

基于稀疏化卷积网络剪枝的火焰图像识别方法

颜佳文, 林献坤, 潘溢洲

上海理工大学 机械工程学院, 上海 200093

摘要:目的 野火预警大多采用烟雾或红外传感器检测,且这些传感器在大型开放式空间下,容易受到环境的影响,从而很难进行开放场所的精准火灾预警,而优越的火焰检测模型往往存在过多的参数量,且存在结构冗余的问题,基于此问题,提出一种改进的 VGG 深度卷积网络架构。方法 以映射变换为基础,进行像素值调整,在保证分类精度的前提下,采用 L1 正则化保证稀疏性,并基于 BN 层进行结构化剪枝,从而降低模型储存数据量,得到精简的模型。结果 大量的仿真试验结果表明:该方法在不同剪枝比例下,在野火架构数据集上,检测与勘误率依然能够保持高的准确精度,改进的模型在剪枝率为 80% 时,准确率达到了 95.29%,提升了 0.92%,并有效解决了模型过参数化的问题;通过不同的微调训练,模型精度略微超过没有进行剪枝时的模型,且在参数量上少了近 20 倍,并随着剪枝率的上升,检测效果在原有精度水平上无明显下降,甚至略高于原始模型精度,这说明在训练过程中,有大量的冗余权重。结论 该方法可以大幅度缩减模型的储存量,并可保证较高的分类精度,具有较好的实际应用意义,可以应用在神经网络存储计算能力较弱的嵌入式设备中。

关键词:深度卷积网络;VGG;火焰检测;剪枝

中图分类号:TP751.1 文献标识码:A doi:10.16055/j.issn.1672-058X.2025.0001.011

Fire Image Recognition Method Based on Sparse Convolutional Network Pruning

YAN Jiawen, LIN Xiankun, PAN Yizhou

School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China

Abstract: Objective Under most circumstances, wildfire warnings primarily rely on smoke or infrared sensors for detection. However, these sensors are susceptible to environmental interference, especially in large open spaces, making it challenging to achieve precise fire alerts in open areas. Additionally, superior flame detection models often have too many parameters and suffer from structural redundancy. Based on the above problems, an improved VGG deep convolutional network architecture was proposed. **Methods** Pixel value adjustments were made based on mapping transformations. While ensuring classification accuracy, L1 regularization was employed to ensure sparsity. Structural pruning was performed based on BN layers, thereby reducing the storage data volume of the model and obtaining a streamlined model. **Results** Extensive simulation results demonstrate that this method maintains high detection and correction accuracy on wildfire architecture datasets under different pruning ratios. The improved model achieves an accuracy of 95.29% at a pruning rate of 80%, an increase of 0.92%, effectively addressing the issue of model over-parameterization. Through various fine-tuning training processes, the accuracy of the improved model slightly surpasses that of the unpruned model, while reducing the parameter volume by nearly twenty times. As the pruning rate increases, the model's detection performance does not significantly decrease from the original precision level, and in some cases, it even slightly exceeds the original model's precision. This indicates that there is a significant amount of redundant weights

收稿日期:2023-08-17 修回日期:2023-10-07 文章编号:1672-058X(2025)01-0079-06

作者简介:颜佳文(1999—),男,江苏盐城人,硕士研究生,从事深度学习与机器学习研究。

通讯作者:林献坤(1975—),男,福建莆田人,副教授,博士,从事高端制造技术研究。Email:miayu_by@163.com.

引用格式:颜佳文,林献坤,潘溢洲.基于稀疏化卷积网络剪枝的火焰图像识别方法[J].重庆工商大学学报(自然科学版),2025,42(1):79-84.

YAN Jiawen, LIN Xiankun, PAN Yizhou. Fire image recognition method based on sparse convolutional network pruning[J].

Journal of Chongqing Technology and Business University (Natural Science Edition), 2025, 42(1): 79-84.

during training. **Conclusion** This method substantially reduces the model's storage volume while ensuring high classification accuracy, demonstrating practical significance for application in embedded devices with limited neural network storage and computing capabilities.

Keywords: deep convolutional network; VGG; fire detection; pruning

1 引言

森林火灾识别预警,具有极其重要的意义。对于森林野火,火焰一旦扩散,不仅会对林业造成巨大损失,而且会破坏生态平衡,严重威胁广大人民的生命财产安全。现今,森林野火预警多采用烟雾或红外传感器检测,但这些传感器在大型开放式空间下,容易受到环境的影响,无法进行实时火灾预警。在处理大量图像数据中,识别火焰信息以加强预警系统的响应速度,是一个全球范围内都备受挑战的难题。广大研究者在近几年,针对森林火灾检测及预警^[1]这一领域也取得了较为显著的突破。Majid^[2]等利用注意力机制使得模型能够更好地定位火焰,但没有考虑计算与储存成本;Dimitropoulos^[3]等使用基于非参数模型的背景减法和颜色分析来定义,并使用线性动力系统和系统袋方法,用于检测火焰的边界,他们使用两种支持向量机分类器对被标记为候选区域的部分进行分类,但时间开销成本较大;为了实现火灾的早期预警,Torgyn^[4]等则利用火焰在初期时会释放大量烟雾这一特点,提出一种针对火焰早期烟雾模型进行火焰预测的方法。可以发现:通过其特征进行火焰识别是很有效的,但很难通过这些特征去适应各个环境下的视频监测。

目前,深度卷积神经网络的自主学习能力,不需要手动设计特征,可以最大化地优化损失函数去学习准则,也可以最大化挖掘数据潜在特征,其诸多优点已经成为学术界的热点研究,但又因为计算量大,便携性差,对硬件的需求较高,所以导致成本很高。为了降低模型的计算与储存量,一系列的模型压缩方法油然而生,如网络剪枝(Pruning)、知识蒸馏(Knowledge)等。现有对网络剪枝开展的研究:Chang等^[5]提出“基于全局过滤器重要性的自适应修剪”,但该方法会带来额外的计算与训练时间;Blalock等^[6]将范数为剪枝基准,对较小的范数权重进行剪枝,并为了防止陷入对比剪枝方法时的常见误区,提出了基准指标,但较为依赖硬件;Chen等^[7]利用基于深度强化学习(DRL)的框架,从而确定卷积层中需要修建的通道,并引入静态修建组件以减少存储空间需求,解决了平衡动态灵活性和存储空间的权衡问题。

综合以上研究,本文提出在结构剪枝下进行稀疏性训练,训练时引用 L1 正则化进行参数稀疏化,以

Batch Normalization(BN 层)权重值为切入点,引入 L1 正则化来控制权重,将稀疏化后的权重值进行排序与筛选,提出一种改进的基于 VGG (Visual Geometry Group)的火焰检测识别算法,解决了在多种复杂图像中的火焰检测,并在保证分类精度的前提下,将模型大小减少了 10 倍。

2 VGG 深度模型

在深度学习被推广之前,传统的目标检测是手动提取特征,使用滑动窗口扫描整张图片,且过程较为繁琐。2012 年,随着卷积神经网络的兴起与推广,一系列的网络模型被陆续提出,例如 AlexNet^[8]、ResNet^[9]、DenseNet^[10]等。而 VGG (Visual Geometry Group)^[11]模型则是一种经典的卷积神经网络架构模型,由 Karen Simonyan 和 Andrew Zisserman 于 2014 年提出。它在 ILSVRC-2014 图像分类竞赛中取得了很好的成绩。

VGG 卷积神经网络模型的主要优点是模型结构简单。VGG-16 采用最简单的卷积层,层层堆叠,利用 3×3 大小的卷积核与 2×2 大小的池化层来加深网络深度。它的基本构建块是连续的 3×3 卷积层,这种结构在网络中被反复使用。VGG-16 共有 16 层,这使得它的结构相对较深。虽然 VGG-16 在当时被认为是非常深的网络,但在之后的发展中,更深更复杂的模型逐渐出现。因其本身的架构,VGG-16 具有较多的参数,约有 1.38×10^8 个参数。这也导致了较高的计算成本。而在每一个卷积层的后面,都会跟一个 ReLU (Rectified Linear Unit) 激活函数,用来增强模型的非线性特性。VGG-16 使用多个 3×3 的小卷积核来代替更大的卷积核(如 5×5 或 7×7)。这样的设计可以使网络更加深入,并且具有更少的参数,从而在一定程度上减轻过拟合问题。VGG-16 在卷积层之后使用了多个最大池化层,这样做很大程度上减小了特征图的尺寸,从而减少计算量与复杂度,并提取更加鲁棒的特征。

VGG-16 现今被研究者们广泛地应用在图像的分类与特征的提取等计算机视觉处理任务,并且它的成功启发了后续更深、更先进的神经网络模型的发展,如 ResNet、Inception 等。尽管 VGG-16 在一些更新的模型中被超越,但它仍然被认为是深度学习中一个非常重要的里程碑,并对深度学习领域产生了及其大的影响。VGG 网络模型如图 1 所示。

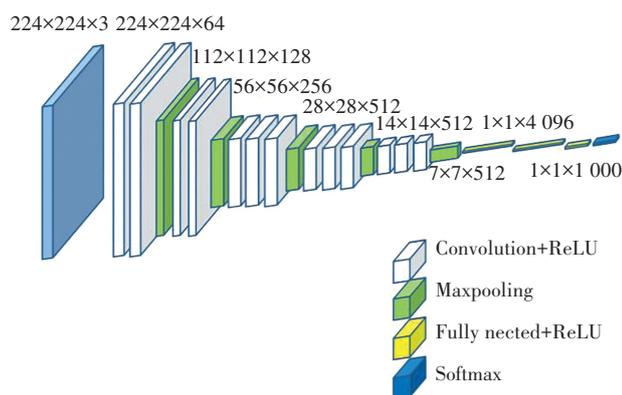


图 1 VGG 网络

Fig. 1 VGG network

3 剪枝基本原理和设计思路

3.1 结构化剪枝

基于幅值权重进行剪枝^[12],这样做并没有缩减整个模型的计算,而是将权重较小及对整个分类精度影响较小的卷积核进行剪枝,避免出现稀疏性结构。再利用稀疏化因子进行剪枝^[13],通过 L1 正则化后的缩放因子 γ ,来对比通道的重要性,剪枝掉不重要的通道,达到精简架构的目的。

结构化剪枝 (Structured Pruning)^[14] 是一种用于精简神经网络的方法,其目标是减少网络的参数和计算成本,以加快推断速度并降低模型的存储需求。相比于传统随机剪枝方法,结构化剪枝能够保留网络的整体结构,使得剪枝后的模型更易于部署和优化。

首先,训练一个神经网络作为原始模型,通常使用标准的训练方法和数据集来获得一个较好的基础模型。通过一些重要性评估准则(例如权重的大小、梯度的绝对值等),来衡量每个过滤器或通道对网络性能的贡献。重要性评估的目标是确定哪些过滤器或通道可以被剪枝而不会显著降低网络性能。根据重要性评估的结果,选择性地剪枝掉不重要的过滤器或通道。这些剪枝操作会使得部分权重变为零或被删除,从而减少模型中的参数量。剪枝后的模型可能会出现性能下降,因为剪枝会引入一些信息损失。因此,需要对剪枝之后的模型进行微调 (Fine-Tuning) 操作,从而达到恢复模型性能的作用。

结构化剪枝的优点在于剪枝后的模型结构仍然保持紧凑,因此,更方便部署在一些可移动的设备中。此外,由于整个过滤器或通道被剪枝,结构化剪枝可以更好地适应硬件加速器和并行计算,进一步提高推理速度。

3.2 非结构化剪枝

非结构化剪枝 (Unstructured Pruning)^[15] 是一种用

于压缩神经网络的方法,它是结构化剪枝的一种对立面。在非结构化剪枝中,每一个权重都可以被独立地剪枝,不会受到其他权重的限制。与结构性剪枝的区别在于:有选择地剪枝不重要的权重,而不是过滤器与通道,被剪枝的权重将变为零或被删除,从而减少模型中的参数量。剪枝后的模型可能会出现分类精度降低等问题,因为剪枝会引入一些信息损失。所以,要对剪枝后的模型进行再微调、再训练,重新恢复模型的性能。

此外,L1 (Lasso) 正则化^[16] 和 L2 (Ridge) 正则化^[16] 是用于神经网络训练中的常见正则化方法。它们在惩罚权重的方式上有所不同,因此对网络训练有不同的影响。由于 L1 正则化具有稀疏性,它倾向于将某些权重归零,从而实现特征选择,只保留对模型最重要的特征,减少了冗余和噪声的影响。L1 正则化使得模型更简单,减少了模型的复杂性,有助于防止过拟合,特别适用于高维数据和少样本情况。稀疏权重可以增加模型的可解释性,因为只有少数特征对预测结果起到显著作用。L2 正则化的平方项保证优化问题曲线是光滑的,L2 正则化相对于 L1 正则化,优化能力更强,有助于快速收敛。L2 正则化则通过对权重进行适度的惩罚,使权重保持较为平衡,避免了权重过大的情况,从而增强了模型的稳定性和泛化能力。这种方法实际上可以被看作是权重衰减,通过减小权重的幅度,降低了不重要特征的影响,从而提升了模型的泛化能力。相对于 L1 正则化,L2 正则化倾向于让所有权重都接近于零,但不会明确地将某些权重归零,因此它不具备特征选择的能力。

复杂性:L2 正则化在一些情况下可能导致过多特征被保留,增加了模型的复杂性。

L1 范数表示向量中各个元素值的绝对值之和,L1 范数也可被用于特征选择,让某些特征值为 0,从而降维,相比较 L2 正则化,L1 正则化要更容易稀疏化。L1 正则化方法具体见式(1):

$$A(\vec{\theta}) = \frac{1}{2} \sum_{i=1}^m (h_{\vec{\theta}}(x^i) - y^i)^2 + \delta \sum_{A=1}^n |w| \quad (1)$$

式(1)中, $A(\vec{\theta})$ 为正则化之后的损失函数项, $\sum_{i=1}^m (h_{\vec{\theta}}(x^i) - y^i)^2$ 为原始神经网络的损失函数, δ 为正则化项与原始模型的损失函数之间的比值。

3.3 BN 层通道剪枝

Batch Normalization 层^[17] 是一种深度卷积神经网络中的常用手段,它的主要目标是标准化网络,加快网络的训练,缩减梯度消失等问题,并增强模型的鲁棒

性。其工作原理是对每个 epoch 的输入进行标准化,使其均值为 0,方差为 1。具体而言,BN 层在每个特征维度上计算均值和方差,并将它们用于标准化输入数据。BN 层有助于在训练过程中,提升整体数据的稳定性,防止梯度消失,从而使神经网络更容易训练。BN 层通常被应用在卷积层或全连接层之后,有助于提高深度神经网络的训练速度和性能。它已经成为深度学习中的一项常见技术,并被广泛用于各种深度学习模型中,具体见式(2):

$$\tilde{x} = \frac{x^k - E[x^k]}{\sqrt{\sigma^2 + \epsilon}} \quad (2)$$

式(2)中, \tilde{x} 为输出, x^k 为输入, $E[x^k]$ 为均值, $\sqrt{\sigma^2 + \epsilon}$ 为

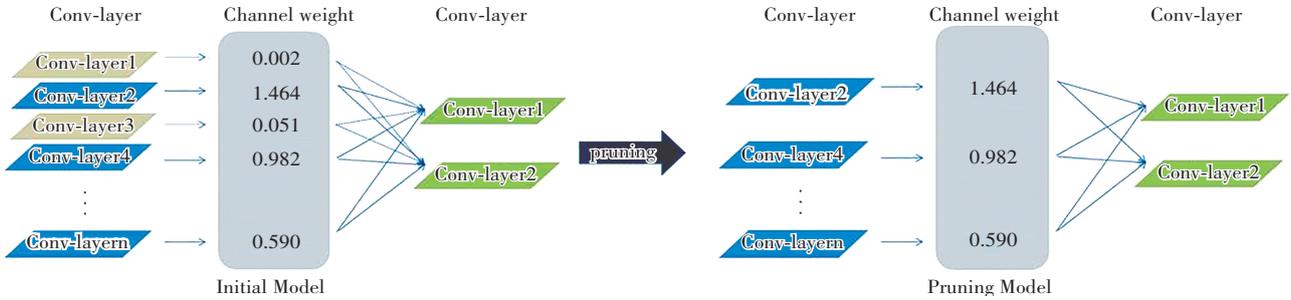


图 2 剪枝流程

Fig. 2 Pruning process

由于正则化后修建不重要的通道会降低模型性能,但可通过微调进行补偿。基于稀疏化剪枝的 VGG 模型算法如表 1 所示。

表 1 基于稀疏化剪枝的 VGG 模型算法

Table 1 VGG model algorithm based on sparse pruning

Algorithm 1	
Input:	初始化权重 w , L1 正则化 sr , 剪枝率 P
Output:	剪枝后模型参数
(1)	for $epoch = 1, 2, \dots, epoch(\max)$ do
(2)	训练模型,更新模型参数
(3)	for $epoch = 1, 2, \dots, epoch(\max)$ do
(4)	训练模型,更新模型参数
(5)	遍历每个 BN 层后的权重,及对应 r 值参数
(6)	对所有 r 参数进行 L1 正则化,并根据剪枝率确定阈值
(7)	根据阈值进行剪枝,得到剪枝后的通道数
(8)	将对应卷积层通道和全连接层删除
(9)	end for
(10)	计算损失并更新模型
(11)	end for

4 仿真实验及结果分析

4.1 实验数据集

目前,实验所用的大多数火焰识别数据集,包括美国国家标准与技术研究院创建的 NIST 数据集。尽管如此,这些数据集的样本数量有限,并且其中的背景呈

标准差。

将式(2)还原:

$$y^k = \gamma^k \tilde{x}^k + \beta^k \quad (3)$$

式(3)中, γ^k 为缩放系数, β^k 为偏置。

针对式(3)中的缩放系数 γ^k , 先进行 L1 正则化。在每一次训练后,会得到所有的缩放系数,再进行排序,从而设定一个 γ^k 排序的阈值。小于阈值的通道会被随机掩码赋值为 0,而大于阈值的通道则会被赋值为 1,这样可以实现通道数的剪枝。再将赋值为 0 的通道进行剪枝,由于每个 γ^k 都对应其通道或神经元,则相应的卷积与线性层也会被剪枝。剪枝流程如图 2 所示:

现单一特点,很多数据集缺少标注,需要大量的人工标注工作量。而火焰及烟雾边缘模糊,会导致标注不一致,难以严谨地评估检测算法。为了增加样本量,实验从各类火焰视频,尤其是森林野火的视频中提取。同时,所有样本都统一至相同尺寸。其中训练集测试样本共 39 375 张图片,测试集 8 617 张图片。对于一些曝光图较高的样本,进行了像素值处理,以映射变换为基础,增强火焰与其周边环境的对比度及改善灰度层次。对比如图 3 所示。



图 3 样本调整对比

Fig. 3 Comparison of sample adjustment

为了提高模型的泛化能力,在训练集中加入各种应用背景下的火焰图片,其中火焰尺寸的大小也从 6×15 到 255×420 不等,并为了增加样本的数量,进行循环采用。数据部分样本如图 4 所示。



图 4 数据中部分样本可视化

Fig. 4 Visualization of some samples in the data

4.2 结果分析

本实验在火焰数据集上进行训练时,单个 batch-size 为 16,累计训练 epoch 为 150,初始学习率为 0.01。不同剪枝率下准确率对比如表 2 所示。在整个训练过程中,利用 Adam 优化器自适应调整步长。为了得出在火焰数据集上最好的训练效果,分别选择剪枝率为 50%至 95%进行训练,图示为 VGG 在不同剪枝率下的测试准确率。基于 VGG 架构分别进行 50%、60%、70%的剪枝率操作后,准确率分别为 93.29%、93.66%、92.7%,且当剪枝率达到 80%时,网络模型的性能最优。而在剪枝率提高至 90%至 95%时,准确率明显下降,由

此可见当剪枝的权重过多时,会造成其结构的破坏,从而导致模型性能下降。因此并不能通过提高剪枝率来提升模型的性能,应当综合评估其指标。

表 2 基于 VGG 网络模型不同剪枝率下的准确率对比
Table 2 Comparison of accuracies under different pruning rates based on VGG network model

剪枝前测试准确率	权重剪枝率	剪枝后准确率
94.37	50	93.29
	60	93.66
	70	92.70
	80	95.29
	90	90.42
	95	70.81

由表 3 可知,在用 L1 正则化保证稀疏性时,L1 正则化的程度通过影响权重阈值的大小来决定剪枝的数量,确定网络的结构参数。从表中不同的剪枝率来看,当模型权重剪枝率达到 80%时,网络模型的性能达到最优,剔除了大量的冗余参数,保留了模型的性能。对比剪枝率为 50%时,可以看出 VGG 网络在针对火焰数据集时,剪裁了较为重要的特征信息,对准确率产生影响,没有达到性能与效率之间的平衡。在没有进行微调时,剪枝率为 80%的模型大小缩减了 92.48 倍,将模型微调后,相比较原始网络模型,微调后的模型缩减了 19.06 倍。

表 3 基于 VGG 网络模型不同剪枝率下的模型参数量对比
Table 3 Comparison of model parameters under different pruning rates based on VGG network model

原始模型参数量/Mb	权重剪枝率/%	剪枝后模型参数量/Mb	微调后模型参数量/Mb
229.35	50	17.7	85.86
	60	15.4	69.90
	70	5.85	28.62
	80	2.48	12.03
	90	0.74	1.31
	95	0.27	0.79

针对火焰数据集,进行不同微调训练,在训练了 60 个 epoch 后,模型的测试集损失收敛,并且在剪枝率达到 80%时,训练后的模型精度略微超过了没有进行剪枝时的模型,且在参数量上少了近 20 倍。

通过表 2 的数据,可以看出随着剪枝率的提高,准确度及分类精度没有很明显的降低,并且要比初始模型的性能要高。说明在网络模型训练过程中,很多权重不重要,通过去除这些冗余权重,成功地将模型的参数运算量缩减了 20 倍,而仍保持了精度水平不变。

5 结 论

在传统深度学习中,通常需要手动选择适当的特征来应对各种各样的室外监控环境,这在复杂的火灾检测场景中可能无法很好地适应。为了改进这种情况,本文在 VGG 深度卷积神经网络的基础之上,提出一种改进的模型。在较高的分类准确性前提下,采用一种基于稀疏化的卷积网络剪枝方法,以减少模型的存储需求。非结构化剪枝虽可以使模型具有比较高的分类精度,但却并不会降低参数量以及减少浮点计算量,并且依赖于硬件设备。在这项研究中,使用了 L1 正则化来保证模型的稀疏性,然后对批归一化(BN)层的权重进行排序,从而确定要剪枝的通道。他们成功地在 VGG 模型上实施了剪枝,通过这种稀疏性剪枝方法,有效减小了模型的存储需求,同时保持了较高的分类精度,这种方法在工程领域中具有极其深远且重要的意义。

参考文献(References):

- [1] 杜晨锡, 严云洋, 刘以安, 等. 基于 YOLOv2 的视频火焰检测方法[J]. 计算机科学, 2019, 46(6): 301-304.
DU Chen-xi, YAN Yun-yang, LIU Yi-an, et al. Video fire detection method based on YOLOv2[J]. Computer Science, 2019, 46(6): 301-304.
- [2] MAJID S, ALENEZI F, MASOOD S, et al. Attention based CNN model for fire detection and localization in real-world images[J]. Expert Systems with Applications, 2022, 189: 116114.
- [3] DIMITROPOULOS K, BARMPOUTIS P, GRAMMALIDIS N. Spatio-temporal flame modeling and dynamic texture analysis for automatic video-based fire detection[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2015, 25(2): 339-351.
- [4] TÖREYİN B U, DEDEO ĞLU Y, GÜDÜKBAY U, et al. Computer vision based method for real-time fire and flame detection[J]. Pattern Recognition Letters, 2006, 27(1): 49-58.
- [5] CHANG J, LU Y, XUE P, et al. Iterative clustering pruning for convolutional neural networks [J]. Knowledge-Based Systems, 2023, 265: 110386.
- [6] BLALOCK D, GONZALEZ ORTIZ J J, FRANKLE J, et al. What is the state of neural network pruning[J]. Proceedings of Machine Learning and Systems, 2020(2): 129-146.
- [7] CHEN J, CHEN S, PAN S J. Storage efficient and dynamic flexible runtime channel pruning via deep reinforcement learning[C]//Proceedings of the Proceedings of the 34th International Conference on Neural Information Processing Systems. 2020: 14747-14758.
- [8] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [9] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 770-778.
- [10] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 4700-4708.
- [11] ZHOU Y, WEI X, WEI J. An improved face liveness detection algorithm based on deep convolution neural network[C]//Proceedings of the 33rd Chinese Control and Decision Conference. Piscataway: IEEE Press, 2021: 1839-1844.
- [12] 乔琪, 赵辉. 基于主导条件和局部极小剪枝机制的 SISO 检测算法[J]. 国外电子测量技术, 2021, 40(7): 37-44.
QIAO Qi, ZHAO Hui. SISO detection algorithm based on dominant condition and local minimal pruning mechanism [J]. Foreign Electronic Measurement Technology, 2021, 40(7): 37-44.
- [13] LIU Z, LI J, SHEN Z, et al. Learning efficient convolutional networks through network slimming [C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2017: 2755 -2763.
- [14] WEN W, WU C P, WANG Y D, et al. Learning structured sparsity in deep neural networks[J]. Frontiers of Information Technology & Electronic Engineering, 2016, 23(8): 54-58.
- [15] TAN M, PANG R, LE Q V. EfficientDet: scalable and efficient object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 10778-10787.
- [16] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
ZHOU Zhi-hua. Machine learning [M]. Beijing: Tsinghua University Press, 2016.
- [17] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the Proceedings of the 32nd International Conference on International Conference on Machine Learning. ICML 2015, 2015: 448-456.

责任编辑:李翠薇