RetinaNet-Res101(教师网络)	0.668	0.886	0.898	0.350	0.337	0.867
RetinaNet-Res50(学生网络)	0.398	0.687	0.682	0.120	0.126	0.376
RetinaNet+本章蒸馏方法	0.712	0.853	0.893	0.405	0.461	0.947
Cascade-Res101(教师网络)	0.616	0.883	0.867	0.190	0.419	0.721
Cascade-Res50(学生网络)	0.609	0.838	0.907	0.229	0.346	0.726
Cascade+本章蒸馏方法	0.601	0.865	0.856	0.189	0.361	0.735

则，金具之间独特的图像特征有很强的提示性作用。在 Faster R-CNN 网络中性能提升较为突出，对于 5 种金具目标的检测精度均超过未添加蒸馏方法的学生网络，交并比阈值为 0.5 的平均精度 mAP_50 提高 25.9%。Retinanet 网络中加蒸馏方法后，挂板、调整板、重锤的精度甚至超过教师网络的检测性能，防震锤和提包式悬垂线夹可能安装位置密集、目标较小，单阶段网络解耦区域时不易区分，故检测效果提升不够明显。Cascade R-CNN[25]网络添加蒸馏方法后，防震锤、调整板、重锤均有小幅度精度提升，其中提包式悬垂线夹、挂板精度没有提升反而降低，猜测这是由于教师网络的性能低于学生网络，证明对于检测网络来说，添加蒸馏方法后性能提升效果要看教师网络的能力是否比学生网络要强。

由表 2 可知，本文方法比细粒度模拟蒸馏方法要更适合复杂背景下的金具检测。添加细粒度模拟蒸馏方法后只对重锤目标的检测效果有小幅提升。本蒸馏方法相比较细粒度方法，对 5 种目标检测效果提升明显，说明本蒸馏方法的优越性。

以 Faster R-CNN 模型为例，学生网络、教师网络及添加蒸馏方法后的学生网络可视化结果如图 8 所示。图 8(a)中学生网络检测会有很多定位重复现象，图 8(b)中教师网络准确定位分类能力较强。图 8(c)中添加知识蒸馏方法后学生网络已近似教师网络性能，有的甚至能达到超过教师网络的检测效果，说明了本文方法的有效性。

表 2 知识蒸馏方法比较

Table 2 Comparison of knowledge distillation methods

方法	mAP_50	防震锤	提包式悬垂线夹	挂板	调整板	重锤
细粒度蒸馏方法[11]	0.478	0.685	0.637	0.031	0.271	0.765
本章蒸馏方法	0.770	0.893	0.929	0.478	0.597	0.951



(a)学生网络 (b)教师网络 (c)蒸馏后学生网络

图 8 不同网络可视化比较

Fig.8 Comparison of different network visualisations

为验证 GcBlock 的作用，本文只采用前景区域蒸馏方法进行实验，模型选用 Faster R-CNN，结果如表 3 所示，捕获防震锤、提包式悬垂线夹等小型目标物体，以及它们与其他目标物体和背景之间的关系，对于在单幅图像中数量较多的这类金具的检测性能有着显著的提升作用。

表 3 不同区域消融实验

Table 3 Ablation experiments in different areas

方法	mAP_50	防震锤	提包式悬垂线夹	挂板	调整板	重锤
教师网络	0.692	0.892	0.912	0.281	0.511	0.862
学生网络	0.511	0.757	0.790	0.105	0.317	0.588
只有前景区域蒸馏	0.513	0.611	0.750	0.164	0.207	0.834
前景区域蒸馏+关系蒸馏	0.770	0.893	0.929	0.478	0.597	0.951

4 结论

1）本文提出一种针对输电线路金具数据集的解耦知识蒸馏方法，本蒸馏方法可添加到单阶段、双阶段检测模型，在特征层利用 Ground-truth 框解耦前景、背景区域。针对前景区域提取共有特征提升分类准确率作为指导准则；捕获金具与金具、金具与背景之间的关系完善整幅图像特征完整性。

2）将本文提出的蒸馏算法添加到 3 种检测模型中，使学生网络检测性能均有大幅提升，有些甚至超过教师网络的检测性能，其中用于 RetinaNet 网络中效果提升最好，mAP_50 提高了 31.4%，对于挂板单类检测目标 AP 值在 Faster R-CNN 网络中最多可提升 37.3%。

3）本蒸馏方法可以实现资源节约的目标、提高了实时性和准确性，同时推动了工程自动化和智能化的发展。这将为工程领域带来更高效、安全和可靠的金具检测解决方案，为轻量化输电线路检测网络奠定了坚实的基础。

参考文献 References

[1] 赵振兵，李延旭，甄 珍，等. 结合 KL 散度和形状约束的 Faster R-CNN 典型金具检测方法[J]. 高电压技术，2020，46(9)：3018-3026.
ZHAO Zhenbing, LI Yanxu, ZHEN Zhen, et al. Typical fittings detection method with faster R-CNN combining KL divergence and shape constraints[J]. High Voltage Engineering, 2020, 46(9): 3018-3026.

[2] 赵振兵，熊 静，李 冰，等. 基于改进 Cascade R-CNN 的典型金具及其部分缺陷检测方法[J]. 高电压技术，2022，48(3)：1060-1067.
ZHAO Zhenbing, XIONG Jing, LI Bing, et al. Typical fittings and its partial defect detection method based on improved Cascade R-CNN[J]. High Voltage Engineering, 2022, 48(3): 1060-1067.

[3] 王韵琳，冯天波，孙 宁，等. 融合注意力与多尺度特征的电力绝缘子缺陷检测方法[J]. 高电压技术，2024，50(5)：1933-1942.
WANG Yunlin, FENG Tianbo, SUN Ning, et al. Defect detection method for power insulators based on attention and multi-scale context information[J]. High Voltage Engineering, 2024, 50(5): 1933-1942.

[4] 邬开俊，徐泽浩，单宏全. 基于 FasterNet 和 YOLOv5 改进的玻璃绝缘子自爆缺陷快速检测方法[J]. 高电压技术，2024，50(5)：1865-1876.
WU Kaijun, XU Zehao, SHAN Hongquan. Rapid detection method for self-exploding defects in glass insulators based on improved FasterNet and YOLOv5[J]. High Voltage Engineering, 2024, 50(5): 1865-1876.

[5] 赵振兵，金超熊，戚银城，等. 基于动态监督知识蒸馏的输电线路螺栓缺陷图像分类[J]. 高电压技术，2021，47(2)：406-414.
ZHAO Zhenbing, JIN Chaoxiong, QI Yincheng, et al. Image classification of transmission line bolt defects based on dynamic supervision knowledge distillation[J]. High Voltage Engineering, 2021, 47(2): 406-414.

[6] 陈仁祥，詹 赞，胡小林，等. 基于多注意力 Faster RCNN 的噪声干扰下印刷电路板缺陷检测[J]. 仪器仪表学报，2021，42(12)：167-174.
CHEN Renxiang, ZHAN Zan, HU Xiaolin, et al. Printed circuit board defect detection based on the multi-attentive faster RCNN under noise interference[J]. Chinese Journal of Scientific Instrument, 2021, 42(12): 167-174.

[7] 孟 浩，田 洋，孙宇婷，等. 全局注意力关系网络的小样本船舶识别[J]. 仪器仪表学报，2021，42(12)：220-227.
MENG Hao, TIAN Yang, SUN Yuting, et al. Few shot ship recognition based on universal attention relationnet[J]. Chinese Journal of Scientific Instrument, 2021, 42(12): 220-227.

[8] 郎 松，曹 选，张艳微，等. 融合改进 YOLOv5 算法的图像全站仪全自动测量方法[J]. 仪器仪表学报，2022，43(5)：120-127.
LANG Song, CAO Xuan, ZHANG Yanwei, et al. Fully automated measurement method of image total station based on the improved YOLOv5 algorithm[J]. Chinese Journal of Scientific Instrument, 2022, 43(5): 120-127.

[9] 方志丹，林伟胜，范 晟，等. 基于层级识别模型的输电线路杆塔小金具缺陷识别方法[J]. 电力信息与通信技术，2020，18(9)：16-24.
FANG Zhidan, LIN Weisheng, FAN Sheng, et al. A defects recognition method for small fittings in power transmission towers based on hierarchical recognition model[J]. Electric Power Information and Communication Technology, 2020, 18(9): 16-24.

[10] 翟永杰，杨 旭，赵振兵，等. 融合共现推理的 Faster R-CNN 输电线路金具检测[J]. 智能系统学报，2021，16(2)：237-246.
ZHAI Yongjie, YANG Xu, ZHAO Zhenbing, et al. Integrating co-occurrence reasoning for Faster R-CNN transmission line fitting detection[J]. CAAI Transactions on Intelligent Systems, 2021, 16(2): 237-246.

[11] 徐海青，余江斌，梁 翀，等. 基于 GAN 的改进 RPN 输电线路细小金具缺陷检测方法[J]. 电子器件，2021，44(6)：1409-1416.
XU Haiqing, YU Jiangbin, LIANG Chong, et al. Detection method for small metal defects of improved RPN transmission line based on GAN[J]. Chinese Journal of Electron Devices, 2021, 44(6): 1409-1416.

[12] CHEN G B, CHOI W, YU X, et al. Learning efficient object detection models with knowledge distillation[C]// Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: ACM, 2017: 742-751.

[13] WANG T, YUAN L, ZHANG X P, et al. Distilling object detectors

with fine-grained feature imitation[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE, 2019: 4928-4937.

[14] SUN R Y, TANG F H, ZHANG X P, et al. Distilling object detectors with task adaptive regularization[J]. arXiv: 2006.13108, 2020.

[15] DU Z X, ZHANG R, CHANG M, et al. Distilling object detectors with feature richness[C]// Proceedings of the 35th International Conference on Neural Information Processing Systems. New York, USA: Curran Associates Inc., 2021: 399.

[16] 赵振兵，蒋志钢，李延旭，等. 输电线路部件视觉缺陷检测综述[J]. 中国图象图形学报，2021，26(11)：2545-2560.
ZHAO Zhenbing, JIANG Zhigang, LI Yanxu, et al. Overview of visual defect detection of transmission line components[J]. Journal of Image and Graphics，2021，26(11)：2545-2560.

[17] DAI X, JIANG Z R, WU Z, et al. General instance distillation for object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE, 2021: 7838-7847.

[18] HU H, GU J Y, ZHANG Z, et al. Relation networks for object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018: 3588-3597.

[19] PARK W, KIM D, LU Y, et al. Relational knowledge distillation[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE, 2019: 3962-3971.

[20] CAO Y, XU J R, LIN S, et al. GCNet: non-local networks meet squeeze-excitation networks and beyond[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision Workshop. Seoul, Korea (South): IEEE, 2019: 1971-1980.

[21] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017: 936-944.

[22] YANG Z D, LI Z, JIANG X H, et al. Focal and global knowledge distillation for detectors[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE, 2022: 4633-4642.

[23] REN S Q, HE K M, 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, 2017, 39(6): 1137-1149.

[24] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318-327.

[25] CAI Z W, VASCONCELOS N. Cascade R-CNN: delving into high quality object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018: 6154-6162.



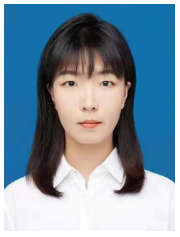
赵振兵
1979—，男，博士，教授，博导
主要研究方向为电力人工智能、电力视觉技术、知识表达与推理、机器学习、数字孪生
E-mail: zhaozhenbing@ncepu.edu.cn

ZHAO Zhenbing
Ph.D., Professor



吕雪纯
1994—，女，硕士
主要研究方向为电力视觉技术、知识蒸馏
E-mail: lvxuechuneilene@163.com

LYU Xuechun



苗思雨(通信作者)
1996—，女，博士生
主要研究方向为电力视觉技术
E-mail: siyumiao_hbu@163.com

MIAO Siyu
Ph.D. candidate
Corresponding author



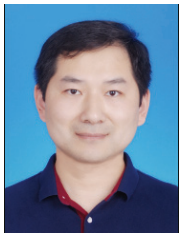
赵文清
1973—，女，博士，教授
主要研究方向为电力视觉、图像处理、大数据等
E-mail: jbzwq@126.com

ZHAO Wenqing
Ph.D., Professor



翟永杰
1972—，男，博士，教授，博导
主要研究方向为模式识别与电力视觉、机器学习与人工智能、计算机控制装置与系统
E-mail: zhaiyongjie@ncepu.edu.cn

ZHAI Yongjie
Ph.D., Professor



张　珂
1980—，男，博士，教授，博导
主要研究内容为计算机视觉、电力人工智能、电力视觉技术、电气信息技术等
E-mail: zhangkeit@ncepu.edu.cn

ZHANG Ke
Ph.D., Professor

收稿日期　2023-08-24　修回日期　2024-09-18　　编辑　卫李静