

基于改进 MobileNetV2 的钢筋混凝土桥梁病害分类识别

Disease Classification and Identification of Reinforced Concrete Bridges based on Improved MobileNetV2

吴立朋^{1,2}, 闫新宇^{1,2}, 金哲诚^{1,2}

(1. 石家庄铁道大学 土木工程学院, 石家庄 050043;

2. 道路与铁道工程安全保障省部共建教育部重点实验室 (石家庄铁道大学), 石家庄 050043)

摘要: 为了及时有效地发现桥梁病害, 克服目前人工目测方法固有的费时、费力且易受主观因素影响的缺陷, 提出一种基于卷积神经网络的轻量化桥梁病害智能识别方法。在保持原 MobileNetV2 网络模型宽度不变的情况下, 通过减少网络中瓶颈模块的数量, 并在其中嵌入 Squeeze and Excitation 通道注意力机制, 使新网络能够更有效地学习和利用特征通道之间的关系, 以提升网络识别性能。结果表明: 经过缩减瓶颈模块和嵌入通道注意力机制两次改进的网络模型, 实现了 98.78% 的识别准确率, 较改进前提高了 2.85%, 计算量也较改进前减少了 23.02 M; 将改进后的网络模型引入 Matlab 的 GUI 界面, 将代码可视化为可以独立使用的桥梁病害识别系统, 为风化、钢筋锈蚀、开裂和孔洞四种桥梁病害的高效识别提供便利。

关键词: 桥梁; 病害识别; MobileNetV2; 注意力机制; GUI

中图分类号: U446 **文献标志码:** A **文章编号:** 1005-8249 (2025) 04-0143-07

DOI: 10.19860/j.cnki.issn1005-8249.2025.04.026

WU Lipeng^{1,2}, YAN Xinyu^{1,2}, JIN Zhecheng^{1,2}

(1. School of Civil Engineering, Shijiazhuang Tiedao University, Shijiazhuang 050043, China;

2. Key Laboratory of Roads and Railway Engineering Safety Control (Shijiazhuang Tiedao

University), Ministry of Education, Shijiazhuang 050043, China)

Abstract: In order to timely and effectively detect bridge diseases, overcome the inherent defects of the current manual visual inspection method in disease investigation, which is time-consuming, laborious, easy to cause potential safety hazards, and easily affected by subjective factors, so as to provide preconditions for targeted bridge management, an intelligent method which is suitable for mobile disease image recognition is proposed. While keeping the width of the original MobileNetV2 network model unchanged, by reducing the number of bottleneck modules and embedding the Squeeze and Excitation channel attention mechanism in the bottleneck module, the correlation between channels is established, so that the network can learn and utilize the relationship between feature channels more effectively. The results show that the accuracy of image recognition is improved, after two improvements in the network model of reducing bottleneck module and embedding channel attention mechanism, the recognition accuracy of 98.78% is achieved, which is 2.85% higher than before the improvement and the computational cost is also reduced by 23.02 M; The improved network model is introduced into the GUI interface of Matlab, and the code is

基金项目: 国家自然科学基金 (51808357); 中央引导地方科技发展资金项目 (236Z3810G)。

作者简介: 吴立朋 (1981—), 男, 博士, 副教授, 研究方向: 结构工程。

通信作者: 闫新宇 (1998—), 女, 硕士研究生, 研究方向: 工程结构管理。

收稿日期: 2024-01-19

研究与应用

visualized as a bridge disease identification system that can be used independently, which provides convenience for the efficient identification of four bridge diseases: efflorescence, steel corrosion, cracking and holes.

Key words: bridge; disease identification; MobileNetV2; attention mechanism; GUI

0 引言

桥梁是重要的交通基础设施,与国家建设、社会进步和人民福祉紧密相关。我国已成为世界桥梁大国,截至2022年底,我国有公路桥梁103.3万座,总长约8.576万km。在环境和荷载共同作用下,桥梁结构性能老化现象与日俱增,随之而来的养护任务日益艰巨。若不采用合理的方法及时发现桥梁病害并适时处理,则可能危及桥梁的使用寿命和承载能力^[1]。桥梁的运营和维护工作已是我国公路管理部门的工作重心,在役桥梁检测需求巨大。桥面、桥底、缆索、墩塔、梁内和水下基础等部位所处检测环境复杂,以人工目测为主的传统桥梁检测方式难以实现特殊区域精细检测,并且容易受人为主观因素影响^[2]。随着人工智能技术的发展,越来越多的桥梁病害检测工作采用智能机器人来完成,机器人可搭载不同的传感器实现桥梁内部、外部构件的智能无损检测。Jang等^[3]提出了一种由多个摄像机、攀爬机器人和控制计算机组成的环形爬壁机器人系统,通过在桥墩上进行移动扫描,获得高质量的原始图像,再进行图像拼接和裂缝特征识别计算;Liu等^[4]提出了一种利用无人机进行桥墩裂缝数字图像评估方法,并重建了三维场景;谢文高等^[5]提出了搭载高清摄像头的水下机器人检测方法,为桥梁水下部分检查只能依靠人工下潜摸查提供了新方式。

近年来,随着图像处理技术的发展,深度学习技术特别是深度卷积神经网络在计算机视觉领域得到广泛应用。孟诗乔等^[6]利用基于Deeplab包含网络优化模块的卷积神经网络对裂缝区域进行识别,并实现了像素级语义分割,提高了原模型识别准确率;杨杰文等^[7]通过对比其他网络模型,证明了一种结合U-Net和Haar-like的深度学习方法的有效性;余加勇等^[8]建立了Mask R-CNN裂缝识别模型,实现了裂缝的自动化检测;王桂平等^[9]利用迁移学习使得模型在小规模桥梁裂缝数据集上也能获得很好的识别效果。为减少裂缝图像中存在噪声、光线、

阴影等因素的干扰,刘凡等^[10]设计了一个并行注意力机制嵌入到Unet网络的解码部分。

为了提高模型准确率,专家学者们设计了多种具有复杂结构的深度卷积网络并将其应用于图像分类^[11]、故障诊断^[12]、图像去雾^[13]等领域。然而由于移动设备和嵌入式设备的计算能力和内存有限,导致复杂网络无法部署,这就限制了深度学习在实时检测方面的应用。为此,专家学者们提出了ShuffleNet^[14]、SqueezeNet^[15]和MobileNet^[16]等轻量级卷积神经网络,与常见的深度卷积神经网络相比,这些网络的结构更简单,能够部署在移动设备和嵌入式设备上。为实现桥梁表观病害的精准快速识别,对MobileNetV2网络模型进行优化和调整,包括修改网络深度减少模型计算量和引入注意力机制,提高模型识别准确率。

1 试验数据和方法

1.1 数据采集

试验所需图像数据集一部分来自于Bing网站搜索获得,一部分来自于CPVR2019收录的开源数据集。试验数据集共包含2460张高分辨率图像,其中风化病害618张,钢筋锈蚀病害618张,开裂病害622张,孔洞病害602张。数据集示例如图1所示。

1.2 数据预处理

每次输入训练网络的图像是统一尺寸,大小均为 224×224 或 227×227 的RGB图像。原始数据集图像尺寸不同,采用两种方式进行调整。离线调整



(a) 风化



(b) 钢筋锈蚀




图1 桥梁病害示例
Fig.1 Examples of bridge diseases image

是数据集图像在被输入训练网络之前，统一调整尺寸，存储在磁盘中；在线调整是将数据集图像直接输入训练网络，利用 Matlab 软件中的深度网络设计器，自动调整图像尺寸为网络所需大小，这种在线调整的方式能够降低存储成本。

为了防止网络出现过度拟合，增强模型的鲁棒性，试验将图像训练数据应用随机几何变换，包括旋转、翻转和缩放。组合方法是指采用其中的任意两种或三种对图像进行预处理。不同的预处理方式产生的效果不同。在 Matlab 中，对于训练的每次迭代，增强图像数据存储是随机几何变换后的图像数据，如图 2 所示。随机扰动每轮的训练数据，因此每轮使用的数据集略有不同，每轮训练图像的实际数量不变，提升了模型的泛化能力。经过变换的图像不会存储在内存中，降低了存储成本。采用缩放、旋转、翻转以及它们的组合方法进行性能对比试验，从中选出最优的数据增强方式对图像进行预处理操作。





图2 图像几何变换示例
Fig.2 Example of image transformation


1.3 桥梁病害分类模型比较

为了使网络实时运行，直接部署到移动端上，选取轻量级网络 MobileNetV2、SqueezeNet、ShuffleNet 及参数量较少的 GoogLeNet 和 ResNet18 进行性

能对比试验。5 个模型的准确度和损失对比曲线如图 3 所示。由图可知，与其他 4 个模型相比，MobileNetV2 的性能更好一些。各个模型的大小和参数量以及在验证集上的准确率见表 1，数据表明 MobileNetV2 准确率最高，模型较小且复杂度低。综上，选取 MobileNetV2 进行改进。



(a) 准确率曲线



(b) 损失曲线

图3 模型性能比较
Fig.3 Comparison of model performance

表1 模型对比
Table 1 Comparison of models

模型	参数量/M	模型大小/Mb	准确率/%
MobileNetV2	2.2	13.0	94.39
GoogLeNet	5.9	27.0	90.04
ResNet18	11.1	44.0	91.17
SqueezeNet	0.7	5.2	91.58
ShuffleNet	0.9	5.2	88.35

1.4 改进 MobileNetV2 网络结构

1.4.1 MobileNetV2 模型结构

MobileNetV2 在 MobileNetV1 的基础上引入了倒置残差模块（先升维，后降维），并将最后一个卷积层后的激活函数 ReLU6 改为线性激活函数 Linear，模块整体结构如图 4 所示，Conv 为卷积操作，

研究与应用

DWConv 代表深度可分离卷积, 3×3 和 1×1 代表卷积核的尺寸。倒置残差模块不仅能增强模型特征提取能力, 而且能够减少模型训练所需要的内存。改用线性激活函数, 保留了更多的特征信息, 更适合用在可移动端和嵌入式设备的桥梁病害识别系统上。




图4 倒置残差模块
Fig. 4 Inverted residual block

1.4.2 减少 Bottleneck 模块数量

为使网络模型在图像识别领域有更好的识别效果, 一些研究通过增加网络深度的方法提高模型准确率。但网络会随深度的增加发生梯度消失和梯度爆炸, 影响网络识别精度。而增加网络宽度会增加通道数量, 使网络提取到更多的图像特征; 同时, 减少网络宽度, 影响图像特征提取。所以保持 MobileNetV2 网络模型宽度不变, 通过减少原网络模型的深度来提高图像识别准确率^[17]。由表 2^[18]可知, 网络初始输入图像尺寸为 224×224 , 特征提取阶段输入图像尺寸分别为 112×112 、 56×56 、 28×28 、 14×14 、 7×7 。根据不同输入图像尺寸将特征提取过程分为 5 个阶段, 每个阶段包含瓶颈模块的数量分别为 3、3、4、6、1。模型浅层网络主要提取图像颜色、边缘等空间信息, 深层网络对这些信息进行再次提取和融合。为避免空间信息在浅层网络丢失, 影响深层网络提取特征, 减少瓶颈模块较多的第四阶段模块数量, 分别设为 4、5、6 个, 以提高网络准确率。

1.4.3 改进 Bottleneck 模块

SE 模块是自适应特征提取注意力机制, 能增强网络对重要特征的关注能力。为了更有效提取桥梁病害特征信息, 在 MobileNetV2 瓶颈模块第一个全连接层和激活函数之间嵌入 SE 模块^[17], 改进后的瓶颈

模块结构如图 5 所示。改进 MobileNetV2 网络结构参数见表 2。




图5 改进 Bottleneck 模块网络结构详图
Fig. 5 The detail network structure of improved Bottleneck module

表2 改进 MobileNetV2 网络结构^[18]
Table 2 The network structure of improved MobileNetV2^[18]

操作	输入	输出通道数	重复次数
Convolution	$224^2 \times 3$	32	1
Bottleneck	$112^2 \times 32$	16	1
Bottleneck	$112^2 \times 16$	24	2
Bottleneck	$56^2 \times 24$	32	3
Bottleneck - SE	$28^2 \times 32$	64	4
Avgpool	$H \times W \times C$	C	
FC	$1^2 \times C$	C/r	
(SE) ReLU	$1^2 \times C/r$	C/r	
FC	$1^2 \times C/r$	C	
Sigmoid	$1^2 \times C$	C	
Bottleneck	$14^2 \times 64$	96	2
Bottleneck	$14^2 \times 96$	160	3
Bottleneck	$7^2 \times 160$	320	1
Convolution	$7^2 \times 320$	1 280	1
Avgpool	$7^2 \times 1\ 280$		1
FC	$1^2 \times 1\ 280$	k	

注: Convolution 为卷积操作, Bottleneck 为瓶颈结构, Avgpool 为全局平均池化, FC 为全连接, H 、 W 、 C 分别表示特征图的高、宽及通道数, r 为通道缩减系数, k 表示数据集所包含的类别数。

1.5 参数设置

每次试验数据集按 7:3 的比例分为训练集 1 722 张和测试集 738 张, 试验均采用相同的训练策略。每批次 30 张图像输入训练模型, 通过前向传播和反向传播计算损失并更新参数; 全部训练数据完成 50 轮

次迭代，设置初始学习率 0.001，采用 SGD 优化器，参数为默认参数。

1.6 评价指标

为了客观评价模型的性能，试验的评价指标采用准确率、精确率、召回率和 F1 值，指标值越高代表模型性能越好。

2 试验结果与分析

2.1 不同数据增强方式对比试验

基于 MobileNetV2 网络对不同的数据增强方式进行对比试验，结果见表 3。表中 On - Resize (224, 224) 代表在线调整输入图像尺寸为 224 × 224；Off - Resize (224, 224) 代表离线调整输入图像尺寸为 224 × 224；RRE 代表将图像进行任意水平和垂直翻转；RRO 代表将图像随机旋转任意角度；RSC 代表将图像随机缩放 10%。方案 1 在线处理图像尺寸比方案 2 离线处理准确度提升 0.89%。在方案 1 的基础上，通过翻转、旋转和缩放三种几何变换方式以及它们的组合来对图像数据进行增强，从表中数据来看，采用方案 4 对数据进行增强后模型的训练效果最好，准确率最高，为 95.93%。方案 4 是对图像进行随机水平、垂直翻转，这也模拟了图像不同的拍摄角度，增强了模型的泛化能力。数据扩充后的数据集图像数量为 7 380 张，后续试验均采用随机翻转的增强方式对图像进行预处理。

表 3 不同数据预处理方式对模型准确度的影响
Table 3 Influence of different data pre - processing methods on model accuracy

序号	数据预处理方式	准确率/%
1	On - Resize (224, 224)	94.39
2	Off - Resize (224, 224)	93.50
3	On - Resize (224, 224) + RRO	91.09
4	On - Resize (224, 224) + RRE	95.93
5	On - Resize (224, 224) + RSC	95.36
6	On - Resize (224, 224) + RRO + RRE	94.75
7	On - Resize (224, 224) + RRO + RSC	92.11
8	On - Resize (224, 224) + RRE + RSC	95.49
9	On - Resize (224, 224) + RRO + RSC + RRE	94.34

2.2 不同瓶颈模块数量对比试验


将 MobileNetV2 网络中第四阶段的瓶颈模块数量分别设置为 4、5、6，在桥梁病害数据集上进行对比试验，见表 4。表中 MobileNetV2 (4)、MobileNetV2 (5)、MobileNetV2 (6) 分别代表模型第 4 阶段的瓶颈模块数

量为 4、5、6 的 MobileNetV2 网络。MobileNetV2 (4) 的各个评价指标均最低；MobileNetV2 (5) 与 MobileNetV2 (6) 相比，准确率、精确率、召回率和 F1 值分别提高了 2.71%、2.61%、2.55%、2.58%。因此，将模型第 4 阶段瓶颈模块数量由 6 个减少为 5 个，使模型性能更好。

表 4 不同瓶颈模块数量模型性能对比
Table 4 Comparison of model performance by different number of Bottleneck block

模型	准确率 /%	精确率 /%	召回率 /%	F1 值 /%
MobileNetV2 (4)	95.26	95.30	95.33	95.31
MobileNetV2 (5)	98.64	98.53	98.50	98.51
MobileNetV2 (6) (原模型)	95.93	95.92	95.95	95.93

采用随机验证集作为测试集对改进后模型进行性能测试，得到混淆矩阵，如图 6 所示。图中 0 为孔洞，1 为开裂，2 为钢筋锈蚀，3 为风化，第 5 行为各病害类别的精确率，第 5 列为各病害类别的召回率。(5, 5) 为模型的整体准确率。改进后模型对孔洞、钢筋锈蚀和风化的识别准确率均有提升，模型对全部样本的识别准确率提高了 2.71%。



(a) 原模型



(b) 改进后模型

图 6 混淆矩阵
Fig. 6 Confusion matrix

研究与应用

2.3 改进 MobileNetV2 网络结构消融试验

通过改进 MobileNetV2 网络结构消融试验,验证了不同改进方法对桥梁病害检测网络性能的影响。以 MobileNetV2 网络为基础,首先修改网络中卷积层的权重学习率因子,将第三、四、五阶段瓶颈模块中的卷积层以及网络最后一个卷积层的权重学习率因子渐进式分别设置为 4、5、6、7,得到网络 W - MobileNetV2 (5);在 W - MobileNetV2 (5) 网络第三阶段的瓶颈模块中引入注意力机制,得到网络 SE - W - MobileNetV2 (5)。不同改进后的消融试验结果见表 5。通过 MobileNetV2 (增强后) 和 W - MobileNetV2 的结果对比可知,渐进式的设置网络中卷积层的权重学习率因子没有使模型的准确率得到提高。由 W - MobileNetV2 和 W - MobileNetV2 (5) 的结果对比可知,缩减网络中瓶颈模块的数量,降低网络的复杂度,平衡网络的深度和宽度也可以提高模型准确度。由 W - MobileNetV2 (5) 和 SE - W - MobileNetV2 (5) 的结果对比可知,在瓶颈模块中引入注意力机制,增加网络对包含图像重要特征通道的关注,网络可以实现更高识别精度。综上,经过三次改进的 MobileNetV2 网络,在桥梁病害数据集上的识别精度为 98.78%。模型的参数量对应于模型的空间上的复杂程度,参数量越大,模型在运行过程中所占用的内存就越多;而计算量对应于模型计算时间上的复杂度,计算量越大,模型计算识别时间越长。在经过缩减模块后的模型上引入注意力机制,相较于原模型,减少瓶颈模块的计算量为 23.34 M,添加注意力机制增加的计算量为 0.32 M,所以模型计算量相较于原模型不但没有增加,反而减少了 23.02 M。对于参数量,虽然增加了 0.1 M,但是准确率提高了 2.85%。综上,改进后的 SE - W - MobileNetV2 (5) 相较于原模型在没有增加更多的模型空间复杂度的前提下,不仅减少了计算量,而且提高了模型的识别精度,使模型的性能得到了提升。

表 5 不同改进方法模型性能对比
Table 5 Comparison of model performance by different improvement methods

模型	参数量 /M	计算量 /M	网络层数	准确率 /%
MobileNetV2 (增强后)	2.2	318.96	154	95.93
W - MobileNetV2	2.2	318.96	154	95.66
W - MobileNetV2 (5)	2.1	295.62	145	97.97
SE - W - MobileNetV2 (5)	2.3	295.94	178	98.78

3 基于 GUI 的病害分类识别系统

采用改进后的 MobileNetV2 病害识别模型能快速、准确识别图像中的病害类别。但模型仍处于代码层面,可通过嵌入识别系统实现模型利用。根据识别系统的设计需求,在 Matlab 的 GUI 界面合理布局控件,并通过编写回调函数实现指定功能。不仅能识别风化、钢筋锈蚀、开裂和孔洞四类桥梁病害,还可对图像进行旋转、灰度化、锐化、滤波和分割四种变换并保存。该系统是后缀为“.exe”的独立可执行文件,不依托于 Matlab 等软件平台。

以一张未经过模型训练的钢筋锈蚀图像为例,识别结果和处理结果如图 7 所示。该系统可以实现上述功能需求,能够对无人机获取的桥梁图像进行病害类型识别,相较于人工巡检桥梁提高了检测效率 and 安全性,也降低了检测成本,具有一定的实用价值。




图 7 识别系统界面展示图
Fig. 7 Display diagram of identification system

4 结论

针对风化、钢筋锈蚀、开裂和孔洞 4 种桥梁病害建立了数据集, 提出了一种基于改进轻量级网络 MobileNetV2 的桥梁病害识别方法, 并利用改进后模型设计了桥梁病害识别系统, 主要结论如下:

(1) 统一图像尺寸, 在线调整比离线调整准确率高; 再增加对图像随机水平和垂直翻转能够使模型训练效果好。

(2) 缩减 MobileNetV2 网络中瓶颈模块并向模块中引入注意力机制, 能使模型准确率进一步提升, 达到 98.78%, 比原模型提高 2.85%, 计算量减少 23.02 M。

(3) 利用改进的 MobileNetV2 网络模型, 设计了一个桥梁病害识别系统, 将代码可视化, 能精准、高效识别风化、钢筋锈蚀、开裂和孔洞 4 种桥梁病害。

参 考 文 献

- [1] 养护优化策略分析 [J]. 公路交通科技, 2019, 36 (2): 95 - 102, 150.
- [2] 张劲泉, 晋杰, 汪云峰, 等. 公路桥梁智能检测技术与装备研究进展 [J]. 公路交通科技, 2023, 40 (1): 1 - 27, 58.
- [3] JANG K, AN Y K, KIM B, et al. Automated crack evaluation of a high - rise bridge pier using a ring - type climber robot [J]. Computer - Aided Civil and Infrastructure Engineering, 2021, 36 (1): 14 - 29.
- [4] LIU Y F, NIE X, FAN J S, et al. Image - based crack assessment of bridge piers using unmanned aerial vehicles and three dimensional scene reconstruction [J]. Computer Aided Civil and Infrastructure Engineering, 2020, 35 (5): 511 - 529.
- [5] 谢文高, 张怡孝, 刘爱荣, 等. 基于水下机器人与数字图像技术的混凝土结构表面裂缝检测方法 [J]. 工程力学, 2022, 39 (增刊 1): 64 - 70.
- [6] 孟诗乔, 张啸天, 乔甦阳, 等. 基于深度学习的网格优化裂缝检测模型研究 [J]. 建筑结构学报, 2020, 41 (增刊 2): 404 - 410.
- [7] 杨杰文, 章光, 陈西江, 等. 基于深度学习的较复杂背景下桥梁裂缝检测 [J]. 铁道科学与工程学报, 2020, 17 (11): 2722 - 2728.
- [8] 余加勇, 李锋, 薛现凯, 等. 基于无人机及 Mask R - CNN 的桥梁结构裂缝智能识别 [J]. 中国公路学报, 2021, 34 (12): 80 - 90.
- [9] 王桂平, 陈旺桥, 杨建喜, 等. 基于迁移学习的桥梁表面病害检测技术研究 [J]. 铁道科学与工程学报, 2022, 19 (6): 1638 - 1646.
- [10] 刘凡, 王君锋, 陈峙宇, 等. 基于并行注意力 UNet 的裂缝检测方法 [J]. 计算机研究与发展, 2021, 58 (8): 1718 - 1726.
- [11] KONG L Z, CHENG J Y. Based on improved deep convolutional neural network model pneumonia image classification [J]. Plos one. 2020, 16 (11): e0258804.
- [12] HAN H, HAO L N, CHENG D Q, et al. GAN - SAE based fault diagnosis method for electrically driven feed pumps [J]. Plos one. 2020, 15 (10): e0239070.
- [13] ZHAO L Q, ZHANG Y P, CUI Y. An attention encoder - decoder network based on generative adversarial network for remote sensing image dehazing [J]. IEEE Sensors Journal. 2022, 22 (11): 10890 - 10900.
- [14] ZHANG X Y, ZHOU X Y, LIN M X, et al. Shufflenet: An extremely efficient convolutional neural network for mobile devices [C] //Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 6848 - 6856.
- [15] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: AlexNet - level accuracy with 50x fewer parameters and <0.5 MB model size [J]. arXiv preprint arXiv: 2016, 1602: 07360.
- [16] HOWARD A G, ZHU M L, CHEN B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications [J]. arXiv preprint arXiv: 2017, 1704: 04861.
- [17] ZHAO L Q, WANG L L, JIA Y F, et al. A lightweight deep neural network with higher accuracy [J]. Plos one, 2022, 17 (8): e0271225.
- [18] SANDLER M, HOWARD A, ZHU M L, et al. Mobilenetv2: Inverted residuals and linear bottlenecks [C] //Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 4510 - 4520.