

# 基于合成卷积层网络结构的焊缝X射线图片缺陷筛选技术

刘骁佳 刘欢 王立群 王宇斐 危荃

(上海航天精密机械研究所, 上海 201600)

**文 摘** 焊接技术应用于多个领域,近些年焊缝缺陷自动检测技术成为了重要的研究方向。本文基于VGG-16卷积神经网络的良好分类性能,提出一种SC-VGG网络结构,利用合成卷积层替换了单个卷积层,同时改进了训练过程中的损失函数,使网络结构更为关注焊缝缺陷类型预测的结果。经过实验测试,SC-VGG网络结构在训练过程中损失函数曲线可以很好的收敛,与其他网络结构相比对焊缝缺陷特征的提取性能更好,平均准确率和召回率达到了95.86%和98.33%,为焊缝缺陷自动化识别提供了算法支撑。

**关键词** 焊缝检测,缺陷识别,VGG-16模型,合成卷积

中图分类号: TG441.7

DOI: 10.12044/j.issn.1007-2330.2021.Z1.014

## Defect Screening Technology of Weld X-ray Image Based on Synthetic Convolution Network Structure

LIU Xiaojia LIU Huan WANG Liqun WANG Yufei WEI Quan

(Shanghai Aerospace Precision Machinery Research Institute, Shanghai 201600)

**Abstract** Welding technology has been applied in many fields. In recent years, automatic detection technology of weld defects has become an important research direction. In this paper, based on the good classification performance of vgg-16 convolutional neural network, a SC-VGG network structure is proposed, in which a single convolution layer is replaced by a composite convolution layer, and the loss function in the training process is improved, so that the network structure pays more attention to the results of prediction of weld defect type. Through the experimental test, SC-VGG network structure in the training process of loss function curve can be very good convergence. Compared with other network structure, SC-VGG network has a better weld defect feature extraction performance, the average accuracy and recall rate reached 95.86% and 98.33%, which provides algorithm support for automatic recognition of weld defects.

**Key words** Weld inspection, Defect identification, VGG-16 model, Synthetic convolution

### 0 引言

焊接技术作为一种常用的金属或热塑性材料的制造工艺,已广泛应用到航空航天、石油化工、工程机械等多个领域,工件焊接质量将直接影响产品整体结构的使用性能和寿命。生产过程中由于工艺和焊接环境等因素影响,工件焊接后焊缝内可能存在气孔、夹渣、未焊透等缺陷,因此使用X射线成像方法进行内部缺陷检测成为一种重要检测手段<sup>[1-3]</sup>。随着图片处理技术的发展,无损检测领域中工件的X射线成像检测技

术应用越来越广泛。然而目前焊缝的X射线图片的缺陷评定过程多数依赖人工评定法,此种作业方式工作效率低,而且受检查人员技术素质、经验、熟练程度和疲劳等主观因素的影响,常有误判和漏判的情况发生,难以满足大批量产品质量实时检查的需要<sup>[4-5]</sup>。

为了消除X射线成像检测人工评定过程中的主观性、差异性问题,近些年焊缝缺陷自动检测技术成为了重要的研究方向,基于卷积神经网络(CNN)已成为焊缝缺陷自动检测领域的研究热点。CNN模型利用网络

收稿日期:2021-08-11

基金项目:上海市浦江人才计划资助(20PJ1405000)

第一作者简介:刘骁佳,1990年出生,博士,高级工程师,主要研究方向为工业大数据和工业人工智能。E-mail:lxj9039@126.com

结构自动学习的特点,可对焊缝缺陷特征自动进行提取,避免了传统算法中人工提取特征的适应性差和复杂度高等问题,实现了焊缝缺陷的自动检测过程。支泽林等<sup>[6]</sup>通过构建基于时间卷积网络的波形序列数据分析模块、基于卷积神经网络的图片数据分析模块和特征自适应融合分类模块,建立了深度学习融合网络模型和模式分类方法,实现了波形序列特征和图片特征的综合分析,最高识别准确率达到85.71%。YANG Lu等<sup>[7]</sup>提出了一种具有多级特征的统一深度神经网络用于焊接缺陷分类,将每个隐含层的多层次特征融合到最后一个隐含层中,综合预测焊接缺陷的类型,同时研究了预训练和精细化策略,以在小数据集下获得更好的泛化性能。充分利用了从每个隐层提取的多层次特征,在测试数据集上分类精度达到91.36%。HOU等<sup>[8]</sup>提出了一种包含三个阶段的X射线图片焊缝缺陷自动检测方案。首先定位焊缝区域,然后建立了基于深度神经网络的分类模型,并用X射线图片裁剪出的面片对分类模型进行训练和检验。最后基于训练好的模型,采用滑动窗口方法对图片进行整体检测。该模型获得了最大值分类准确率为91.84%。MA等<sup>[9]</sup>利用卷积神经网络(CNN)和主动视觉的概念,提出了一种从SCD图片中自动检测典型咬边、气孔和烧穿缺陷的新方法,在通用Image Net数据集上训练的VGG16网络体系结构的输出特征,使用自适应细化VGG16中间特征映射的卷积模块,在训练数据量较少的情况下提高了学习精度。姜洪权等<sup>[10]</sup>根据焊接缺陷的特点,提出了一种考虑焊接区域和分布特征的焊接模型,将随机森林和CNN相结合,提高了特征提取的能力。使焊接模型具有一定的动态适应性,实验结果表明该方法比传统的CNN方法具有更高的识别率。




图1 VGG-16模型网络结构  
Fig. 1 VGG-16 model network structure

VGG-16通过简单的模型组合实现更深层次的网络结构,并通过不断深化网络结构来提高性能。然而传统的VGG-16模型参数较多,多次训练迭代过程会增强模型的拟合能力但也会使得模型产生过拟合现象,并且由于VGG-16采用卷积层、池化层和全

虽然上述方法在进行焊缝缺陷检测时取得了很好的效果,但上述方法过于关注提升准确率,在实际生产应用过程中应更关注于缺陷产品召回率,召回率指标达标后方可进行工程化应用。同时由于CNN方法在识别过程中为了得到一致假设从而使得模型容易变成过拟合状态,采用梯度下降算法很容易使训练结果收敛于局部最小值而非全局最小值,难以达到最优模型状态,从而影响缺陷检测效果。为了解决上述问题,本文基于VGG-16模型在图片分类中的良好性能,结合VGG-16模型网络结构规则、分类性能突出、对各数据集适应性强的特点,提出一种用于焊缝X射线图片缺陷自动检测的SC-VGG网络模型。该模型在VGG-16模型的基础上,用合成卷积层代替部分卷积层,实现焊缝缺陷的特征提取和焊缝X射线图片的自动检测。

## 1 研究方法

### 1.1 传统VGG-16神经网络结构分析

典型神经网络VGG-16有16个权值层,包括13个卷积层和3个全连接层<sup>[11-13]</sup>,如图1所示。由图可知,VGG-16网络结构输入为 $224 \times 224 \times 3$ ,经过 $3 \times 3$ 的卷积核连续卷积堆叠组成新的卷积序列,边界填充为1保持卷积过程数据大小不变。利用ReLU激活函数使大规模计算网络具有良好的稀疏性。随着网络的不断深入,图片的高度和宽度每次都会减少一半,而通道数却在增加,每次卷积运算后通道数会增加两倍。网络的最后一部分是全连接层,由三个全连接层组成,通道数分别为4096、4096、1000,并通过SoftMax分类器进行分类输出。神经网络的每一层都构建在由独立分布的神经元组成的多个平面上,层与层之间的连接是不完全连接的卷积计算,每个神经元由输入单元的某些维数加权组成。

连接层顺序连接,模型参数调整困难,无法很好提取图片的精细特征,限制了焊缝缺陷识别的效果。

### 1.2 SC-VGG网络结构

基于VGG-16模型结构的基础上,提出一种合成卷积层的VGG模型(Synthetic Convolutional VGG,

SC-VGG),网络结构示意图如图2所示。

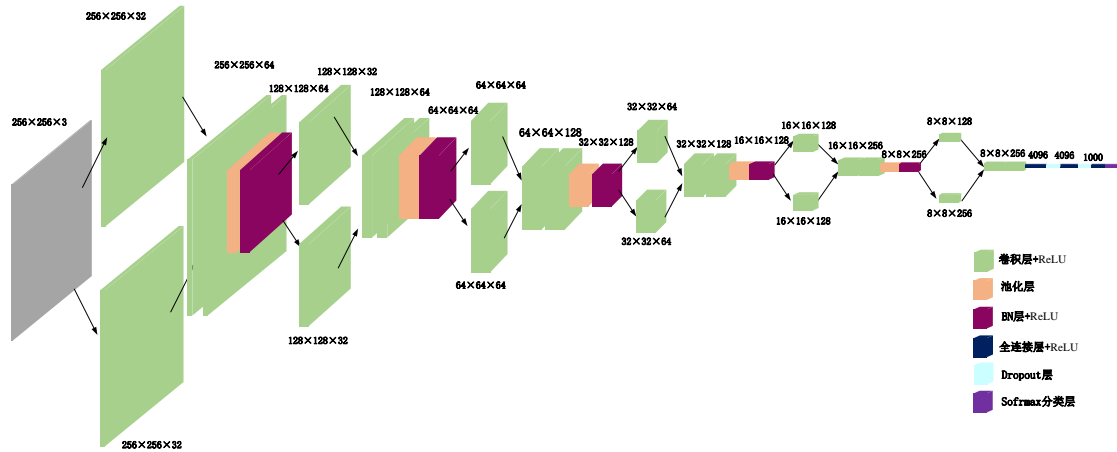


图2 SC-VGG模型网络结构

Fig. 2 SC-VGG model network structure

表1 SC-VGG网络结构输出结果

Tab. 1 Output of SC-VGG network structure

层数	输入图分辨率	操作	卷积核大小	输出图分辨率
1	256×256×3	Conv1-1	3×3×3×32	256×256×64
		Conv1-2	5×5×3×32	
2	256×256×64	MaxPool1	2×2	128×128×64
3	128×128×64	Conv2-1	3×3×64×32	128×128×64
		Conv2-2	5×5×64×32	
4	128×128×64	MaxPool2	2×2	64×64×64
5	64×64×64	Conv3-1	3×3×64×64	64×64×128
		Conv3-2	5×5×64×64	
6	64×64×128	MaxPool3	2×2	32×32×128
7	32×32×128	Conv4-1	3×3×128×64	32×32×128
		Conv4-2	5×5×128×64	
8	32×32×128	MaxPool4	2×2	16×16×128
9	16×16×128	Conv5-1	3×3×128×128	16×16×256
		Conv5-2	5×5×128×128	
10	16×16×256	MaxPool5	2×2	8×8×256
11	8×8×256	Conv6-1	3×3×256×128	8×8×256
		Conv6-2	5×5×256×128	
12	8×8×256	Linear1	-	1×1×4096
13	1×1×4096	Linear2	-	1×1×4096
14	1×1×4096	Linear3	-	1×1×1000
15	1×1×1000	Softmax	-	4

由图2可以得到,搭建的SC-VGG网络模型由6个合成卷积层、5个池化层和、5个BN层、3个全连接层和2个Dropout层所组成,224×224×3的图片输入数据经过合成卷积层、池化层、全连接层、BN层、Dropout层顺序连接的共同作用,最终得到一系列特征向量,输入到Softmax分类器中进行分类,SC-VGG

网络结构每层输出结果如表1所示。

SC-VGG模型结构中,将原有顺序连接的单个卷积层使用2个并联的卷积层进行替换,并且2个并联的卷积层所使用的卷积核大小分别为3×3和5×5,将其合成为1层卷积,成为合成卷积层结构。通过合成卷积层结构,SC-VGG模型可将多个特征进行联合,通道数进行了合并,不同大小的卷积特征提取的特征进行了融合,在每一特征信息量不变的情况下增加了图片特征。SC-VGG模型中合成卷积层结构与单个卷积层结构相比,更好的提取了图片的局部信息差异性和边缘纹理特征,提升模型整体对焊缝缺陷细微边缘特征的数据张量的提取能力,提高了焊缝X摄像图片中缺陷识别能力。

为应对由于模型参数较多、多次训练迭代过程带来的过拟合问题,SC-VGG结构添加了Dropout层,将Dropout层应用于激活层后,Dropout层通过随机丢弃训练模型节点来减少模型的过拟合,在每次反向传播中,主动层中的隐藏节点按一定比例随机选取,使得全连通网络具有一定的稀疏性,由于隐藏节点以一定的概率随机出现,使得两个神经元不会同时出现,减少了神经元之间的协作自适应关系,提高了网络的鲁棒性<sup>[14]</sup>。同时为避免网络模型训练过程中样本特征过于分散,SC-VGG结构结构在池化层后添加了Batch Normalization(BN)层,使前一层神经网络的输出值归一化到均值为0、方差为1的标准正态分布,然后作为后一层神经网络神经元的输入值,使得激活输入值远离饱和区,落入非线性函数的敏感区域,避免了梯度消失的问题,提高了泛化能力,而且在打乱样本训练顺序的情况下,能够提高精度。

## 2 结果与分析

### 2.1 数据集的构建

所用的数据集由生产中实际产生图片组成,每张图片都通过X射线图片采集装置获得,由气孔、夹渣、未焊透和无缺陷四部分构成,典型图片如图3所示。由于实际生产中无缺陷的图片为绝大多数,含有缺陷的图片数据量不足,因此可对图片数据集进行扩充增大样本量。由于卷积神经网络可以用于不同位置、视角、尺度的鲁棒分类,因此可以使用图片基本变换来有效地扩展数据集。数据集扩展是对原始图片样本进行处理,原始图片样本通过剪切、旋转、插值等图片变换方法进行处理。它不仅可以获得更多的训练数据集,而且可以通过增加训练过程中的干扰来提高网络结构的分类精度。

原始图片进行扩充后共有3300张图片,其中气

孔、夹渣、未焊透各600张,无缺陷图片1500张。为了评价本文提出方法的效果,分别从数据集中选取了气孔、夹渣、未焊透各100张图片,无缺陷图片400张,共700张图片作为测试集,其余的图片作为训练集,将得到的X射线焊缝图片大小归一化为 $256 \times 256 \times 3$ 像素。通过分层等距抽样得到训练集,保证了抽样样本结构和样本整体的一致性,提高了样本的代表性。同时由于本文数据量的限制,为了更进一步验证本文方法的泛化能力,采用K折交叉验证对测试集进行划分,其中 $K=10$ 。K折交叉验证会将数据集划分为K个部分,每次选择其中一个部分作为测试集,其余 $K-1$ 部分组成训练集对该模型进行训练,训练过程重复K次。




图3 焊缝X射线典型图片

Fig. 3 Typical X-ray pictures of welds

## 2.2 构造损失函数

为处理数据集离散型数值特征,并使得特征之间的距离计算更加合理,对焊缝数据状态标签进行One-Hot编码,采用4位状态寄存器来对4个状态进行编码,每个状态都由他独立的寄存器位,并且在任意时候只有一位有效,如表2所示。

由于多分类交叉熵损失函数求导更简单,损失值仅与正确类别的概率有关,因此采用交叉熵损失函数衡量模型预测能力,表现出预测结果与实际数据的差距程度,交叉熵函数公式如下:

$$\text{loss} = - \sum_{i=1}^n y_i \lg \left( \hat{y}_i \right) \quad (1)$$

表2 不同类别焊缝缺陷数量和Onehot编码

Tab. 2 Number of weld defects of different categories and Onehot code

类别	图片数量	编码
气孔	600	1000
夹渣	600	0100
未焊透	600	0010
无缺陷	1500	0001



式中,  $y$  为真实标签,  $\hat{y}$  为网络结构预测值, 是一个属于 0~1 的值。

X 射线图像的焊缝缺陷识别在实际应用过程中, 更为关注缺陷产品预测结果, 对缺陷产品预测结果的正确率要求更为严格, 对无缺陷产品预测结果的正确率要求相对较低, 然而交叉熵损失函数结构本身决定了不同类别图片预测偏差在损失值中绝对比重相同。因此对损失函数进行优化, 当编码的最后一位不为 1 时, 此时焊缝图片便签为有缺陷类型, 损失值计算公式如下:

$$\text{loss} = -\sum_{i=1}^n \frac{1}{\binom{\hat{y}_i}{y_i}} \lg \binom{\hat{y}_i}{y_i} \quad (2)$$

由(2)式可知, 当缺陷类型图片的预测结果错误时, 整体预测损失值将升高, 即损失函数对缺陷类型图片预测结果的错误进行惩罚, 使网络模型训练后结果不收敛, 以此确保缺陷产品预测结果的正确性。同时网络结构训练过程中采用随机梯度下降算法, 在每轮网络结构训练迭代过程中, 随机优化某一条训练数据上的损失函数, 使得参数更新速度加快。与其他梯度下降算法相比, 特别是在数据冗余的情况下, 该算法能更有效地利用数据信息, 同时随机梯度下降法不容易陷入原始损失的奇点中, 整体计算代价更小。

### 2.3 评价指标

方法性能将使用混淆矩阵进行评价, 混淆矩阵如表 3 所示。模型的输出结果主要包括两个类别, 无缺陷和缺陷。每个样本通过焊缝缺陷识别模型将获得一个输出类别。然后, 将该输出类别与样本真实类别进行比较, 即可汇总获得该模型的混淆矩阵。

表 3 混淆矩阵  
Tab. 3 Confusion matrix

预测 真实	缺陷	无缺陷
缺陷	True positive(TP)	False negative(FN)
无缺陷	False positive(FP)	True negative(TN)

由混淆矩阵可以计算获得多种性能评价指标。本文采用召回率、精确率和准确率三个指标对本文方法性能结果进行评价。而企业工程应用中一般对图片缺陷的召回率要求严格, 即要求把有缺陷的样本识别成无缺陷的比例尽可能的少。同时精确率和准确率作为最常用的性能指标, 可以对该方法的正负样本的分类精度做出一个评价。准确率和漏报率公式可由以下公式计算获得:

$$\text{recall} = \frac{TP}{TP + FN} \quad (3)$$

$$\text{precision} = \frac{TP}{TP + FP} \quad (4)$$

$$\text{accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

### 2.4 结果与讨论

焊缝 X 射线图片缺陷检测实验使用操作系统为 Centos7.6, 采用开源人工智能系统框架 Tensorflow1.15 搭建 SC-VGG 卷积神经网络结构, 计算机 GPU 为 RTX2080。为验证本文 SC-VGG 模型结构训练结果的有效性, 选择 VGG16、VGG19、AlexNet 三种模型结构与本文采用 SC-VGG 模型结构进行对比实验, 四种模型结构各进行 1 000 次训练, 通过模型训练可获得训练过程损失值变化, 如图 4 所示。从图中 4 可以看出, 训练迭代次数(epoch)为 200 时, 4 个网络模型的 loss 值都有明显的减小。但 SC-VGG 由于损失函数的更改, 当网络结果对缺陷类别判定错误时其损失值将增大, 因此在相同的迭代次数时 SC-VGG 损失值更高。在进行了 700 次迭代之后 SC-VGG 损失值达到平稳状态, 此时损失值略高于 VGG16、VGG19、AlexNet 三种模型结构的损失值, 但曲线依然处于收敛状态, 在焊缝缺陷识别方面具有很好的有效性。

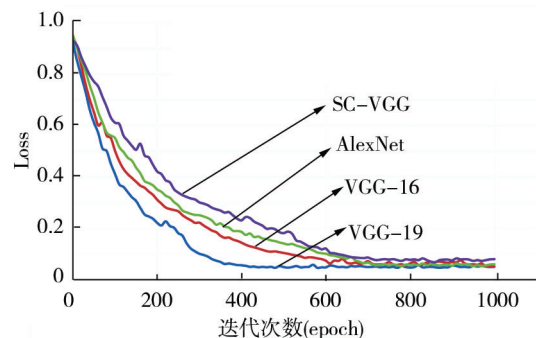


图 4 不同结构模型训练过程损失值变化

Fig. 4 Loss value during training of different structural models

使用训练后生成的 SC-VGG 模型, 对测试集中的焊缝图片进行分类预测, 其预测结果如表 4 所示。

表 4 SC-VGG 模型焊缝缺陷检测结果

Tab. 4 Test results of weld defects of SC-VGG model

类别	图片数量	召回率/%	精确率/%	总准确率/%
气孔	100	100	91.74	
夹渣	100	98	95.15	95.86
未焊透	100	97	89.81	

使用 VGG16、VGG19、AlexNet、SC-VGG 四种网络结构训练 1000 次生成的模型, 对测试集中的所有图片进行分类性能的比较, 采用 10 折交叉验证法, 其结果如表 5 所示。由表 5 结果可知 SC-VGG 网络结构对测试集中图片进行预测时, 其召回率和准确率

都有明显的提升,对X射线焊缝图像缺陷识别取得了很好的效果。

表5 4种结构模型分类结果比较  
Tab. 5 Comparison of classification results of four structural models

模型	平均精确率/%	总准确率/%	平均召回率/%	单幅图像分类时间/s
AlexNet	86.45	89.43	89.33	0.0899
VGG16	88.31	90.86	90.67	0.0883
VGG19	87.77	91.57	93.33	0.1056
SC-VGG	92.19	95.86	98.33	0.1284

### 3 结论

通过提出一种基于VGG16网络结构的SC-VGG模型的卷积神经网络,可对X射线焊缝图像进行筛选,利用合成卷积层结构对焊缝缺陷特征进行了有效的提取,同时改进了训练过程中的损失函数。通过10折交叉验证法进行测试可知,与传统VGG16、VGG19、AlexNet网络结构相比,本文方法对X射线焊缝图像缺陷分类的准确率和召回率更高,平均准确率和召回率达到了95.86%和98.33%,为X射线焊缝图像的缺陷筛选提供了基础。

#### 参考文献

[1] 申清明,高建民,李成. 焊缝缺陷类型识别方法的研究[J]. 西安交通大学学报,2010,44(7):100-103.

SHEN Mingqing, GAO Jianmin, LI Cheng. Research on identification method of weld defect type [J]. Journal of Xi'an Jiaotong University, 2010,44(7):100-103.

[2] 王思宇,高炜欣,张翔松. X射线焊缝图像缺陷检测算法综述[J]. 热加工工艺,2020,49(15):1-8.

WANG Siyu, GAO Weixin, ZHANG Xiangsong. Review of X-ray weld image defect detection algorithm [J]. Hot Working Technology, 2020,49(15):1-8.

[3] 张立新. 无损检测中焊缝X射线底片数字化仪及焊缝图像缺陷检测识别系统[J]. 西安工业大学学报,2021,41(1):93.

ZHANG Lixin. The digitizer of X-ray negative film of weld and the defect detection and recognition system of weld image in nondestructive testing [J]. Journal of Xi'an Technological University, 2021,41(1):93.

[4] 刘梦溪,巨永锋,高炜欣. 深度卷积神经网络的X射线焊缝缺陷研究[J]. 传感器与微系统,2018,37(5):37-39+43.

LIU Mengxin, JU Yongfeng, GAO Weixin. Research on X-ray weld defects based on deep convolution neural network [J]. Transducer and Microsystem Technologies, 2018, 37(5):37-39+43.

[5] 余永维,殷国富,殷鹰. 基于深度学习网络的射线图

像缺陷识别方法[J]. 仪器仪表学报,2014,35(9):2012-2019.

YU Yongwei, YIN Guofu, YIN Ying. Ray image defect recognition method based on deep-learning network [J]. Chinese Journal of Scientific Instrument, 2014,35(9):2012-2019.

[6] 支泽林,姜洪权,杨得焱. 图谱数据深度学习融合模型及焊缝缺陷识别方法[J]. 西安交通大学学报,2021,55(5):73-82.

ZHI Zelin, JIANG Hongquan, YANG Deyan. Deep-learning fusion model of atlas data and weld defect recognition method [J]. Journal of Xi'an Jiaotong University, 2021,55(5):73-82.

[7] YANG Lu, JIANG Hongquan. Weld defect classification in radiographic images using unified deep neural network with multi-level features [J]. Journal of Intelligent Manufacturing, 2020,32(2):1-11.

[8] HOU Wenhui, WEI Ye, JIE Guo. Automatic detection of welding defects using deep neural network [J]. Journal of Physics Conference Series, 2018,933(1):012006.

[9] MA Guohong, YU Lesheng, YUAN Haitao. A vision-based method for lap weld defects monitoring of galvanized steel sheets using convolutional neural network [J]. Journal of Manufacturing Processes, 2021,64(1):130-139.

[10] 姜洪权,贺帅,高建民. 一种改进卷积神经网络模型的焊缝缺陷识别方法[J]. 机械工程学报,2020,56(8):235-242.

JIANG Hongquan, HE Suan, GAO Jianmin. An improved convolution neural network model for weld defect recognition [J]. Journal of Mechanical Engineering, 2020,56(8):235-242.

[11] 戚超,左毅,陈哲琪. 基于改进VGG16的大米加工精度分级方法研究[J]. 农业机械学报,2021,52(5):301-307.

QIN Chao, ZUO Yi, CHEN Zheqi. Research on rice processing accuracy classification method based on improved VGG-16 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021,52(5):301-307.

[12] 何凯,马红悦,冯旭. 基于改进VGG-16模型的英文笔迹鉴别方法[J]. 天津大学学报(自然科学与工程技术版),2020,53(9):984-990.

HE Kai, MA Hongyue, FENG Xu. English handwriting identification method based on improved VGG-16 model [J]. Journal of Tianjin University (Science and Technology), 2020,53(9):984-990.

[13] 甄珍,赵志鹏. VGG16在地下排水管道缺陷图像分类中的应用[J]. 科学技术创新,2021(7):101-102.

ZHEN zhen, ZHAO Zhipeng. Application of VGG-16 in defect image classification of underground drainage pipeline [J]. Scientific and Technological Innovation, 2021(7):101-102.

[14] LIU Cong, XU Weisheng, WU Qidi. Learning motion and content-dependent features with convolutions for action recognition [J]. Multimedia Tools and Applications, 2016(21):13023-13039.