

基于改进 ResNeXt50 残差网络的锦鲤选美方法

王军龙¹ 宣 魁¹ 熊海涛¹ 王 峰² 李 娟¹

(1. 青岛农业大学机电工程学院, 青岛 266109; 2. 青岛农业大学海洋科学与工程学院, 青岛 266109)

摘要: 锦鲤选美的不同等级之间具有高相似度的特点,目前都是人工进行选美分级。为解决人工选美所存在的效率低、主观性强、成本高的问题,提出了一种基于迁移学习和改进 ResNeXt50 残差网络的锦鲤选美方法。本文首先构建了红白、大正、昭和 3 种锦鲤的选美等级数据集。其次,采用迁移学习策略提高训练速度,并从 SE 注意力模块、Hardswish 激活函数和 Ranger 优化器 3 方面对 ResNeXt50 模型进行了改进,构建了 SH-ResNeXt50 锦鲤选美分级模型。试验结果表明:SH-ResNeXt50 模型有效提升了锦鲤选美的等级分选能力,模型准确率达 95.6%,损失值仅 0.074,优于常用的 AlexNet、GoogLeNet、ResNet50 和 ResNeXt50 网络模型。最后,采用 Grad-CAM 分析 SH-ResNeXt50 模型的可解释性,结果表明 SH-ResNeXt50 模型和人工识别的感兴趣区域基本一致。本文所提出的方法实现了具有高相似度的锦鲤不同等级的智能分选,对其它具有高相似度的生物等级分选具有借鉴意义。

关键词: 锦鲤选美; 等级分选; 迁移学习; 深度学习; 目标识别; 目标分类

中图分类号: TP393 文献标识码: A 文章编号: 1000-1298(2023)S1-0330-08

Beauty Pageant of Koi Method Based on Improved ResNeXt50 Residual Network

WANG Junlong¹ XUAN Kui¹ XIONG Haitao¹ WANG Feng² LI Juan¹

(1. College of Electrical and Mechanical Engineering, Qingdao Agricultural University, Qingdao 266109, China

2. College of Marine Science and Engineering, Qingdao Agricultural University, Qingdao 266109, China)

Abstract: There is a high similarity among different levels of the koi for beauty pageant, and beauty grading for koi is currently done manually. To solve these problems of low efficiency, strong subjectivity and high cost of manual beauty pageants, a sorting method for koi beauty pageant was proposed based on transfer learning and improved ResNeXt50 residual network. Firstly, a rank dataset was constructed for the beauty pageant on Kohaku, Taisho and Showa koi. Secondly, the transfer learning strategy was adopted to improve the training speed and improve the ResNeXt50 model from three aspects of SE attention module, Hardswish activation function and Ranger optimizer, further a SH-ResNeXt50 classification model was proposed and constructed for koi pageant. The experimental results showed that the SH-ResNeXt50 model effectively improved the sorting ability for koi beauty pageant, with an accuracy of 95.6% and a loss value of only 0.074, which was better than the commonly used AlexNet, GoogLeNet, ResNet50 and ResNeXt50 network models. Finally, the interpretability of SH-ResNeXt50 model was analyzed by Grad-CAM, and the results showed that the regions of interest of SH-ResNeXt50 model was basically consistent with those recognized by the humans. The approach proposed realized the intelligent sorting of different levels of koi beauty pageant with high similarity, which had reference significance for other biological level sorting with high similarity.

Key words: beauty pageant of koi; level sorting; transfer learning; deep learning; object detection; object classification

收稿日期: 2023-05-20 修回日期: 2023-08-16

基金项目: 国家自然科学基金项目(32073029)、山东省自然科学基金重点项目(ZR2020KC027)和山东省研究生教育质量提升计划项目(SDYJG19134)

作者简介: 王军龙(1997—),男,硕士生,主要从事深度学习和图像识别研究,E-mail: 1396760119@qq.com

通信作者: 李娟(1969—),女,教授,博士生导师,主要从事机器视觉、人工智能和故障诊断研究,E-mail: lijuan291@sina.com

0 引言

锦鲤作为具有美好寓意的观赏鱼,因绚丽的色彩、潇洒的泳姿,被誉为“水中活宝石”^[1]。锦鲤种类繁多、价值差异性大且相似度高,因此锦鲤的选美在锦鲤育种和养殖中具有重要的作用。目前,锦鲤的等级选美以及品种周期性筛选全部都是人工进行^[2],存在效率低、劳动强度高、成本高、主观性强等问题。因此,开展锦鲤的智能选美方法研究对于选美和育种都具有重要的理论意义和应用价值。

随着锦鲤养殖规模的扩大,锦鲤的市场价值也在不断增加。由于不同锦鲤品种的价格和观赏价值差异非常大,锦鲤的选美和育种分选越来越重要。因受到了学者们的重视。彭芳等^[3]对红白、大正与昭和品种进行了分类,并提出了锦鲤的 4 级分类方法。宋述芹等^[4]从颜色、图案和谱系的角度人工将锦鲤分为 3 个品种。然而,传统的锦鲤人工选美分类方法存在效率低、工作强度大等缺点。更重要的是需要专业人士进行分选,而由于熟练度、水平和判别标准的不同,分类错误情况经常发生。近年来,随着人工智能的发展^[5-7],深度学习已广泛应用于图像识别和图像分类等多个领域^[8-10]。在对鱼类的分类方面,万鹏等^[11]提出了一种基于改进 ResNet50 模型的淡水鱼种类识别方法,对 6 种淡水鱼进行识别。GONG 等^[12]提出了一种基于迁移学习和视觉转换器的多鱼分类 (Fish-TViT) 的方法,在高、低分辨率环境下对淡水鱼类进行了分类研究。然而,对于锦鲤分类的研究却鲜见。ZHENG 等^[13]构建了 KRS-Net 分类网络对 13 种不同种类的锦鲤进行品种分类,测试准确率达到 97.9%。但其只是对锦鲤的不同品种进行分类。目前还没有对锦鲤选美等级进行智能分类的研究报道。而锦鲤选美属于在同一类别中分出不同等级,存在同一选美等级的锦鲤具有相似度高难以分辨的问题。

为了解决上述问题,本文构建一个选美分选数据集,并提出 SH-ResNeXt50 选美模型,以实现锦鲤选美的等级分选,并通过与主流网络 (AlexNet^[14]、GoogLeNet^[15]、ResNet50^[16] 和 ResNeXt50^[17]) 进行对比实验,验证本文方法的优越性。

1 材料与方法

1.1 锦鲤选美分级标准

目前,锦鲤的选美将锦鲤的体型、色彩、花纹和鳞片作为评选标准。锦鲤的脊柱必须笔直;锦鲤的

体高与体长比应为 1:2.6 至 1:3 之间;头顶部应丰厚饱满,整体花纹需匀称,总量不应少于体表面积的 30%。

红白锦鲤具体要求是身体背部花纹要分布匀称,斑纹的边际整洁,红斑和白色间无过渡色。红斑花纹在头部不过嘴吻,两边不下眼,腮盖部分要明亮,没有红斑的插入;大正锦鲤要求头部不能有墨,肩部必须有墨,墨的规律是小斑块,不太连贯的墨,底色为纯白色,头部无黑斑,其头部着色不应渲染眼鼻、颊部及顶端吻部,胸鳍以有 2~3 条黑纹为优;昭和锦鲤头部需有大块红斑或墨斑,色质均匀边缘清晰、色彩较深为好。鱼身斑纹一定要为白色,需占全身的 20%,胸鳍要大小适中,占总身长的 1/4,且胸鳍的颜色为元黑最佳。根据上述评选标准将锦鲤进行划分。

1.2 图像采集

以红白、大正与昭和 3 种锦鲤作为研究对象,使用佳能数码相机 (EOS 200D 型) 采集分辨率 2 400 像素×1 600 像素的锦鲤原始图像各 185、149、217 幅。图 1 展示了 3 个品种锦鲤图像。数据集取自锦鲤的实际养殖数据,采用的方法也将应用于锦鲤的实际养殖和生产中,为养殖户进行锦鲤的等级划分提供切实可行的方法。




图 1 3 种锦鲤品种图像

Fig. 1 Images of three kinds of koi

1.3 图像增强

首先,将红白、大正和昭和锦鲤图像各分成 5 个等级,包括极品、一类、二类、三类、四类,分别标记并存放至相应位置,供程序调用。其次为了提高卷积神经网络的泛化能力以及防止模型在训练过程中出现过拟合,对 551 幅锦鲤图像通过调整亮度、对比度、色度、镜像、旋转、水平和垂直平移 6 种图像增强方法进行数据增强,来提高训练后模型的鲁棒性,数据增强效果如图 2 所示。

该数据集在图像增强后每个具有 5 种等级的锦鲤共 8 948 幅图像,包括训练集中的 6 727 幅图像、测试集中的 2 221 幅图像。由于红白、大正和昭和的图像扩展数量足够,没有将 3 个品种的原始图像进行训练。本文对锦鲤图像进行了数据增强处理后,各品种的具体图像数量见表 1。




图2 数据增强效果示意图
Fig.2 Schematic of data enhancement effect

表1 3种锦鲤品种图像数量

锦鲤品种	原始图像数量	扩增的数量	扩增后图像数量
红白	185	2 780	2 965
大正	149	2 357	2 506
昭和	217	3 290	3 507
总数	551	8 427	8 948

1.4 迁移学习训练策略

通过引入迁移学习策略,利用 ImageNet 数据集对原始网络模型进行预训练,利用预训练模型的初始权重对网络参数进行初始化,将预训练模型迁移到锦鲤图像识别中,对预训练模型的权重与偏差进行微调,以提高模型的泛化能力与分类识别效果^[18]。迁移学习减少了构建深度学习网络模型所需的训练数据量和实验平台的计算力,使得模型无须从零开始重新训练和学习^[19]。

1.5 试验设备

运行深度学习模型使用的硬件配置以及相应的操作环境如表 2 所示。在此硬件和配置环境下,使用 Pytorch 搭建试验平台,运行程序的批量大小设置为 16,训练集、测试集按照比例 8:2 进行划分,计算机配置 2 个 NVIDIA RTX2080Ti 的 GPU 和 1TB 的存储容量,因此计算机硬件条件的配置能达到所用深度学习模型的要求。

表2 系统配置

系统配置	型号/数值
操作系统	Windows 10
GPU	NVIDIA RTX2080 Ti
CPU	Intel Xeon E5-4627 v4
运行内存/GB	64
存储容量/TB	1
编程语言	Python
Python 版本	Python 3.10.10

2 改进 ResNeXt50 的深度学习算法

2.1 SE 注意力模块

近年来,注意力模块在深度学习中得到了广泛的应用^[20]。在自然语言处理和图像分割领域注意力模块已经取得了很大的进展^[21]。注意力模块将注意力集中在感兴趣区域,抑制不必要的特征,对不同的特征赋予不同的权重,提高模型的效率和准确性^[22]。SENet (Squee-and-exciting network) 是一种代表性的通道注意力机制,具有结构简单,易于部署,不需要引入新功能或层次的优点^[23]。SE 模块网络结构如图 3 所示。每个通道 C 的输入特征 I 首先通过挤压操作 F_{sq} 在空间维度上进行压缩。然后,他们被输送到激励操作 F_{ex} 的全连接层中,以及每个特征通道的权重由 sigmoid 激活函数生成。最后,Reweight 操作完成每个原始特征的重新缩放以获得注意特征提取结果。其中, F_{sq} 和 F_{scale} 分别是全局平均池化和加权操作, F_{ex} 表示通过 2 个全连接和激活函数进行处理。 F_{sq} 、 F_{ex} 、 F_{scale} 的计算式如下

$$F_{sq}(u_c) = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W u_c(i,j) \tag{1}$$

$$F_{ex}(z,W) = \sigma(W_2 \sigma(W_1 z)) \tag{2}$$

$$F_{scale}(u_c,s_c) = s_c u_c \tag{3}$$

式中 $u_c(i,j)$ ——位置 (i,j) 的 C 通道的特征值
 $H、W$ ——特征张量的高度与宽度
 $W_1、W_2$ ——参数矩阵
 σ ——sigmoid 激活函数
 $u_c、s_c$ ——二维矩阵与权重




图3 SENet 网络结构
Fig.3 SENet network structure

2.2 Hardswish 激活函数

Hardswish 激活函数的加入可以增强网络非线性能力,提高了神经网络的表达能力,有效缓解 ReLU 激活函数神经元坏死的问题。不仅具有良好的数值稳定性和快速计算速度的优点,而且还可以提取图像中最大池化层的主要信息,同时减少运算量,且可以作为分割函数来实现减少内存访问次数^[24]。因此,为了进一步提高本文锦鲤等级分选的认识能力,在使用 SE 注意力模块改进残差单元后,用 Hardswish 激活函数将 ResNeXt50 与 SE 注意力模

块网络结构中的 ReLU 激活函数全部替代,进一步提高了模型的鲁棒性和泛化能力。Hardswish 激活函数 $f(x)$ 为

$$f(x) = \begin{cases} 0 & (x \leq -3) \\ x & (x \geq 3) \\ \frac{x(x+3)}{6} & (-3 < x < 3) \end{cases} \quad (4)$$

$f(x)$ 用于过滤输入数据 x ,通过特征映射的方式控制输入数据 x 从底层到顶层的传输,并在 40 层以上的网络上优于其他激活函数。

2.3 Ranger 优化器

深度学习最常用的优化方法是随机梯度下降法,但在大规模数据训练中,该方法效率偏低。随机梯度下降是当前神经网络中使用最为广泛的优化算法之一,但该算法训练速度慢,同时很容易使模型陷入局部最优解中。为了使模型具有较好的泛化能力和更快的训练速度,本文引入了 Ranger

优化器,该优化器综合了 RAdam 与 LookAhead 优化器的优点,对学习率适应性增强,可以根据不同参数的梯度大小来自动调整学习率,来避免学习率过大或过小导致训练不稳定问题,使模型获得更高的收敛速率,并且在不同任务上具有较好的通用性^[25]。

2.4 SH-ResNeXt50 识别算法构建

为了更好地提高算法的性能,缓解 ResNet50 模型在特征融合过程中没有区分每个通道特征的问题,研究改进 ResNeXt50 的锦鲤等级分选识别深度学习算法。图 4 显示了用于锦鲤等级分选识别的 SH-ResNeXt50 的示意图。首先在每个残差单元中引入 SE 注意力模块,根据每个特征通道的重要性自适应重新校准,并将其与原特征融合,有效提高了残差单元的利用率。此外,将网络中的 ReLU 激活函数用 Hardswish 激活函数替代来提高网络的性能,并且模型训练使用 Ranger 优化器来提高它的




图 4 SH-ResNeXt50 网络结构示意图

Fig. 4 SH-ResNeXt50 network structure diagram

性能。

2.5 评价指标

为了对比不同模型的准确程度,保证最优模型的识别效果,以准确率和损失值判定锦鲤分选识别模型的性能。准确率反映网络模型识别的准确程度,损失值是指损失函数的收敛值,当预测类别与真实标签相同时, $y_i = 1$, 否则 $y_i = 0$ 。

3 试验结果分析与讨论

3.1 改进 ResNeXt50 的锦鲤等级选美模型参数设置

本研究所调整的模型参数为网络输入图像尺寸、批量大小、学习率、全连接层的输出和训练的迭代次数。改进 ResNeXt50 模型的参数设置如表 3 所示。

表 3 改进 ResNeXt50 模型参数

参数	数值
输入图像尺寸/(像素×像素)	224×224
学习率	1.0×10^{-4}
批量大小	16
分类类别数	15
训练迭代次数	100

3.2 SH-ResNeXt50 与经典模型对比

AlexNet 模型训练结果如图 5 所示,随着迭代次数的增加,AlexNet 模型训练集和测试集准确率分

别稳定在 86.6% 和 86.3%;损失值先大幅度下降后趋于稳定,最终训练集损失值稳定在 0.344 附近,测试集损失值稳定在 0.326。

GoogLeNet 模型训练结果如图 6 所示,随着迭代次数增加,模型准确率逐渐提高后趋于稳定,训练集与测试集两者准确率最终稳定在 90.3%、90.6%;模型损失值下降后慢慢趋向稳定,最终,训练集、测试集的损失值分别稳定在 0.229、0.313。与 AlexNet 模型相比,训练集准确率提高 3.7 个百分点,测试集准确率提高 4.3 个百分点,训练集和测试集损失值分别降低 0.115 和 0.013。




图 5 AlexNet 模型准确率和损失值

Fig.5 Accuracy and loss values of AlexNet model




图 6 GoogLeNet 模型准确率和损失值

Fig.6 Accuracy and loss values of GoogLeNet model

ResNeXt50 模型是 ResNet50 模型的提升与改进,ResNeXt50 模型利用残差连接和组卷积来最大化特征提取能力。试验表明,ResNeXt50 模型的训练集和测试集准确率为 92.6%、92.8%,相比于

ResNet50 模型,分别提升 0.4 个百分点,训练集与测试集损失值分别为 0.114、0.121,两者分别降低 0.068、0.038,未出现过拟合和欠拟合现象。ResNeXt50 模型准确率和损失值如图 7 所示。




图 7 ResNeXt50 模型准确率和损失值

Fig.7 Accuracy and loss values of ResNeXt50 model

SH-ResNeXt50 模型结果如图 8 所示,随着迭代次数的增加,SH-ResNeXt50 模型训练集与测试集准确率

逐渐增加,分别稳定在 95.4%、95.6%,损失值先逐渐下降,后趋于稳定,分别稳定在 0.102、0.074。




图 8 SH-ResNeXt50 模型准确率和损失值

Fig. 8 Accuracy and loss values of SH-ResNeXt50 model

如表 4 所示,为了验证该算法有效性,SH-ResNeXt50 模型的测试准确率与经典算法 AlexNet、GoogLeNet、ResNet50、ResNeXt50 相比分别提高 9.3、5.3、2.8、2.4 个百分点。由于引入 SE 注意力模块,替换了激活函数并结合了 Ranger 优化器,增加了模型计算量,因此模型训练时间相对于其他模型略有增加,但是提高了模型鲁棒性和泛化能力。

表 4 SH-ResNeXt50 模型与经典模型测试集结果对比
Tab. 4 Comparison of SH-ResNeXt50 model and classical model test set results

模型	训练一轮用时/s	准确率/%	损失值
AlexNet	216	86.3	0.326
GoogLeNet	221	90.3	0.229
ResNet50	227	92.8	0.159
ResNeXt50	206	93.2	0.121
SH-ResNeXt50	242	95.6	0.074

综上所述,以训练集、测试集准确率和损失值为评价指标,AlexNet、GoogLeNet、ResNet50、ResNeXt50 模型以及构建的 SH-ResNeXt50 模型的准确率依次增强,损失值逐次降低,验证了 SH-ResNeXt50 模型的有效性。

3.3 添加不同模块对 ResNeXt50 网络的影响

为了进一步探讨 SH-ResNeXt50 网络的高效性,设计 5 组消融试验分析 SE 注意力模块、Hardswish 激活函数 $f(x)$ 和 Ranger 优化器对锦鲤等级识别结果的影响。消融试验结果如表 5 所示,其中“√”表示采用此项,“×”表示未采用此项。

为了验证 SE 注意力模块的可行性,将原始的 ResNeXt50 模型中的残差单元替换成经过 SE 模块改进的残差单元。如表 5 所示,在仅采用 SE 注意力模块改进后,准确率为 94.3%,提高 1.1 个百分点,这表明引入 SE 注意力模块有助于构建更好的锦鲤等级识别模型。

表 5 消融试验

Tab. 5 Ablation experiment

模型	试验 1	试验 2	试验 3	试验 4	试验 5
SE 模块	×	√	×	√	√
Hardswish	×	×	√	√	√
Ranger	×	×	×	×	√
准确率/%	93.2	94.3	93.8	94.5	95.6

为了探索 Hardswish 激活函数 $f(x)$ 的有效性,在试验中将原有模型的 ReLU 激活函数全部替换成了 Hardswish 激活函数 $f(x)$,由于它可以产生很强的正则化效果,并在任何地方都是连续可导的,因此模型识别精度提高 0.6 个百分点。

在研究 Ranger 优化器对模型的贡献时,将最常用的 Adam 优化器替换成 Ranger 优化器。实验表明 Ranger 优化器的引入使模型准确率提高 1.1 个百分点,模型的泛化能力和性能显著提升。以上结果表明 SE 注意力机制、Hardswish 激活函数和 Ranger 优化器的组合对 ResNeXt50 网络模型在提高锦鲤等级分选的识别中是有效可靠的。

3.4 不同激活函数和优化器对模型的影响

为了增强 SH-ResNeXt50 网络的说服力,对添加不同激活函数和优化器的网络模型进行对比验证。试验表明,如表 6 所示,使用 SGD 优化器时,模型准确率低且训练用时没有优势;对于使用 Adam、Ranger 优化器的模型来说,添加 Hardswish 激活函数比有 LeakReLU 激活函数的网络模型的准确率分别提高 0.4、1.5 个百分点,损失值下降 0.012、0.042;使用相同激活函数的模型,不同优化器下准确率分别提高 0.2、1.3 个百分点,损失值分别下降 0.01、0.04。综合对比来看,SH-ResNeXt50 的训练时间虽有所增加,但准确率有所提高,损失值有所下降,增强了 SH-ResNeXt50 网络模型的性能。

3.5 模型可解释性

深度学习算法的可解释性是理解工作原理的重

表 6 添加不同激活函数和优化器的模型性能结果对比

Tab.6 Adding different activation functions and optimizers to compare model performance results

模型	训练一 轮用时/s	测试集 准确率/%	损失值
SE + ResNeXt50 + LeakReLU + Adam	212	93.9	0.126
SE + ResNeXt50 + LeakReLU + SGD	221	64.9	0.743
SE + ResNeXt50 + LeakReLU + Ranger	204	94.1	0.116
SE + ResNeXt50 + Hardswish + Adam	229	94.3	0.114
SE + ResNeXt50 + Hardswish + SGD	225	70.6	0.725
SE + ResNeXt50 + Hardswish + Ranger	242	95.6	0.074

要参考,采用梯度分类激活图(Grad class activation mapping, Grad-CAM)^[26],选择算法的最后一层卷积中提取的特征将图像进行可视化。在锦鲤等级选美识别算法中可视化的感兴趣区域如图 9 所示。与蓝色区域相比,图像红色和黄色区域是锦鲤识别算法更感兴趣的区域。其中颜色越红,该区域对算法的贡献越大。由此可知,锦鲤的纹理、色彩是进行等级分选

时识别贡献较高的特征,这与人工识别感兴趣区域是一致的。




图 9 锦鲤 Grad-CAM 可视化结果

Fig.9 Grad-CAM visualization results of koi

4 结束语

针对人工进行锦鲤等级选美、育种周期性筛选时存在的效率低,主观性差异大,劳动强度高等问题,通过引入迁移学习策略,从 SE 注意力模块、Hardswish 激活函数以及结合新的 Ranger 优化器 3 方面对 ResNeXt50 模型进行改进,构建了 SH-ResNeXt50 模型,模型准确率为 95.6%,损失值仅 0.074,试验结果证明了本文方法的有效性。通过与经典算法对比,验证了本文方法在锦鲤等级选美时具有较好的鲁棒性和泛化能力。Grad-CAM 分析结果表明 SH-ResNeXt50 模型的可信性。该方法为高相似度物种的等级分选提供了新的思路,对水产养殖和育种具有潜在的实用价值。

参 考 文 献

[1] 李潇轩,李志辉,尹陆乐,等. 浅谈锦鲤文化传承与发展[J]. 水产养殖, 2020, 41(3): 78-80.
LI Xiaoxuan, LI Zhihui, YIN Lule, et al. Discussion on the cultural inheritance and development of koi carp[J]. Aquaculture, 2020, 41(3): 78-80. (in Chinese)

[2] BAIRWA M K, SAHARAN N, RAWAT K D, et al. Effect of LED light spectra on reproductive performance of koi carp (Cyprinus carpio)[J]. Indian Journal of Animal Research, 2017, 51(6): 1012-1018.

[3] 彭芳,陈康勇,钟为铭,等. 三种锦鲤的分类和鉴赏[J]. 科学养鱼, 2018(8):82-83.
PENG Fang, CHEN Kangyong, ZHONG Weiming, et al. Classification and appreciation of three species of koi[J]. Sci. Fish Farming, 2018(8): 82-83. (in Chinese)

[4] 宋述芹,段培旭. 锦鲤及其品种分类[J]. 齐鲁渔业, 2009(26): 53-54.
SONG Shuqin, DUAN Peixu. Koi and its variety classification[J]. Shandong Fish, 2009(26): 53-54. (in Chinese)

[5] 李道亮,王帅星,王聪. 柔性可穿戴传感技术在智慧渔业中的应用进展[J]. 农业工程学报, 2023, 39(13):1-13.
LI Daoliang, WANG Shuaixing, WANG Cong. Application of flexible wearable sensing technology in smart fishery[J]. Transactions of the CSAE, 2023, 39(13): 1-13. (in Chinese)

[6] 赵博,宋正河,毛文华,等. 基于 PSO 与 K-均值算法的农业超绿图像分割方法[J]. 农业机械学报, 2009, 40(8): 166-169.
ZHAO Bo, SONG Zhenghe, MAO Wenhua, et al. Agriculture extra-green image segmentation based on PSO and K-means clustering[J]. Transactions of the Chinese Society for Agricultural Machinery, 2009, 40(8): 166-169. (in Chinese)

[7] GREWAL P S, OLOUMI F, RUBIN U, et al. Deep learning in ophthalmology: a review[J]. Canadian Journal of Ophthalmology-Journal Canadien D Ophtalmologie, 2018, 53(4): 309-313.

[8] LIU P, ZHANG C F, QI H, et al. Multi-attention DenseNet: a scattering medium imaging optimization framework for visual data pre-processing of autonomous driving systems[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(12): 396-407.

[9] 戚超,左毅,陈哲琪,等. 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.
QI Chao, ZUO Yi, CHEN Zheqi, et al. Rice processing accuracy classification method based on improved VGG16 convolution neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(5): 301-307. (in Chinese)

[10] 高新怡,陈琦,陈冠宇,等. 卷积神经网络在实时检测领域的研究[J]. 软件工程, 2022, 25(6): 22-29.

- GAO Xinyi, CHEN Qi, CHEN Guanyu, et al. Research on convolutional neural networks in real-time detection[J]. *Software Engineering*, 2022, 25(6): 22–29. (in Chinese)
- [11] 万鹏, 赵竣威, 朱明, 等. 基于改进 ResNet50 模型的大宗淡水鱼种类识别方法[J]. *农业工程学报*, 2021, 37(12): 159–168.
- WAN Peng, ZHAO Junwei, ZHU Ming, et al. Freshwater fish species identification method based on improved ResNet50 model[J]. *Transactions of the CSAE*, 2021, 37(12): 159–168. (in Chinese)
- [12] GONG B, DAI K Y, SHAO J, et al. Fish-TViT: a novel fish species classification method in multi water areas based on transfer learning and vision transformer[J]. *Heliyon*, 2023, 9(6): e16761.
- [13] ZHENG Y L, DENG L M, LIN Q, et al. KRS-Net: a classification approach based on deep learning for koi with high similarity[J]. *Biology-Basel*, 2022, 11(12): 1727.
- [14] JU Z Y, XUE Y J. Fish species recognition using an improved AlexNet model[J]. *Optik*, 2020, 223: 165499.
- [15] HUANG X, CHEN W, YANG W. Improved algorithm based on the deep integration of googlenet and residual neural network [J]. *Journal of Physics: Conference Series*, 2021, 1757(1): 012069.
- [16] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770–778.
- [17] XIE S, GIRSHICK R, DOLLAR P, et al. Aggregated residual transformations for deep neural networks[C] // Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 5987–5995.
- [18] 袁培森, 宋进, 徐焕良. 基于残差网络和小样本学习的鱼图像识别[J]. *农业机械学报*, 2022, 53(2): 282–290.
- YUAN Peisen, SONG Jin, XU Huanliang. Fish image recognition based on residual network and few-shot learning[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(2): 282–290. (in Chinese)
- [19] 彭红星, 何慧君, 高宗梅, 等. 基于改进 ShuffleNetV2 模型的荔枝病虫害识别方法[J]. *农业机械学报*, 2022, 53(12): 290–300.
- PENG Hongxing, HE Huijun, GAO Zongmei, et al. Litchi diseases and insect pests identification method improved ShuffleNetV2[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(12): 290–300. (in Chinese)
- [20] 孙龙清, 王新龙, 王泊宁, 等. 基于 ResNet-CA 的鱼群饱腹程度识别方法[J]. *农业机械学报*, 2022, 53(增刊 2): 219–225, 277.
- SUN Longqing, WANG Xinlong, WANG Boning, et al. Identification method of fish satiation level based on ResNet-CA[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(Supp. 2): 219–225, 277. (in Chinese)
- [21] CHEN J D, ZHANG D, ZEB A, et al. Identification of rice plant diseases using lightweight attention networks[J]. *Expert Systems With Applications*, 2021, 169: 114514.
- [22] AVILES J C, KOUKI A. Position-aided mm-wave beam training under NLOS conditions[J]. *IEEE Access*, 2016, 4: 8703–8714.
- [23] HU J, SHEN L, SUN G. Squeeze-and-Excitation networks[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 7132–7141.
- [24] 薛勇, 王立扬, 张瑜, 等. 基于 GoogLeNet 深度迁移学习的苹果缺陷检测方法[J]. *农业机械学报*, 2020, 51(7): 30–35.
- XUE Yong, WANG Liyang, ZHANG Yu, et al. Defect detection method of apples based on GoogLeNet deep transfer learning [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(7): 30–35. (in Chinese)
- [25] 徐建鹏, 王杰, 徐祥, 等. 基于 RAdam 卷积神经网络的水稻生育期图像识别[J]. *农业工程学报*, 2021, 37(8): 143–150.
- XU Jianpeng, WANG Jie, XU Xiang, et al. Image recognition for different developmental stages of rice by RAdam deep convolutional neural networks[J]. *Transactions of the CSAE*, 2021, 37(8): 143–150. (in Chinese)
- [26] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization[J]. *International Journal of Computer Vision*, 2020, 128(2): 336–359.