

深度学习下混凝土结合面粗糙度等级识别

卓文涛¹, 汪石农¹, 程志军²

1. 安徽工程大学 电气工程学院, 安徽 芜湖 241000

2. 龙信建设集团有限公司, 江苏 南通 226100

摘要:目的 由于混凝土结合面的粗糙程度影响其本身的抗剪性能和粘结强度, 因此设计出一种能够识别混凝土结合面粗糙程度的深度学习模型, 以更加直观、快速地检测出结合面的粗糙程度; 方法 首先, 以 ResNet50 模型为基础, 识别采集的混凝土结合面深度图的粗糙度等级, 得到以主网络识别粗糙度的深度学习模型; 之后, 在此基础上对模型的识别精度进行改进。分别采用三种不同的方式在 ResNet50 的第一个卷积层后面嵌入 CBAM 注意力机制、CBAM 通道注意力机制和 CBAM 空间注意力机制, 并且在嵌入的过程中保持主网络的参数一致, 得到三种结合卷积和注意力机制的深度学习模型。结果 通过仿真, 得到 ResNet50 模型的识别准确率为 86.99%, 而采用 GoogLeNet 和 AlexNet 的准确率分别为 82.88% 和 83.56%。在 ResNet50 基础上嵌入三种注意力机制的准确率分别为 60.27%、93.84% 和 91.78%。结论 相较于 GoogLeNet 和 AlexNet, ResNet50 具有较高的识别准确率, 而嵌入 CBAM 通道注意力机制的 ResNet50 具有最高的识别准确率, 因此可以更好地识别混凝土结合面的粗糙度。

关键词: 结合面; 粗糙度等级; ResNet50; 注意力机制

中图分类号: TP391 **文献标识码:** A **doi:** 10.16055/j.issn.1672-058X.2026.0004.009

Identification of the Roughness Grade of the Concrete Joint Surface Using Deep Learning

ZHUO Wentao¹, WANG Shinong¹, CHENG Zhijun²

1. School of Electrical Engineering, Anhui Polytechnic University, Wuhu 241000, Anhui, China

2. Longxin Construction Group Co., Ltd., Nantong 226100, Jiangsu, China

Abstract: **Objective** The roughness of a concrete joint surface significantly affects its shear performance and bonding strength. Therefore, this study designs a deep learning model capable of identifying the roughness grade of concrete joint surfaces. The model enables a more intuitive and rapid assessment of joint surface roughness. **Methods** First, ResNet50 was used as the backbone network to identify the roughness grades of the collected depth maps of concrete joint surfaces. Thus, a deep learning model for roughness identification based on this backbone network was obtained. Then, to further improve the identification accuracy of the model, three different embedding strategies were adopted. The convolutional block attention module (CBAM), its channel attention component, and its spatial attention component were respectively embedded behind the first convolutional layer of ResNet50. The parameters of the backbone network were kept unchanged during this process. As a result, three deep learning models that combined convolutional and attention mechanisms were obtained. **Results** Simulation results showed that the identification accuracy of ResNet50 was 86.99%, compared with 82.88% for GoogLeNet and 83.56% for AlexNet. When three different attention mechanisms were embedded into

收稿日期: 2024-04-01 修回日期: 2024-07-25 文章编号: 1672-058X(2026)04-0068-07

作者简介: 卓文涛(1998—), 女, 江苏徐州人, 硕士研究生, 从事人工智能方向研究。

通信作者: 汪石农(1980—), 男, 安徽桐城人, 副教授, 从事光伏发电系统与微电网研究。Email: wsn@ahpu.edu.cn.

引用格式: 卓文涛, 汪石农, 程志军. 深度学习下混凝土结合面粗糙度等级识别[J]. 重庆工商大学学报(自然科学版), 2026, 43(4): 68-74.

Zhuo Wentao, Wang Shinong, Cheng Zhijun. Identification of the roughness grade of the concrete joint surface using deep learning [J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(4): 68-74.

ResNet50, the model achieved accuracies of 60.27% after embedding the full CBAM, 93.84% after embedding the channel attention, and 91.78% after embedding the spatial attention. **Conclusion** Compared with GoogLeNet and AlexNet, ResNet50 demonstrates higher identification accuracy. Among the attention-enhanced models, the ResNet50 embedded with the CBAM channel attention mechanism achieves the highest accuracy. Therefore, this model is more effective in identifying the roughness grade of concrete joint surfaces.

Keywords: joint surface; roughness grade; ResNet50; attention mechanism

混凝土作为一种重要的建筑材料,在建筑业中的用途十分广泛。不同粗糙度等级的混凝土结合面影响其抗剪性能,粗糙度增大,抗剪性能也增大;粗糙度还间接影响混凝土结合面的强度和耐久性,通过改善润滑条件、减小磨损来提高其使用强度和耐久性;不同施工工艺所形成的混凝土其粗糙度也不同。可见,研究混凝土结合面粗糙度的等级识别具有重要意义。

传统的粗糙度检测方法有接触式测量方法和非接触式测量方法^[1]。接触式测量方法包括比较测量方法、针触法和印模法;非接触式测量方法有光切法、光学传感器法等。文献[2]采用铺砂法测量混凝土表面粗糙度,通过摊铺实验获取最少用砂量和测区数,用砂料的体积除以测区的面积便可以计算出粗糙度。最终得到3个有代表性的测区,可以代替整块叠合板进行粗糙度检测,并得到了固定的单个测区用砂量。该方法原理简单,适用于单块混凝土板的粗糙度测量,但操作烦琐,不适合在样本数多的情况下使用。文献[3]提出了一种基于边缘检测的混凝土表面粗糙度测量方法。通过图像处理技术,先进行去噪处理,之后利用两级边缘检测法找出边缘,用最小二乘法拟合边缘关系,最后运用BP神经网络进行训练。虽然精度有所提升,但文中提出的两阶段边缘检测算法会有5.3%以内的误差。文献[4]采用图像处理技术获取混凝土表面粗糙度,后续研究可以借鉴此方法获取粗糙度。但是该文献侧重于表面粗糙度对混凝土性能的影响,并没有着重研究更优的获得粗糙度的计算方法。文献[5]采用图像处理的方法,构造出像素点,得出了图像粗糙度的表征公式。这一公式可以定量计算粗糙度,但是采集图像使用的是智能手机,易受光照不均等因素影响图片质量,进而影响计算的准确度。文献[6]采用三维激光扫描技术来获取混凝土表面粗糙度,提出点云校正算法,实现了三维点云计算。但该方法仅为现场使用手持式粗糙度测量仪提供了理论研究的可能性,并没有落实到现场使用。由于上述文献中的方法各有不足,因此混凝土结合面粗糙度质量检测已成为建筑行业亟待解决的关键基础技术难题。因此,研究高效、快捷的混凝土结合面粗糙度等级识别方法具有重要的理论意义和工程价值。

针对混凝土结合面粗糙度等级识别中存在的问题,本文提出了一种基于深度学习的测量方法。先通

过裁剪、旋转和平移等方法获得大量且相同尺寸的数据集图片,解决了采集图片中样本分布不均衡的问题,并提高了模型的泛化能力和鲁棒性;然后运用深度学习模型对大量的图像数据进行训练,得到可靠的、能够识别图像粗糙度等级的深度学习模型。在此模型上加入不同的注意力机制,分析了不同注意力机制对深度学习模型的影响,最终得到最优的粗糙度等级识别模型,以达到提高模型识别精确度、缩短模型识别时间的目的。

1 样本的采集与扩充

1.1 样本采集

选用奥比中光相机采集混凝土结合面的图片,可得到一对一的彩色图与深度图,两种图片的数量均为2 229张,它们的分辨率为128×128。为了增强样本的可靠性和训练模型的泛化能力,需要采集多种类型的结合面图片。图1展示了该相机采集到的几种不同类型的结合面彩色图,这些图片分别为拉毛料、花纹钢板、泡泡膜、小键槽以及露骨料。




图1 部分结合面图片

Fig. 1 Examples of concrete joint surface images

1.2 样本扩充

进行深度学习之前,要确保数据集的均衡性,保证模型的训练和性能不受到影响。为此,本文采取平衡数据集的方法对图片的数量进行处理,以保证后续的深度学习进程不受到样本数量的制约。

首先,对采集到的深度图做算法处理,将不同粗糙度等级的图片分类在不同的文件夹中。其次,在对粗糙度等级进行分类的过程中,发现粗糙度为“光滑”的图片远多于粗糙度为“较光滑”和“粗糙”的图片,因此通过裁剪、旋转等方法对采集的图片数量进行处理,使不同粗糙度等级的图片数量相当。将粗糙度等级为“光滑”的图片设置为“等级 1”,“较光滑”的图片设置为“等级 2”,“粗糙”的图片设置为“等级 3”。按照 7:1:2 的比例,将数据集分为训练集、验证集和测试集三个部分,经过数据扩充以及数据划分后的图片数量如表 1 所示。

表 1 数据划分后的图片数量

Table 1 Number of pictures after data division

粗糙等级	训练集	验证集	测试集	总 数
等级 1	1 085	155	311	1 551
等级 2	1 142	163	327	1 632
等级 3	1 146	163	392	1 638

2 ResNet50_CBAM 粗糙度等级识别模型

2.1 ResNet50 模型

ResNet50 是一个由 50 层卷积神经网络组成的模型,本质属于深度残差网络,其中包含了 1 个全连接层和 49 个卷积层^[7-8]。如图 2 所示,该模型由七个部分组成,其中,二、三、四、五部分包含了残差块。该模型经过前五个部分的卷积计算,到达池化层后会将结果转换为向量的形式,最后经过分类器对向量进行分类。在对数据集进行训练之后,ResNet50 能够在精度和速度上都表现出优于其他深度神经网络的性能^[9],在图像分类、物体检测和计算机视觉问题中都得到了广泛的应用。




图 2 ResNet50 模型

Fig. 2 ResNet50 model

ResNet50 的残差结构如图 3 所示,其特有的多层残差结构可以解决梯度消失问题。图 3 的输入为特征矩阵,直线顺序依次经过了卷积核为 1×1 、 3×3 、 1×1 的卷积层,起到了降维(通道变少)和升维(通道变多)的作用^[10]。经过卷积后的特征矩阵和原特征矩阵相加,最后再经过激活层^[11]。ResNet50 在较浅的网络深度、较少的参数数量以及相对较低的参数复杂度下,所需的训练时间和计算成本都要比其他深度神经网络低得多。




图 3 ResNet50 的残差结构

Fig. 3 Residual structure of ResNet50

通过改变输入层图片尺寸和输出层分类参数,便可以使深度学习模型适应混凝土结合面深度图的大小。在 ResNet50 中,通过卷积层和池化层的操作,将输入的图像信息转化为向量的形式,最后通过 Softmax 函数对向量信息进行分类。在此基础上,通过更改全连接层的权值,能够更好地拟合复杂的非线性关系,最后便可得到训练后的 ResNet50,此时的模型训练速度也得到了提升。

2.2 注意力机制模型

ResNet50 虽然堆叠了很多层,可以提取更多的特征^[12],处理复杂的图像分类任务和识别任务,但是它的残差网络中存在着大量的冗余,在训练的过程中需要更多的计算资源,并且大量的参数也会导致过拟合现象^[13]。为了解决这些问题,将 CBAM 注意力机制、CBAM 空间注意力机制、CBAM 通道注意力机制分别嵌入 ResNet50 中,通过比较三种方式的准确率,找到更好的网络模型。这样不仅结合了卷积和注意力机制,还实现了从空间和通道上对图像进行关注,提升了原本网络模型的性能。

CBAM 是一种轻量的注意力模块,在识别物体上更加敏感^[14],可以在通道和空间维度上实现相应的功能^[15]。实现 CBAM 注意力机制的流程图如图 4 所示。从图中可以看出,CBAM 包括两个相互独立的功能模块,即空间注意力模块和通道注意力模块^[16],可以从空间和通道上实现相应的关注^[17]。




图 4 CBAM 注意力机制流程图

Fig. 4 Flowchart of the CBAM attention mechanism

空间注意力机制利用特征图的内在联系,生成空间关注特征图。与通道注意机制不同,空间注意力机制更多地考虑了特征图上有效信息的位置,相对于通道注意力机制,该方法更侧重于多个局部特征的关联,从而获取更为完整的信息。图 5 显示了该注意力机制的计算流程图。首先,对输入的特征图执行平均池化和最大池化,此过程在通道维度上进行;随后拼接平均池化和最大池化后的特征,再将此特征送入卷积层,得到最后的空间注意力特征图。




图 5 空间注意力机制流程图

Fig. 5 Flowchart of the spatial attention mechanism

通道注意力机制作为 CBAM 的一个子模块,旨在压缩特征图的空间维度,同时通过最大池化和平均池化两种方式对特征图进行空间维度的压缩,从而更多地关注通道上的信息。将这两种池化后的特征同时送到由多个卷积层构成的共享感知机制中,形成最终的通道注意力特征图。由于其中的多个全连接层会造成空间信息损失过多,因此需对通道注意力机制进行改进。在激活函数后加入一层 3×3 的平均池化层,并去掉由多个全连接层构成的共享多层感知机制,重新训练。实验表明:该方式可以减小模型的计算量,在保留整体特征的同时还不容易过拟合,图 6 为改进后的通道注意力机制。




图 6 改进后的通道注意力机制流程图

Fig. 6 Flowchart of the improved channel attention mechanism

2.3 ResNet50 与三种注意力机制结合模型

由于 CBAM 注意力机制由通道和空间注意力机制两种组成,因此分别采用三种方式将注意力机制插在 ResNet50 第一个卷积层之后,再将三种方法得到的精

确度作比较,可得到最佳的组合方式。三种注意力机制插入的方案如下:方式一将通道注意力机制和空间注意力机制串联起来,嵌入第一个卷积层之后;方式二单独将改进的通道注意力机制嵌入第一个卷积层之后;方式三单独将空间注意力机制嵌入在第一个卷积层之后。三种注意力机制与 ResNet50 结合的方式如图 7 所示。在不改变原始主网络的情况下,在 ResNet50 的第一个卷积层后面分别嵌入三种注意力机制。其中,通道和空间注意力机制能够更精准地识别结合面的特征,减少经过神经网络流动的信息冗余^[18];同时,该方法也能解决计算量大的负载问题,缩短网络训练的时间,提高原网络模型的识别效率。




图 7 三种注意力机制与 ResNet50 结合方式图

Fig. 7 Three attention mechanisms combined with ResNet50

3 仿真实验与结果分析

3.1 实验环境

研究以英特尔 Core i7-8565U 为基础进行实验。实验环境配置:CPU 为酷睿 i7 第 8 代系列, GPU 为 MX250, 主频为 1.8 GHz, 运行内存为 8 GB。软件环境基于 Windows 11 系统及 MATLAB 2023a 版本。

在训练模型时采用的训练参数:批大小 (Mini batch size) 为 96, 最大训练次数 (Max epochs) 为 6, 采用 Sgdm 梯度下降法, 验证频次 (Validation frequency) 为 30, 初始学习率 (Initial learn rate) 为 0.001, 学习率下降因子 (Learn rate drop factor) 为 0.8。

3.2 消融实验

为了评估不同模型的性能,需要对三种网络进行消融实验,找出最佳的网络模型,量化以 ResNet50 主干网络为基础的识别效果。在实验过程中,要保证数据集和主网络及其参数均一致,只改变注意力机制的种类,确保只有这一个变量影响到模型的整体性能,最终以验证集的准确率为最终的模型准确率。实验的结果如表 2 所示。

表 2 三种网络模型训练结果

Table 2 Training results of the three network models

注意力机制插入方式	验证集准确率
方式一	60.27%
方式二	93.84%
方式三	91.78%

由表 2 可知,方式一将通道注意力机制和空间注意力机制串联起来,嵌入第一个卷积层之后的准确率最低,低于不加入任何注意力机制的主网络,说明方式一不能有效关注图片的显著特征,反而降低了原本网络的性能。相较于方式三单独将空间注意力机制嵌入在第一个卷积层之后,方式二单独将改进的通道注意力机制嵌入第一个卷积层之后的验证集准确率最高,强化了对图片显著特征的关注,验证集准确率能达到 93.84%。这说明在 ResNet50 的基础上,加入改进的 CBAM 通道注意力机制,可以提高混凝土结合面粗糙度等级的识别准确率。

3.3 不同卷积神经网络准确率对比

将加入 CBAM 通道注意力机制的 ResNet50 与其他网络作对比,可以直观验证该网络的识别准确率。如图 8 所示,R+CC 代表加入 CBAM 通道注意力机制的 ResNet50,R+CS 代表加入 CBAM 空间注意力机制的 ResNet50,R 代表 ResNet50,R+C 代表加入 CBAM 注意力机制的 ResNet50,A 代表 AlexNet,G 代表 GoogLeNet。其中,AlexNet^[19]在 2012 年被设计和提出,是由 ImageNet 比赛获胜者 Hinton 及其学生 Alex Krizhevsky 发明的一种图像分类算法。该算法是基于深度学习的算法,其中包含了 5 个卷积层和 3 个全连接层,可实现大规模 GPU 的集成训练。GoogLeNet^[20]是由 2014 年 ILSVRC 竞赛冠军谷歌提出,它的主要方法是将多个池化或卷积操作连接成一个网络模块,再将多个网络模块连接成 GoogLeNet。因此,GoogLeNet 的结构具有模块化的特征。




图 8 各卷积神经网络准确率

Fig. 8 Accuracy of each convolutional neural network

从图 8 可以看出,相比于 AlexNet 和 GoogLeNet 网络,ResNet50 准确率较高。在 ResNet50 基础上分别加入 CBAM 注意力机制、CBAM 通道注意力机制和 CBAM 空间注意力机制,结果表明:加入 CBAM 通道注意力机制的 ResNet50 准确度最高。

3.4 学习率对模型准确度的影响

学习率通过影响损失函数进而影响是否能找到全局的最优点,学习率过大或过小都会影响网络模型的最佳性能。通过设置四个不同的学习率,分别是 0.01、0.001、0.000 1、0.000 01,来观察模型的准确度情况。

图 9 为不同学习率下 ResNet50_CBAM 通道注意力机制的准确度。从图 9 可以看出,学习率大小对模型性能有显著影响。当学习率为 0.001 时,准确度最高,在此基础上学习率增大或减小,准确度都会下降。因此选用 0.001 作为最终使用的学习率。




图 9 不同学习率下的 ResNet50_CBAM 通道注意力机制准确度

Fig. 9 Accuracy of ResNet50 with CBAM channel attention at different learning rates

3.5 结果分析

为进一步说明添加 CBAM 通道注意力机制后的 ResNet50 能有效识别混凝土结合面粗糙度等级,现计算测试集的混淆矩阵。混淆矩阵由真实结果和预测结果组成^[21-22],同时通过混淆矩阵可以计算出精确率、准确率和召回率^[23]。

准确率 ζ_{acc} 是真正类和真负类在总样本中所占的比例,准确率越高,说明该网络模型的效果越好,计算公式如下:

$$\zeta_{acc} = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FN} + N_{FP} + N_{TN}} \quad (1)$$

精确率 ζ_{pre} 是真正类在真正类和假正类样本中所

占的比例,精确率越高,说明网络模型的效果越好,计算公式如下:

$$\zeta_{\text{pre}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \quad (2)$$

召回率 ζ_{rec} 是真正类在真正类和假负类中所占的比例,召回率的值越大,说明网络模型的效果越好,计算公式如下:

$$\zeta_{\text{rec}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \quad (3)$$

其中,真正类 (N_{TP}) 指的是样本的实际类为正类,模型的辨识结果也为正类;真负类 (N_{TN}) 指的是样本的真实类为负类,并且被模型判定为负类;假正类 (N_{FP}) 指的是样本的真实类别是负类,而模型却把它作为一个正类来鉴别;假负类 (N_{FN}) 指的是样本的真实类别是正类,而被模型判定为负类。

图 10 中,每行数据总和代表这个分类中的真实样本数目,而每列数据之和则代表这个分类中被预测为该类别的样本数目。根据图 10,可计算出该模型的准确率为 93.10%。等级 1 的精确率为 92.23%,召回率为 93.75%;等级 2 的精确率为 93.77%,召回率为 92.05%;等级 3 的精确率为 94.71%,召回率为 92.03%;通过混淆矩阵可以看出,ResNet50_CBAM 通道注意力机制能对测试集图片的粗糙度等级有效划分。




图 10 混淆矩阵

Fig. 10 Confusion matrix

4 结束语

本文提出了一种基于深度学习模型的混凝土结合面粗糙度检测方法。通过对样本扩充,可以达到增强数据的效果。通过对 CBAM 通道注意力机制进行改进,去掉其中的多层感知机制,可以避免空间信息损失过多的问题。经过仿真可知,加入 CBAM 通道注意力

机制的 ResNet50 模型能够更好地识别结合面的粗糙度等级。

将 ResNet50_CBAM 通道注意力机制同时与五种网络模型做对比,发现此网络模型可以很好地提高识别准确率,识别准确率能达到 93.84%。相比于 ResNet50、ResNet50_CBAM 注意力机制、ResNet50_CBAM 空间注意力机制、GoogLeNet 和 AlexNet,ResNet50_CBAM 通道注意力机制准确率分别提高了 6.85%、33.57%、2.06%、10.96%、10.28%。因此,该模型能对混凝土结合面粗糙度等级进行有效识别和分类,在混凝土结合面粗糙度的检测行业中有一定的应用价值。

通过图片采集,该模型也能对桌面、墙壁等物体表面的粗糙度进行检测,缩短实际检测时间,且方式便捷,应用场景较为广泛。

参考文献(References):

- [1] 李健. 高速钢轧辊粗糙度非接触式检测系统的研究[D]. 贵阳: 贵州大学, 2023.
Li Jian. Research on Non-contact Measuring System of High Speed Steel Roll Roughness[D]. Guiyang: Guizhou University, 2023.
- [2] 赵建华, 李敏, 凌良建, 等. 用砂量与测区数对混凝土叠合板粗糙度检测的影响分析[J]. 建筑技术, 2023, 54(21): 2670-2673.
Zhao Jianhua, Li Min, Ling Liangjian, et al. Analysis of the influence of sand amount and measured area number on the roughness detection of concrete composite slab[J]. Architecture Technology, 2023, 54(21): 2670-2673.
- [3] Ma J, Wang T, Li G, et al. Concrete surface roughness measurement method based on edge detection[J]. The Visual Computer, 2024, 40(3): 1553-1564.
- [4] Dai M, Wang X, Cheng C, et al. Efficient evaluation of concrete fracture surface roughness using fringe projection technology[J]. Materials, 2023, 16(12): 4430.
- [5] 甘磊, 金洪杰, 沈振中. 混凝土表面粗糙度数字图像表征方法及应用[J]. 土木工程学报, 2022, 55(8): 67-76.
Gan Lei, Jin Hongjie, Shen Zhenzhong. Digital image characterization method of concrete surface roughness and its application[J]. China Civil Engineering Journal, 2022, 55(8): 67-76.
- [6] Hu N, Chen Z, Ma R, et al. Research on the detection and measurement of roughness of dam concrete layers using 3D laser scanning technology[J]. Sustainability, 2023, 15(3): 2649.
- [7] Li Z, Zhou L, Bin X, et al. Utility of deep learning for the

- diagnosis of cochlear malformation on temporal bone CT[J]. Japanese Journal of Radiology, 2024, 42(3): 261–267.
- [8] Chen Y M, Tsai J T, Ho W H. Automatic identifying and counting blood cells in smear images by using single shot detector and Taguchi method[J]. BMC Bioinformatics, 2022, 22(Suppl 5): 635.
- [9] Talaat F M, El-sappagh S, Alnowaiser K, et al. Improved prostate cancer diagnosis using a modified ResNet50-based deep learning architecture[J]. BMC Medical Informatics and Decision Making, 2024, 24(1): 23.
- [10] 李赫, 王玉, 范凯, 等. 基于深度学习、小波变换和可见光谱的茶树冻害程度评估[J]. 光谱学与光谱分析, 2024, 44(1): 234–240.
- Li He, Wang Yu, Fan Kai, et al. Evaluation of freezing injury degree of tea plant based on deep learning, wavelet transform and visible spectrum[J]. Spectroscopy and Spectral Analysis, 2024, 44(1): 234–240.
- [11] 郝子源, 杨玮, 李浩, 等. 基于多源信息和深度学习的多作物叶面积指数预测模型研究[J]. 光谱学与光谱分析, 2023, 43(12): 3862–3870.
- Hao Ziyuan, Yang Wei, Li Hao, et al. Study on prediction models for leaf area index of multiple crops based on multi-source information and deep learning[J]. Spectroscopy and Spectral Analysis, 2023, 43(12): 3862–3870.
- [12] Du H, Wang W, Wang X, et al. Scene image recognition with knowledge transfer for drone navigation[J]. Journal of Systems Engineering and Electronics, 2023, 34(5): 1309–1318.
- [13] 陈国麟, 姚行艳. 基于 CNN-Transformer 的锂离子电池健康状态估计[J]. 重庆工商大学学报(自然科学版), 2024, 41(2): 66–73.
- Chen Guolin, Yao Xingyan. State of health estimation of lithium-ion battery based on CNN-transformer[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2024, 41(2): 66–73.
- [14] Yang F, Wang F, Luan Z, et al. Automatic segmentation of gas plumes from multibeam water column images using a U-shape network[J]. Journal of Oceanology and Limnology, 2023, 41(5): 1753–1764.
- [15] Yang R, Du Y, Kwan W, et al. A quick and reliable image-based AI algorithm for evaluating cellular senescence of gastric organoids[J]. Cancer Biology & Medicine, 2023, 20(7): 519–536.
- [16] Zhuang H, Xia Y, Wang N, et al. Interactive method research of dual mode information coordination integration for astronaut gesture and eye movement signals based on hybrid model[J]. Science China Technological Sciences, 2023, 66(6): 1717–1733.
- [17] Yang Y J, Liu Y M, Zhang W J, et al. SNR-adaptive deep joint source-channel coding scheme for image semantic transmission with convolutional block attention module[J]. The Journal of China Universities of Posts and Telecommunications, 2024, 31(1): 1–11.
- [18] 袁培森, 丁毅飞, 徐焕良. 基于深度主动学习与 CBAM 的细粒度菊花表型识别[J]. 农业机械学报, 2024, 55(2): 258–267.
- Yuan Peisen, Ding Yifei, Xu Huanliang. Fine-grained chrysanthemum phenotype recognition based on deep active learning and CBAM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 258–267.
- [19] K G D, Balasubramanian K, C S. Feature analysis and classification of maize crop diseases employing AlexNet-inception network[J]. Multimedia Tools and Applications, 2024, 83(9): 26971–26999.
- [20] 江莉, 向世召. 基于 CEEMDAN-VSSLMS 的滚动轴承故障诊断[J]. 计算机集成制造系统, 2024, 30(3): 1138–1148.
- Jiang Li, Xiang Shizhao. Rolling bearing fault diagnosis based on CEEMDAN-VSSLMS[J]. Computer Integrated Manufacturing Systems, 2024, 30(3): 1138–1148.
- [21] Riehl K, Neunteufel M, Hemberg M. Hierarchical confusion matrix for classification performance evaluation[J]. Journal of the Royal Statistical Society Series C: Applied Statistics, 2023, 72(5): 1394–1412.
- [22] 刘小峰, 舒仁杰, 柏林, 等. 一种新的稀疏分类融合方法及其在机车轴承故障诊断中的应用[J]. 中国电机工程学报, 2020, 40(17): 5675–5682.
- Liu Xiaofeng, Shu Renjie, Bai Lin, et al. A novel sparse classification fusion method and its application in locomotive bearing fault diagnosis[J]. Proceedings of the CSEE, 2020, 40(17): 5675–5682.
- [23] 高珂, 翁顺, 陈志丹, 等. 基于模式识别的结构健康监测异常数据诊断[J]. 建筑结构学报, 2024, 45(3): 113–122.
- Gao Ke, Weng Shun, Chen Zhidan, et al. Pattern recognition-based data anomaly detection for structural health monitoring[J]. Journal of Building Structures, 2024, 45(3): 113–122.

责任编辑:陈 芳