第 50 卷 第 12 期：5269-5280 高电压技术 Vol.50, No.12: 5269-5280
2024 年 12 月 31 日 High Voltage Engineering December 31, 2024
DOI: 10.13336/j.1003-6520.hve.20231754

基于多尺度轻量化卷积的高压输电线路巡检

李利荣[1,2]，梅　冰[1,2]，戴俊伟[1,2]，毛　锐[3]，童庆刚[3]，时　愈[4]
（1. 太阳能高效利用及储能运行控制湖北省重点实验室(湖北工业大学)，武汉 430068；2. 新能源及电网装备安全监测湖北省工程研究中心(湖北工业大学)，武汉 430068；3. 国家电网公司西南分部，成都 610040；4. 武汉工程大学电气信息学院，武汉 430205）

摘　要：无人机搭载轻量化模型进行高压输电线路巡检对于保障输电系统的安全运行至关重要，针对目前轻量化模型中特征提取不够丰富导致高压输电线路巡检效果较差的问题，该文提出了一种多尺度轻量化卷积(multi-scale lightweight convolution，MSLConv)，其进行了不同尺度与深度的特征融合，并实现了网络轻量化。同时在混洗注意力(shuffle attention，SA)中提出一种新的更具适应性的通道混洗方法，并将 MSLConv 与 SA 相结合设计了 MSLConvSA1 与 MSLConvSA2 特征提取模块，提高了 MSLConv 的通道利用率。在处理样本输出时，提出了一种基于样本的双重归一化与激活的组合方法，该方法能在通道数较少的轻量化模型中对通道特征进行更细粒度的调整，且能更好地建立样本间的特征关系。最后以 YOLOv5n 为基线进行一系列改进，得到了 MSV1 与 MSV2 两种模型。经实验证明，相对于基线，这两种模型的参数量分别减少了 43.8%和 28.6%，计算量分别减少了 38.1%和 23.8%。同时，mAP@.5(IoU 阈值为 0.5 时的平均检测精度值)分别提升了 5.2%和 5.4%，mAP@.5:.95(IoU 阈值为 0.5~0.95，取步长为 0.05 时的平均检测精度值)分别提升了 3.3%和 4.7%。

关键词：高压输电线路巡检；轻量化模型；混洗注意力；MSLConv；YOLOv5n

High-voltage Transmission Line Inspection Based on Multi-scale Lightweight Convolution

LI Lirong[1,2], MEI Bing[1,2], DAI Junwei[1,2], MAO Rui[3], TONG Qinggang[3], SHI Yu[4]
(1. Hubei Key Laboratory for High-efficiency Utilization of Solar Energy and Operation Control of Energy Storage System, Hubei University of Technology, Wuhan 430068, China; 2. Hubei Engineering Research Center for Safety Monitoring of New Energy and Power Grid Equipment, Hubei University of Technology, Wuhan 430068, China; 3. State Grid Corporation Southwest Branch, Chengdu 610040, China; 4. School of Electrical and Information Engineering, Wuhan Institute of Technology, Wuhan 430205, China)

Abstract：The use of unmanned aerial vehicles equipped with lightweight models for high-voltage power transmission line inspections is crucial for ensuring the safe operation of power transmission systems. Currently, insufficient feature extraction in lightweight models may lead to inferior effectiveness in high-voltage power transmission line inspections, thus this paper proposes a multi-scale lightweight convolution (MSLConv). MSLConv fuses features at different scales and depths while achieving network lightweight. In the shuffle attention (SA) module, a novel and more adaptive channel shuffling method is introduced. The MSLConv is combined with SA to design two feature extraction modules, MSLConvSA1 and MSLConvSA2, thereby enhancing the channel utilization of MSLConv. When processing sample output, this paper proposes a combined method based on sample-based dual normalization and activation. This method allows for finer adjustments of channel features in lightweight models with fewer channels and a better establishment of feature relationships between samples. Finally, this paper conducts a series of improvements based on the YOLOv5n baseline, resulting in two models: MSV1 and MSV2. The experimental results demonstrate that, compared to the baseline, MSV1 and MSV2 can reduce parameter quantities by 43.8% and 28.6%, and reduce computational loads by 38.1% and 23.8%, respectively. Additionally, mAP@.5(average detection accuracy value at an IoU threshold of 0.5) is improved by 5.2% and 5.4%, and mAP@.5:.95(average detection accuracy value when the IoU threshold is 0.5~0.95 and the step size is 0.05) is improved by 3.3% and 4.7% for MSV1 and MSV2, respectively.

Key words：high-voltage transmission line inspection; lightweight model; shuffle attention; MSLConv; YOLOv5n

基金资助项目：国家自然科学基金 (62071172)；新能源及电网装备安全监测湖北省工程研究中心开放基金 (HBSKF202121)。
Project supported by National Natural Science Foundation of China (62071172), Open Foundation of Hubei Engineering Research Center for Safety Monitoring of New Energy and Power Grid Equipment (HBSKF202121).

0 引言

架空输电线路曝露于外界，容易受到天气和周围环境的影响。因此，输电线路的巡检对于保障其安全运行至关重要。传统巡检方式主要依赖人工，工人通过望远镜或其他工具，结合经验对输电线路及电力部件进行观测。然而，人工巡检存在诸多限制。比如，架空线路分布广泛，配电线路设备繁多且复杂，仅依靠人工巡检难以对整个输电线路的设备情况和安全隐患进行系统化和数字化管理[1]。

现代技术提供了许多创新的解决方案来代替传统的人工巡检。例如：利用无人机部署目标检测算法进行输电线路的巡检，该方式不仅提高了巡检效率，还降低了巡检人员的工作风险[2-5]，同时可以开展输电线路的安全隐患样本收集，促进面向线路的人工智能远程安全督查数据集的建设。文献[6]采用快速区域卷积神经网络(faster region-based convolutional neural network，Faster R-CNN)对绝缘子进行检测，取得了较好的识别效果，但由于其为两阶段的目标检测算法，在检测实时性上表现较差。文献[7]采用了 YOLOv3 这类单阶段检测算法，提高了 Faster R-CNN 的检测实时性，并提升了一定的检测精度。文献[8]采用 YOLOv5 算法，弥补了 YOLOv3 在小目标检测上的不足，并显著提高了绝缘子缺陷识别的准确性。然而，受硬件限制，上述算法在参数量和浮点数上均不利于模型在无人机等移动端的部署。文献[9]将 YOLOv3 中主干网络用轻量级的网络替代，大幅减少了原始网络的参数量和浮点数，但轻量化的网络常由于使用了较少的通道数，导致特征不够丰富，检测精度难以保证。

为解决现有轻量化网络在有限通道数基础上获取信息不足的问题，本文提出了一种全新的多尺度轻量化卷积(multi-scale lightweight convolution, MSLConv)，并将其与混洗注意力(shuffle attention, SA)[10-11]结合，设计了 MSLConvSA1 与 MSLConvSA2 特征提取模块。

此外，针对当前高压输电线路巡检数据集中普遍存在的类别样本分布不均所带来的梯度更新问题，本文选择了动量化、自适应、双均值梯度(momentumized, adaptive, dual averaged GRADient, MADGRAD)优化器对网络进行优化[12]。最后，本文提出了一种基于样本的双重归一化与激活的组合方法，实现了对小数据集中的通道特征归一化更细粒度的调整，并建立了样本间的特征联系。本文以 YOLOv5n 模型为基线，对上述方法进行大量实验，验证了本文方法的优越性。

1 相关准备工作

1.1 数据集的构建

本文数据集由无人机所拍摄的 1 454 张图像，共计 11 481 个样本组成，利用 labelImg 标注软件对图像中的目标样本进行标注。相较于现有的输电线路数据集，本文所提供的数据集包含更多样本类别，更贴合实际的输电线路巡检需求[13]。本文的数据集经过细致分类，包括 6 个类别：绝缘子串(Insulator)、绝缘子缺陷(Defect)、屏蔽环(Shielding Ring)、安全线夹(Safety Clamp)、鸟巢(Nest)和防震锤(Vibration Damper)，能够全面涵盖高压输电线路中的主要部件，为相关研究和巡检工作提供更完善的资源，各类别的部分标注情况如图 1 所示。数据集标注完成后，在保证样本分布基本一致的情况下，按照 6:2:2

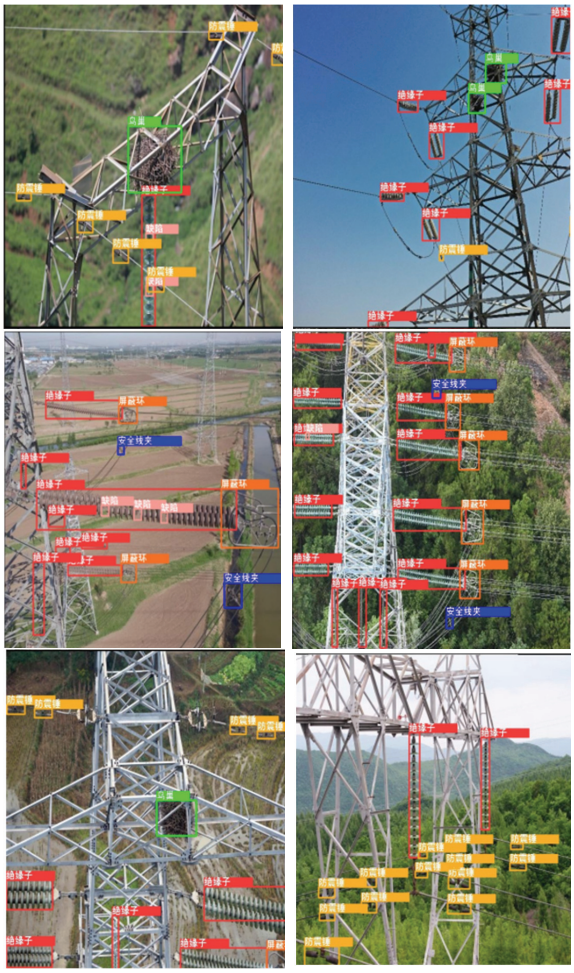


图 1 输电线路巡检数据集样本标注情况

Fig.1 Annotation status of transmission line inspection dataset samples

将数据集分为训练集、验证集和测试集。这样的划分有助于模型的训练、调优和评估，具体类别分布如图 2 所示。

1.2　优化器的选择

在 YOLOv5 系列算法中，通常使用随机梯度下降(stochastic gradient descent，SGD)优化器，并提供自适应矩估计(adaptive moment estimation，Adam)[14]与带权重衰减的 Adam(Adam with weight decay，AdamW)[15]两种优化器作为替代项以满足不同任务和实验需求。

本文数据集包含 6 种类别，其中绝缘子的样本数量远多于其他类别，鸟巢的样本数量远少于其他类别(详见图 2)。虽然 SGD 优化器在众多的大型公共数据集都表现出优越性，但面对样本数量分布不均的数据集，SGD 更倾向于拟合样本数量较多的类别，从而导致样本数量较少的类别出现欠拟合现象。

Adam 和 AdamW 都是自适应的优化算法，两者一阶动量和二阶动量均采用指数移动平均(exponential moving average，EMA)的方式进行更新，但 EMA 极大地阻碍了含有梯度平方项的 Adam 与 AdamW 在稀疏模型中的应用。在稀疏模型中许多梯度接近于零，梯度的平方运算导致其进一步缩小，EMA 中的迭代缓冲区会导致稀疏梯度的更新更加缓慢。

因此，本文选择了更适合于数据集特性的 MADGRAD 优化器。MADGRAD 对密集梯度和稀疏梯度采用不同的更新方式，使得其对于数据集中的稀疏梯度更具针对性。具体而言，MADGRAD 的更新式如下：

$$\lambda_k = l_{r_k} \cdot \sqrt{k+1} \tag{1}$$

$$S_{k+1} = S_k + \lambda_k g_k \tag{2}$$

$$V_{k+1} = V_k + \lambda_k g_k^2 \tag{3}$$

$$Z_{k+1} = x_k - \frac{1}{\sqrt[3]{V_{k+1}} + \varepsilon} S_{k+1} \tag{4}$$

$$x_{k+1} = (1 - c_{k+1}) x_k + c_{k+1} Z_{k+1} \tag{5}$$

式(1)中：λ_k 为自适应学习率；l_{r_k} 为学习率序列；k 为迭代次数。式(2)为一阶动量 S_{k+1} 表达式；g_k 为参数所对应的梯度。式(3)为二阶动量 V_{k+1} 表达式；g_k^2 为参数所对应的梯度的平方。式(4)为当前参数根据一阶动量与二阶动量对参数 x_k 进行更新后的参数值 Z_{k+1}；ε 为超参；式(5)为 Z_{k+1} 进行 EMA 操作后的最终参数值 x_{k+1}，其中 c_{k+1} 为 EMA 动量序列。

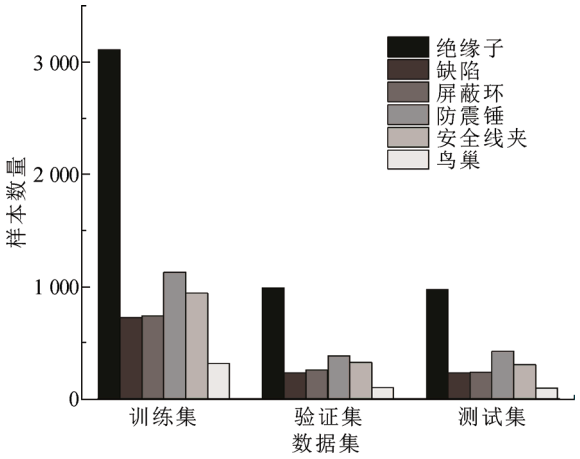


图 2　输电线路巡检数据集样本数量分布

Fig.2　Distribution of sample quantities in transmission line inspection dataset

当梯度为稀疏梯度时，MADGRAD 只计算梯度张量中的非零梯度值，这样可以避免不必要的计算和内存使用。式(2)与式(3)中的一阶动量和二阶动量直接通过 λ_k 进行 g_k 与 g_k^2 的累加，能够以稀疏的方式进行动量更新。此外，MADGRAD 采用立方根来调节学习率，能更有效地减少大梯度的影响，更适合于稀疏梯度更新。当面对稀疏梯度将 c_{k+1} 设置为 1，以删除迭代缓冲区能更灵敏地进行稀疏梯度的参数调整。

1.3　基于样本的双重归一化与激活组合方法

在目标检测领域，批归一化(batch normalization，BN)[16]是最常用的归一化方法。BN 在众多大型数据集上取得了成功，但面对诸如本文这种类别样本数量分布不均的小数据集，往往归一化效果不佳。组归一化(group normalization，GN)[17]相比 BN 在小型数据集上有更好的归一化效果，GN 的主要思想是将通道分为多个组，在组内进行特征信息统计，GN 在通道数较少的网络模型上可以实现更细粒度的调整和更好的适应性。GN 不仅避免了对批次样本数量的依赖，还能够更好地处理数据在通道维度上的特征。但 GN 只依赖于单个样本进行归一化的方法无法建立样本间的信息交流。

基于样本的进化归一化激活函数[18](evolving normalization activation-sample based，EvoNorm-S)是基于 GN 的进化归一化-激活方法，它引入进化策略来自适应学习和优化归一化统计量，并通过进化搜索算法，自动发现网络架构中最优的归一化和激活方法组合，其性能超越了单独设计的现有组合。EvoNorm-S 不依赖于批次，只针对单个样本，因此

能简单实现小批量数据的稳定训练。为了适应不同的模型架构和任务需求，EvoNorm-S 具有 EvoNorm-S0、EvoNorm-S1 及 EvoNorm-S2 这 3 种版本。其中 EvoNorm-S0(E_{S0})的表达式如式(7)。

$$f(\mathrm{GN}(x))=f\left(\frac{x-\mu_{w,h,c/g}}{\sqrt{\sigma^2_{w,h,c/g}(x)+\varepsilon}}\gamma+\beta\right) \tag{6}$$

$$E_{S0}=\frac{xf(v_1x)}{\sqrt{\sigma^2_{w,h,c/g}(x)+\varepsilon}}\gamma+\beta \tag{7}$$

式中：GN(*)为组归一化函数；f(*)为表达式的函数表达；γ 为可训练的比例因子；β 为可训练偏移量；v_1 为可训练向量数值。

对比式(6)与式(7)，EvoNorm-S0 与 f(GN(x))不同的是，前者是归一化与激活的交错处理，后者则是依次处理。EvoNorm-S0 标准差 $\sqrt{\sigma^2}$ 计算上与 GN 是一致的，但在分子部分，并没有用输入 x 减去均值 $\mu_{w,h,c/g}$，而是先对输入缩放后再进行激活。EvoNorm-S1(E_{S1}) 与 EvoNorm-S2(E_{S2}) 都沿袭了 EvoNorm-S0 的设计思路，表示分别如式(8)与式(9)所示。它们都利用与 GN 有关的 $\sigma^2_{w,h,c/g}(x)$ 与 $\mu_{w,h,c/g}$ 进行归一化，可以在通道数较少的网络模型上实现更细致的归一化调整。

$$E_{S1}=\frac{f(x)}{\sqrt{\sigma^2_{w,h,c/g}(x)+\varepsilon}}\gamma+\beta \tag{8}$$

$$E_{S2}=\frac{f(x)}{\sqrt{\mu_{w,h,c/g}(x^2)+\varepsilon}}\gamma+\beta \tag{9}$$

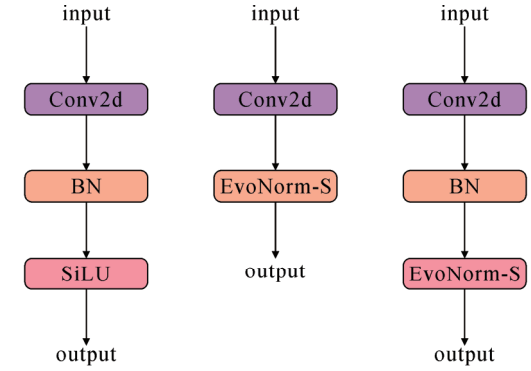
通常激活函数和归一化方法是与卷积操作一起设计的，如 YOLOv5n 的 Conv 卷积模块采用的是 SiLU 激活函数结合 BN(Batch Normalization)的组合(如图 3(a)所示，图中 Conv 2d 为 2 维卷积操作)。由于 EvoNorm-S 中已包含了隐式的归一化方法，所以通常没有再添加其他归一化方法，其结构如图 3(b)所示。为弥补 GN 的不足，本文在 EvoNorm-S 基础上引入 BN(如图 3(c)所示)，使卷积模块包含两种不同的归一化方法，以弥补批次样本间的关系，这种基于样本的双重归一化与激活的组合方法能综合利用 BN 与 GN 两种归一化方法的优点，能更好地适应本文数据集和通道数量较少的轻量化模型。

2 基于多尺度轻量化卷积的高压输电线路巡检模型

2.1 总体网络框架图

本文提出的高压输电线路巡检网络主要基于 YOLOv5n 模型改进。原始 YOLOv5n 模型如图 4，其中 Conv 表示卷积模块，K6 表示卷积核大小为 6×6，S2 表示卷积的步长为 2，C16 表示卷积的输出通道数为 16，C3 表示集成 3 个卷积层(Conv)和多个 Bottleneck 模块的组件，SPPF(spatial pyramid pooling-fast)为特征融合模块，Upsample 表示上采样操作，Concat 表示拼接操作，其他类似。6×6 卷积核用于对初始的输入图片进行下采样，此时的图片分辨率最高，像素间的方差最小，使用较大的卷积核可获得更好的全局信息。3×3 卷积核可以在保证感受野的情况下提取特征，且不会带来过多的计算量，这是目前用于提取特征较为广泛的卷积核大小。1×1 卷积核主要用于升维和降维，提高网络表达能力。

基于多尺度轻量化卷积的高压输电线路巡检总体网络框架如图 5 所示。本文对 YOLOv5n 中所有单独的 3×3 卷积模块(Conv K3, S2)用 MSLConvSA2 替换。同时本文基于 MSLConvSA1 设计了一种新的 Bottleneck 模块，将其命名为



(a) 原始卷积模块 (b) EvoNorm-S (c) 本文卷积模块

图 3 卷积模块的设计

Fig.3 Design of convolution module

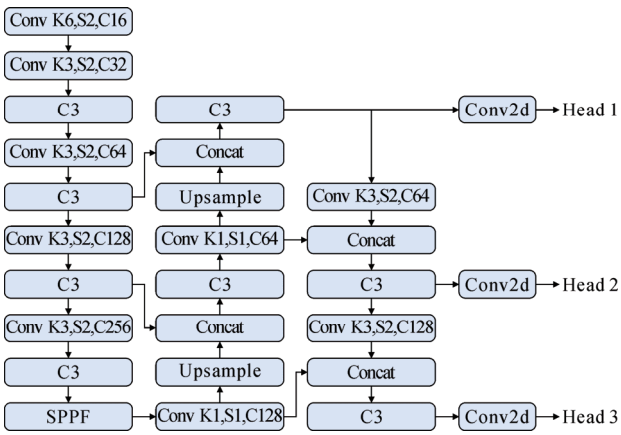


图 4 YOLOv5n 结构图

Fig.4 YOLOv5n architecture diagram

MSLBottleneck，且用其替换 YOLOv5n 的所有 C3 模块(图 6(a)所示)，而不是仅替换 C3 模块中的 Bottleneck(图 6(b)所示)。MSLBottleneck 的具体结构如图 6(c)右图所示，其先用一个 1×1 的卷积对输入特征通道数降维到原来的一半，再将其输入 m 个 MSLConvSA1 模块中，最后用一个 1×1 的卷积升维至原通道数。可以看到，MSLBottleneck 相比 C3 模块更加简洁。此外，由于新网络模型层数的增加，为了保留更丰富的图像细节，本文将第一个 6×6 卷积替换为 3×3 卷积。

2.2　多尺度轻量化卷积(multi-scale lightweight convolution，MSLConv)

为实现神经网络模型的轻量化，通常会减少模型通道数，以减小参数量和计算量。以 YOLOv5 系列为例，YOLOv5n 在保持 YOLOv5s 其他结构不变的情况下，将其通道数减少一半，参数量由 YOLOv5s 的 7.035 M 减少为 YOLOv5n 的 1.777 M，计算量由 16.0 G 变为 4.2 G。较少的通道数意味着较少的维度信息，在通道数较少的条件下，获取足够的特征信息是实现模型轻量化的主要挑战。

卷积操作在神经网络中能够有效地提取特征信息，但对一层输入进行普通卷积获取到的该层次的特征信息有限。因此，本文提出一种融合不同深度、尺度特征的多尺度轻量化卷积 MSLConv。如图 7 所示，当 MSLConv 的卷积步长 S=1 时，本文对给定特征 $X \in \mathbf{R}^{H\times W\times C}$ (设其高度为 H，宽度为 W，通道数为 C)沿通道进行 1:1 拆分，生成 2 个通道数为 $C/2$ 的特征 X_1 与 X_2。对 X_2 部分不进行任何处理，仅将其作为建立长距离依赖关系的浅层信息向深层网络传递。X_1 则进行两级特征提取，首先按式(10)进行普通卷积：

$$Y = F_{k_1\times k_1} * X_1 \tag{10}$$

式中：*表示普通卷积操作；$F_{k_1\times k_1}$ 表示进行卷积的卷积核的大小为 $k_1\times k_1$。得到新特征 Y 后，再次对 Y 沿通道进行 1:1 的拆分生成特征 Y_1 与 Y_2。同样对于 Y_2 部分不进行额外操作，对 Y_1 部分进行卷积核大小为 $k_2\times k_2$ 的卷积提取特征 Z，如式(11)所示：

$$Z = F_{k_2\times k_2} * Y_1 \tag{11}$$

最后将 X_2、Y_2 与 Z 进行连接(concatenate，Concat)操作，得到输出特征层 O。可以发现在上述结构中，虽然进行了 2 次普通卷积，但卷积操作中的通道数逐次减半，且剩下的一半通道 X_2 与 Y_2 部分并没有进行额外操作，因此 MSLConv 模块相对普通卷积

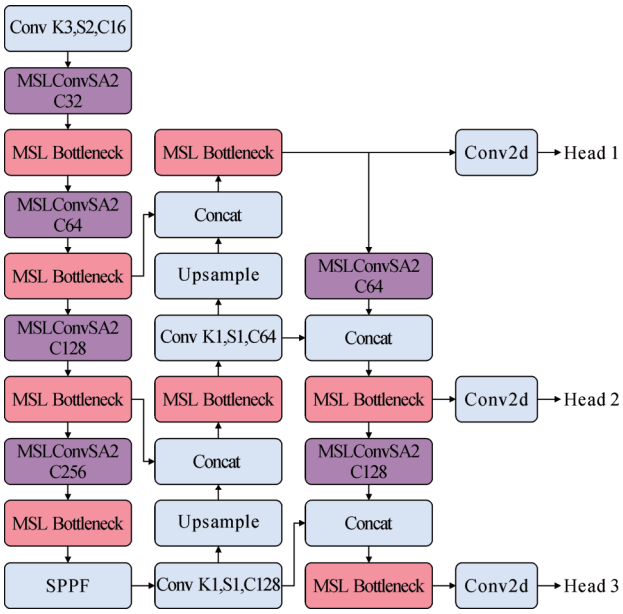
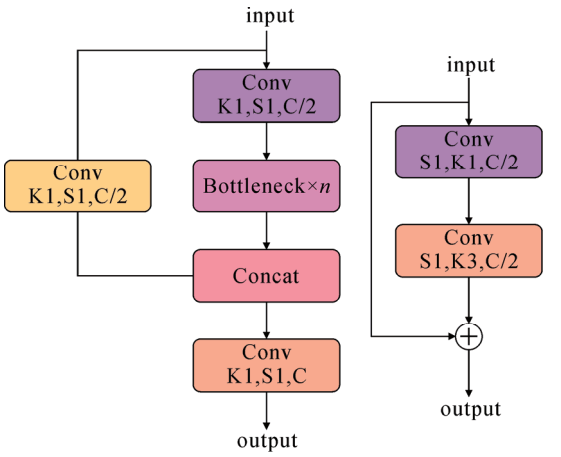


图 5　基于多尺度轻量化卷积的高压输电线路巡检总体网络框架图

Fig.5　Overall network framework diagram for high-voltage power transmission line inspection based on multi-scale lightweight convolution



(a) C3模块　(b) Bottleneck　(c) MSLBottleneck

图 6　C3 模块的改进

Fig.6　C3 module improvements

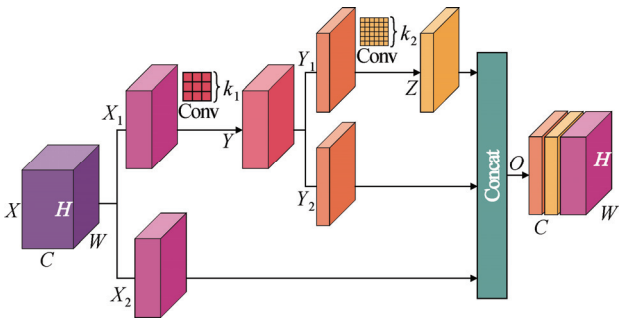


图 7　MSLConv S=1 时结构图

Fig.7　Structure diagram of MSLConv with S=1

不仅大大减少了计算量，还保留了一部分原始信息，防止了浅层特征的丢失。文献[19]中提到，浅层网络中包含纹理、边缘这类对目标定位有益的低级特征，深层网络中包含物体形状、结构、上下文这类对目标识别与分类有益的高级特征。MSLConv 中的 X_2 与 Y_2 部分能作为浅层信息与深层信息融合，可以提高模型在定位和识别上的综合表现，并得到 3 个具有不同大小感受野和不同深度的特征信息，获取了更丰富的特征层次。

如图 8 所示，当 MSLConv 的步长 S=2 时，其操作流程基本与 S=1 时一致。不同的是，X_1 的第 1 次卷积将步长设置为 2，以对图像进行下采样，得到特征 Y'。而第 2 次卷积在本文方法中依旧采取步长为 1 不变，得到特征 Z'。为使特征拼接时的图像尺度一致，且表现出不同特征之间的差异，对 X_2 部分采用了具有灵活权重配比的 SoftPool[20]的池化下采样处理。

综上所述，MSLConv 能在获得 3 个不同尺度特征信息的同时，大大减少计算量。基于此，本文将其命名为多尺度轻量化卷积。

2.3 MSLConv 与 SA 的结合(MSLConvSA1，MSLConvSA2)

在 MSLConv 模块中，各级卷积均只针对当前通道数中的一半进行，而另一半通道信息只进行了直接融合操作。因此，在重复使用 MSLConv 模块时，部分通道一直得不到有效利用。为充分利用各通道信息，本文将混洗注意力机制 SA 与 MSLConv 进行了结合使用。

如图 9 所示，本文将图 9(a)中的结构命名为 MSLConvSA1，其中 MSLConv 的步长 S=1，其原始输入与 SA 处理后的输出进行了 add 操作，以加强特征的原始表达。将图 9(b)的结构命名为 MSLCovnSA2，其中 MSLConv 的步长 S=2，由于对输入进行了下采样，图像大小发生变化，因此没有进行原始输入的 add 操作。

SA 不仅能进行通道混洗，以加强通道间的特征交互，还能建立通道与空间依赖关系，从而更好地捕捉全局特征。SA 具体处理流程分为两步，如图 10 所示，第一步通过注意力机制，将给定输入特征 $X \in \mathbf{R}^{H\times W\times C}$，按通道维度将其分为 G 组，即 $X=[X_1,\cdots,X_G]$。对于每组中的特征 $X_k \in X$，将其按通道维度划分为两个分支 X_{k1} 与 X_{k2}，分别用于建立通道注意力[21]与空间注意力[22]。对 X_{k1} 进行全局

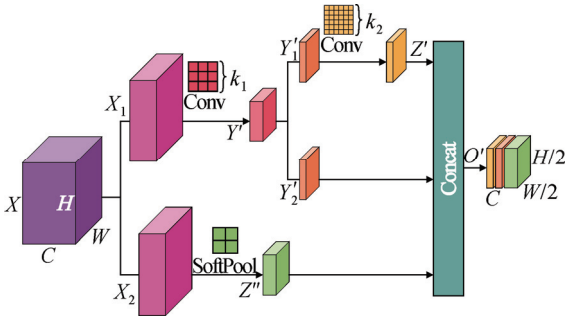
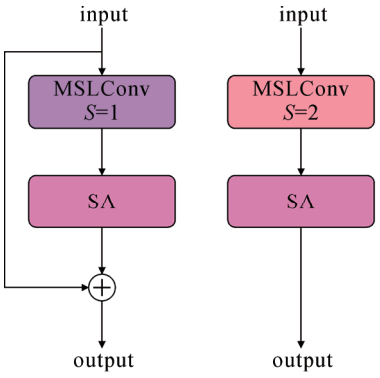


图 8 MSLConv S=2 结构图

Fig.8 Structure diagram of MSLConv with S=2



(a) MSLConvSA1 (b) MSLConvSA2

图 9 MSLConv 结合 SA 注意力

Fig.9 Combination of MSLConv with self-attention

平均池化(global average pooling，GAP)生成通道信息 α_c，对 X_{k2} 则利用组归一化来获得空间信息 α_s。通道注意力与空间注意力的最终输出为式(12)与式(13)所示。

$$X'_{k_1}=\sigma(w_1\cdot\alpha_c+b_1)\cdot X_{k_1} \tag{12}$$

$$X'_{k_2}=\sigma(w_2\cdot\alpha_s+b_2)\cdot X_{k_2} \tag{13}$$

式中：w_1 与 w_2 以及 b_1 与 b_2 分别用于对 α_c 与 α_s 进行缩放与平移，以增强通道信息与空间信息的表达能力；$\sigma(\cdot)$ 为 Sigmoid 激活函数，用以将特征映射到[0,1]的范围内，使其更适合作为权重。将上述 2 个分支进行拼接，所有分组后的子特征都进行上述相同的处理然后拼接，得到了具有空间与通道注意力依赖关系的特征 X'。

SA 的第二步是对 X' 进行通道混洗。通常的通道混洗操作如图 11 所示，假设输入通道 C=6，若将通道混洗的组数设置为 g=2，首先将输入依据分组数 g 进行 Reshape 为 2 维矩阵，在对其进行转置操作，最后将转置后的矩阵展开成 1 维，完成通道混洗。不难发现，通道混洗的分组数直接决定了通道打乱的混乱程度。

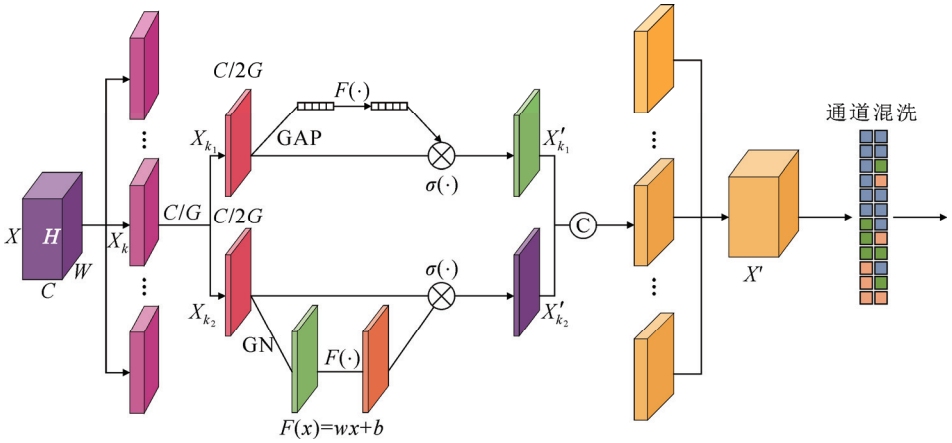


图 10　SA 模块

Fig.10　SA module

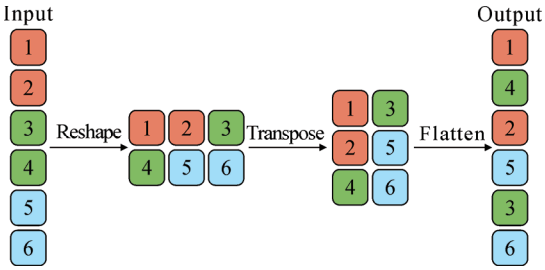


图 11　通道混洗示意图

Fig.11　Channel Shuffle Illustration

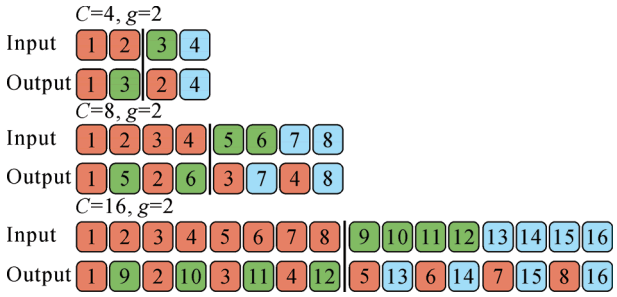


图 12　固定分组数为 2 的通道混洗

Fig.12　Channel shuffling with a fixed group number of 2

前文提到进行 MSLConv 操作后，可得到 3 个不同尺度与不同深度的特征，其通道数比例为 2:1:1。如图 12 所示，本文将这 3 种特征分别用红、绿和蓝 3 种色块表示，面对不同通道数的网络层数，假设 C=4、8、16。文献[10]将通道混洗的分组数 g 固定为 2，这样的设置会导致混洗总是发生在两组之间，混洗后每一组中总是只有两种特征(对应图中两个颜色)，特征的交互不够充分，且组数固定的混洗方法缺乏对不同深度网络特征的适应性。

为解决上述问题，本文提出一种新的以固定每组通道数为分组方式的通道混洗方法，这样的设定可以使不同通道数的网络层得到不同的分组数，如式(14)所示。

$$g = C / C_i \tag{14}$$

式中：C 为输入通道数；C_i 为分组后的每组的固定通道数；g 为固定每组通道数 C_i 后的分组数。如图 13 所示，若将通道混洗的每组通道数 C_i 固定为 4，在浅层网络中，如 C=4 时，通道数较少，通道混洗的必要性较低，所以设置固定通道数可以使最浅层网络不进行通道混洗。随着网络的加深，通道数依次增加，如 C=8 时，通道被分成两组，特征的交互出现在两种不同的特征之间。当 C=16 时，通道分成了 4 组，特征交互出现在 3 种不同特征之间，混洗程度依次增加，MSLConv 的 3 种不同的特征之间的交互更加充分。

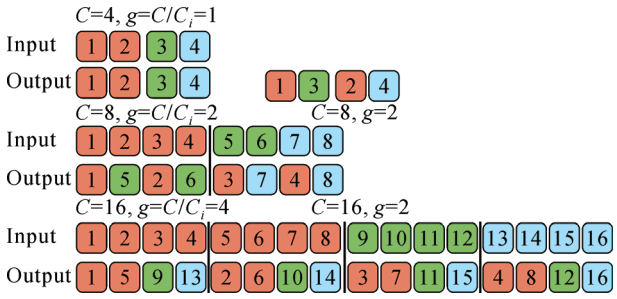


图 13　固定每组通道数 C_i=4 进行通道混洗

Fig.13　Channel shuffling with a fixed group channel number C_i=4

综上所述，相比传统的分组方式，这种分组方式可以更好地匹配不同深度网络层的通道混洗需求，使特征交互更加灵活更加充分。

3 实验结果与分析

3.1 实验环境介绍

本文实验环境配置如下：深度学习框架为pytorch 版本为 1.13，编程语言为 Python3.9，实验平台为 Ubuntu22.04，显卡为 RTX3060(显存 12G)。

3.2 对比实验

3.2.1 优化器对比实验

选择合适的优化器通常是提升网络性能最直接有效的方法。为验证 MADGRAD 优化器对本文数据集的有效性，本文使用了 SGD、Adam、AdamW 及 MADGRAD 这 4 种优化器，均在默认推荐超参数条件下进行对比实验。实验结果如表 1 所示，MADGRAD 优化器在 IoU=0.5 时平均精度均值(mAP@.5)以及 IoU 阈值从 0.5 到 0.95(步长 0.05)上的平均精度均值(mAP@.5:.95)均有大幅度提升。

从表 2 可以发现，由于 MADGRAD 对密集梯度与稀疏梯度的更新方式不同，样本最多的绝缘子与样本较少的鸟巢、防震锤和安全线夹在 mAP@.5 均有明显提升。表 2 中 a—f 依次对应 Insulator、defect、Shielding Ring、Vibration Damper、Safety Clamp 与 Nest(后文皆采用这种表达形式)。

图 14 与图 15 展示了 4 种优化器的 2 张损失函数曲线图。观察曲线图可发现，相比于 SGD、Adam 和 AdamW 而言，MADGRAD 优化器在训练难度较大，不会出现过早的拟合现象，且在曲线中 MADGRAD 比其他 3 条曲线更平滑，不会出现反复抖动。因此，综合考虑这些指标，可得出 MADGRAD 优化器在本文数据集上相较 SGD、Adam 与 AdamW 具有明显的优越性。

3.2.2 激活函数对比实验

为了验证 EvoNorm-S 激活函数的有效性，本文将 Conv 模块中的 SiLU 激活函数分别替换为 Mish、Haradswish、FReLU 及 EvoNorm-S 后，在原始 YOLOv5n 模型下进行了对比实验。

通过表 3 可发现，尽管 EvoNorm-S 系列已经包含了归一化方法，但其与 BN 结合时，在 mAP@.5 与 mAP@.5:.95 均优于其没有与 BN 结合时的数据表现，且优于其他激活函数与 BN 的结合。在 EvoNorm-S 系列与 BN 的结合中，EvoNorm-S2+BN 表现出最佳性能，其 mAP@.5 为 83.0%，mAP@.5:.95 为 42.2%，也优于除 EvoNorm-S0+BN 的其他组合。本文提出的基于样本的双重归一化与激活的组合，发挥了两种归一化方法的优点，提升了检测性能。

3.2.3 MSLConvSA 对比实验

为验证 MSLConvSA 的有效性，本文对上述改进的 YOLOv5n 网络结构做了关于 MSLConv 的系列对比实验。其中对 MSLConvSA2 与 MSLConvSA1 中的卷积核大小 k_1、k_2 分别在不同赋值情况下进行了对比实验，以探究最佳的 MSLCovnSA2 和 MSLConvSA1 组合。同时，本文还对每个 MSLBottleneck 中的 MSLCovnSA 分别使用一次和两次做了对比分析，分别表示为 MSLCovnSA1 和 MSLCovnSA1。实验中优化器为 MADGRAD，激活函数和归一化方法的选择为 EvoNorm-S2 与 BN 的结合。

表 4 与表 5 中的 S1 与 S2 分别对应 MSLConvSA1 与 MSLConvSA2。第 1 行表示原始的 YOLOv5n 模型检测结果。表 5 中“3-1*2”表示

表 1 优化器对比

Table 1 Optimizer comparison

优化器	mAP@.5/%	mAP@.5:.95/%
SGD	81.1	41.9
Adam	81.7	41.5
AdamW	81.3	41.2
MADGRAD	84.0	44.7

表 2 不同样本类别优化器检测效果对比(mAP@.5)

Table 2 Comparison of optimizers for different sample categories (mAP@.5)

优化器	mAP@.5/%					
	a	b	c	d	e	f
SGD	85.9	78.9	95.7	71.7	77.2	77.4
Adam	85.2	75.9	95.9	71.8	78.9	82.4
AdamW	85.5	76.5	96.5	69.1	75.6	84.6
MADGRAD	88.7	77.2	95.9	75.4	81.0	85.7

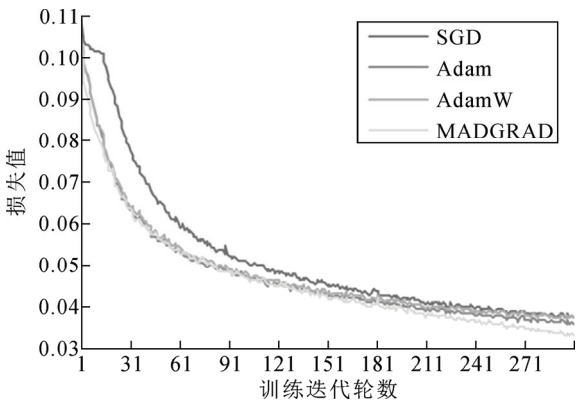


图 14 Bounding box 损失 L_{box} 曲线图

Fig.14 Bounding box Loss L_{box} curve

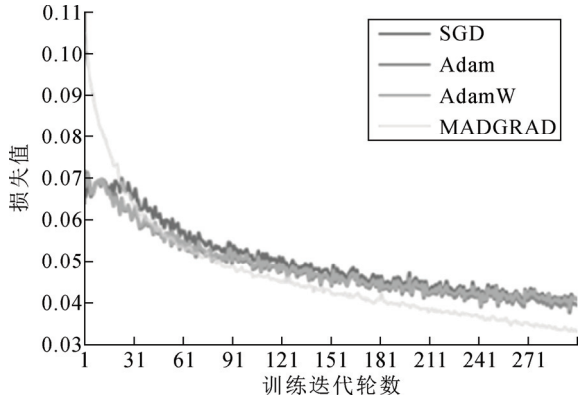


图 15　目标检测损失 L_{obj} 曲线图

Fig.15　Object detection loss L_{obj} curve

表 3　激活函数对比

Table 3　Activation function comparison

激活函数	mAP@.5/%	mAP@.5:.95/%
SiLU+BN	81.1	41.9
Haradswish+ BN	81.2	40.6
Mish+BN	81.3	41.3
FReLU+BN	77.2	38.6
EvoNorm-S0	79.5	40.2
EvoNorm-S0+BN	81.6	42.4
EvoNorm-S1	81.2	40.9
EvoNorm-S1+BN	81.8	41.3
EvoNorm-S2	80.3	40.5
EvoNorm-S2+BN	83.0	42.2

使用了卷积核大小分别为 k_1=3、k_2=1 的卷积两次，其他表述类推。

观察表 4 可发现，MSLConvSA1(3-5) 与 MSLConvSA2(3-1)的组合(本文简称 MSV1)在参数与计算量相比 YOLOv5n 模型大大减少的情况下检测精度最高，MSV1 在参数量和浮点数(计算量)上相比 YOLOv5n 模型分别减少了 43.8%和 38.1%，mAP@.5 提升了 1.1%，而 mAP@.5:.95 仅下降 0.3%。

表 5 表明 MSLConvSA1(3-5*2)与 MSLConvSA2 (3-3)组合(本文简称 MSV2)展示了类似的效果，而且 MSV2 相对 MSV1 具有更高精度，同时也具有相对更高的参数量与计算量。

本文将 MSV1 与 MSV2 与 YOLOV5n 模型中各类别的 mAP@.5 与 mAP@.5:.95 进行了更精细的对比，表 6 与表 7 中 a—f 表征同表 2。

在 mAP@.5 方面，MSV1 模型相对于基线在 Insulator、Defect 和 Nest 的识别上分别提升了 0.6%、3.3%和 3.9%，表现出优越性。然而，在其他类别的识别上，MSV1 模型与基线相比略有下降，MSV2 模型相对于基线在所有类别的识别上均有提升。可以发现，MSV1 模型在 Defect 和 Nest 识别上相对较好，而 MSV2 模型在各类别的识别上均有较大优势。

表 4　MSLBottleneck 中 MSLConvSA1 数量为 1 时对比实验

Table 4　Comparison experiment of MSLConvSA1 quantity in MSLBottleneck with repetition count of 1

S2	S1	mAP@.5/%	mAP@.5:.95/%	参数量/10^6	浮点数/10^9
—	—	85.2	45.5	1.777	4.2
3-1	3-1	85.5	45.3	0.913	2.4
3-1	3-3	85.2	45.0	0.941	2.4
3-1	3-5	86.3	45.2	0.998	2.6
3-3	3-1	84.9	44.4	0.967	2.5
3-3	3-3	85.5	44.3	0.995	2.5
3-3	3-5	85.0	44.8	1.052	2.7
3-5	3-1	85.4	45.2	1.072	2.7
3-5	3-3	84.5	44.6	1.103	2.8
3-5	3-5	84.2	44.3	1.159	2.9

表 5　MSLBottleneck 中 MSLConvSA1 数量为 2 时对比实验

Table 5　Comparison experiment of MSLConvSA1 quantity in MSLBottleneck with repetition count of 2

S2	S1	mAP@.5/%	mAP@.5:.95/%	参数量/10^6	浮点数/10^9
—	—	85.2	45.5	1.777	4.2
3-1	3-1*2	85.2	44.7	1.046	2.7
3-1	3-3*2	85.3	45.4	1.012	2.8
3-1	3-5*2	85.9	46.3	1.216	3.1
3-3	3-1*2	85.1	45.2	1.100	2.8
3-3	3-3*2	85.1	45.3	1.156	3.0
3-3	3-5*2	86.5	46.6	1.269	3.2
3-5	3-1*2	85.8	46.0	1.207	3.0
3-5	3-3*2	85.6	45.4	1.264	3.2
3-5	3-5*2	85.9	46.5	1.377	3.5

表 6　数据集各样本类别 mAP@.5 对比实验

Table 6　Comparison experiment of mAP@.5 for different sample categories of the dataset

模型	mAP@.5/%						
	all	a	b	c	d	e	f
YOLOv5n	85.2	88.8	82.8	97.1	77.6	81.7	83.5
MSV1	86.3	89.4	86.1	96.7	77.3	81.2	87.4
MSV2	86.5	89.6	84.6	97.2	78.6	82.5	86.3

表 7　数据集各样本类别 mAP@.5:.95 对比实验

Table 7　Comparison experiment of mAP@.5:.95 for different sample categories of the dataset

模型	mAP@.5:.95/%						
	all	a	b	c	d	e	f
YOLOV5n	45.5	55.3	30.3	73.3	36.1	37.3	40.9
MSV1	45.2	55.4	27.9	73.0	35.6	36.0	43.6
MSV2	46.6	57.4	30.4	72.3	35.3	39.4	45.1

在 mAP@.5:.95 方面，MSV2 模型相对于 MSV1 与基线模型在 4 类目标的检测效果最优，且在 Nest 的检测上提升最高，提升了 4.2%。

综上所述，相对于基线模型，MSV1 与 MSV2 均不同程度地减小参数量和浮点数的同时，保持了检测效果的可靠性，可根据不同的任务需求，对两种模型进行选择。

3.2.4 通道混洗对比实验

2.3 节提到，SA 将通道分为 g 组进行混洗用以打乱通道顺序，解决在多次使用 MSLConv 模块中部分通道利用不足的问题。为探究通道分组对网络模型性能的影响，本文按分组的不同方式进行了对比实验。分组有两类方式：一类是直接按固定组数进行划分，在文献[10]中作者将组数固定设置为 g=2，本文另外提供了 g=4 和 g=8 的两种分组情况进行对比分析；另一类是按每组固定的通道数进行分组产生不同的组数，即 g=C/8、g=C/16 与 g=C/32。具体分组及对比实验结果见表 8 所示。

从表 8 可发现，SA 中的分组数对实验效果有直接影响，相比于固定分组数而言，固定每组通道数的分组方式能带来更大的收益，在分组数为 C/16 时，网络的表现最佳。以固定每组通道数的方式分组可以实现在浅层网络中分组数较少，而深层网络中分组数较多，具有更大的灵活性和适应性，因此提升了检测性能。

3.3 消融实验

3.3.1 MSV2 消融实验

为验证 Channel Shuffle 对通道利用效率的影响，以及 MSLConv 中 SA 注意力机制所建立的空间依赖关系和通道依赖关系对检测结果的影响，本文对连续使用 MSLConvSA2 的 MSV2 进行了消融实验。

通过表 9 可发现，进行通道混洗后 mAP@.5 与 mAP@.5:.95 分别提升了 1.7%和 0.3%。在 MSLConv 中加入 SA 注意力机制后，相比只进行通道混洗 mAP@.5 与 mAP@.5:.95 提升了 0.5%和 0.9%。综上所述，本文对 MSLConvSA 的设计合理有效。

3.3.2 整体网络消融实验

为验证本文改进方法的有效性以及各组件对整体网络模型的影响，本文设计了系列消融实验，具体操作是在原始基线模型上逐步进行改进，并观察模型性能。为简化表述，表中 A 为 MADGRAD 优化器，B 表示 EvoNorm-S2 激活函数与 BN 的结合，C 表示 MSV1，D 表示 MSV2，第一行表示基准网络模型的各项参数。从表 10 可发现，本文对整体网络改进在 mAP@.5 与 mAP@.5:.95 均有提升情况下，大幅度的减少了参数量和浮点数。

3.4 不同网络对比实验

为验证本文方法的优越性，本文选取目前较先进的 YOLOv6n、YOLOv7-Tiny 和 YOLOv8n 目标检测算法以及本文的基线 YOLOv5n 和本文的 MSV1、MSV2，在其模型推荐的超参和优化器下进行对比实验[23]。

根据表 11，首先，从 mAP@.5 指标来看，MSV1 和 MSV2 分别为 86.3%与 86.5%，高于其他算法(范围为 79.0%~85.4%)。从 mAP@.5:.95 指标来看，MSV1 和 MSV2 的表现也相对较好，分别为 45.2%和 46.6%，高于其他算法(范围为 41.9%~44.6%，其中 MSV1 表现差于 YOLOv8n)。这说明 MSV1 和 MSV2 在整体检测效果上具有优越性。同时，MSV1 和 MSV2 的参数量具有较大幅度的减少，分别为 0.998 M 和 1.269 M。浮点数大幅度降低，分别为 2.6 G 和 3.2 G。相比其他算法，MSV1 和 MSV2 模

表 8 不同分组数对检测结果影响

Table 8 Impact of different number of groups on detection results

g	mAP@.5/%	mAP@.5:.95/%
2	83.9	45.3
4	85.5	45.6
8	84.8	44.7
C/8	85.5	45.8
C/16	86.5	46.6
C/32	85.3	45.5

表 9 MSV2 消融实验

Table 9 MSV2 ablation experiment

模块名	mAP@.5/%	mAP@.5:.95/%
MSLConv	84.1	45.4
MSLConv +Channel_shuffle	85.8	45.7
MSLConv+SA(MSLConv+SA)	86.3	46.6

表 10 整体模型消融实验表

Table 10 Comprehensive network ablation experiment

A	B	C	D	mAP@.5/%	mAP@.5:.95/%	参数量/10^6	浮点数/10^9
				81.1	41.9	1.777	4.2
✓				84.0	44.7	1.777	4.2
✓	✓			85.2	45.5	1.777	4.2
✓	✓	✓		86.3	45.2	0.998	2.6
✓	✓		✓	86.5	46.6	1.269	3.2

表 11　不同网络对比实验

Table 11　Comparative experiments of different networks

算法	mAP@.5/%	mAP@.5:.95/%	参数量/10^6	浮点数/10^9	运行时间/ms
YOLOV5n	81.1	41.9	1.777	4.20	4.1
YOLOV6n	79.0	43.3	4.300	11.07	3.6
YOLOV7-Tiny	85.4	44.6	6.020	13.10	3.4
YOLOV8n	83.1	46.1	3.068	8.10	3.5
MSV1	86.3	45.2	0.998	2.60	4.3
MSV2	86.5	46.6	1.269	3.20	4.6

型大小更小，占用的计算资源较少，同时检测精度得以保留甚至提升。这意味着 MSV1 和 MSV2 在无人机这类移动端的部署上更具优势。但在运行时间上，模型 MSV1 与 MSV2 由于网络层数的增多，导致其推理时间相比于其他网络模型稍有增加，但其仍处于较高水准，满足实时检测需求。

4　结论

1）本文引入了一种创新的多尺度轻量化卷积 MSLConv。相比于普通卷积，每经过一次 MSLConv 处理都可以得到 3 个不同深度和尺度的特征信息，保证了检测的精度，同时由于通道数依次减半，大幅度减少了参数量和浮点数。

2）本文将 SA 模块与 MSLConv 结合，设计了 MSLConvSA1 与 MSLConvSA2 两种模块，并提出了以固定每组通道数的方式进行分组，以适应不同深度网络进行不同混乱程度的通道混洗。

3）针对数据集类别样本分布不均的特点，本文引入了 MAGRAD 优化器，其对稀疏梯度与密集梯度的不同处理方式，提升了样本数量较少类别的检测精度。为更好地建立轻量化网络进行归一化时样本间的联系，本文提出了基于样本的双重归一化与激活的组合方法，并结合不同归一化方法的优点，进一步提升了网络性能。

4）本文所提出的算法 MSV1 与 MSV2 在本文高压输电线路巡检数据集上的 mAP@.5 分别为 86.3%和 86.5%，mAP@.5:.95 分别为 45.2%和 46.6%，两者综合表现优于目前较先进的 YOLOv6、YOLOv7-Tiny 和 YOLOv8n(mAP@.5:.95 优于 MSV1)以及基线 YOLOv5n 等目标检测算法。且 MSV1 与 MSV2 参数量分别为 0.998 M 和 1.269 M，浮点数分别为 2.60 G 和 3.20 G，两者参数量与浮点数大大小于其他模型，更利于在无人机等移动终端的部署。

未来，高压输电线路的巡检模型必然会朝着更加轻量化且更高精度的方向不断发展，但值得注意的是，本文改进方法离工程应用还有距离，尤其在模型的运行时间指标上还需进一步优化，且本文方法尚未在其他目标检测模型上进行详细研究和探讨。未来的研究将继续在保持检测精度的基础上实现模型轻量化，并进一步减少模型的推理时间，为高压输电线路的无人机巡检及高精度快速的其他目标检测领域提供技术支持，同时希望在其他模型上完善这些改进方法的应用。

参考文献　References

[1] DISYADEJ T, PROMJAN J, POOCHINAPAN K, et al. High voltage power line maintenance & inspection by using smart robotics[C]// 2019 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT). Washington, USA: IEEE, 2019: 1-4.

[2] LUO Y H, YU X, YANG D S, et al. A survey of intelligent transmission line inspection based on unmanned aerial vehicle[J]. Artificial Intelligence Review, 2023, 56(1): 173-201.

[3] 刘开培，李博强，秦　亮，等. 深度学习目标检测算法在架空输电线路绝缘子缺陷检测中的应用研究综述[J]. 高电压技术，2023，49(9)：3584-3595.
LIU Kaipei, LI Boqiang, QIN Liang, et al. Review of application research of deep learning object detection algorithms in insulator defect detection of overhead transmission lines[J]. High Voltage Engineering, 2023, 49(9): 3584-3595.

[4] 付　晶，谈家英，周立玮，等. 输电线路无人机巡检图像缺陷智能识别方法分析[J]. 高电压技术，2023，49(增刊 1)：103-110.
FU Jing, TAN Jiaying, ZHOU Liwei, et al. Analysis of intelligent defect recognition method in UAV inspection images of transmission lines[J]. High Voltage Engineering. 2023, 49(Supplement 1): 103-110.

[5] 周自强，袁光裕，冯万兴，等. 基于深度学习的输电线路图像目标识别与分析[J]. 高电压技术，2020，46(增刊)：300-304.
ZHOU Ziqiang, YUAN Guangyu, FENG Wanxing, et al. Transmission line image target recognition and analysis based on deep learning[J]. High Voltage Engineering, 2020, 46(Supplement): 300-304.

[6] 程海燕，翟永杰，陈　瑞. 基于 Faster R-CNN 的航拍图像中绝缘子识别[J]. 现代电子技术，2019，42(2)：98-102.
CHENG Haiyan, ZHAI Yongjie, CHEN Rui. Faster R-CNN based recognition of insulators in aerial images[J]. Modern Electronics Technique, 2019, 42(2): 98-102.

[7] ADOU M W, XU H R, CHEN G H. Insulator faults detection based on deep learning[C]// 2019 IEEE 13th International Conference on Anti-counterfeiting, Security, and Identification (ASID). Xiamen, China: IEEE, 2019: 173-177.

[8] LI Q, ZHAO F, XU Z P, et al. Insulator and damage detection and location based on YOLOv5[C]// 2022 International Conference on Power Energy Systems and Applications (ICoPESA). Singapore: IEEE, 2022: 17-24.

[9] 吴　涛，王伟斌，于　力，等. 轻量级 YOLOV3 的绝缘子缺陷检测方法[J]. 计算机工程，2019，45(8)：275-280.
WU Tao, WANG Weibin, YU Li, et al. Insulator defect detection method for lightweight YOLOV3[J]. Computer Engineering, 2019, 45(8): 275-280.

[10] ZHANG Q L, YANG Y B. SA-Net: shuffle attention for deep convolutional neural networks[C]// ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Toronto, Canada: IEEE, 2021: 2235-2239.
[11] 李利荣，张云良，陈　鹏，等. 基于上下文信息增强与特征细化的绝缘子破损检测方法[J]. 高电压技术，2023，49(8)：3405-3414.
LI Lirong, ZHANG Yunliang, CHEN Peng, et al. Detection method of insulator breakage based on context augmentation and feature refinement[J]. High Voltage Engineering, 2023, 49(8): 3405-3414.
[12] DEFAZIO A, JELASSI S. Adaptivity without compromise: a momentumized, adaptive, dual averaged gradient method for stochastic optimization[J]. The Journal of Machine Learning Research, 2022, 23(1): 144.
[13] 李利荣，陈　鹏，张云良，等. 基于改进 CenterNet 的输电线路电力器件及异常目标检测[J]. 高电压技术，2023，49(11)：4757-4765.
LI Lirong, CHEN Peng, ZHANG Yunliang, et al. Detection of power devices and abnormal objects in transmission lines based on improved CenterNet[J]. High Voltage Engineering, 2023, 49(11): 4757-4765.
[14] KINGMA D P, BA J. Adam: A method for stochastic optimization[C]// 3rd International Conference on Learning Representations. San Diego, USA: ICLR, 2015.
[15] LOSHCHILOV I, HUTTER F. Decoupled weight decay regularization[C]// 7th International Conference on Learning Representations. New Orleans, USA: ICLR, 2019.
[16] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]// Proceedings of the 32nd International Conference on International Conference on Machine Learning. Lille, France: JMLR. org, 2015: 448-456.
[17] WU Y X, HE K M. Group normalization[C]// Proceedings of the 15th European Conference on Computer Vision (ECCV). Munich, Germany: Springer, 2018: 3-19.
[18] LIU H X, BROCK A, SIMONYAN K, et al. Evolving normalization-activation layers[C]// Proceedings of the 34th International Conference on Neural Information Processing Systems. Vancouver, Canada: Curran Associates Inc., 2020: 1136.
[19] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017: 936-944.
[20] STERGIOU A, POPPE R, KALLIATAKIS G. Refining activation downsampling with SoftPool[C]// Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE, 2021: 10337-10346.
[21] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: 2018: 7132-7141.
[22] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]// Proceedings of the 15th European Conference on Computer Vision (ECCV). Munich, Germany: Springer, 2018: 3-19.
[23] JIANG P Y, ERGU D, LIU F Y, et al. A Review of Yolo algorithm developments[J]. Procedia Computer Science, 2022, 199: 1066-1073.



李利荣
1974—，女，博士，讲师，硕导
主要从事计算机视觉、图像分析与处理等方面的研究工作
E-mail: RongLi@hbut.edu.cn
LI Lirong
Ph.D.



梅　冰
1998—，男，硕士生
主要从事计算机视觉与输电线路关键部件识别及异常检测方面的研究工作
E-mail: 409206123@qq.com
MEI Bing



戴俊伟
1999—，男，硕士生
主要从事目标检测等方面的研究工作
E-mail: 1552622960@qq.com
DAI Junwei



毛　锐(通信作者)
1981—，男，硕士，高工
主要从事电力安全生产、电力调度、电网设备安全运行等方面的研究工作
E-mail: 107425648@qq.com
MAO Rui
Senior engineer
Corresponding author



童庆刚
1982—，男，硕士，高工
主要从事电力安全生产、安全督查、安全分析等方面的研究工作
E-mail: 66355710@qq.com
TONG Qinggang
Senior engineer



时　愈
1985—，女，博士，副教授，硕导
主要从事模式识别、精确制导等方面的研究工作
E-mail: shiyu0125@163.com
SHI Yu
Ph.D.
Associate professor

收稿日期　2023-09-24　修回日期　2023-12-23　　编辑　卫李静