

DOI: 10.19783/j.cnki.pspc.230248

# 基于深度学习的高压隔离开关分合状态检测算法研究

杜耀文<sup>1,2</sup>, 谢静<sup>1</sup>, 刘志坚<sup>1</sup>, 于虹<sup>2</sup>, 周帅<sup>2</sup>, 林杰<sup>3</sup>

(1. 昆明理工大学电力工程学院, 云南 昆明 650500; 2. 云南电网有限责任公司电力科学研究院, 云南 昆明 650217;  
3. 云南电网有限责任公司文山供电局, 云南 文山 663000)

**摘要:** 高压隔离开关的正常工作是电力系统稳定运行的前提。为正确识别隔离开关的分合状态, 提出一种轻量化改进型 YOLOv5s 目标检测算法。首先, 针对隔离开关数据集, 采用二次优化 K-means++ 聚类算法重新获取锚框参数。然后, 将模型中的损失函数由 CIOU 替换为具有更强收敛性能的 EIOU, 加快模型训练的收敛速度。最后, 在模型主干特征提取网络的最后一层添加 CBAM 注意力模块, 加强模型特征提取能力。在此基础上, 采用通道稀疏化剪枝的方法对改进后的模型进行轻量化处理, 减小模型体积和算力消耗。实验结果表明, 改进后的模型识别平均精度均值到达 97.4%, 轻量化处理后的模型大小为 3.92 MB, 使得模型更加容易部署到移动设备完成实时检测。

**关键词:** 神经网络; 隔离开关; 模型轻量化; 目标检测; 深度学习

## A detection algorithm for opening and closing states of high-voltage isolation switches based on deep learning

DU Yaowen<sup>1,2</sup>, XIE Jing<sup>1</sup>, LIU Zhijian<sup>1</sup>, YU Hong<sup>2</sup>, ZHOU Shuai<sup>2</sup>, LIN Jie<sup>3</sup>

(1. Faculty of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650500, China;  
2. Electric Power Research Institute of Yunnan Power Grid Co., Ltd., Kunming 650217, China;  
3. Wenshan Power Supply Bureau of Yunnan Power Grid Co., Ltd., Wenshan 663000, China)

**Abstract:** Normal operation of high-voltage disconnect switches is a prerequisite for the stable operation of power systems. To correctly identify the breaking and closing states of disconnect switches, a lightweight improved YOLOv5s target detection algorithm is proposed. First, the anchor frame parameters are reacquired using a quadratic optimized K-means++ clustering algorithm for the disconnecting switch dataset. Then, the loss function in the model is replaced from CIOU to EIOU with stronger convergence performance to accelerate the convergence speed of model training. Finally, a CBAM attention module is added to the last layer of the model backbone feature extraction network to strengthen the model feature extraction capability. The improved model is lightened using the channel sparsification pruning method to reduce the model size and arithmetic power consumption. The experimental results show that the average accuracy of the improved model reaches 97.4% and the model's size is 3.92 MB after the light weighting process, making the model easier to deploy to mobile devices for real-time detection.

This work is supported by the Key Project of Basic Research Program of Yunnan Province (No. 202301AS070055).

**Key words:** neural networks; isolated switches; light weighting of models; target detection; deep learning

## 0 引言

高压隔离开关是变电站中使用较多的电力设备, 其主要作用是在检修其他输变电设备时, 确保

电路上的安全隔离, 在电力系统中扮演了重要角色<sup>[1]</sup>。高压隔离开关在长期运行当中可能因为机械故障或者是工作人员操作不当而使得隔离开关不能正常分合闸, 所以, 正确检测隔离开关的分合闸状态对电力系统的稳定运行起着重要作用<sup>[2-4]</sup>。

长期以来, 定期巡检<sup>[5]</sup>是电力系统故障排查的主要方式, 在巡检时又辅以技术手段来提高巡检质

基金项目: 云南省基础研究计划重点项目资助(202301AS070055)

量。为了能够正确检测隔离开关的分合闸状态, 有学者从红外成像测温<sup>[6]</sup>、触头温度在线监测<sup>[7]</sup>、触指压力检测<sup>[8]</sup>和振动加速度-超声波融合传感器<sup>[9]</sup>等方法入手展开研究。文献[10]通过分析电机电流特征来区分隔离开关的机械故障, 此方法存在一定的缺陷, 即在受到冲击电流的影响时容易出现误检。也有学者从数据角度展开研究, 如文献[11]提出一种结合三维空间的数据扩充方法, 通过求解三维坐标、空间旋转变换、透视投影生成新的隔离开关数据, 然后使用扩充后数据训练目标检测模型实现隔离开关状态识别。

传统的人工巡检在巡检周期、效率以及危险性等方面都存在一定的问題<sup>[12]</sup>, 随着数字电网概念的提出以及人工智能新技术的发展, 利用无人机实现智能化巡检已是大势所趋<sup>[13]</sup>。有学者利用机器学习来实现隔离开关识别, 文献[14]提出了一种基于霍夫森林的设备状态识别方法, 并结合了启发式算法, 能够同时检测多个设备, 也提高了检测准确率。文献[15]通过像素积分投影法对闸刀分合闸情况进行特征提取, 将提取到的特征值导入 BP 神经网络中进行训练, 得到一个能够自动识别闸刀位置的分类器, 其识别准确率可达 95% 以上。然而, 传统机器学习存在模型泛化能力弱的问题, 面对多目标检测、遮挡、光照变化、尺度变化和视角变化等复杂环境时难以有效识别。

随着技术的进步, 机器学习领域发展出了深度学习这一分支<sup>[16]</sup>, 并提出了 SSD<sup>[17]</sup>、Faster RCNN<sup>[18-19]</sup>、Mask RCNN<sup>[20-21]</sup>、MobileNet<sup>[22]</sup>、YOLO<sup>[23-25]</sup>等一系列优秀深度学习模型。文献[26]利用改进 YOLOv3 算法来对高压隔离开关中设备异常发热点进行检测, 通过实验验证了深度学习模型在隔离开关检测中的有效性。文献[27]通过改进传统的卷积神经网络来识别隔离开关工作状态, 该方法首先利用非极大值抑制和直线拟合算法实现隔离开关定位, 然后利用隔离开关长宽比实现工作状态的区分。通过对深度学习模型的各项改进能够一定程度提升模型的识别准确率及泛化性能, 然而, 由于模型过大无法直接部署在终端检测设备上, 这降低了检测的实时性。

基于上述分析可知, 现有模型在检测准确率、泛化能力、部署成本及检测实时性等方面还没有达到很好的平衡, 为解决该问题, 本文提出了一种轻量化改进型神经网络模型。

经过试验对比, YOLOv5s 在几个常用 YOLO 模型中表现较好, 故本文模型选择以 YOLOv5s 为基础模型, 通过改进模型来提升检测准确率和泛化

能力, 再通过剪枝改进后模型来实现模型轻量化, 减小模型体积并提升检测速度, 降低实际部署成本。在模型改进方面, 采用二次优化 *K-means++* 聚类来获取锚框参数; 通过改用 EIOU 损失函数来加快模型训练收敛速度; 在模型主干特征提取网络之后添加 CBAM 注意力模块来加强模型特征提取能力。在模型轻量化方面, 采用通道稀疏化剪枝的方法剪去模型中冗余的通道, 最终获得一个轻量化改进型 YOLOv5s 模型。通过分析实验结果可知, 改进后的 YOLOv5s 模型平均精度均值(mean average precision, mAP)为 97.4%, 与基础模型相比提升了 2.2%, 剪枝后的模型大小仅为 3.92 MB, 每秒检测 345 帧。轻量化模型使检测精度与检测速度达到了有效平衡, 能够用于部署到变电站的终端设备上完成隔离开关分合状态检测。

## 1 YOLOv5s 模型结构

单阶段目标检测模型 YOLO(You Only Look Once)能够在保持检测精度的同时获得较快的检测速度, 在实时检测系统中被广泛应用。YOLOv5 作为 YOLO 系列的第 5 版模型, 各方面性能都有较大的提升, YOLOv5 又分为 x、l、m、s、n 几个不同版本, YOLOv5s 是其中深度最浅、特征图宽度最小的网络, 能够极大地降低模型的运算量和内存占用量。

YOLOv5s 模型结构依次为主干特征提取网络(CSPDarknet)、颈部网络(Neck)和检测网络(Head), 整体结构如图 1 所示。

### 1.1 主干特征提取网络

在主干特征提取网络中, 输入为 RGB 的 3 通道图像, 图像维度为(640, 640, 3), 输入图像经过 Focus、CBS 及 CSP1\_X 等模块的处理后完成特征提取。

在图像特征信息提取中, 常常采用下采样的方法。一般的下采样操作包括最大池化和平均池化, 但这些池化操作会损失部分图像信息。为了解决这个问题, 引入了 Focus 模块。该模块通过切片(slice)操作对输入的图像进行处理, 以每隔一个像素取一个值, 并形成 4 个独立特征层, 然后将 4 个独立特征层堆叠在一起, 将宽高信息融合到通道维度上, 从而将原来的 3 通道扩充为 12 通道, 使得特征图维度变为(320, 320, 12)。通过这种方式, 在完成二倍下采样的同时还保留了全部的图像信息。

主干特征提取网络中, CSP1\_X 是由基础块 CBS 和残差组件(Res unit)构成的残差块。在残差组件中, 残差边对输入不做任何处理, 直接与主干边

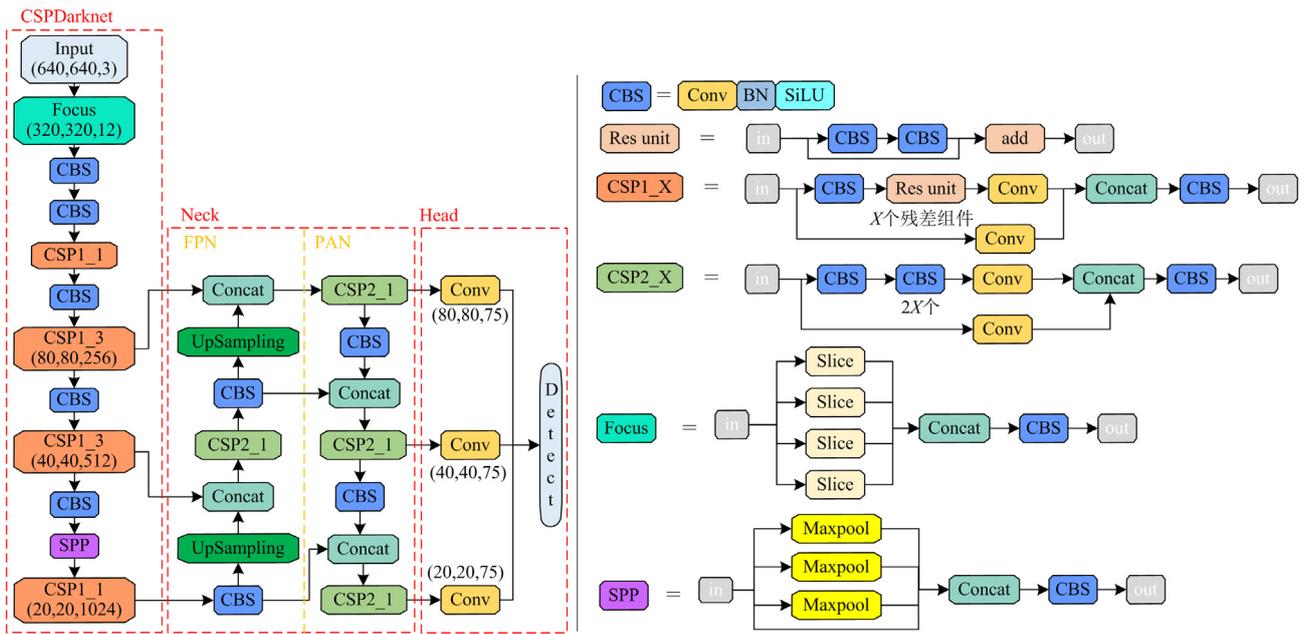


图 1 YOLOv5s 模型结构图

Fig. 1 YOLOv5s model structure diagram

的输出结合。这种残差结构的跳跃连接可以缓解深度神经网络中梯度消失的问题<sup>[28]</sup>，从而提升网络提取特征的能力。而残差块则是一个更大的残差网络，其中的主干部分通过堆叠不同数量的残差组件来构建，同时另外一个残差边经过少量处理后直接与主干相结合。

经过主干特征提取网络处理后输出 3 个有效特征层，3 个特征层的维度分别为(20, 20, 1024)、(40, 40, 512)、(80, 80, 256)，这 3 个有效特征层将用于颈部网络的构建。

### 1.2 颈部网络

颈部网络中包含特征金字塔网络<sup>[29]</sup>和路径聚合网络<sup>[30]</sup>两个部分。特征金字塔网络是自顶向下的，将高层的语义特征信息通过上采样的方式进行传递融合，而路径聚合网络与特征金字塔网络的信息传递方向正好相反，路径聚合网络自底向上传递定位特征，并对高、低特征层进行参数聚合。这两个网络的结合增强了不同特征层之间的信息融合，从而保留对目标检测有利的特征信息。

### 1.3 检测网络

经过颈部网络处理的加强特征图将被传送到检测网络中，3 个加强特征图完成一次卷积操作后获得 3 个检测模块，它们的维度依次为(20, 20, 75)、(40, 40, 75)、(80, 80, 75)，这 3 个检测模块分别用于检测大、中、小目标，模型根据待检测目标的大小自动选择检测模块，最终输出检测结果。

## 2 改进 YOLOv5s 模型

### 2.1 基于二次优化的 K-means++ 锚框聚类

在目标检测模型训练之前，需要人为设定锚框(anchor)，模型训练时调整锚框以接近标注框，在使用模型进行目标检测时也是依据训练后的模型参数来调整锚框以正确框选出待检测目标。原始 YOLOv5s 模型的锚框参数是对 COCO 数据集采用 K-means 聚类得到的。然而，COCO 数据集与隔离开关数据集的待检测目标尺寸存在一定的差异，故本文采用基于 K-means 改进的 K-means++ 算法对隔离开关数据集进行聚类处理，以获得最终的锚框参数。K-means++ 与 K-means 聚类算法的区别在于聚类中心的初始化过程，K-means 算法对聚类中心的选取是完全随机的，而 K-means++ 算法在聚类中心初始化过程中会使聚类中心之间的距离尽可能远，并逐步选取 K 个聚类中心。

二次优化 K-means++ 聚类的具体计算过程如下。

1) 从数据集 Y 中随机选取一个样本点作为第一个初始聚类中心。

2) 对于数据集中的每一个样本点  $x_i$ ，计算它与已选择的聚类中心之间的距离  $D(x_i)$ 。

3) 选择下一个聚类中心，从数据集中选择具有最大  $D(x_i)$  的样本点作为新的聚类中心，选择该样本点作为新聚类中心的概率为  $P(x_i)$ 。

$$P(x_i) = \frac{D(x_i)^2}{\sum_{x_i \in Y} D(x_i)^2} \quad (1)$$

4) 重复步骤 2)和 3), 直到  $K$  个聚类中心都被确定。

5) 二次优化: 所有样本点到各自所属聚类中心的距离最短。

$$J = \min \sum_{i=1}^m \|x_i - c_k\|^2 \quad (2)$$

式中:  $J$  表示所有样本点到各自所属聚类中心的距离之和;  $m$  表示样本点总数;  $c_k$  表示第  $k$  个聚类中心。

完成上述步骤所求得的聚类中心则为最优聚类中心。

## 2.2 EIOU 损失函数

在 YOLOv5s 模型中, 原本的损失函数 CIOU\_Loss 被替换为 EIOU\_Loss<sup>[31]</sup>。这两个损失函数都由 3 个部分组成, 分别是交并比损失  $L_{IOU}$ 、中心距离损失  $L_{dis}$  和宽高损失  $L_{asp}$ 。在 CIOU\_Loss 中通过宽高比来计算宽高损失, 而 EIOU\_Loss 是分别计算预测框与真实框的宽度损失和高度损失, 这将有助于提升模型的收敛速度。

$$L_{CIOU} = L_{IOU} + L_{dis} + L_{asp} = 1 - I + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \quad (3)$$

式中:  $L_{CIOU}$  表示 CIOU 损失;  $L_{IOU}$  表示交并比损失;  $L_{dis}$  表示中心距离损失;  $L_{asp}$  表示宽高损失;  $I$  表示交并比;  $\rho$  表示求两个中心点的欧式距离;  $b$ 、 $b^{gt}$  分别表示预测框和真实框的中心点;  $c$  表示的是能够同时包含预测框和真实框的最小闭包区域的对角线距离;  $\alpha$  表示权重参数;  $v$  表示预测框与真实框宽高比的距离。

$$L_{EIOU} = L_{IOU} + L_{dis} + L_{asp} = 1 - I + \frac{\rho^2(b, b^{gt})}{c^2} + \frac{\rho^2(w, w^{gt})}{c_w^2} + \frac{\rho^2(h, h^{gt})}{c_h^2} \quad (4)$$

式中:  $L_{EIOU}$  表示 EIOU 损失;  $w$ 、 $h$  分别表示预测框的宽和高;  $w^{gt}$ 、 $h^{gt}$  分别表示真实框的宽和高;  $c_w^2$ 、 $c_h^2$  分别表示覆盖预测框与真实框最小外接框的宽和高。

## 2.3 CBAM 注意力模块

本文选择在主干特征提取网络的最后一层之后加入 CBAM 注意力模块<sup>[32]</sup>, 以对经过主干特征提取网络的特征图进行进一步处理。CBAM 注意力模块如图 2 所示, 在 CBAM 中综合了通道和空间注意力机制, 输入的特征图分别经过通道注意力模块和空间注意力模块处理, 获取对应的权重系数  $M_c$  和  $M_s$ 。在通道注意力模块中, 输入的特征图经过最

大池化和平均池化处理, 然后通过共享感知机处理后进行堆叠, 最后使用 Sigmoid 函数将堆叠结果规范化到 0~1 之间, 最终得到特征的通道权重系数  $M_c$ 。而在空间注意力模块中, 经过池化处理后的结果直接进行堆叠, 省去了共享感知机处理的环节, 最后再经过 Sigmoid 函数处理得到特征的空间权重系数  $M_s$ 。CBAM 注意力模块与 SE、ECA 等注意力模块相比, 它可以同时兼顾特征图的通道和空间两个维度, 通过加权的方式获取更多有利于目标检测的特征信息。

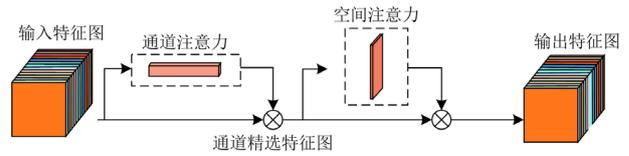


图 2 CBAM 注意力模块

Fig. 2 CBAM attention module

## 3 网络模型轻量化

改进模型能够提升模型检测精度, 而模型轻量化可以使模型更容易部署到前端以实现实时检测。本文采用通道稀疏化剪枝<sup>[33]</sup>的方法来实现模型轻量化。在 YOLOv5s 模型中, 存在用于加速网络收敛并提升泛化性能的批归一化(batch normalization, BN)层, BN 层的计算公式为

$$y_i = \gamma \cdot \hat{x}_i + \beta \quad (5)$$

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 - \varepsilon}} \quad (6)$$

式中:  $x_i$  和  $y_i$  分别表示 BN 层的输入和输出;  $\gamma$  和  $\beta$  分别表示缩放和位移参数;  $\mu_B$  和  $\sigma_B^2$  分别表示均值和方差;  $\varepsilon$  为非零常数。

模型在 BN 层中引入了缩放和位移参数, 用于将输出结果归一化到正常范围内。可以将 BN 层的  $\gamma$  参数作为模型轻量化的缩放因子, 通过缩放因子来衡量各个通道对模型目标检测的贡献程度。为筛选出利于目标检测的通道, 可以将缩放因子代入到损失函数当中进行训练, 改进后损失函数计算公式如式(7)所示。

$$L = \sum_{(x,y)} l(f(x,W), y) + \lambda \sum_{\gamma \in \Gamma} g(\gamma) \quad (7)$$

式中:  $L$  表示总损失函数;  $x$  表示输入样本;  $W$  表示可训练的权重;  $f()$  表示深度学习模型的输出;  $y$  表示最终的目标;  $l()$  表示损失函数;  $\lambda$  为平衡两个求和项的可变参数;  $\Gamma$  表示缩放因子集合;  $g()$  表示 L1 稀疏正则化。第一个求和项代表正常训练模型的损失函数值, 第二个求和项是对缩放因子  $\gamma$  进

行 L1 正则化稀疏处理的损失函数值, 两项结合之后得到了新的损失函数。

通过使用新的损失函数对网络进行稀疏化训练, 可以筛选出对模型目标检测贡献度较小的通道。如图 3 所示, 经过训练后, 部分缩放因子变得非常小, 将这部分缩放因子所对应的通道剪去后将获得一个更加轻量化的网络模型。

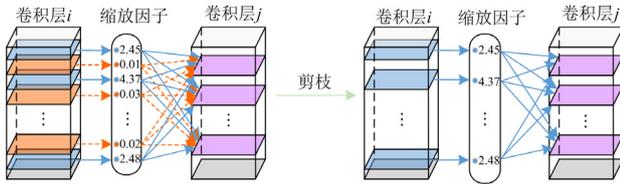


图 3 通道稀疏化剪枝

Fig. 3 Channel thinning pruning

#### 4 实验与结果分析

本实验所采用的软硬件配置情况如下: 操作系统选择 Windows10, CPU 采用 Intel Core i7-10700KF @3.80 GHz, 内存为 32 GB, 显卡为 NVIDIA GeForce RTX 3060(12 GB 显存), 搭配 CUDA11.0 和 cudnn8.0.5.39, 选择与 CUDA11.0 对应的深度学习框架 Pytorch1.7.1, 编程语言环境为 Python3.6.13。

##### 4.1 数据预处理

实验数据预处理过程如图 4 所示。本实验使用的高压隔离开关数据来自于南网某公司变电站, 经过筛选, 共保留原始图片 1477 张, 这些图片涵盖了夜间拍摄、多目标、小目标、阳光直射、阴雨天气等复杂情况。对于原始数据集中的隔离开关分、合闸两类目标, 使用标注工具 Labellmg 完成对所有图片的标注工作。在标注过程中, 将隔离开关分闸状态标注为“open”, 合闸状态标注为“close”, 标注结束后, 获取图片对应的标签文件, 这些标签文件将用于后续的目标检测和模型训练。

训练神经网络模型需要充足的数据量。此外, 数据集中正负样本的不平衡也会影响最终模型的识别效果。因此, 采用旋转、平移、加噪声和改变图片亮度等数据增强方式实现数据扩充和平衡正负样本。经过这些变换后的图片能够模拟出拍摄角度变化、光照强度变化、图片模糊等复杂情况, 从而用于测试模型的泛化能力。经过数据扩充后共有 7385 张图片, 采用随机选取的方法预留数据集中的 10% 作为测试集, 用于测试模型的各项指标, 剩余数据按照 9:1 的比例划分为训练集和验证集。

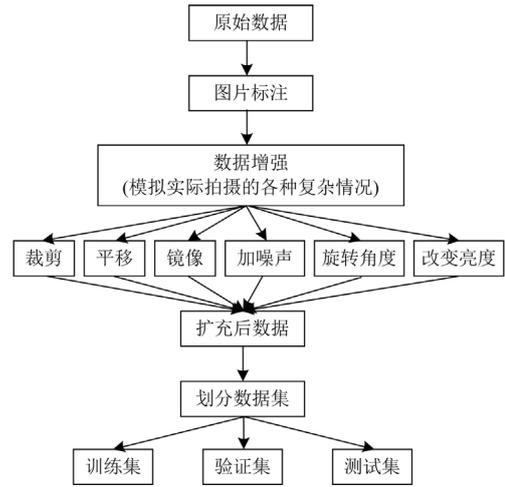


图 4 数据预处理流程

Fig. 4 Data processing processes

##### 4.2 模型评价指标

在本文中, 采用精确率  $P$ 、召回率  $R$ 、平均精度 (average precision, AP)、平均精度均值 (mean average precision, mAP) 和每秒检测帧数 (frames per second, FPS) 作为模型的评价指标, 各评价指标的计算式分别为

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (8)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (9)$$

$$e = \int_0^1 P dR \quad (10)$$

$$e_m = \frac{\sum_{j=1}^n e_j}{n} \quad (11)$$

$$F = \frac{1}{t_{avg}} \quad (12)$$

式中:  $P$  表示精确率;  $N_{TP}$  和  $N_{FP}$  分别表示正确识别和错误识别的样本数;  $R$  表示召回率;  $N_{FN}$  表示未识别出的样本数;  $e$  表示平均精度;  $e_m$  表示平均精度均值;  $e_j$  表示第  $j$  个类别的平均精度;  $n$  表示预测类别数 (在本文中  $n=2$ , 对应隔离开关的分、合两种状态);  $F$  表示每秒检测帧数;  $t_{avg}$  表示检测一张图片所用的时间, 单位为帧/s。

##### 4.3 实验设置

本文实验主要分为两个阶段。第一个阶段是改进后 YOLOv5s 模型实验, 实验对象是改进后 YOLOv5s 模型, 该阶段包含模型训练和测试, 用于获取具有较高检测精确率的模型。第二阶段是轻量

化模型实验, 实验对象是第一阶段结束所获得的模型, 该阶段包含通道稀疏训练、剪枝、微调、测试

和优化训练, 用于获取最优轻量化模型。整体实验过程如图 5 所示。

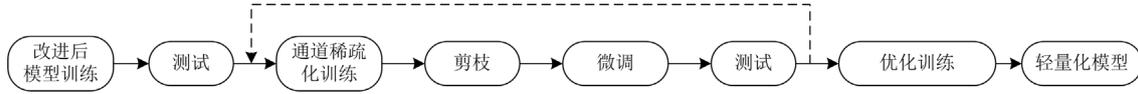


图 5 实验过程

Fig. 5 Test procedure

实验中, 输入图像尺寸设置为  $416 \times 416$ 。第一阶段的模型训练和第二阶段的稀疏训练都设置为 100 个轮次, 第二阶段的微调训练设置为 50 个轮次。初始学习率设置为 0.001。

#### 4.4 实验结果分析

实验共分为 3 组, 第 1 组为主要 YOLO 模型对比试验, 用于对比选用模型; 第 2 组为消融实验, 验证各改进方法的有效性; 第 3 组为轻量化试验, 用于验证模型轻量化效果。

实验 1, 几个不同版本 YOLO 模型对比试验, 如表 1 所示, 本实验主要对比了模型体积、mAP、AP 和 FPS 几项指标。

表 1 不同 YOLO 模型结果对比

Table 1 Comparison of the results of different YOLO models

模型	模型体积/MB	$e_m/\%$	$e/\%$		$F$
			open	close	
YOLOv3	117	89.9	87.1	92.7	62
YOLOv4	244	91.4	90.9	91.8	33
YOLOv5s	13.7	88.1	85.1	91.0	133
YOLOv5x	165	86.6	81.8	91.3	40
YOLOv7	71.3	27.0	18.7	35.4	102

注: open、close 分别表示隔离开关的开、关状态, 下同。

从表 1 中可以看出, YOLOv4 是所有模型中识别精度最高的, 但 YOLOv4 的模型体积也是最大的, 较大的模型体积限制了其在移动设备的部署。此外, 冗余的网络模型也导致了较慢的检测速度, 仅为 33 帧, 是所有模型中检测速度最慢的。YOLOv7 作为较新的版本, 在隔离开关数据集上的表现也并没有很好, 虽然在检测速度及模型体积方面有所提升, 但是其检测精度较低, 难以满足实际应用的要求。而 YOLOv5s 在所有模型中的整体表现较好, 拥有最快的检测速度和最小的模型体积, 适合部署到前端的移动设备上实时检测。然而, 其检测精度仍有待提高, 因此将通过改进模型来解决这个问题。

实验 2, 此实验为消融实验, 在该实验中, 采用数据增强后的数据集训练原始 YOLOv5s 基础模型, 将其作为基准模型, 用于对比各项改进措施对

模型的影响。模型 a、模型 b 和模型 c 分别表示采用了  $K$ -means++ 聚类、EIOU 损失函数和 CBAM 注意力模块, 本文模型综合了 3 项改进。

从图 6 中可以看出, 采用  $K$ -means++ 聚类和 EIOU 损失函数都能加快模型训练时的收敛速度, 而采用 CBAM 注意力模块的模型 c, 由于增加注意力模块导致模型结构及参数变得更加复杂, 模型训练需要更长的收敛时间。本文模型综合了上述 3 项改进措施, 综合效果最好。可以看出, 在相同训练轮次下, 其损失值最小, 在加强模型特征提取能力的同时加快了模型训练收敛时间。

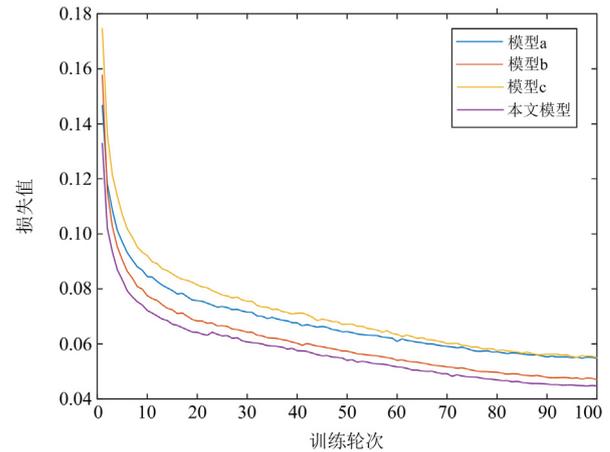


图 6 各模型损失值变换情况

Fig. 6 Transformation of loss values for each model

在表 2 中, 与基准模型相比, 模型 a 和模型 c 都有一定的性能提升, 尤其是在召回率方面, 提升了模型的目标检测能力。另外, 模型的检测速度也有了显著的提升,  $F$  值保持在 300 以上。模型 c 引入了 CBAM 注意力模块, 增加了模型的复杂度, 使得训练时间增加。模型 b 在检测精度及检测速度方面的提升效果并不明显, 但是通过改进损失函数, 提升了模型的收敛速度并降低了模型的训练时间。本文方法综合了上述 3 项改进的优势, 能够在提升模型检测能力的同时平衡模型训练时间。

实验 3, 轻量化实验, 共进行两轮, 每一轮轻量化包括稀疏训练、剪枝和微调 3 个环节。在第一轮轻量化中, 使用改进后的模型进行剪枝, 在第二

轮轻量化中, 使用第一轮结束后的模型进行剪枝。最后, 对第二轮轻量化模型进行优化训练, 得到最终的轻量化模型。

表 2 消融实验

Table 2 Ablation experiments

模型	P/%	R/%	e <sub>m</sub> /%	e/%		F	训练用时/h
				open	close		
基础模型	96.7	94.8	95.2	92.4	97.9	204	4.474
模型 a	97.4	96.6	96.8	95.4	98.3	333	4.513
模型 b	96.9	95.6	95.8	94.1	97.5	312	4.380
模型 c	97.8	96.5	97.1	95.5	98.6	333	5.082
本文模型	97.3	97.2	97.4	96.5	98.4	322	4.473

轻量化实验如表 3 所示, 在第一轮轻量化实验中, 首先进行稀疏训练, 筛选出模型中的冗余通道, 然后根据设定的剪枝阈值(本轮剪枝阈值为 0.6)剪去冗余通道。可以发现, 剪枝后模型的检测精度显著下降, e<sub>m</sub> 值仅为 12.1%。接下来, 通过微调训练来恢复检测精度。由于第一轮剪枝时剪枝阈值已经接近极限, 模型中剩余较少的冗余通道, 所以在进行第二轮轻量化实验时, 模型体积基本没有减小。最后, 通过优化训练来进一步恢复轻量化模型的检测精度。可以发现, 轻量化模型对比改进后模型虽然检测精度有一定的下降, 但是模型体积更小, 检测速度也更快, 这让模型在各方面都达到了较好的平衡。

表 3 轻量化实验

Table 3 Light weighting experiments

模型	模型体积/MB	P/%	R/%	e <sub>m</sub> /%	F
改进后 YOLOv5s	13.7	97.3	97.2	97.4	322
稀疏训练	13.6	96.8	96.2	97.5	344
第一轮 剪枝	3.94	49.7	24.8	12.1	476
微调	3.94	96.2	88.3	88.4	384
稀疏训练	3.94	94.4	93.1	92.7	357
第二轮 剪枝	3.92	23.5	68.3	19.9	333
微调	3.92	94.5	91.3	90.9	322
优化训练	3.92	96.4	96.6	97.0	345

为了验证模型轻量化的效果, 测试了 YOLOv5s 模型改进前、改进后和轻量化模型的计算量(FLOPs)与参数量(Params)等参数, 具体结果如表 4 所示。

从表 4 中可以看出, 完成轻量化的 YOLOv5s 模

型计算量为 2.25 G, FPS 值为 345 帧/s, 可以以更低的成本完成快速检测。以嵌入式 AI 平台 JETSON Nano2 GB 为例, 其每秒浮点运算数(FLOPS)为 0.5T, 将轻量化模型部署在此类嵌入式平台上可以完成 32 位浮点数的运算, 在完成快速检测的同时还可以保证模型的检测精度。

表 4 模型参数对比

Table 4 Comparison of model parameters

模型	模型体积/MB	e <sub>m</sub> /%	F	FLOPs/G	Params/MB
改进前	13.7	95.2	204	3.48	7.10
改进后	13.7	97.4	322	3.48	7.07
轻量化	3.92	97.0	345	2.25	1.94

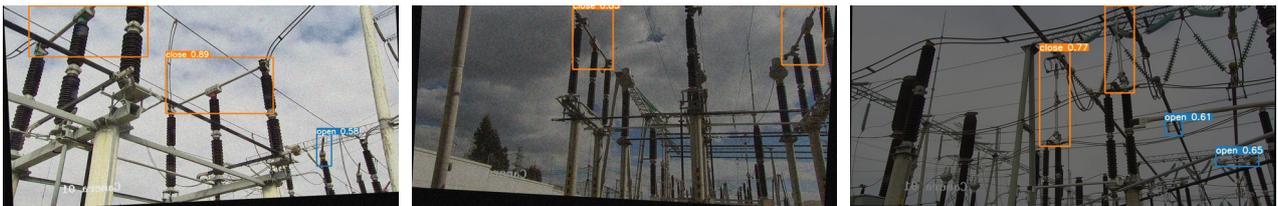
图 7 展示了改进后 YOLOv5s 模型在小目标、多目标、阳光直射和阴雨天气等复杂环境下的检测效果。可以看出, 在各项复杂环境下, 模型正确区分了高压隔离开关的分合闸状态, 表现出较好的检测效果。



图 7 部分复杂环境下检测效果

Fig. 7 Detection in some complex environments

图 8 展示了 YOLOv5s 模型在改进前、改进后和轻量化后的实际检测效果。可以看出, 图 8(a)中改进前的基础 YOLOv5s 模型对一些小目标的检测能力较弱, 在 3 张图片中均有一些小目标漏检。在图 8(b)中, 改进后的 YOLOv5s 模型在特征提取能力方面有了明显增强, 这使得一些小目标和遮挡目标都能被检测出来。在图 8(c)中, 使用轻量化模型检测隔离开关, 虽然出现了部分分闸状态隔离开关漏检的情况, 但是该模型依然能够检测出图片中主要几个隔离开关的状态, 可以满足实际检测的需求。



(a) 改进前模型



图 8 各阶段 YOLOv5s 检测效果

Fig. 8 YOLOv5s test results by stage

最终轻量化模型能够实现检测速度的提升和模型体积的降低。从检测结果来看,改进后的模型由于增加了注意力机制,特征提取能力得到了增强,使得一些小目标也能被检测出来。而轻量化后的模型对分闸状态下的部分隔离开关未能检测出来,这主要是剪枝时部分通道被剪去,影响了小目标特征的提取,但是也可以看出轻量化模型还能检测出被遮挡的目标,这在一定程度上平衡了检测效果。

## 5 结论

针对隔离开关状态检测中出现的模型体积大和检测精度低等问题,提出了一种轻量化改进型神经网络模型算法,通过改进 YOLOv5s 基础模型来提升检测精度和模型泛化能力,再通过稀疏化剪枝实现模型轻量化。经过一系列模型对比实验,得出以下结论:

1) 采用二次优化  $K$ -means++ 实现锚框聚类与在模型主干特征提取网络最后一层之后添加 CBAM 注意力模块能够提升模型检测精度,但是模型结构的改变也使得模型训练时间少量增加。

2) EIOU 损失函数将原本 CIOU 损失函数的纵横比损失改进为分别求取宽、高损失,提升了模型的收敛速度,解决了结论 1) 中出现的训练时间长的问題。

3) 采用通道稀疏化剪枝的方法剪去模型中的冗余结构,降低了模型体积和参数计算量,提升了模型检测速度。

实验表明,改进后模型的 mAP 值为 97.4%,对比基础模型提升了 2.2 个百分点。模型轻量化处理后 mAP 值为 97.0%,体积为 3.92 MB,检测速度为

345 帧/s,这使得模型能以更低的成本部署到移动端设备中完成实时检测。

## 参考文献

- [1] 庞小峰, 马金伟, 王流火, 等. 强风下高压隔离开关风荷载及其力学特性研究[J]. 高压电器, 2022, 58(6): 205-211.  
PANG Xiaofeng, MA Jinwei, WANG Liuhuo, et al. Study on wind load and mechanical properties of high voltage disconnector under strong wind[J]. High Voltage Apparatus, 2022, 58(6): 205-211.
- [2] 郑克勤, 吕旺燕, 聂铭, 等. 户外高压隔离开关触头材料的腐蚀与防护分析[J]. 广东电力, 2019, 32(7): 124-133.  
ZHENG Keqin, LÜ Wangyan, NIE Ming, et al. Analysis on corrosion and protection of contact materials of outdoors high voltage disconnectors[J]. Guangdong Electric Power, 2019, 32(7): 124-133.
- [3] 成林, 张鸿业, 伊同强, 等. 基于 3D 电场时频分析的隔离开关绝缘缺陷检测方法[J]. 高电压技术, 2020, 46(4): 1417-1423.  
CHENG Lin, ZHANG Hongye, YI Tongqiang, et al. Insulation defect detection method for disconnecting switches based on time-frequency analysis of 3D electric fields[J]. High Voltage Engineering, 2020, 46(4): 1417-1423.
- [4] 张赛鹏, 冯世涛, 赵春明, 等. 基于威布尔分布和蒙特卡洛法的高压隔离开关可靠性研究[J]. 高压电器, 2021, 57(6): 86-93, 101.  
ZHANG Saipeng, FENG Shitao, ZHAO Chunming, et al. Study on reliability of high voltage disconnector based on Weibull distribution and Monte Carlo method[J]. High

- Voltage Apparatus, 2021, 57(6): 86-93, 101.
- [5] 陈磊, 邓欣怡, 陈红坤, 等. 电力系统韧性评估与提升研究综述[J]. 电力系统保护与控制, 2022, 50(13): 11-22.  
CHEN Lei, DENG Xinyi, CHEN Hongkun, et al. Review of the assessment and improvement of power system resilience[J]. Power System Protection and Control, 2022, 50(13): 11-22.
- [6] 李先锋, 胡晨刚, 高振宇, 等. 基于多特征融合的 GIS 隔离开关接触状态评估方法[J]. 热力发电, 2023, 52(5): 22-28.  
LI Xianfeng, HU Chengang, GAO Zhenyu, et al. Evaluation method of contact state of GIS disconnecter based on multi-feature fusion[J]. Thermal Power Generation, 2023, 52(5): 22-28.
- [7] 李中祥, 宋建成. 高压隔离开关触头温度在线监测系统的研制[J]. 高压电器, 2009, 45(2): 11-13, 17.  
LI Zhongxiang, SONG Jiancheng. On-line temperature measurement system for contacts in HV switchgear[J]. High Voltage Apparatus, 2009, 45(2): 11-13, 17.
- [8] 程林, 徐惠, 刘宇飞, 等. 基于力矩-转角曲线的水平折臂式隔离开关机械状态检测方法[J]. 高压电器, 2020, 56(4): 192-198.  
CHENG Lin, XU Hui, LIU Yufei, et al. Mechanical state detection method of horizontal folding arm disconnecter based on torque-angle curve[J]. High Voltage Apparatus, 2020, 56(4): 192-198.
- [9] 张昭宇, 胡一丹, 宋颜峰, 等. 电力设备机械振动-超声波融合检测传感器研制及应用[J]. 中国电机工程学报, 2023, 43(14): 5713-5722.  
ZHANG Zhaoyu, HU Yidan, SONG Yanfeng, et al. Development and application of mechanical vibration-ultrasound combined sensor for power equipment[J]. Proceedings of the CSEE, 2023, 43(14): 5713-5722.
- [10] 邱志斌, 阮江军, 黄道春, 等. 基于电机电流检测的高压隔离开关机械故障诊断[J]. 中国电机工程学报, 2015, 35(13): 3459-3466.  
QIU Zhibin, RUAN Jiangjun, HUANG Daochun, et al. Mechanical fault diagnosis of high voltage disconnecter based on motor current detection[J]. Proceedings of the CSEE, 2015, 35(13): 3459-3466.
- [11] 刘梓权, 王慧芳, 管敏渊, 等. 隔离开关图像数据扩充方法及其在自动状态识别中的应用[J]. 高电压技术, 2020, 46(2): 441-447.  
LIU Ziquan, WANG Huifang, GUAN Minyuan, et al. Data augmentation method for disconnecting switch images and its application in automatic state recognition[J]. High Voltage Engineering, 2020, 46(2): 441-447.
- [12] 罗潇, 於锋, 彭勇. 基于深度学习的无人机电网巡检缺陷检测研究[J]. 电力系统保护与控制, 2022, 50(10): 132-139.  
LUO Xiao, YU Feng, PENG Yong. UAV power grid inspection defect detection based on deep learning[J]. Power System Protection and Control, 2022, 50(10): 132-139.
- [13] 顾晓东, 唐丹宏, 黄晓华. 基于深度学习的电网巡检图像缺陷检测与识别[J]. 电力系统保护与控制, 2021, 49(5): 91-97.  
GU Xiaodong, TANG Danhong, HUANG Xiaohua. Deep learning-based defect detection and recognition of a power grid inspection image[J]. Power System Protection and Control, 2021, 49(5): 91-97.
- [14] 邵剑雄, 闫云凤, 齐冬莲. 基于霍夫森林的变电站开关设备检测及状态识别[J]. 电力系统自动化, 2016, 40(11): 115-120.  
SHAO Jianxiong, YAN Yunfeng, QI Donglian. Substation switch detection and state recognition based on Hough forests[J]. Automation of Electric Power Systems, 2016, 40(11): 115-120.
- [15] 刘子英, 张靖, 邓芳明. 基于 BP 神经网络的高压隔离开关分合闸监测识别[J]. 电力系统保护与控制, 2020, 48(5): 134-140.  
LIU Ziyang, ZHANG Jing, DENG Fangming. Monitoring and identification of state of opening or closing isolation switch based on BP neural network[J]. Power System Protection and Control, 2020, 48(5): 134-140.
- [16] 郦阳, 王宝华. 继电保护系统故障的智能定位方法研究[J]. 电力系统保护与控制, 2022, 50(2): 69-76.  
LI Yang, WANG Baohua. An intelligent fault location method for a relay protection system[J]. Power System Protection and Control, 2022, 50(2): 69-76.
- [17] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C] // 14th European Conference on Computer Vision, October 11-14, 2016, Amsterdam, The Netherlands: 21-37.
- [18] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [19] 李国进, 姚冬宜, 艾娇燕, 等. 基于改进 Faster R-CNN 的水面漂浮物识别与定位[J]. 信阳师范学院学报(自然科学版), 2021, 34(2): 292-299.  
LI Guojin, YAO Dongyi, AI Jiaoyan, et al. Detection and localization of floating objects via improved Faster R-CNN[J]. Journal of Xinyang Normal University (Natural Science Edition), 2021, 34(2): 292-299.
- [20] WANG B, DONG M, REN M, et al. Automatic fault

- diagnosis of infrared insulator images based on image instance segmentation and temperature analysis[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(8): 5345-5355.
- [21] 韩谷静, 何敏, 雷宇航, 等. 基于改进 U-Net 的输电线路绝缘子图像分割方法研究[J]. 智慧电力, 2022, 50(3): 93-99.  
HAN Gujing, HE Min, LEI Yuhang, et al. Image segmentation method of transmission line insulator based on improved U-Net[J]. Smart Power, 2022, 50(3): 93-99.
- [22] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[M]. arXiv, 2017.
- [23] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA: 779-788.
- [24] 杨学存, 和沛栋, 陈丽媛, 等. 基于深度可分离卷积的轻量级 YOLOv3 输电线路鸟巢检测方法[J]. 智慧电力, 2021, 49(12): 88-95.  
YANG Xuecun, HE Peidong, CHEN Liyuan, et al. Bird's nest detection on lightweight YOLOv3 transmission line based on deep separable convolution[J]. Smart Power, 2021, 49(12): 88-95.
- [25] 李思妍, 台升, 张宇航, 等. 基于轻量化 YOLOv3 和 Tesseract OCR 的电力设备标志牌识别技术[J]. 智慧电力, 2021, 49(7): 79-85, 108.  
LI Siyan, TAI Sheng, ZHANG Yuhang, et al. Electrical sign recognition technology based on simplified YOLOv3 and Tesseract OCR[J]. Smart Power, 2021, 49(7): 79-85, 108.
- [26] 陈富国, 蔡杰, 李中旗. 基于机器视觉的高压隔离开关设备状态判别与故障诊断技术[J]. 微型电脑应用, 2022, 38(2): 191-194.  
CHEN Fuguo, CAI Jie, LI Zhongqi. State discrimination and failure recognition technology of high voltage disconnecter equipment based on machine vision[J]. Microcomputer Applications, 2022, 38(2): 191-194.
- [27] 张骥, 张金锋, 朱能富, 等. 基于改进深度学习的刀闸状态识别方法研究[J]. 电测与仪表, 2018, 55(5): 8-13.  
ZHANG Ji, ZHANG Jinfeng, ZHU Nengfu, et al. Research of the switch state recognition method based on the improved deep learning[J]. Electrical Measurement & Instrumentation, 2018, 55(5): 8-13.
- [28] 王艺皓, 丁洪伟, 李波, 等. 复杂场景下基于改进 YOLOv3 的口罩佩戴检测算法[J]. 计算机工程, 2020, 46(11): 12-22.  
WANG Yihao, DING Hongwei, LI Bo, et al. Mask wearing detection algorithm based on improved YOLOV3 in complex scenes[J]. Computer Engineering, 2020, 46(11): 12-22.
- [29] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA: 936-944.
- [30] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA: 8759-8768.
- [31] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146-157.
- [32] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C] // 15th European Conference on Computer Vision, September 8-14, 2018, Munich, Germany: 3-19.
- [33] LIU Z, LI J, SHEN Z, et al. Learning efficient convolutional networks through network slimming[C] // 2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy: 2755-2763.

收稿日期: 2023-03-12; 修回日期: 2023-07-21

作者简介:

杜耀文(1997—), 男, 硕士研究生, 研究方向为智能电网在线监测与故障诊断; E-mail: 2965022609@qq.com

谢静(1983—), 女, 通信作者, 博士, 讲师, 研究方向为智能电网在线监测与故障诊断; E-mail: xiejingkmust@163.com

刘志坚(1975—), 男, 教授, 博士生导师, 主要研究方向为电力系统稳定与控制。E-mail: 248400248@qq.com

(编辑 周金梅)