

# 基于改进 ResNet50 模型的大宗淡水鱼种类识别方法

万 鹏<sup>1,2</sup>, 赵竣威<sup>1</sup>, 朱 明<sup>1,2</sup>, 谭鹤群<sup>1,2</sup>, 邓志勇<sup>1</sup>, 黄毓毅<sup>1</sup>,  
吴文锦<sup>3</sup>, 丁安子<sup>3</sup>

(1. 华中农业大学工学院, 武汉 430070; 2. 农业农村部长江中下游农业装备重点实验室, 武汉 430070; 3. 湖北省农业科学院农产品加工与核农技术研究所, 武汉 430070)

**摘 要:** 针对传统鱼类识别方法存在特征提取复杂、算法可移植性差等不足, 该研究提出了一种基于改进 ResNet50 模型的淡水鱼种类识别方法。研究以鳊鱼、鳙鱼、鲤鱼、鲫鱼、草鱼、白鲢 6 种大宗淡水鱼为对象, 通过搭建淡水鱼图像采集系统获取具有单一背景的淡水鱼图像, 同时通过互联网搜索具有干扰背景的淡水鱼图像, 共同构建淡水鱼图像数据集; 再对淡水鱼图像进行预处理, 以增加样本多样性; 构建改进 ResNet50 模型, 增加全连接层 Fc1 以及 Dropout, 引入迁移学习机制训练模型, 同时选择 CELU 作为激活函数提高神经网络表达能力, 通过 Adam 优化算法更新梯度, 并嵌入余弦退火方法衰减学习率。为验证改进 ResNet50 模型的准确率等性能, 对 6 种淡水鱼进行种类识别, 结果表明: 在单次验证方法下, 选用包含单一背景图像和干扰背景图像构成的淡水鱼图像数据集训练模型, 识别准确率为 96.94%, 比经典模型提高 1.22%, 单张淡水鱼图像样本的平均检测时间为 0.234 5 s; 在四折交叉验证下, 选用具有单一背景图像的数据集, 模型的识别准确率为 100%, 选用包含单一背景图像和干扰背景图像的淡水鱼图像数据集, 模型的识别准确率为 96.20%, 说明模型具有较好的泛化性能和鲁棒性。针对混淆矩阵的可视化结果表明: 改进的 ResNet50 模型具有通用的结构和训练方式, 对不同背景下的淡水鱼进行种类识别具有较高的准确率, 可为淡水鱼种类识别提供技术借鉴。

**关键词:** 图像识别; 水产养殖; 淡水鱼; 种类识别; 深度学习; 改进 ResNet50 模型; 超参数优化; 可视化

doi: 10.11975/j.issn.1002-6819.2021.12.019

中图分类号: TP391.4

文献标志码: A

文章编号: 1002-6819(2021)-12-0159-10

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. doi: 10.11975/j.issn.1002-6819.2021.12.019 http://www.tcsae.org

Wan Peng, Zhao Junwei, Zhu Ming, et al. Freshwater fish species identification method based on improved ResNet50 model[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2021, 37(12): 159-168. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.2021.12.019 http://www.tcsae.org

## 0 引 言

中国是淡水鱼养殖大国, 2019 年淡水鱼养殖产量 2 548.02 万 t, 占全部淡水养殖总产量的 84.55%<sup>[1]</sup>。淡水鱼种类繁多, 品种之间差异很大; 淡水鱼的种类识别在淡水鱼的养殖、捕捞、加工等过程具有重要作用<sup>[2-4]</sup>。目前, 中国淡水鱼分类主要依靠人工进行, 劳动强度大、效率低、准确率不高, 制约着淡水鱼养殖产业及生产加工机械化、自动化的发展<sup>[5-6]</sup>。因此, 开展淡水鱼识别方法研究对于提高淡水鱼种类识别效率、研发新的种类识别装置具有重要意义。

传统的淡水鱼品种识别方法研究主要通过机器视觉技术获取鱼体的图像, 再通过图像处理技术对鱼体图像进行分析, 提取鱼体特征值并构建模型对淡水鱼进行种类

识别。这方面国内外相关研究人员开展了较多工作。张志强等<sup>[7]</sup>基于机器视觉技术获取鱼体图像, 通过提取鱼体图像的颜色分量、长短轴之比等特征值, 构建模型对 4 种淡水鱼进行种类识别, 准确率可达 96.67%。万鹏等<sup>[8]</sup>通过图像处理技术提取鱼体外观特征, 构建 BP 神经网络对 4 种淡水鱼进行种类检测, 准确率达到 92.50%, 平均检测时间为 1.3 s。吴一全等<sup>[9]</sup>提出了一种基于 Krawtchouk 矩、灰度共生矩阵、多核支持向量机 (Support Vector Machine, SVM) 的识别方法, 对 5 种鱼分类识别准确率可达 95.83% 以上。胡灿<sup>[10]</sup>通过图像处理获取鱼体的颜色、形态、纹理等 25 个特征值, 采用主成分分析 (Principal Component Analysis, PCA) 和粒子群优化 (Particle Swarm Optimization, PSO) 算法对其降维、优化, 生成极限学习机 (Extreme Learning Machine, ELM) 分类器对鱼体进行分类识别, 准确率达到 96.67%。涂兵等<sup>[11]</sup>提出利用鱼体背部轮廓相关系数算法对鱼类进行识别, 对 4 种淡水鱼的识别率均达到 91%, 但无法识别背部轮廓曲率接近的鱼体。此外, White 等<sup>[12]</sup>利用机器视觉技术, 根据不同比目鱼的倾斜度以及体长的差异建立 7 种比目鱼种类识别模型, 准确率达 99.8%。Larsen 等<sup>[13]</sup>通过对海水鱼的形态、纹理特征进行提取, 采用线性判别法 (Linear

收稿日期: 2012-05-11 修订日期: 2021-06-06

基金项目: 国家重点研发计划项目 (2018YFD0700903-2); 湖北省农业科技创新中心 2020 年重大科技研发专项 (2020-620-000-002-03); 湖北省农业科技创新中心创新团队项目 (2016620000001044); 中央高校基本科研业务费专项基金资助项目 (107-11041910103)

作者简介: 万鹏, 博士, 副教授, 研究方向为水产品加工技术与装备、淡水渔业养殖装备、农产品品质的智能检测等。

Email: wanpeng09@mail.hzau.edu.cn

Discriminant Analysis, LDA) 对 3 类鱼的 108 张图像进行分类识别, 正确率达到 76%。Alsmadi 等<sup>[14]</sup>通过提取海水鱼的颜色、纹理特征, 并以 BP 反向传播神经网络对 20 类鱼进行分类, 平均识别率为 84%。综上所述可知, 传统的鱼类品种识别主要通过图像预处理, 提取鱼体的颜色、形状、纹理、轮廓等特征<sup>[15-16]</sup>, 通过构建 BP 神经网络、SVM 等模型进行种类识别, 特征提取复杂、且需要依赖人工进行选择, 识别精度不高<sup>[17]</sup>, 不具备可迁移性; 同时只能提取鱼体表面的特征, 难以挖掘到深层的区别力强的特征, 在不同的背景、光照等干扰下识别效果较差。

近年来, 随着深度学习算法研究的日益深入, 其在识别方面显示出了许多优越性, 在鱼类的品种分类识别、检测等领域也有较多研究。顾郑平等<sup>[18]</sup>利用卷积神经网络对海水鱼进行分类识别准确率达 98.6%。陈英义等<sup>[19]</sup>采用迁移学习训练模型构建优化的 FTVGG16 模型, 对远洋捕捞的海水鱼进行识别准确率为 95.89%。王文成等<sup>[20]</sup>提出基于 ResNet50 网络框架的鱼类图像识别算法, 对 10 种海水鱼进行分类识别准确率达到 93.33%。Vaneeda 等<sup>[21]</sup>开发了经过合成数据训练的卷积神经网络, 对蓝鳕鱼、大西洋鲱鱼和大西洋鲑鱼的识别精度达到 94%, Banan 等<sup>[22]</sup>通过搭建 VGG16 神经网络模型, 采用 5 倍交叉验证法进行训练和评估对 4 种海水鱼进行种类识别, 准确率可达 99.9%。深度学习算法具有自动学习、提取研究对象的颜色、轮廓等低层次特征以及内在联系等高层次特征的优点, 且构建的种类识别模型具有可迁移性<sup>[23]</sup>; 但是模型训练数据集不足、图像背景单一等因素会导致模型识别率和泛化能力降低。因此研究并构建基于深度学习的淡水鱼种类识别模型, 不仅能够降低人工对于鱼体特征值选择的难度和准确度, 而且具有较好的迁移性, 能够适用于不同场景的检测应用, 对提高鱼体的品种识别速度, 开发智能化的淡水鱼分类分级装置具有重要借鉴意义。

本文研究的目的, 探索通过构建大宗淡水鱼图像数据集, 在分析深度学习中经典 ResNet50 模型网络结构的基础上, 对 ResNet50 模型网络进行改进, 并对模型的相关参数进行优化, 以期构建适用于不同应用场景的淡水鱼种类识别方法, 提高淡水鱼分类分级的准确率和工作效率。


## 1 淡水鱼图像数据的构建及预处理

### 1.1 淡水鱼图像数据获取

本文以鳊鱼、鳊鱼、鲤鱼、鲫鱼、草鱼、白鲢 6 种大宗淡水鱼为研究对象, 为了获取足够的淡水鱼图像样本构建淡水鱼图像数据集, 本文采用图像采集装置获取具有单一背景的淡水鱼图像, 同时采用从互联网搜索具有干扰背景的淡水鱼图像。淡水鱼图像采集装置如图 1 所示。

淡水鱼图像采集装置由 XY 水平移动平台、转向板、光源以及包含 Matrox 图像采集卡的计算机硬件系统、图像采集软件系统、BASLER 工业相机 (德国 Blaser, acA640-90gm)、镜头 (Computar, M0814-MP2) 等组成。

通过 XY 水平移动平台以及转向板调节相机相对于鱼体的位置, 通过图像采集软件控制 BASLER 工业相机从淡水鱼的正上方和倾斜 45° 方向获取淡水鱼图像。为了扩展淡水鱼图像数据集, 本文分别采集鱼头朝向随机放置的淡水鱼鱼体正反两面的图像构建单一背景图像数据集; 同时, 通过互联网搜索包含有单一品种的完整淡水鱼鱼体及干扰背景的图片构建具有干扰背景图像数据集, 则淡水鱼图像数据集由单一背景图像数据集和干扰背景图像数据集构成。淡水鱼图像样本如图 2 所示。



1.计算机硬件系统 2.图像采集软件系统 3.转向板 4.BASLER 工业相机 5.XY 水平移动平台 6.光源 7.淡水鱼正上方的工业相机 8.淡水鱼正上方倾斜 45° 方向的工业相机  
1.Computer hardware system 2.Image acquisition software system 3.Steering board 4.BASLER industrial camera 5.XY horizontal moving platform 6.Light source 7.The industrial camera directly above the freshwater fish 8.The industrial camera directly above the freshwater fish inclining 45 degrees

图 1 图像采集装置

Fig.1 Image acquisition device

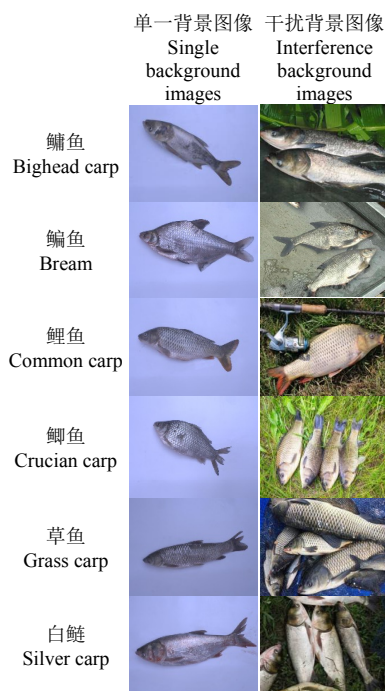


图 2 淡水鱼图像样本

Fig.2 Freshwater fish image samples

淡水鱼图像数据集中不同品种的淡水鱼图像样本数量分布如表 1 所示。

本文构建的淡水鱼图像数据集中, 采集到的单一背景图像样本为 2 700 张; 互联网搜索的干扰背景图像样本为 1 880 张, 两者组成混合图像样本数据集为 4 580 张, 即为淡水鱼种类识别图像数据集。

表 1 淡水鱼图像数据集数量分布

鱼种类 Fish species	单一背景 Single background	干扰背景 Interference background	总数 Total number
鳊鱼 Bighead carp	300	340	640
鳊鱼 Bream	750	340	1 090
鲤鱼 Common carp	300	300	600
鲫鱼 Crucian carp	750	300	1050
草鱼 Grass carp	300	300	600
白鲢 Silver carp	300	300	600
图像总数 Total number of images	2 700	1 880	4 580

## 1.2 图像预处理

为了加快网络模型的训练和收敛速度、提升模型的准确率等，需要对用于模型训练的图像数据集进行预处理。本文调用 Pytorch 算法工具库对淡水鱼图像进行空间尺度变换、张量处理及归一化处理。其中空间尺度变换对鱼体图像进行随机缩放、裁剪、水平翻转以及变换亮度、对比度等处理；张量处理将鱼体图像中像素点的单通道颜色值由[0, 255]转变成[0, 1]，将图像转变成张量格式；最后对张量图像进行归一化处理。经预处理后，淡水鱼图像的分辨率为 224 像素×224 像素×3 通道。

## 2 改进 ResNet50 种类识别模型的构建及其优化

### 2.1 改进 ResNet50 模型的构建

随着神经网络深度的增加，会出现梯度消失、退化等问题，导致模型难以训练、错误率增加，包含残差结构的网络模型能够在很大程度上避免出现此种问题。因此本文选择具有残差结构的 ResNet50 模型，并对其结构进行优化后用于淡水鱼种类识别研究。ResNet50 模型的残差结构如图 3。

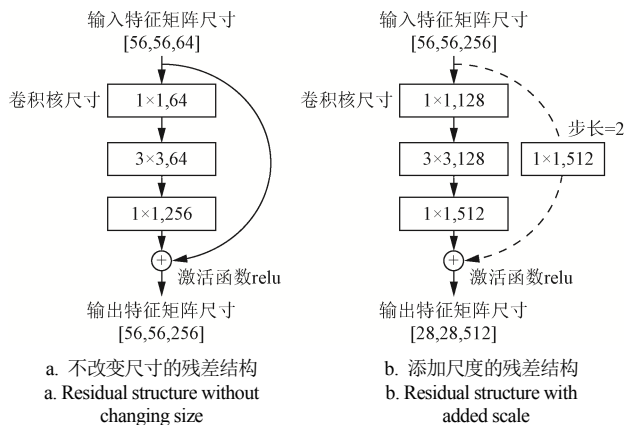


图 3 ResNet50 模型的残差结构<sup>[24]</sup>  
Fig.3 Residual structure of Resnet50 model

在 3×3 卷积核的前后，采用 1×1 的卷积核降维和升维可以减小模型的参数量。残差结构 a 中的实线和残差结构 b 中的虚线部分为输入的下采样函数，残差结构 a 表示不改变尺寸的残差块，即输出特征矩阵的高和宽不改变；残差结构 b 为添加尺度的残差块，输出特征矩阵的高和宽为输入的一半。ResNet50 模型的残差结构增加了输出特征图的维度，能够解决梯度退化、消失问题。

以残差结构为基础的 ResNet50 模型其经典结构及改进后的结构如图 4 所示。

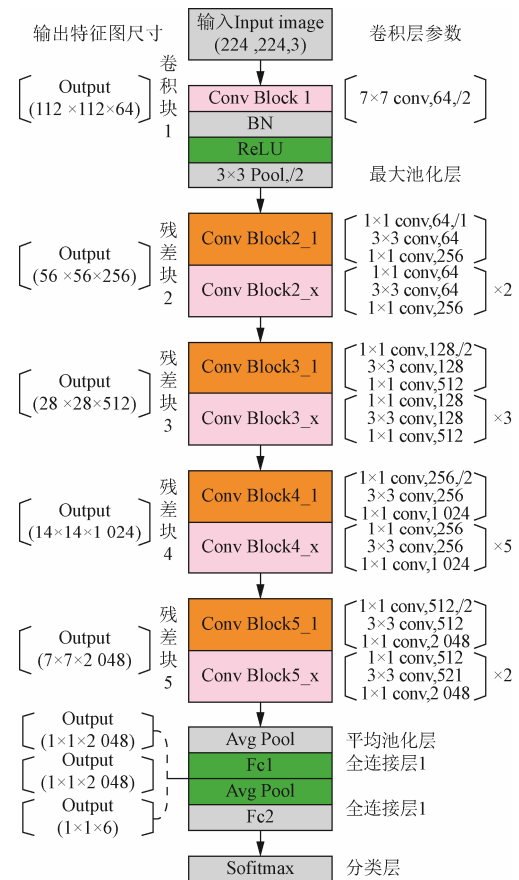
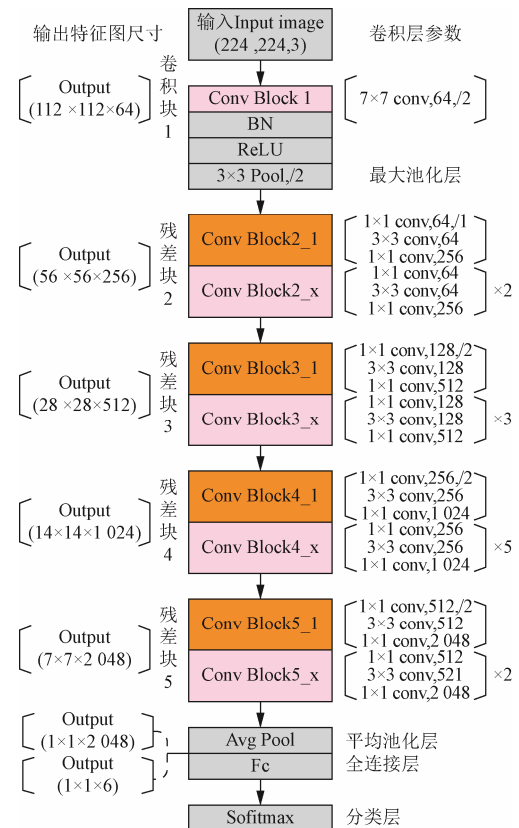


图 4 ResNet50 模型的网络结构  
Fig.4 Network structure of Resnet50 model



改进后的 ResNet50 模型结构和经典 ResNet50 的模型结构主体部分相同。2 种模型结构中的 Input (224, 224, 3) 均表示输入大小为 224 像素×224 像素×3 通道的淡水鱼图像, 模型网络结构左侧 Output (112×112×64) 表示输出特征图的尺寸, 右侧表示多层神经网络的卷积组成, 如“7×7 conv, 64, /2”中卷积核的尺寸为 7×7, 通道数为 64, 步长为 2。Conv Block1 表示第一个卷积块 1, 其中包含 1 个卷积层; Conv Block2\_1、Conv Block3\_1、Conv Block4\_1、Conv Block5\_1 表示添加尺度的残差块, 残差块的数目均为 1; Conv Block2\_x、Conv Block3\_x、Conv Block4\_x、Conv Block5\_x 表示不改变尺寸的残差块, 残差块的数目分别为 2、3、5、2。Conv Block2 至 Conv Block5 定义为残差块 2、3、4、5, 每个残差块均由 3 个卷积层组成, 即一共包含有  $3 \times (3+4+6+3)+1=49$  个卷积层。

神经网络结构中 Conv 为卷积层, BN 为批标准化操作, Pool 表示最大池化层, Avg Pool 表示平均池化层, Fc 为全连接层。从整体上可理解为 5 个卷积块, 包括 1 个 7×7 的卷积层、4 个 3×3 的残差块, 卷积核的数量分别为 64、64、128、256、512。对于 7×7 卷积层, “/2”表示卷积核的移动步长为 2, 数据填充默认为 1, 卷积层不添加偏置 (bias); 批标准化 BN 加速网络训练, 且将 BN 层放在 Conv 和激活函数之间; 对于 3×3 池化层, 步长为 2, 数据填充为 1。

图 4 中改进后的 ResNet50 网络结构由 49 个卷积层和 2 个全连接层组成, 绿色标记为网络结构的改进之处, 激活函数选择 CELU 代替原始模型的 ReLU; 通过 Kaiming 正态分布初始化卷积层权重, 全连接层不添加; 在卷积神经网络的深度上, 增加了 1 个全连接层 Fc1, 同时在 Fc1 和 Fc2 中添加 Dropout。

将预处理后的图像输入, 经过一系列残差块处理后, 输出特征图尺寸为 7×7×2 048, 再经过平均池化层以及 flatten 展平处理后, 输出特征矩阵变为 1×1×2 048, 然后输入到全连接层 Fc1、Fc2, 输出特征图的通道数分别为 2 048、6, 最后由 Softmax 分类器输出 6 种淡水鱼的对应概率值, 从而给出种类识别结果。

## 2.2 改进 ResNet50 网络的结构优化

根据图 4 中改进 ResNet50 模型的网络结构, 需要对其激活函数及其初始化权重方式、全连接层及其 Dropout、损失函数、优化算法及其学习率衰减进行改进和优化。

### 2.2.1 激活函数及其初始化权重方式

ReLU 是神经网络中普遍使用的激活函数, 特点是运算速度快、性能好, 但输入  $x < 0$  时函数输出为零, 反向传播时损失梯度消失, 导致参数不能进行更新, 造成神经元死亡。为解决此问题, 改进 ResNet50 模型选择 CELU<sup>[25]</sup> 为激活函数, CELU 为折点非线性且连续可微的指数平滑函数, 有利于神经网络的收敛和泛化性能。CELU 激活函数的计算公式如下, 取  $\alpha$  为 0.075, 函数输出值对比如图 5。

$$\text{CELU}(x, \alpha) = \begin{cases} x & \text{if } x \geq 0 \\ \alpha \left( \exp\left(\frac{x}{\alpha}\right) - 1 \right) & \text{if } x < 0 \end{cases} \quad (1)$$





图 5 激活函数 ReLU 和 CELU 曲线

Fig.5 The curve of the activation functions ReLU and CELU

Kaiming 正态分布在 CELU 激活函数中能够加快模型的收敛, 具有较好的效果<sup>[26]</sup>, 本文模型选择 Kaiming 正态分布作为初始化权重方式。

### 2.2.2 全连接层及其 Dropout

改进 ResNet50 模型网络结构中增加了 1 个全连接层 Fc1, 可以通过神经网络提取更多的特征信息, 同时添加 Dropout 能够避免过拟合风险, 降低分类泛化误差。将 Dropout 参数设置为 0.5, 网络在训练过程中会随机失活一半的神经元; 当梯度反向传播时, 失活后断开的神经元将不参与参数的更新。Dropout 正向传播<sup>[27]</sup>如图 6 所示, 梯度由输入神经元传至输出神经元。



a. 未使用 Dropout  
a. Dropout is not used

b. 使用 Dropout  
b. Using Dropout

图 6 未使用 Dropout 和使用 Dropout 正向传播的神经网络  
Fig.6 The neural network forward propagation without dropout and forward propagation with dropout

### 2.2.3 损失函数选择

本文选择交叉损失熵 (Cross Entropy Loss) 作为改进 ResNet50 模型的损失函数, 其在网络训练时梯度更大, 网络优化更快。表达式为

$$\text{Loss} = -\frac{1}{M} \sum_i^M \sum_j^N p_{ij} \log q_{ij} \quad (2)$$

式中 Loss 表示损失函数;  $M$  表示样本数,  $N$  表示类别数;  $p_{ij}$  表示标签的真实值中第  $i$  个样本的第  $j$  个类别的概率分布值;  $q_{ij}$  表示网络的预测值中第  $i$  个样本的第  $j$  个类别的概率分布值。

### 2.2.4 优化器及其学习率衰减

学习率决定了神经网络模型的学习进度, 可以控制网络模型权重的更新比率。Adam 优化算法<sup>[28]</sup>在损失梯度更新时, 能够为神经网络设置自适应的学习率。本文中改进 ResNet50 网络模型选择 Adam 优化算法, 默认学习率为 0.001, 指数衰减率  $\beta_1$ 、 $\beta_2$  分别为 0.9、0.999, 除零

误差项  $\varepsilon=1 \times 10^{-8}$ 。

同时,学习率衰减可以极大提高 Adam 优化算法的性能<sup>[29]</sup>,在改进 ResNet50 模型中,选择余弦退火 (Cosine Annealing) 衰减学习率,并将其参数 T\_max 设置为迭代次数的大小,在网络训练过程中随着网络迭代次数的增加逐步减小,网络收敛更快。

### 3 改进 ResNet50 种类识别模型的训练与评估

#### 3.1 模型的训练环境

本文中模型训练的试验环境为:基于 Python3.6 编程语言的 Pytorch 深度学习框架,操作系统为 Windows 10, GPU 为内存 4GB 的英伟达 GTX1050Ti,同时使用 CUDA 平台加速网络训练,基础配置为 Anaconda3、PyCharm。

#### 3.2 单次验证方法

将数据集划分为训练集和测试集,比例分别为 75%、25%,通过训练集训练模型,在测试集上评估模型的性能,称之为单次验证的普通验证方法。单次验证方法通过对模型训练一次,能够更快速的得出训练结果并优化出超参数。


#### 3.3 四折交叉验证

利用构建的淡水鱼图像数据集,对 ResNet50 模型训练后,需要对模型的识别准确率、损失、检测时间等进行评估。交叉验证是一种模型训练和评估方式,它将数据集划分后,图像样本在训练和测试过程中被重复使用,构成多组互不相交的训练集和测试集<sup>[30]</sup>。K 折交叉验证中 K 的选择与数据集大小有关,其计算公式为

$$K \approx \log(n) \quad (3)$$

式中  $n$  表示数据集大小。

本文中淡水鱼样本图像数据集大小为 4 580,因此 K 值取 4,划分的每个数据集的大小为 1 145,即训练集和测试集的比例分别为 75%、25%。四折交叉验证方法如图 7。



注: D<sub>1</sub>、D<sub>2</sub>、D<sub>3</sub>、D<sub>4</sub> 分别表示 4 个子数据集 Data set 1、Data set 2、Data set 3、Data set 4。

Note: D<sub>1</sub>, D<sub>2</sub>, D<sub>3</sub> and D<sub>4</sub> represent the four sub datasets data set 1, data set 2, data set 3 and data set 4 respectively.

图 7 四折交叉验证方法

Fig.7 The 4-fold cross validation method

四折交叉验证方法将整个数据集随机划分为 D<sub>1</sub>、D<sub>2</sub>、D<sub>3</sub>、D<sub>4</sub> 四个子数据集,之间无交集且样本数量相同。依次从 4 个数据集中选择 1 个作为测试集,另外 3 个作为训练集;然后进行 4 次独立的模型训练和测试过程,最后将 4 次模型的测试结果取平均值,作为此模型的泛化误差。使用四折交叉验证能够对泛化误差有更好的近似,对模型的预测性能给出公正的评估。

#### 3.4 网络训练过程

引入迁移学习机制训练模型,将大数据集 ImageNet 上预训练的模型权重迁移到种类识别模型的训练过程中。由于深度学习中的图像等数据集庞大,迁移学习能够加速网络模型收敛,增强分类模型的准确率。

针对改进 ResNet50 模型在不同种类和不同超参数模型上的对比,选择单次验证方法训练和评估模型的性能。针对改进 ResNet50 网络模型在不同数据集上的对比,采用四折交叉验证方法来训练和评估模型的性能。模型的训练流程如图 8。

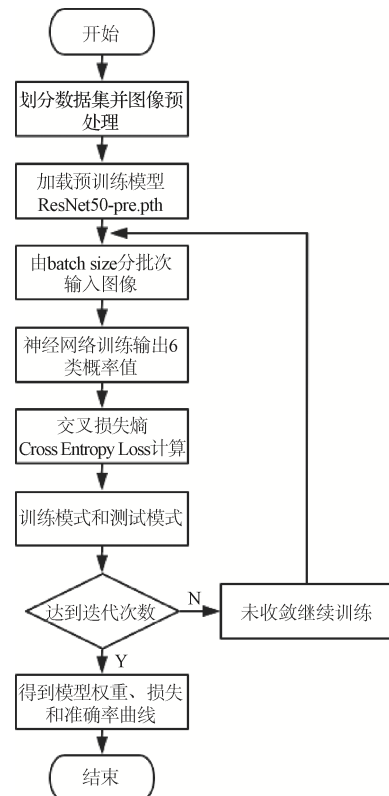


图 8 改进 ResNet50 训练流程图

Fig.8 Improved ResNet50 training flow chart

具体训练过程如下:

通过 Pytorch 深度学习框架中数据集加载方式,加载 ResNet50-pre.pth 预训练模型,从训练集中每次抽取的图像数量为批大小 (batch size)。利用 Adam 优化算法和余弦退火来调整每个迭代次数 (epoch) 的学习率 (learning rate),使其随着迭代次数逐渐减小。每批次样本在梯度下降时更新一次参数,迭代次数设置为 60。

在训练集上对改进 ResNet50 进行训练,在测试集上获得每个迭代次数的模型测试结果。交叉损失熵函数使得损失逐渐减小,准确率逐渐增加。

经过 60 个迭代次数后网络会逐步收敛,直至训练和测试的损失、准确率稳定。由于每次训练时模型损失或准确率曲线在不同的迭代次数下有波动,因此保存测试准确率最高的模型权重,同时得到损失和准确率曲线。

## 4 改进 ResNet50 模型的超参数优化

### 4.1 学习率的选择

Adam 优化算法中学习率设置过小, 模型收敛速度较慢; 设置过大则出现不收敛状态, 损失函数会错过最优

解<sup>[31]</sup>。选择初始批大小为 16, 由于 Adam 优化算法中学习率默认值为 0.001, 因此取不同数量级的参数值, 比较学习率为 0.01、0.001、0.000 1、0.000 01 时模型的训练效果。依次对学习率进行粗调和微调, 学习率调节时对损失值和准确率的影响如图 9 所示。




图 9 学习率调节时对损失值和准确率的影响

Fig.9 Influence of learning rate tuning on loss value and accuracy

由图 9 可知, 学习率为 0.01、0.001 时模型不收敛和收敛缓慢, 且损失值较大; 学习率为 0.000 01 时模型收敛比 0.000 1 较快, 但在最后的损失偏高, 故学习率为 0.000 1 时收敛效果较好。

由于学习率为 0.000 1、0.000 01 时训练结果相差不大, 故对其进行微调, 设置初始学习率为 0.000 01、0.000 03、0.000 05、0.000 1、0.000 3、0.000 5, 比较模型的训练效果。由图 9 b、图 9 c 可知, 学习率为 0.000 03、0.000 05、0.000 1 时, 模型收敛较快, 且收敛稳定后损失较低。当网络迭代至 50 后, 学习率为 0.000 1 时测试准确率最高, 因此选择学习率为 0.000 1。

### 4.2 批大小的选择

批大小对神经网络模型性能的影响不如学习率敏感, 但进一步提升神经网络性能时, 就要考虑批大小对模型性能的影响。确定了学习率为 0.000 1 后, 不同的批大小对损失和准确率的影响如图 10 所示。




图 10 不同批大小对损失值和准确率的影响

Fig.10 Influence of different batch size on loss value and accuracy

由图 10 可知, 当批大小为 8、64 时损失较大, 当批大小为 32、64 时模型训练所需的内存不足, 出现内存溢出现象; 当批大小为 16 时模型收敛较快, 能获得较高的准确率, 因此选择批大小为 16。

## 5 结果与分析

### 5.1 不同神经网络模型对比

本文利用包含单一背景图像和干扰背景图像的淡水鱼图像数据集对改进的 ResNet50 模型进行训练, 并与其他模型进行对比。采用单次验证法, 将淡水鱼图像数据集按照 75%、25%划分为训练集和测试集, 即包含淡水鱼图像 3 435、1 145 张。不同模型的预处理方式、初始化权重、优化算法等基本设置保持相同, 迭代次数为 60, 学习率和批大小分别取 0.000 1 和 16, 使用迁移学习进行模型训练, 则不同模型的种类识别结果对比如表 2 所示。

表 2 不同模型的种类识别结果对比

Table 2 Comparison of the results of different kinds of models

模型种类 Model type	浮点运算量 Flops	准确率 Accuracy/%	平均检测时间 Average detection time/s	训练时间 Training time/s
AlexNet	$0.71 \times 10^9$	91.17	0.047 5	48.89
VGG16	$15.45 \times 10^9$	93.44	0.562 4	163.13
VGG19	$19.60 \times 10^9$	93.01	0.666 3	185.29
GoogleNet	$1.59 \times 10^9$	94.85	0.087 2	72.18
ResNet18	$1.82 \times 10^9$	95.37	0.094 7	58.03
ResNet34	$3.67 \times 10^9$	95.89	0.170 3	77.51
ResNet50	$4.11 \times 10^9$	95.72	0.204 7	117.29
改进 ResNet50	$4.12 \times 10^9$	96.94	0.234 5	133.27

从表 2 可知:

1) 改进 ResNet50 模型在训练时间上比 VGG16、VGG19 分别减小 29.86、52.02 s, 准确率比 VGG16、VGG19 分别提升 3.5%、3.93%, 平均检测时间比 VGG16、VGG19 分别减小 0.327 9、0.431 8 s。由于 VGG 网络模型的浮点运算量较大, 网络模型较复杂, 因此改进 ResNet50 比 VGG 各方面都要优秀。

2) 改进 ResNet50 模型的准确率比 AlexNet、GoogleNet 准确率高 5.77%、2.09%, 在识别准确率上优



势明显。

3) 改进 ResNet50 模型平均检测时间、训练时间比经典 ResNet50 模型分别增加 0.029 8、15.89 s, 但测试准确率为 96.94%, 准确率提升 1.22%; 单张图像样本的平均检测时间为 0.234 5 s, 使用该模型不会明显增加检测所需时间。同时, 在本文研究中, 种类识别对测试准确率的评估优要先于平均检测速度。因此本研究中改进 ResNet50 模型的结构和激活函数等优化方式可以使模型获得更好的种类识别效果。

### 5.2 改进 ResNet50 模型在不同数据集上对比

通过构建的淡水鱼图像数据集, 分别使用单一背景图像数据集、干扰背景图像数据集以及包含单一背景图像和干扰背景图像的淡水鱼图像数据集对改进 ResNet50 模型进行训练和测试, 模型的训练和评估方式采用四折交叉验证。单一背景图像数据集中, 训练集和测试集的大小分别为 2 025、675; 干扰背景图像数据集中, 训练集和测试集的大小分别为 1 410、470; 淡水鱼图像数据集中, 训练集和测试集的大小分别为 3 435、1 145, 结果如表 3 所示。

表 3 改进 ResNet50 模型在不同数据集种类识别结果对比

Table 3 Comparison of species recognition results of improved ResNet50 in different data sets

数据集类型 Dataset type	数据集大小 Dataset size	训练集 Training set		测试集 Test set	
		准确率 Accuracy/%	损失 Loss	准确率 Accuracy/%	损失 Loss
单一背景 Single background	2 700	98.52	0.042 3	100.00	0.000 1
干扰背景 Interference background	1 880	92.55	0.281 1	91.17	0.398 2
淡水鱼图像数据集 Data sets of the freshwater fish images	4 580	96.82	0.087 9	96.20	0.184 8

从表 3 可知:

1) 在单一背景图像数据集上, 模型测试准确率达到 100%, 训练和测试损失分别为 0.042 3、0.000 1。说明模型网络收敛充分, 对单一背景下淡水鱼的识别效果较好, 适用于具有单一背景的淡水鱼种类识别和分级任务。


2) 在干扰背景图像数据集上, 模型测试准确率为 91.17%, 训练和测试损失分别为 0.281 1、0.398 2, 相比其他 2 种数据集上准确率较低、损失较大, 说明数据集数量小容易导致网络收敛不足。

3) 在淡水鱼图像数据集上, 模型测试准确率达到 96.20%, 训练和测试损失分别为 0.087 9、0.184 8。相比干扰背景图像数据集的种类识别效果, 模型识别准确率显著提升 5.03%, 说明扩充数据集后, 模型的泛化能力和鲁棒性增强, 适用于具有单一背景、干扰背景的淡水鱼种类识别和分级任务。

### 5.3 混淆矩阵对种类识别结果可视化分析


混淆矩阵在评判分类模型的优劣和分类性能时具有较好的显示性<sup>[22]</sup>, 在淡水鱼种类识别上可以显示出识别

错误的鱼体的数量。分别利用包含 6 种淡水鱼样本图像的淡水鱼图像数据集及单一背景图像数据集对改进的 ResNet50 模型进行训练, 对不同应用场景下模型的识别效果进行可视化分析, 在混淆矩阵中呈现的结果如图 11 所示。



a. 淡水鱼图像数据集

a. The freshwater fish images data set



b. 单一背景图像数据集

b. Single background images data set

图 11 淡水鱼图像数据集和单一背景图像数据集上混淆矩阵  
Fig.11 Confusion matrix on the freshwater fish images data set and single background data set

观察 2 种混淆矩阵, 淡水鱼图像数据集上, 识别出的淡水鱼数量基本分布在对角线上, 出现个别偏差; 单一背景图像数据集上, 每类淡水鱼的识别结果均分布在对角线上, 说明可以成功识别出所有淡水鱼类别。

混淆矩阵中衡量模型性能的指标通常有准确率 (Accuracy)、精确度 (Precision)、召回率 (Recall) 和 F1 分数 (F1 score), 公式如下

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}} \quad (4)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (5)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (6)$$

$$\text{F1 score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (7)$$

式中 TP 表示淡水鱼样本为真实种类, 模型识别为正确的种类的数量; FN 表示淡水鱼样本为真实种类, 模型识别

为错误的种类的数量; FP 表示淡水鱼样本为错误种类, 模型识别为正确的种类的数量; TN 表示淡水鱼样本为错误种类, 模型识别为错误的种类的数量。准确率为所有样本被正确分类的概率, 即为模型整体的识别准确率; 精确度表示所有预测类别中, 模型预测正确的比例; 召回率表示所有真实类别中, 模型预测正确的比例;  $F1$  分数是精确率和召回率的综合评价指标, 在两者中间取得了很好的平衡。

根据图 11 中混淆矩阵, 得到不同数据集上 6 种淡水鱼种类识别试验结果如表 4 所示。

表 4 不同数据集上淡水鱼种类识别试验结果  
Table 4 Experimental results of freshwater fish species identification under the different data set

种类 Species	淡水鱼图像数据集 The freshwater fish images data set				单一背景图像数据集 Single background images data set			
	数量 Quantity	精确度 Precision	召回率 Recall	$F1$ 分数 $F1$ score	数量 Quantity	精确度 Precision	召回率 Recall	$F1$ 分数 $F1$ score
鳊鱼 Bighead carp	160	0.97	0.94	0.95	75	1.00	1.00	1.00
鳊鱼 Bream	273	0.99	1.00	0.99	187	1.00	1.00	1.00
鲤鱼 Common carp	150	0.94	0.93	0.93	75	1.00	1.00	1.00
鲫鱼 Crucian carp	262	0.99	0.98	0.98	188	1.00	1.00	1.00
草鱼 Grass carp	150	0.95	0.97	0.96	75	1.00	1.00	1.00
白鲢 Silver carp	150	0.95	0.95	0.95	75	1.00	1.00	1.00

由表 4 分析得出结论:

1) 在淡水鱼图像数据集上训练模型, 模型的精确度、召回率和  $F1$  分数都比较高, 160 个鳊鱼样本中有 9 个识别错误, 150 个鲤鱼样本中有 10 个识别错误, 这两类的识别效果相对有偏差, 但整体的准确率达到了 96.94%, 即表 2 中改进 ResNet50 的准确率, 说明模型识别准确率较高。

2) 在单一背景图像数据集上训练模型, 由于图像的背景干扰很小, 因此精确度、召回率和  $F1$  分数都达到了 100%, 说明 ResNet50 模型对单一背景淡水鱼的识别准确率为 100%, 模型识别效果优秀。

这表明改进 ResNet50 模型性能优越, 能够适用于单一背景下及干扰背景下鱼体的种类识别。

#### 5.4 卷积层输出特征可视化

为了进一步说明本文改进 ResNet50 模型中卷积层的工作原理, 根据图 5 中改进 ResNet50 模型的网络结构, 分别对卷积块 1 和残差块 2、3、4、5 的最后一个卷积层进行输出特征可视化, 输出特征图依次对应 b、c、d、e、f, 结果如图 12 所示。

由图 12 可知, 由卷积块 1 到卷积块 5 的最后一个卷积层, 神经网络学习、提取的特征信息由整体至局部不断细化。图 12 b、图 12 c 中 Conv Block1\_conv1、Conv Block 2\_3\_conv3 卷积层保留了大部分原始鱼体的图像信

息; 图 12 d、图 12 e 中卷积层 Conv Block 3\_4\_conv3、Conv Block 4\_6\_conv3 的卷积核, 对颜色、边缘形成的部分纹理进行了描述, 更多地表达图像的线条、轮廓等抽象特征; 图 12 f 中最后一个卷积层 Conv Block 5\_4\_conv3 的卷积核提取图像的纹理和特定信息, 仅仅保留了图像的高阶像素信息。通过对卷积层的输出特征进行可视化, 能够反映卷积层提取特征的过程和原理, 以及神经网络底层的特征信息。

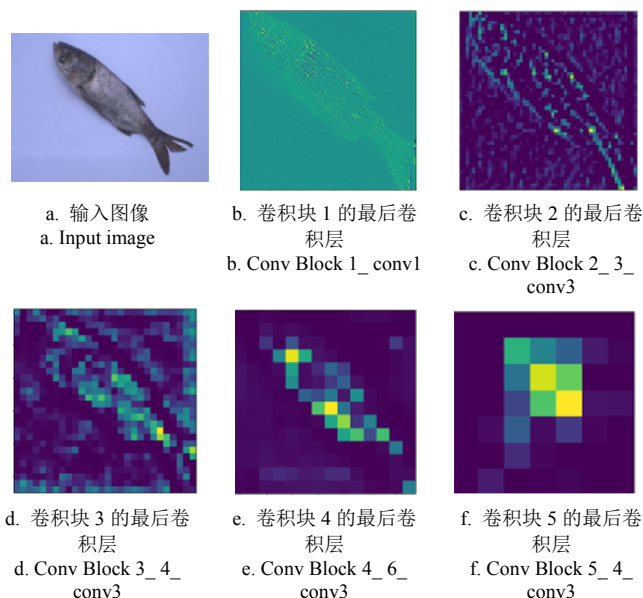


图 12 改进 ResNet50 模型卷积层输出特征可视化

Fig.12 Improved ResNet50 model convolution layer output feature visualization

## 6 结 论

本文提出了一种基于改进 ResNet50 模型的淡水鱼种类识别方法, 以鳊鱼、鳊鱼、鲤鱼、鲫鱼、草鱼、白鲢 6 种大宗淡水鱼为研究对象, 搭建基于机器视觉的淡水鱼图像采集系统获取单一背景的淡水鱼图像 2 700 张, 同时基于互联网搜索 6 种淡水鱼图像 1 880 张, 构建了淡水鱼种类识别图像数据集。以 Pytorch 为深度学习框架, 在经典 ResNet50 基础上, 增加全连接层 Fc1 以及 Dropout、引入迁移学习进行模型训练、选择 CELU 为激活函数、使用 Adam 优化算法更新梯度并嵌入了余弦退火方法衰减学习率等对 6 种淡水鱼进行种类识别。主要结论如下:

1) 在单次验证方法下, 选用包含单一背景图像和干扰背景图像的淡水鱼图像数据集对改进 ResNet50 模型进行训练, 学习率为 0.000 1、批大小为 16; 对淡水鱼种类进行识别准确率可达到 96.94%, 相比经典 ResNet50 模型提高了 1.22%, 对单张淡水鱼图像样本的平均检测时间为 0.234 5 s。

2) 通过四折交叉验证方法对比研究了不同场景下的识别效果, 单一背景图像数据集下模型识别准确率可达 100%, 淡水鱼图像数据集下模型识别准确率为 96.20%, 说明模型泛化能力较强, 适用于不同背景下的应用。

3) 通过混淆矩阵对种类识别结果可视化分析, 在淡水鱼图像数据集上训练模型, 整体的预测准确率达到了 96.94%; 在单一背景数据集上训练模型时, 每类淡水鱼



的精确度、召回率和  $F1$  分数均可达到 100%。进一步验证了改进 ResNet50 模型的性能优越, 能够应用于不同背景下的 6 种淡水鱼种类识别。

### 参 考 文 献

- [1] 于秀娟, 徐乐俊, 吴反修. 中国渔业统计年鉴[M]. 北京: 中国农业出版社, 2020.
- [2] 张军文, 陈庆余, 欧阳杰, 等. 中国淡水鱼前处理加工技术研究进展[J]. 安徽农业科学, 2018, 46(21): 25-28. Zhang Junwen, Chen Qingyu, Ouyang Jie, et al. Research progress in freshwater fish pretreatment and processing technology in China[J]. Anhui Agricultural Sciences, 2018, 46(21): 25-28. (in Chinese with English Abstract)
- [3] 邹伟. 淡水鱼连续式去头尾装置的设计与试验研究[D]. 武汉: 华中农业大学, 2018. Zou Wei. Design and Experimental Research of Continuous Head and Tail Device for Freshwater Fish[D]. Wuhan: Huazhong Agricultural University, 2018. (in Chinese with English Abstract)
- [4] 谭鹤群, 高星星. 链式剖鱼机工艺参数优化试验[J]. 农业工程学报, 2011, 27(6): 332-336. Tan Hequn, Gao Xingxing. Optimization test of technological parameters of chain fish splitter[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2011, 27(6): 332-336. (in Chinese with English Abstract)
- [5] 杨东海, 张胜茂, 汤先峰. 基于机器视觉技术的鱼类识别研究进展[J]. 渔业信息与战略, 2019, 34(2): 37-45. Yang Donghai, Zhang Shengmao, Tang Xianfeng. Research progress of fish recognition based on machine vision technology[J]. Fisheries Information and Strategy, 2019, 34(2): 37-45. (in Chinese with English Abstract)
- [6] 陈从平, 吴杞, 吴喆, 等. 一种基于图像处理的鱼类自动分类方法: 以四种淡水鱼为例[J]. 软件工程, 2018, 21(12): 7-11. Chen Congping, Wu Qi, Wu Zhe, et al. An automatic fish classification method based on image processing: A case study of four freshwater fish[J]. Software Engineering, 2018, 21(12): 7-11. (in Chinese with English Abstract)
- [7] 张志强, 牛智有, 赵思明. 基于机器视觉技术的淡水鱼品种识别[J]. 农业工程学报, 2011, 27(11): 388-392. Zhang Zhiqiang, Niu Zhiyou, Zhao Siming. Freshwater fish species identification based on machine vision technology[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2011, 27(11): 388-392. (in Chinese with English Abstract)
- [8] 万鹏, 潘海兵, 龙长江, 等. 基于机器视觉技术淡水鱼品种在线识别装置设计[J]. 食品与机械, 2012, 28(6): 164-167. Wan Peng, Pan Haibing, Long Changjiang, et al. Design of online identification device for freshwater fish species based on machine vision technology[J]. Food and Machinery, 2012, 28(6): 164-167. (in Chinese with English Abstract)
- [9] 吴一全, 殷骏, 戴一冕, 等. 基于蜂群优化多核支持向量机的淡水鱼种类识别[J]. 农业工程学报, 2014, 30(16): 312-319. Wu Yiquan, Yin Jun, Dai Yimian, et al. Freshwater fish species identification based on bee colony optimization multi-core support vector machine[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2014, 30(16): 312-319. (in Chinese with English Abstract)
- [10] 胡灿. 基于 ELM 算法的鲜活淡水鱼图像自动归类研究[D]. 湘潭: 湘潭大学, 2017. Hu Can. Research on Automatic Classification of Fresh Freshwater Fish Images based on ELM Algorithm[D]. Xiangtan: Xiangtan University, 2017. (in Chinese with English Abstract)
- [11] 涂兵, 王锦萍, 王思成, 等. 基于背部轮廓相关系数算法的淡水鱼种类识别研究[J]. 计算机工程与应用, 2016, 52(16): 162-166. Tu Bing, Wang Jinping, Wang Sicheng, et al. Identification of freshwater fish species based on back contour correlation coefficient algorithm[J]. Computer Engineering and Application, 2016, 52(16): 162-166. (in Chinese with English Abstract)
- [12] White D J, Svellingen C, Strachan N J C. Automated measurement of species and length of fish by computer vision[J]. Fisheries Research, 2006, 80(4): 203-210.
- [13] Larsen R, Olafsdottir H. Shape and texture based classification of fish species[C]. //Scandinavian Conference on Image Analysis. Springer-Verlag, 2009: 745-749.
- [14] Alsmadi M K, Omar K B, Noah S A, et al. Fish recognition based on robust features extraction from size and shape measurements using neural network[J]. Journal of Computer Science, 2010, 6(10): 1059-1065.
- [15] 陈文辉, 蔡妹妹, 严松, 等. 基于深度卷积神经网络与迁移学习的鱼类分类识别[J]. 福建师大福清分校学报, 2019(5): 30-38. Chen Wenhui, Cai Meishu, Yan Song, et al. Fish classification and recognition based on deep convolution neural network and transfer learning[J]. Journal of Fuqing Branch of Fujian Normal University, 2019(5): 30-38. (in Chinese with English Abstract)
- [16] 段青玲, 李道亮, 姚红, 等. 基于图像处理的目标鱼识别方法及系统: 201310317701.3[P]. 2016-07-06.
- [17] 胡涛. 基于深度学习的鱼类识别研究[D]. 杭州: 浙江工业大学, 2019. Hu Tao. Research on Fish Recognition Based on Deep Learning[D]. Hangzhou: Zhejiang University of Technology, 2019. (in Chinese with English Abstract)
- [18] 顾郑平, 朱敏. 基于深度学习的鱼类分类算法研究[J]. 计算机应用与软件, 2018, 35(1): 200-205. Gu Zhengping, Zhu Min. Research on fish classification algorithm based on deep learning[J]. Computer Applications and Software, 2018, 35(1): 200-205. (in Chinese with English Abstract)
- [19] 陈英义, 龚川洋, 刘炜琦, 等. 基于 FTVGG16 卷积神经网络的鱼类识别方法[J]. 农业机械学报, 2019, 50(5): 223-231. Chen Yingyi, Gong Chuanyang, Liu Yeqi, et al. Fish recognition method based on FTVGG16 convolutional neural network[J]. Transactions of The Chinese Society for Agricultural Machinery(Transactions of the CSAM), 2019, 50(5): 223-231. (in Chinese with English Abstract)
- [20] 王文成, 蒋慧, 乔倩, 等. 基于 ResNet50 网络的十种鱼类图像分类识别研究[J]. 农村经济与科技, 2019, 30(19): 60-62. Wang Wencheng, Jiang Hui, Qiao Qian, et al. Classification and recognition of ten fish images based on ResNet50 network[J]. Rural Economy and Technology, 2019, 30(19): 60-62. (in Chinese with English Abstract)
- [21] Vaneeda A, Olav H N, Shale R, et al. Fish species identification using a convolutional neural network trained on synthetic data[J]. ICES Journal of Marine Science, 2019, 76(1): 342-349.
- [22] Banan A, Nasiri A, Taheri-Garavand A. Deep learning-based appearance features extraction for automated carp species identification[J]. Aquacultural Engineering, 2020, 89: 134-

- 139.
- [23] 胡越, 罗东阳, 花奎, 等. 关于深度学习的综述与讨论[J]. 智能系统学报, 2019, 14(1): 1-19.  
Hu Yue, Luo Dongyang, Hua Kui, et al. Overview and discussion on deep learning[J]. Journal of Intelligent Systems, 2019, 14(1): 1-19. (in Chinese with English Abstract)
- [24] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision & Pattern Recognition. IEEE Computer Society, 2016, 1-12.
- [25] Barron J T. Continuously differentiable exponential linear units[C]. International Conference on Learning Representations(ICLR), 2017, 1-2.
- [26] Henmi T, Zara E, Hirohashi Y, et al. Adaptive signal variances: CNN initialization through modern architectures[C]//International Conference on Learning Representations(ICLR), 2020, 1-22.
- [27] 雷雨婷, 丁学文, 孙彦, 等. 基于 Inception-v3 卷积神经网络模型的人脸识别[J]. 天津职业技术师范大学学报, 2019, 29(4): 49-54.
- Lei Yuting, Ding Xuewen, Sun Yan, et al. Face recognition based on Inception-v3 convolutional neural network model[J]. Journal of Tianjin Polytechnic Normal University, 2019, 29(4): 49-54. (in Chinese with English Abstract)
- [28] Kingma D, Ba J. Adam: A method for stochastic optimization[C]. International Conference on Learning Representations(ICLR), 2015, 1-15.
- [29] Loshchilov I, Hutter F. Decoupled weight decay regularization[C]//International Conference on Learning Representations(ICLR), 2019, 1-19.
- [30] Yoonsuh Jung. Multiple predicting K-fold cross-validation for model selection[J]. Journal of Nonparametric Statistics, 2017, 30(1): 10-15.
- [31] 贾宇霞, 樊帅昌, 易晓梅. 基于显著性增强和迁移学习的鱼类识别研究[J]. 渔业现代化, 2020, 47(1): 38-46.  
Jia Yuxia, Fan shuaichang, Yi Xiaomei. Fish identification based on saliency enhancement and transfer learning[J]. Fisheries Modernization, 2020, 47(1): 38-46. (in Chinese with English Abstract)

## Freshwater fish species identification method based on improved ResNet50 model

Wan Peng<sup>1,2</sup>, Zhao Junwei<sup>1</sup>, Zhu Ming<sup>1,2</sup>, Tan Hequn<sup>1,2</sup>, Deng Zhiyong<sup>1</sup>, Huang Yuyi<sup>1</sup>, Wu Wenjin<sup>3</sup>, Ding Anzi<sup>3</sup>

(1. College of Engineering, Huazhong Agricultural University, Wuhan 430070, China; 2. Key Laboratory of Agricultural Equipment in Mid-lower Yangtze River, Ministry of Agriculture and Rural Affairs, Wuhan 430070, China; 3. Research Institute of Agricultural Products Processing and Nuclear-agricultural Technology, Hubei Academy of Agricultural Sciences, Wuhan 430070, China)

**Abstract:** Species identification of freshwater fish has a wide range of applications in most fields, such as breeding, fishing, and processing. However, most traditional algorithms of fish identification cannot meet the ever-increasingly high requirements in recent years, such as simple feature extraction, high accuracy, and portability. In this study, a new identification algorithm was proposed for the freshwater fish species using an improved ResNet50 model. Six types of freshwater fish were taken as the research objects, including the bighead, bream, carp, crucian, grass carp, and silver carp. An image acquisition system was established for the freshwater fish images with a single background. As such, an image dataset of freshwater fish was constructed to joint those images with interference background on the Internet. A Pytorch framework was then selected to perform image preprocessing of freshwater fish for the sample diversity. An improved ResNet50 model was thus built to identify the freshwater fish species. Firstly, the fully connected layer Fc1 and Dropout were added, while the migration learning was introduced to train the model. Secondly, CELU was selected as the activation function to improve the expression of the neural network. Finally, Adam optimization was used to update the gradient. A cosine annealing was also embedded to attenuate the learning rate. In addition, the hyperparameters of the model were optimized in the multiple model training. Correspondingly, six kinds of freshwater fish were identified to verify the accuracy and performance of the improved ResNet50 model. A single validation test under a four-fold cross-validation model was carried out to train and evaluate the model. The confusion matrix was used to visualize the recognition of each type of fish. The results showed that: the image dataset of freshwater fish consisting of a single and interference background images was selected to train the model under the single validation, where the accuracy rate was 96.94%, 1.22% higher than before. The average detection time was 0.2345s for a single freshwater fish image. The accuracy rate of the model was 100% under the four-fold cross-validation, when the dataset of the freshwater fish image was selected with a single background. By contrast, the accuracy rate of the model was 96.20%, when the dataset of freshwater fish image consisted of a single and interference background, indicating an excellent general performance and robustness. The accuracy, recall and F1 score of each type of freshwater fish were relatively high visualized to the confusion matrix, when the model was trained on the freshwater fish image and a single background dataset, indicating the superior performance of the model. The improved ResNet50 model presented a general structure and training, while a high accuracy rate under different backgrounds. The finding can provide a sound technical reference for the identification of freshwater fish species in intelligent aquaculture.

**Keywords:** image recognition; aquaculture; freshwater fish; species recognition; deep learning; improved ResNet50 model; hyperparameter optimization; visualization