

监控画面识别与异常检测

管勤 李昌德* 张珂鑫 刘元

武昌理工学院

DOI:10.12238/acair.v2i2.7351

[摘要] 由于信号干扰、设备老化等原因,探测到的图像中会有各类噪声掺杂其中。若不能有效地对该图像进行去噪,会降低后续识别的精度。针对此问题,本文提出了一种改进MobileNetV2网络结构,该结构使用ECA模块对原始block模块进行重构,使用重构后的block模块构建的MobileNetV2能够使网络具有更强的特征学习能力,进而能够有效地监测出多种噪声类型,相较于MobileNetV2,监测精度提高了1.82%。此外,在自建的异常图像数据集中,使用Grad-CAM算法对不同的改进网络进行了可视化研究,研究发现随着网络层次的加深,网络能够学习到更加高级的特征表示能力。

[关键词] 异常图像识别; MobileNetV2; ECA

中图分类号: TP273 **文献标识码:** A

Monitoring screen recognition and anomaly detection

Qin Guan Changde Li Kexing Zhang Yuan Liu

College of Artificial Intelligence

[Abstract] Due to signal interference, aging equipment, and other factors, detected images may be contaminated by various types of noise. Failure to effectively denoise the image will compromise the accuracy of subsequent recognition. To tackle this issue, an enhanced MobileNetV2 network structure is proposed in this paper. This structure incorporates the ECA module to rebuild the original block module, thereby enhancing MobileNetV2's feature learning capability. As a result, it can effectively detect various noise types, achieving a 1.82% improvement in detection accuracy compared to the original MobileNetV2. Furthermore, utilizing the self-built anomaly image dataset, various enhanced networks were visualized via the Grad-CAM algorithm. The study revealed that deeper network levels facilitated the acquisition of more sophisticated feature representation capabilities.

[Key words] MobileNetV2; ECA; Refactoring the original block

引言

目前,异常图像分类技术已在工业生产、交通运输和医疗分析等多个领域得到广泛应用^[1]。在视频监控运行过程中,由于配置错误、硬件故障,以及恶劣天气条件如暴雨和强光等因素的影响,系统产生的图像质量可能会下降。这些因素不仅干扰系统的正常运作,还可能在所捕获的图像中引入多种噪声,例如椒盐噪声、高斯噪声和脉冲噪声,从而对图像质量产生负面影响。因此,有效识别图像中的不同噪声类型是一项重要挑战。

当前常用的异常图像分类技术主要分为基于机器学习方法和深度学习方法两类。文献^[2]提出了一种基于支持向量机(SVM)的数据分类预测方法,该方法对监测数据样本进行归一化处理,再采用多项式核函数支持向量机,使得对监测数据样本的预测具有较高的预测准确度。文献^[3]提出了一种基于高斯区间的

核函数SVM分类模型,该模型通过定义二元区间数,提高了分类精度,同时提出了线性区间核、多项式区间核和Sigmoid区间三种核函数构造方法,实验结果表明,在不同的区间型数据集使用合适的区间核函数,能够提高分类精度。文献^[4]提出了一种利用遗传算法来优化SVM参数组合的方法,实验结果表明,此方法能有效提升分类任务的准确率。文献^[5]提出一种基于改进SVM的图像识别方法,通过粒子群优化算法对SVM模型的内部参数进行寻优,实验结果表明,该方法能够有效的提高识别准确率并且极大的缩短了识别时间。尽管这些方法在小规模数据集上的执行效果良好,但将它们应用到大规模数据集时,这些方法无法取得优异的性能。

随着深度学习在图像分类领域不断发展,如何对异常图像进行检测成为了当前此类研究的热点^{[6][7]}。文献^[8]提出了一种基于改进MobileNetV2的人脸表情识别模型,在其引入压缩通道因

子和ECA机制,实验结果表明改进后的模型不仅在参数数量方面较其他主流网络模型有明显优势,同时还提高了识别准确率。文献^[9]针对复杂场景下远程视频监控图像异常检测困难,传统算法功能单一等问题,提出了一种基于深度学习的全自动远程视频异常图像检测方法。采用权重初始化(Xavier)方法对自行设计的卷积神经网络的参数进行初始化,然后在CNN的输出层获得远程视频异常图像检测结果。实验结果表明,该方法可以对远程视频监控中突然出现遮挡、模糊和场景切换等多种异常同时进行实时检测。文献^[10]针对图像高斯噪声,视频图像偏色和视频图像条纹干扰等问题,提出了一种利用快速傅里叶变换进行条纹检测的方法。实验结果表明,该方法能有效的检测出随机产生的条纹干扰图像。文献^[11]采用深度学习中的深度置信网络(DBN)构建了一个分类器,用于监控视频图像中异常情况的检测。实验结果表明,与基于支持向量机的异常检测方法相比,该方法的灵敏度,准确率要更高。文献^[12]针对图像噪声对目标识别性能的影响,提出了一种基于深度学习的方法来提取图像特征。具体来说,通过深度神经网络(DNET)连接不同层的特征图来增强模型对含噪图像的识别能力,实验结果表明,该方法在处理加入噪声的测试集时表现出了显著的性能提升。




图1 MobileNetV2网络整体结构

虽然上述方法在异常图像识别领域取得了进展,但在处理特定类型的噪声,例如色彩失真和画面黑白时,其识别率仍然较低。此外,这些技术在提取和处理关键特征方面的效率还有提升空间。为了解决这些问题,本文提出了一种针对MobileNetV2网络模型的改进方法。具体而言,在该网络模型的第一个卷积层后引入通道注意力模块(Efficient Channel Attention, ECA),以增强网络对关键特征的捕获能力。同时,本文还采用了四种不同的重构策略对MobileNetV2的原始block结构进行优化,并且在自建数据集上进行了详细的实验,证明了改进网络的可行性。

1 理论知识

1.1 卷积与激活函数

卷积层是神经网络的核心组件之一,其与全连接层的主要区别在于卷积层具有更少的训练参数,这有助于防止模型过拟合。卷积操作涉及卷积核应用于输入特征图,通过逐点相乘并求和的方式来提取特征后,再加上一个偏置项,其表达式为:

$$y_i = \sum_{j \in M_j} x_i \times k_{ij} + b_j \quad (1)$$

式(1)中 y_i 是第 i 个通道的输入特征图, y_j 是第 j 个通道的输出特征图, k 代表卷积核, b 是偏置项, M_j 是通道数的集合。

修正线性单元(Rectified Linear Unit, ReLU)激活函数在深度学习中得到了广泛应用,主要因为它能够有效地解决梯度消失问题。ReLU函数的导数在输入大于0时为1,这一特性确保了在进行反向传播时,梯度不会衰减,从而保持了特征图的数值范围不变。这种非线性激活函数的使用,使得深度神经网络的训练变得更加高效。ReLU激活函数公式为:

$$y = \max(0, x) \quad (2)$$

全局平均池化层GAP(global average pooling)是一种在卷积神经网络中常用的操作,通过计算每个通道的全局平均特征,得到一个 C 维的向量 z 。GAP显著减少了模型的参数数量,从而降低了过拟合的风险。其表达式如式3所示。

$$z = \text{GAP}(x): R^{C \times H \times W} \rightarrow R^C \quad (3)$$

式(3)中, C 代表通道数量, H 代表特征图的高度, W 代表特征图的宽度。式(3)中的每个元素 z_c (其中 $c=1, 2, 3, \dots, c$) 是通过所有 $H \cdot W$ 位置上的第 c 个通道的值取平均得到的。

1.2 MobileNetV2网络

在MobileNetV2网络的设计中,采用了两个关键结构来优化性能和效率:倒残差结构和ReLU6激活函数,如图1所示。一方面,倒残差结构有助于解决深度网络中的梯度消失问题,从而提高模型的性能,此外,该结构还减少了模型的参数数量。另一方面,ReLU6激活函数提供更平滑的梯度,防止过度激活和梯度消失问题。本节将详细介绍这两个关键模块的工作原理和实现细节。

1.2.1 短接结构的优势与应用




图2 倒残差结构中有无短接结构

文献^[13]中引入了短接结构,该结构通过将输入直接连接到输出,有效地解决了梯度在深层网络传播过程中的消失问题。这种设计允许梯度可以直接从输入层传递到输出层,从而在多层网络中保持了梯度的稳定流动。实验证明,采用短接结构的模型在分类、检测和分割任务上均展现出了优异的性能。短接结构是一种在深度学习模型中广泛使用的技术,如图2所示,它能够将早期的特征信息与当前特征融合,有效缓解梯度消失和网络退化问题,从而提升模型的训练效率和性能。

1.2.2 倒残差结构

文献^[14]总结了残差网络的研究背景和意义,针对残差单元、网络框架、混合改进三个方面进行模型改进,实验得出改进后的模型提高了算法精度。文献^[15]提出了一种基于注意力机制和残差卷积网络的算法,该方法能够有效防止梯度消失和梯度爆炸,从而提升了网络模型的精度。因此,本文选用带有逆残差结构的MobileNetV2网络。

倒残差结构通常涉及以下操作:

首先,采用 1×1 的卷积核来提高输入特征图的维度,并应用ReLU激活函数,其表达式如下:

$$F_1(x) = \text{ReLU}(PW(x)) \quad (4)$$

式(1)中, $PW(x)$ 指的是逐点卷积, x 是输入特征图。

其次,对式(4)的输出进行深度卷积,接着应用ReLU激活函数,这个过程表达式如下:

$$F_2(x) = \text{ReLU}(DW(F_1(x))) \quad (5)$$

式(5)中, DW 表示深度卷积。

最后,通过降维再次使用 1×1 卷积核来降低特征图的维度,但是此时采用Linear线性激活函数。

$$F_3(x) = \text{Linear}(PW(F_2(x))) \quad (6)$$

$$F_4(x) = F_3(x) + x \quad (7)$$

式(7)表示残差连接, $F_3(x)$ 与原始输入特征图 x 相加。

综上所述,逆残差结构可用上述数学公式表示,即首先对输入特征图进行升维,然后通过主路径提取特征,接着升维,最后通过残差连接将结果与原始输入相加,得到最终的输出。

1.3 ECA模块

文献^[16]提出了一种高效通道注意ECA(Efficient Channel Attention)模块,用于提高深度卷积神经网络(CNN)的性能。ECA模块通过避免降维和适当的跨通道交互,在保持模型复杂度的同时带来显著性能增益。ECA的结构如图3所示,由图3可知,该模块使用了全局平均池化层(GAP)和一个1维卷积层,特殊地,卷积层的卷积核大小不是手工指定的,而是使用了一种卷积核自适应选择方法,其数学表达式见式(8)。




图3 ECA结构示意图

$$z_c = \frac{1}{H \times W} \sum_{h=1}^H \sum_{w=1}^W X_{c,h,w} \quad (8)$$

通过计算每个通道的平均像素值,得出一个包含个元素的向量,其中每个元素都代表了对应通道的全局信息。

2 基于注意力机制的改进MobileNetV2算法

本文针对色彩失真和画面黑白二者识别率低下问题,引入了ECA注意力机制,并提出了四种改进方法,具体的网络结构如图4所示。首先,本文针对步长为1的原始block模块,提出在原始block模块后直接插入ECA模块,如图4(a)所示。在每个倒置残差模块的末尾都应用了ECA模块,以进一步提升特征表示能力。研究表明^{[17][18]},增加网络宽度可以提高性能,因此,本文将原始block改为双分支结构以增加网络宽度,如图4(b)所示。最后,本文将经过ECA模块处理后的输出与经过倒置残差结构处理后的输出进行相乘操作。

实验结果表明,结构(a)和结构(b)都可以取得更好的精度,但本文认为还存在其它可能更好的设计方法。

本文尝试一种新的设计思路,将输入特征与经过ECA模块输出部分、倒置结构输出部分进行三特征图相乘,得到了如图4(c)所示的结构。然而,本文发现如果直接将输入特征与卷积特征相乘可能会将特征值压缩到非常小的一个范围(如接近于0),这样在特征图上的变化会非常微小,使网络无法有效地区分各种噪声的特征。

为了解决上述问题,本文在三特征图相乘后加入了Sigmoid激活函数^[19]来将输出特征图的值压缩到(0-1)的区间,如图4(d)所示。实验结果表明,使用结构(d)重构的MobileNetV2网络比使用结构(c)重构的MobileNetV2网络的精度更高。

3 实验及结果分析

3.1 数据集建立及超参数选取

针对日常社区常见的7种监控异常干扰情况,在图像异常识别领域中,常见的异常有色彩失真、画面卡顿、过度曝光等7种,在此基础上,本文引入正常类图像,目的是提高异常检测的准确性和可靠性。因此,本文共建立了8个类,每类图像共有1400张。自建数据集实例如图5所示。




图4 四种重构方法



图5 数据集各类型示例

表1 实验软、硬件配置

配件	型号
CPU	AMD Ryzen 9 5900HX, 8核, 主频 3.30GHz
内存	16GB
硬盘	477GB SSD
操作系统	Windows 11
开发工具	Python 3.10.2 Pytorch 2.0.1

本文实验选用MobileNetV2网络作为基础网络,网络内部参数与原始MobileNetV2保持一致。此外,在模型的训练过程中,

本文采用批量梯度下降法进行优化。具体来说,本文将batch_size设置为32,学习率被设定为0.001,以便在每次迭代中处理。训练过程共进行了54次迭代,同时,为了有效地评估模型的泛化能力,本文按照7:3的比例划分原始数据集。实验环境的硬件和软件具体配置如表1所示。

3.2实验结果分析

使用改进后的结构对MobileNetV2进行了重构,具体网络结构如图4所示。在四种重构的MobileNetV2网络中,本文使用了图4中的(a)、(b)、(c)和(d)四种不同的block,并分别命名为MobileNet_ECA_1, MobileNet_ECA_2, MobileNet_ECA_3, MobileNet_ECA_4。

对比实验结果表明, MobileNet_ECA_1模型的准确率比采用原始倒置残差模块的MobileNetV2模型的准确率提高了1.82%。

表2 自建数据集上各个模型的实验结果

实验模型	准确率%	损失	参数量/M	每批训练时间/s
AlexNet	90.03	0.137	16	0.123
VGG-16	91.40	0.022	70	0.901
VGG-19	83.45	0.032	75	0.877
SVM	56.67	-	15	-
随机森林	75.66	-	-	-
MobileNetV1	90.54	0.287	4	0.325
MobileNetV2	92.50	0.182	2	0.301
MobileNetV2_ECA_1	94.32	0.212	2	0.299
MobileNetV2_ECA_2	93.17	0.198	2	0.298
MobileNetV2_ECA_3	90.67	0.423	2	0.311
MobileNetV2_ECA_4	94.22	0.111	2	0.301

表3 模型在各类别上的准确率对比

	MobileNetV2	MobileNetV2_ECA_1	MobileNetV2_ECA_2	MobileNetV2_ECA_3	MobileNetV2_ECA_4
正常	92.86%	100.00%	91.43%	53.57%	91.43%
画面卡顿	97.14%	96.43%	97.86%	94.29%	96.43%
过度曝光	98.15%	100.00%	100.00%	95.71%	97.56%
模糊	98.57%	100.00%	100.00%	100.00%	100.00%
色彩失真	99.19%	96.43%	99.29%	100.00%	100.00%
高斯噪声	91.43%	96.43%	95.71%	75.86%	96.28%
椒盐噪声	98.29%	99.29%	100.00%	92.85%	100.00%
画面黑白	92.43%	100.00%	100.00%	66.43%	100.00%

在 loss 值方面, MobileNetV2 模型和 MobileNet_ECA_1 模型的 loss 值分别为 0.182 和 0.212, 在训练时间上两者接近。 MobileNet_ECA_2 模型的准确率比 MobileNetV2 网络提高了 0.67%。该模型的损失值为 0.198, 其每批训练时间与 MobileNetV2 非常接近。然而, MobileNet_ECA_3 模型的准确率比 MobileNetV2 网络降低了 1.83%, 其损失值为 0.423, 与 MobileNetV2 网络相差较大, 每批训练时间为 0.311s。 MobileNet_ECA_4 模型的准确率比 MobileNetV2 模型提高了 1.72%, 其 loss 值为 0.111, 每批训练时间为 0.231s。

与传统算法相比, MobileNet_ECA_1 模型、 MobileNet_ECA_2 模型、 MobileNet_ECA_4 模型的准确率都高于其它的传统算法, 并且在参数量上明显的优于传统算法。

为了验证 ECA 模块在 MobileNetV2 网络中的作用和效果, 本文进行了一系列的消融实验。本文对比了引入 ECA 模块前后的网络性能。具体来说, 我们将原始的 MobileNetV2 网络与引入 ECA

模块后的改进网络进行了对比实验。实验结果显示, 引入 ECA 模块后, 改进网络在自建异常图像数据集上的监测精度有了显著的提升。

其次为了查看对复杂图像分类是否会出现过拟合问题, 本文将训练过程中的 loss 曲线和 accuracy 曲线进行了可视化。

由图 6 所示, 可以观察到传统的 MobileNetV2 网络与四种重构的 MobileNetV2 网络在训练集上均表现出良好的性能。此外, 结合表 2 所呈现的数据, 可以发现这三种重构模型均未出现过拟合的现象。但是, MobileNet_ECA_3 网络的收敛速度稍慢于其它四个模型。

由图 7 所示, 这四种模型的损失函数在整个训练过程中均呈现持续下降的趋势, 然而, MobileNet_ECA_3 网络的损失函数与其它三种模型相比, 下降速度较慢。因此, 通过该实验结果得出由于该网络在训练过程中收敛速度较慢, 导致损失函数的下降幅度较小。




图6 四种模型准确率




图7 四种模型损失值

模型在各类别上的准确率如表3所示,实验表明,除了MobileNetV2_ECA_3以外,其余改进方法,均较原始网络识别率有所提升。

由表3可知,本文提出的MobileNet_ECA_2、MobileNet_ECA_3和MobileNet_ECA_4提高了对色彩失真这一类类型的检测精度,相较于MobileNetV2,它们分别提高了0.1%、0.81%和0.81%; MobileNet_ECA_1、MobileNet_ECA_2和MobileNet_ECA_4提高了对画面黑白这一类类型的检测精度,相较于MobileNetV2,它们分别提高了7.57%、7.57%和7.57%,这说明了本文提出方法的有

效性。

3.3可视化分析

为了探究本文方法是否可以学习到有意义的特征,使用Grad-CAM算法对不同的改进网络进行了可视化研究,发现随着网络层次的加深,网络能够学习到更加高级的特征表示能力。

图8中,(a)到(i)分别是AlexNet、VGG16、VGG19、MobileNetV1、MobileNetV2、MobileNetV2_ECA_1、MobileNetV2_ECA_2、MobileNetV2_ECA_3和MobileNetV2_ECA_4网络提取到的特征图,从上到下分别是同一网络中不同层提取到的特征图,第1到4行




图8 上述表二各网络模型对应热力图




图9 MobileNet_ECA_4模型有无短接操作的比较

分别是同一网络中第1、3、5、7个卷积层提取到的特征。从图8(a)到(d)可知, MobileNetV2提取到的特征是最全面的, 相比于AlexNet, MobileNetV2提取到的特征更加聚焦, 相比于VGG16 MobileNetV2提取到的特征更多, MobileNetV2和VGG19提取到的特征较为相似, 但是VGG19没有将注意力放到图像的噪声上, 而是提取了更多无意义的特征。从图8(d)的第1行到第4行可知, MobileNetV2从第1个卷积层开始就已经可以注意到图像中的噪声, 这也是其它网络无法得到的结果, 随着层数的加深, MobileNetV2可以提取到更多关于噪声的特征, 从而提高了它的识别精度。从图8(d)到(i)可知, 相比于MobileNetV2, MobileNetV2_ECA_1、MobileNetV2_ECA_3、MobileNetV2_ECA_4可以获得更加聚焦的特征, 而不是像MobileNetV2中涣散的特征, 这也是这三个网络可以比MobileNetV2更好结果的原因。从图8(f)

到(i)的第1行到第4行可知, MobileNetV2_ECA_1、MobileNetV2_ECA_2、MobileNetV2_ECA_3和MobileNetV2_ECA_4都在第1个卷积层后没有提取到关于噪声的任何特征, 在第3个卷积层后才逐渐提取到了关于噪声的特征, 这就意味着四种不同的改进 MobileNetV2提取特征比其它网络要慢。从图8(d)到(i)的第1行和第3行可以看出, 第1个卷积层提取到的特征也在第3个卷积层中提取到的特征有所体现, 第1个卷积层和第3个卷积层提取到的特征也在第5个卷积层提取到的特征有所体现, 这也说明了bottleneck中残差操作的重要性, 可以将浅层特征叠加到深层特征上, 从而在抽象特征中叠加细节特征。随着改进 MobileNetV2层数的增多, MobileNetV2_ECA_1、MobileNetV2_ECA_2和MobileNetV2_ECA_4会提取更多的特征从而提高模型的性能。

为了探究短接操作对本文方法有哪些影响, 本文对加入短接操作和没加入短接操作的MobileNet_ECA_4网络进行了可视化研究。如图9所示, 从左到右表示不同层提取到的特征可视化, (a)中的4张图是加入了短接操作的特征变化, 而在(b)中未进行短接操作, 发现其对特征的捕获能力相对较弱。因此, 短接操作的存在使得梯度可以直接流向更深的网络层, 这有助于缓解梯度消失的问题, 从而提高了模型的训练稳定性和泛化能力。

4 结论

本文构建了11200张图像的异常图像数据集, 提出三种有效的重构方法来提高MobileNetV2的特征提取能力, 具体来说, MobileNet_ECA_1模型有1.77%的提升, MobileNet_ECA_2模型有1.54%的提升, MobileNet_ECA_4模型有1.21%的提升。

在特征可视化实验中, 发现在自建数据集中, 并不是所有的深层网络都可以取得更好的结果, 如VGG19的识别率低于VGG16, 也就是说更深的网络在此数据集上学习会发生过拟合现象, MobileNetV2网络不仅是一个轻量级网络还可以在浅层提取到有意义的噪声特征, 这也是本文选择MobileNetV2网络作为基线的原因, 本文提出了四种改进方法, 三种改进方法都可以有效地提取噪声特征, 提高网络的性能。

[参考文献]

- [1]唐启义,冯明光.DPS数据处理系统[M].北京:科学出版社,2007.
- [2]芦伟东.基于SVM的边境频谱监测数据分类预测[J].中国无线电,2022,(09):44-46.
- [3]祁晓博,宋金玉,史颖.面向区间型数据的不同区间核SVM分类模型[J].山西大学学报(自然科学版),2023,46(03):628-635..
- [4]张善进,潘甦.基于改进SVM算法的室内人员身份识别技术[J].移动通信,2023,47(04):85-91.
- [5]马佳佳,陈友鹏,王克强.基于优化SVM的虫害图像识别研究[J].中国粮油学报,2022,37(05):10-15.
- [6]胡正平,张乐,李淑芳,等.视频监控系统异常目标检测与定位综述[J].燕山大学学报,2019,(1):12.
- [7]王佑卿,李振杰.基于深度学习的视频质量诊断技术研究[J].中国安防,2018,(6):3.
- [8]严春满,张翔,王青朋.基于改进MobileNetV2的人脸表情识别[J].计算机工程与科学,2023,45(06):1071-1078.

[9]杨亚虎,王瑜,陈天华.基于深度学习的远程视频监控异常图像检测[J].TelecommunicationEngineering,2021,61(2):6.

[10]李世杰.面向安保监控的视频图像处理和识别算法研究[D].国防科学技术大学,2014.

[11]张闻中,华守彤,陈逸,等.基于智能定位的工业现场全天候监控视频异常检测研究[J].制造业自动化,2022,(03):044.

[12]陈斌.基于视频图像的人体异常情绪识别算法研究[J].大理大学学报,2021,8(12):27.

[13]SandlerM,HowardA,ZhuM,etal.Mobilenetv2:Invertedresidualsandlinearbottlenecks[C]//ProceedingsoftheIEEEconferenceoncomputervisionandpatternrecognition,2018:4510-4520.

[14]郭癭秀.残差网络研究综述[J].ApplicationResearchofComputers/JisuanjiYingyongYanjiu,2020,37(5).

[15]李文志,屈晓旭.基于注意力机制和残差卷积网络的语音增强[J].舰船电子工程,2022,42(5):96-100.

[16]WangQ,WuB,Zhu P,et al.ECA-Net:Efficient channel attention for deep convolutional neural networks[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition.2020:11534-11542.

[17]严春满,王铖.卷积神经网络模型发展及应用[J].JournalofFrontiersofComputerScience&Technology,2021,15(1).

[18]林景栋,吴欣怡,柴毅,等.卷积神经网络结构优化综述[J].自动化学报,2020,46(1):24-37.

[19]张焕,张庆,于纪言.激活函数的发展综述及其性质分析[J].西华大学学报(自然科学版),2021,40(4):1-10.

作者简介:

管勤(2002--),男,汉族,湖北省孝感市人,在读本科,研究方向:智能科学与技术。

张珂鑫(2004--),女,汉族,陕西省西安市人,在读本科,研究方向:智能科学与技术。

刘元(2002--),男,汉族,河北省张家口市人,在读本科,研究方向:智能科学与技术。

通讯作者:

李昌德(1959--),男,汉族,四川省遂宁市人,博士,研究方向:AI先进自动化控制系统。